

مقاله پژوهشی

مروری بر روش‌های کشف تقلب بانکی با استفاده از هوش مصنوعی

Doi: 10.30508/kdip.2022.349333.1044

سیدمجید اکبرالسادات (نویسنده مسئول)^۱ | بابک اسماعیل پور^۲

۱- گروه هوش مصنوعی و رباتیک، دانشگاه آزاد اسلامی (واحد قوچان)، قوچان، ایران

۲- استادیار گروه کامپیوتر، دانشگاه آزاد اسلامی (واحد مشهد)، مشهد، ایران

تاریخ دریافت: ۱۴۰۱/۰۴/۰۶

تاریخ پذیرش: ۱۴۰۱/۱۰/۰۶

صفحه: ۴۱ - ۲۰

چکیده:

تقلب بانکی با توجه به تأثیرات مخرب آن، یکی از تهدیدآمیزترین مشکلاتی است که هر جامعه بشری با آن دست‌وپنجه نرم می‌کند. این عمل به استفاده عمدی از اطلاعات نادرست برای کلاهبرداری از پول یا دارایی فرد یا سازمان دیگری اشاره دارد. صنعت بانکداری برای چندین دهه از سیستم‌های مبتنی بر قوانین برای شناسایی تقلب و بررسی انسانی تراکنش‌ها استفاده کرده است. سیستم‌های مبتنی بر قانون شامل الگوریتم‌هایی هستند که انواع مختلفی از اقدامات شناسایی را انجام می‌دهند که به صورت دستی توسط متخصصان تقلب نوشته شده‌اند. این سیستم‌ها به تنظیم دستی سناریوها نیاز دارند، که در تشخیص ضمنی همبستگی‌های معاملاتی که به تقلب اشاره می‌کنند، دچار چالش می‌شوند. با توجه به ضعف‌های ذاتی رویکرد تشخیص تقلب مبتنی بر قانون در بانک‌ها و داده‌های محدودی که بر الگوریتم‌های یادگیری ماشین تحت نظارت متداول استفاده می‌شود، نیاز مبرمی به تکنیک‌ها یا سیستم‌های جدید تشخیص تقلب وجود دارد که بتوانند با افزایش سریع تقلب‌ها و موارد پول‌شویی مقابله کنند. این تحقیق با استفاده از رویکرد مروری و با هدف بررسی روش‌های کشف تقلب بانکی به بررسی ادبیات تحقیق و توصیف نتایج مرتبط می‌پردازد.

کلمات کلیدی: تقلب بانکی، بانکداری الکترونیک، کلاهبرداری، معاملات متقلبانه، تراکنش‌های جعلی، کشف تقلب بانکی.

۱- مقدمه

تقلب با توجه به تأثیرات مخرب آن، یکی از تهدیدآمیزترین مشکلاتی است که هر جامعه بشری با آن دست‌وپنجه نرم می‌کند. این عمل به استفاده عمدی از اطلاعات نادرست برای کلاهبرداری از پول یا دارایی یک فرد یا سازمان دیگر اشاره دارد (ویلیام^۱، ۲۰۲۲). در طول رکود اقتصادی ناشی از همه‌گیری کرونا، به دلیل افزایش تعداد افراد بیکار در طول دوره، شاهد افزایش فعالیت‌های کلاهبرداری بوده‌ایم (شیهم بیتسا^۲، ۲۰۲۱). هزاران نفر بیکار شدند، حقوق‌ها کاهش یافت و نرخ بیکاری افزایش یافت. به طور طبیعی، افراد بیشتری منابع کمتری برای بقای خود در اختیار دارند، که این انگیزه‌ای برای افزایش فعالیت‌های کلاهبرداری می‌باشد، زیرا مردم در تلاش برای زنده ماندن در دوران سخت اقتصادی هستند. کارشناسان تقلب استدلال می‌کنند که تقلب از سه عنصر که شامل فشار، فرصت و منطقی‌سازی است؛ نشأت می‌گیرد (کارتیس^۳، ۲۰۱۲). به گفته محققین، کلاهبرداری زمانی اتفاق می‌افتد که فردی فشار و انگیزه غیرقابل تقسیم برای ارتکاب کلاهبرداری ایجاد کند. در بیشتر موارد، برای مرتکب تقلب، نیازهای برآورده نشده بی‌پایان است و برای افراد مختلف متفاوت می‌باشد. که می‌تواند شامل؛ افزایش صورت حساب پزشکی، کاهش درآمد در خانواده یا بدهی قمار باشد. هنگامی که فرد نیازهای برآورده نشده داشته باشد و منابع محدودی داشته باشد، فرصت ارتکاب تقلب را شناسایی می‌کند. ادراک فرصت‌ها ممکن است مدیریت بی‌پروا یا فقدان کنترل‌های داخلی در یک واحد تجاری باشد که تقلب را به یک فعالیت آسان تبدیل می‌کند. در نهایت، فرد تصمیم خود برای ارتکاب تقلب با متقاعد کردن خود مبنی بر اینکه به پول بیشتری نیاز دارد یا در نهایت آن را پس می‌دهد، منطقی می‌کند. با توجه به شرایط اقتصادی فشارها و انگیزه‌هایی برای ارتکاب کلاهبرداری افزایش یافته است که این امر باعث می‌شود کلاهبرداران به راحتی

اقدامات خود را منطقی کنند. تقلب در صنعت بانکداری رایج است و شامل؛ فیشینگ ایمیل، کلاهبرداری از کارت اعتباری، پول‌شویی، تقلب در درخواست وام، تقلب در صورت‌های مالی و کلاهبرداری سایبری می‌شود. با ظهور بانکداری دیجیتال، کلاهبرداری دیجیتال نیز در این بخش رایج‌تر شده است. بنابراین، مهم است که اذعان کنیم که مدیریت تقلب در صنعت بانکداری و بازرگانی ضروری شده است، که مسلماً فرآیندی طاقت‌فرسا است. کلاهبرداران در کشف حفره‌ها ماهر شده‌اند و تکنیک‌های مؤثری مانند فیشینگ برای افراد ناآگاه و کلاهبرداری خلاقانه از آنها ایجاد کرده‌اند (ماریوت^۴، ۲۰۲۱). بنابراین، روش‌های کشف کلاهبرداری باید به طور مداوم تکامل یابند زیرا کلاهبرداران در طراحی تکنیک‌هایی مؤثرتر می‌شوند که سیستم‌های امنیتی سفت و سخت بانکی را دور می‌زنند و یاد می‌گیرند که چگونه افراد ناآگاه را متقاعد کنند که پول خود را در اختیار آنها بگذارند. تقلب مربوط به پرداخت یکی از جنبه‌های کلیدی آژانس‌های جرائم سایبری است و تحقیقات اخیر نشان داده است که استفاده از تکنیک‌های یادگیری ماشین برای شناسایی تراکنش‌های جعلی در مقادیر زیادی از داده‌های پرداخت مؤثر است. چنین تکنیک‌هایی توانایی شناسایی معاملات متقلبانه‌ای را دارند که حساب‌برسان انسانی ممکن است نتوانند آن‌ها را شناسایی کنند و همچنین این کار را به صورت بلادرنگ انجام دهند (نیکولاس، کوپا و لیخاک^۵، ۲۰۲۱). کشف دقیق تقلب^۶ (FD) می‌تواند اعتماد مشتریان بانک را در انجام امور بانکی‌شان به صورت آنلاین افزایش دهد. با پیشرفت تکنولوژی، تقلب به طور چشمگیری افزایش می‌یابد، که منجر به زیان‌های قابل توجهی برای شرکت‌ها می‌شود، بنابراین شناسایی تقلب به مسئله‌ای حائز اهمیت تبدیل شده است (کو، لو، سیوانگتان و هانگ^۷، ۲۰۲۰). بررسی شاخص ایمنی رایانه مایکروسافت نشان داد که تأثیر سالانه فیشینگ و اشکال مختلف سرقت هویت می‌تواند

1- Williams

2- Shihembetsa

3- CURTIS

4- Maruti

5- Nicholls, Kuppa, & Le-Khac

6- Fraud detection

7- Kou, Lu, Sirwongwattana, & Huang

غيرقابل پيش بينى ممكن است اشتباه كند. بنابراين، دقت كمترى دارد، زيرا هميشه به دانش فعلى خود اعتماد دارد؛ حتى براى مواردى كه دانش كافى نيست.

كشوف قلب براى بانكدارى آنلاين يك زمينه مطالعاتى بسيار مهم است، زيرا مجرمان سايبى حملات جديد كلاهبردارى پيچيدهاى را به صورت روزانه طراحى مى كنند، بنابراين اين امر مستلزم آن است كه محققان تكنيك هاى جديد كشف قلب را به طور مداوم توسعه دهند. طبق نظر (ماراتونا^۴، ۲۰۱۳) در دسترس بودن اطلاعات دقيق در مورد سيستم كشف قلب بسيار محدود است زيرا صنعت بانكدارى به ندرت آمار كشف قلب را منتشر مى كند. به ويژه، تأمين كنندگان امنيت مؤسسات مالى، شركت هاى شخص ثالثى هستند كه از مالكيت معنوى خود در برابر روبا محافظت مى كنند. بنابراين، هم بانك ها و هم آژانس هاى فناورى اطلاعات؛ اطلاعات سيستم هاى امنيتى خود را منتشر نمى كنند (بولتون و هند^۵، ۲۰۰۲). همچنين، توسعه روش هاى جديد براى شناسايى قلب دشوار است زيرا تبادل افكار در مورد شناسايى قلب بسيار محدود است، اما نويسندگان بر اين مفهوم تأكيد مى كنند كه تكنيك هاى كشف قلب نبايد به طور عمومى بيان شود. در غير اين صورت مجرمان ممكن است از همان داده ها بهره بگيرند (فوآ، لى، اسميت و گالير^۶، ۲۰۱۰). اغلب دو انتقاد اصلى از داده كاوى براى شناسايى قلب وجود دارد: كمبود اطلاعات تجربى واقعى در دسترس عموم، و فقدان تكنيك ها و روش هاى به خوبي تبليغ شده است.

در دو دهه گذشته، با تكامل فناورى مورد استفاده در بخش بانكدارى مالى، طرح هاى قلب مورد استفاده كلاهبرداران نيز تغيير كرد (استوجنا^۷، ۲۰۱۹). دو حوزه اصلى كه در آن قلب صورت مى گيرد، شامل؛ برنامه هاى كاردى وب يا موبایل بانكدارى اينترنتى و پرداخت هاى ATM، POS يا تاجر آنلاين با استفاده از كارت هاى بانكى مى باشد. گزارش نيلسون^۸ (۲۰۲۰). بر افزايش هدف قرار دادن بازگانان

به ۵ ميليارد دلار آمريكا برسد، درحالى كه هزينه ترميم آسيب به شهرت افراد آنلاين مى تواند تا ۶ ميليارد دلار يا بيشتر باشد. به طور متوسط براى هر ضرر ۶۳۲ دلار آمريكا تخمين زده مى شود (ماركيان و ليم^۱، ۲۰۱۴). روش هاى سنتى تشخيص قلب در صنعت بانكدارى مبتنى بر قانون بوده است كه در آن انسان ها قوانين را تعريف مى كنند. ۹۰ درصد مؤسسات مالى و بانكى بر اين روش ها تكيه مى كنند. درحالى كه افراد بيشترى از فناورى هاى جديد استفاده مى كنند، سناريوهاى قلب بيشترى ممكن است؛ اتفاق بيفتد و اين روش هاى مبتنى بر قوانين را در آينده غيرقابل مهر و موم و ناپايدار مى سازد. علاوه بر اين، مثبت كاذب (يعنى تراكنش هاى غير متقالبانه كه به عنوان جعلى فهرست بندى شده اند) باعث ضرر ميليون ها دلارى در معاملات و شكايات مشتريان در صنعت بانكدارى مى شود. روش هاى مبتنى بر قانون كمك زيادى به اين نتايج مى كنند. كيوبانو^۲ (۲۰۲۰) مطالعه اى را با ۱۰۰۰ مصرف كننده بزرگسال انجام داد و در آن متوجه شد حدود ۲۵ درصد از آنها كه تراكنش هايشان رد شده بود، به تجارت با روبا تمايل داشتند. اين ميزان روى آوردن به روبا براى مصرف كنندگان ۱۸ تا ۲۴ ساله به ۳۶ درصد افزايش يافته است. همچنين براى افراد بين ۲۵ تا ۳۴ سال به ۳۱ درصد افزايش يافته است. اين نتايج مطالعه نشان دهنده نياز مبرم به روش هاى دقيق تر و مدرن تر كشف قلب است. به جاى جلوگيرى از تراكنش غيرمجاز، سيستم هاى بانكدارى اينترنتى كشف قلب بايد بلافاصله كلاهبردارى ها را دريك حساب در معرض خطر شناسايى كنند (ريچاردز^۳، ۲۰۰۳). رويكرد مبتنى بر قوانين متعارف براى كسب دانش (KA) براى يك تجارت بسيار كند، كار فشرده و پرهزينه اى است. شكندگى نيز يكي از كاستى هاى پايه هاى قوانين مرسوم بود و اين سيستم ها هميشه سعى مى كنند پاسخى بدهند، حتى ممكن است نادرست باشد. شكندگى به نرم افزارى اطلاق مى شود كه در مواجهه با يك موقعيت

- 1- Marican, & Lim
- 2- Ciobanu
- 3- Richards
- 4- Maruatona
- 5- Bolton, & Hand
- 6- Phua, Lee, Smith, & Gayler
- 7- Stojanov
- 8- Nilson Report

دارد. عملی‌ترین گزینه الگوریتم‌های یادگیری ماشین نصب شده در سیستم‌های بانکی هستند (گابینو و همکاران، ۲۰۲۱). با توجه به ضعف‌های ذاتی رویکرد تشخیص تقلب مبتنی بر قانون در بانک‌ها و داده‌های محدودی که بر الگوریتم‌های یادگیری ماشین تحت نظارت متداول استفاده می‌شود، نیاز مبرمی به تکنیک‌ها یا سیستم‌های جدید شناسایی وجود دارد که بتوانند با افزایش سریع تقلب‌ها و موارد پول‌شویی مقابله کنند. لذا این مقاله با هدف بررسی روش‌های کشف تقلب بانکی، به مرور ادبیات اخیر مرتبط با این موضوع می‌پردازد.

۲- مبانی نظری

ادبیات تخصصی و راه‌حل‌های موجود در بازار در دهه گذشته بر جمع‌آوری مقادیر قابل‌توجهی از داده‌ها در مورد تراکنش‌ها (و رفتار کاربر) و اصلاح الگوریتم‌های مورد استفاده برای شناسایی تقلب متمرکز شده‌اند. در همین راستا، قوانین اتحادیه اروپا (به‌عنوان مثال، PSD۲) به‌منظور تحمیل تعهدات به ذینفعان برای شناسایی تقلب به تصویب رسیده است. با این حال، از یک سو قانون تشریح سطح بالایی از این الزام قانونی ارائه می‌کند و از سوی دیگر، راه‌حل‌های موجود در بازار از نظر داده‌های جمع‌آوری‌شده و به‌ویژه تلاش برای تجمیع داده‌ها به‌منظور تولید متنوع می‌باشد. نتایج دقیق‌تر منجر به مبحثی می‌شود که هنوز در ادبیات تخصصی یا توسط قانون‌گذاران به‌طور عمیق مورد تجزیه و تحلیل قرار نگرفته است. محققانی مانند کارمیناتی و همکاران^۵ (۲۰۱۸)، در دهه گذشته شیوه‌های مختلفی را که می‌توان از چنین جزئیاتی برای کشف و پیشگیری از تقلب استفاده کرد، تحلیل کرده‌اند (کارمیناتی، و همکاران^۶، ۲۰۱۸). نتیجه‌گیری‌های آن‌ها منجر به رویکردهای مختلفی برای الگوریتم‌های کشف تقلب، با تأکید بر روش‌های یادگیری ماشین شده است (بائو، هیلاری، و کی^۷، ۲۰۲۲)؛ زیرا تجمیع داده‌ها و تحلیل

توسط سازمان‌های جرائم مالی سازمان‌یافته برای ارتکاب کلاهبرداری، با توسعه فناوری اطلاعات کشور و بازرگان که بر توانایی تاجر برای جلوگیری از تقلب تأثیر می‌گذارد، تأکید کرده است (گابینو، بریک، ماری، میهای و اسچو^۱، ۲۰۲۱؛ ناتان، ویکتور، گان و کات^۲، ۲۰۱۹). حدود ۵۶ درصد از اروپایی‌ها نگران این هستند که قربانی تقلب شوند (گابینونا، و همکاران، ۲۰۲۱). در سال ۲۰۱۹، ۲۶ درصد از جمعیت اتحادیه اروپا گزارش دادند که پیام‌های جعلی دریافت کرده‌اند، از جمله پیام‌های مربوط به اعتبار بانکداری الکترونیک (اروستا و کامپوننت^۳، ۲۰۲۰). خانواده‌های مختلف بدافزار آسیب‌های مختلفی به مصرف‌کننده، زیرساخت‌های حیاتی، مؤسسات مالی و بانکی وارد کرده‌اند و به اهداف مورد نظر تبدیل شده‌اند (اسچو، گافتیا، آچیم، و کوتاک^۴، ۲۰۲۰). مکانیسم‌های تقلب از نظر بانکداری اینترنتی و تراکنش‌های کارت دارای ویژگی‌هایی هستند که می‌تواند به کشف تقلب کمک کند، مانند مکان شروع پرداخت، جزئیات گیرنده پرداخت، مهر زمانی پرداخت.

برای افزودن به چالش سیستم سنتی مبتنی بر قوانین، کلاهبرداران فاقد الگوهای خاص هستند و دائماً رفتار خود را در طول زمان تغییر می‌دهند و سیستم‌ها را دست‌وپاگیر و به سرعت منسوخ می‌کنند. نیاز آشکار به تغییر رویکرد در سیستم‌های امنیتی در سیستم‌های بانکی وجود دارد. طبق گزارش نیلسون (۲۰۲۰)، پیش‌بینی می‌شد که کلاهبرداری مربوط به کارت‌ها تا سال ۲۰۲۰ تنها به مبلغ حیرت‌انگیز ۳۰ میلیارد دلار در سطح جهان برسد. علاوه بر این، با اختلال فناوری در بخش بانکی به دلیل وجود کانال‌های پرداخت متعدد مانند کارت‌های اعتباری و نقدی، گوشی‌های هوشمند، نرخ تراکنش‌ها طی چند سال گذشته به‌طور تصاعدی افزایش یافته است. کلاهبرداران همچنین تاکتیک‌های کلاهبرداری بسیار مؤثری را توسعه داده‌اند. با توجه به این وضعیت، نیاز به توسعه رویکردهای سخت و قوی‌تر کشف تقلب در بانک‌ها وجود

1- Gbudeanu, Brici, Mare, Mihai, & cheau

2- Nathan, Victor, Gan, & Kot

3- Eurostat, & Components

4- cheau, Gaftea, Achim, & Cotoc

5- Carminati

6- Carminati, et al

7- Bao, Hilary, & Ke

توجه به انواع الگورتم‌های تشخیص تقلب پیشنهاد شده در مقالات تحقیقاتی منتشر شده در سه سال گذشته (۲۰۱۸-۲۰۲۱)، موجود در پنج پایگاه داده تحقیقاتی (ACM، Science Direct، Emerald Full text، IEEE Transactions Springer-Link)، بر اساس کلیدواژه‌های خاصی با هدف شناسایی جنبه‌های حریم خصوصی در نظر گرفته شده توسط این الگورتم‌ها ("تشخیص تقلب بانکی GDPR"، "تشخیص تقلب بانکی حریم خصوصی"، "تکنیک‌های تشخیص تقلب بانکی تجمعی"، "تکنیک‌های تشخیص تقلب بانکی")؛ انواع الگورتم‌های تشخیص تقلب بانکی در جدول شماره (۱) ارائه شده است.

تاریخی داده‌ها می‌تواند به یافتن الگوهای تقلب کمک کند (پولیتو، آلیپس، و پاتساکیتس^۱، ۲۰۱۹). این الگوهای تقلب می‌توانند به شناسایی یا پیش‌بینی تراکنش‌های تقلبی احتمالی کمک کنند. الگورتم‌های تشخیص، ویژگی‌های موجود تقلب‌ها را با تراکنش‌های فعلی در حال تجزیه و تحلیل مطابقت می‌دهند، در حالی که الگورتم‌های پیش‌بینی تلاش می‌کنند تا کلاه‌برداری‌هایی را شناسایی کنند که ویژگی‌های متفاوتی نسبت به تقلب‌های تاریخی دارند. محققان عموماً بر دقت نتایج و افزایش جمع‌آوری داده‌ها و تجمیع داده‌ها برای دستیابی به این هدف، هم برای الگورتم‌های کارآگاهی و هم برای الگورتم‌های پیش‌بینی تمرکز کرده‌اند (جها، گالین، و وستلند^۲، ۲۰۱۲). با

جدول ۱- تعداد مقالات منتشر شده در سه سال اخیر در خصوص انواع الگورتم‌های تشخیص تقلب بانکی

پایگاه داده / عبارت کلیدی	ژورنال‌های Springer-Link	IEEE	Emerald	Science Direct	کتابخانه دیجیتال ACM
تشخیص تقلب بانکی GDPR	۱۶۷	۷۲	۲۱	۱۱۳	۵۵۲
تشخیص تقلب در بانکداری حریم خصوصی	۸۹۱	۵۵۴	۱۹۳	۲۵۶	۵۹۱
تکنیک‌های تشخیص تقلب بانکی تجمعی	۲۸۸	۱۸۱	۴۴	۹۰	۷۷۶

1- Politou, Alepis, & Patsakis

2- Jha, Guillen, & Westland

الگوریتم‌های یادگیری ماشین، تشخیص تقلب در کارت اعتباری با استفاده از روش‌های Pipeling و Ensemble Learning (باگا، گویال، گوپتا و گویال^۵، ۲۰۲۰)، و تشخیص تقلب در کارت اعتباری با استفاده از شبکه عصبی مصنوعی (پینتو، و سابریرو^۶، ۲۰۲۲). ابزارهای مورد استفاده برای شناسایی فعالیت‌های متقلبان برای الگوهای تقلب شناسایی شده، سال به سال پیچیده‌تر و کارآمدتر می‌شوند و الگوریتم‌های یادگیری ماشین یکی از بهترین گزینه‌ها در این زمینه هستند، زیرا پیشرفت‌های فناوری از مرزها عبور می‌کنند و موارد بیشتری در دسترس قرار می‌گیرند (بیلگین، مارکو و دمیر^۷، ۲۰۱۲). اوگرک، ام، اوگرک، ای. و باهتیر^۸ (۲۰۱۹) سعی کردند روش‌های تقلب کارت اعتباری را با استفاده از مدلی با مجموعه داده Kaggle ارزیابی کنند. روش انتخاب شده شبکه‌های عصبی مصنوعی چند لایه^۹ (MANN) بود. برای شناسایی تقلب، این محققین از ویژگی‌هایی مانند: نقدی/خروجی، بدهی، پرداخت، مبلغ تراکنش یا ارزش محلی استفاده کرده‌اند. نتایج مطالعه نشان داد که روش انتخاب شده مؤثر است. همچنین، لی، هانگ، لیو و جیانگ^{۱۰} (۲۰۲۱)، با استفاده از مجموعه داده Kaggle، ایده یک روش ترکیبی را برای کاهش عدم تعادل طبقاتی با همپوشانی بر اساس ایده تقسیم و فتح ارائه کردند. برای این منظور از معیار ارزیابی آنتروپی وزن دار پویا استفاده شد. این آزمایش حتی از آزمایش‌های قبلی موفق‌تر بود مطالعاتی که رفتار افراد در انجام تراکنش‌ها را به عنوان روشی برای شناسایی تراکنش‌های جعلی کارت هدف قرار می‌دهند نیز وجود دارد: کارمیناتی و همکاران (۲۰۱۸) Banksealer را به عنوان یک سیستم پشتیبانی تصمیم ارائه کردند. این سیستم، برای هر کاربر یک مدل می‌سازد و سپس آن را بر روی این سیستم مدل می‌کند. در مرحله دوم، استحکام سیستم Banksealer در برابر مجرمان احتمالی بررسی شد. این رویکرد در ایتالیا پیاده‌سازی شد،

از سال ۲۰۱۸، مطالعات مربوط به سیاست حفظ حریم خصوصی داده‌های شخصی^۱ (سیاست GDPR) شروع به ظاهر شدن کردند. استالابوردیلون، پیارس و تسکالاسکی^۲ (۲۰۱۸) یک تحلیل بین‌رشته‌ای از GDPR در زمینه طرح‌های شناسایی الکترونیکی انجام داد. این مطالعه در بریتانیا انجام شد و یک نمای کلی از نحوه تفسیر این موقعیت‌ها ارائه کرد. در این مطالعه، نویسنده یک مبنای قانونی را پیشنهاد می‌کند که می‌تواند به مدیریت خوب حریم خصوصی توسط هر دو طرف درگیر کمک کند. علاوه بر این، در ارتباط با این موضوع، مطالعاتی در مورد میزان نفوذ در درخواست داده‌های شخصی شروع شده است. در این رابطه هوراک، استاپکا و هوساک^۳ (۲۰۱۹) به مسائل مربوط به تأثیر GDPR بر نرم‌افزار امنیت سایبری، از نظر عملیاتی پیشگیری از حادثه و رسیدگی به حوادث توجه کردند. خطرات نقض محرمانه بودن و اصل به حداقل رساندن داده‌ها با درخواست داده‌های شخصی مورد بررسی قرار گرفت، و همچنین این واقعیت که به اشتراک‌گذاری این اطلاعات توسط مشتری می‌تواند نگرانی‌های مشابهی را ایجاد کند. ارزیابی تأثیر حریم خصوصی داده‌ها^۴ (DPIA) که برای این سناریو انجام شد، نشان داد که با توجه به مکانیسم‌های کاهش خطر خاص، ریسک‌ها بالا نیستند. روش مورد استفاده در این مقاله به درک ریسک‌های موجود و مدیریت آسان‌تر آنها کمک کرد.

این مسائل مزاحمت حریم خصوصی نیز ارتباط نزدیکی با جلوگیری از تقلب کارت اعتباری دارد. تعداد قابل توجهی از نویسندگان به موضوع کشف تقلب پرداخته‌اند و الگوریتم‌های مورد استفاده به منظور ترکیب مکانیسم‌ها و طرح‌های جدید مورد استفاده توسط کلاه‌برداران به طور مداوم در حال بهبود هستند. تعدادی از مطالعات وجود دارد که تقلب کارت را از دیدگاه‌های مختلف تجزیه و تحلیل می‌کند: تشخیص تقلب کارت اعتباری با استفاده از

1- General data protection legislation

2- Stalla- Bourdillon, Pearce, & Tsakalakis

3- HorakHorák, Stupka, & Husák

4- Data Privacy Impact Assessment

5- Bagga, Goyal, Gupta, & Goyal

6- Pinto, & Sobreiro

7- Bilgin, MARCO LAU, & Demir

8- Örek, M., Örek, E., & Bahtiyar

9- Multi-layered artificial neural networks

10- Li, Huang, Liu, & Jiang

اما نتايج مطالعه نشان داد كه مي‌تواند مجموعه داده مفيدی در سراسر جهان ارائه كند (كارمينيات، و همكاران^۱، ۲۰۱۸). چن و همكاران^۲ (۲۰۱۹) نيز روشی را براي تشخيص تراكنش‌ها بر اساس رفتار افراد ايجاد كردند. مدلی كه در مقاله آنها استفاده شد: هايپر كره^۳ نام دارد. اين مطالعه به اين نتيجه رسيد كه اثر توصيف رفتار انسان با فراوانی معاملات آنها مرتبط است (چن و همكاران، ۲۰۱۹). علاوه بر اين، وانگ و وانگ^۴ (۲۰۱۹) رفتار كاربر را از منظر فاصله زمانی بين درخواست ارزیابی كردند و دريافتند رفتارهای ربات مانند، در سيستم بانكداري آنلاين وجود دارد. نتايج مطالعه نشان داد كه پس از مقايسه دو الگوريتم، آنترپي Renyi در تمايز رفتار ربات از رفتار انسان نسبت به آنترپي شانون^۵ برتری دارد. محققين ديگر از مدل‌های مختلفی به منظور شناسایی تراكنش‌های تقلبی استفاده كردند. چن و همكاران (۲۰۲۰) يك مدل امتیازدهی ترکیبی را برای اين منظور توسعه داد. اين مدل مي‌تواند يك امتیاز اعتباری دقيق به دست آورد و حتی ريسك اعتباری را کاهش دهد (چن، ياداك، خان، و ژو، ۲۰۲۰). مصر، تاكار، گوش و ساها^۶ (۲۰۲۰) يك مدل دومرحله‌ای برای شناسایی تراكنش‌های تقلبی پيشنهاده كردند. در مرحله اول از يك رمزگذار خودكار استفاده می‌شود كه ویژگی‌های تراكنش را به يك بردار مشخصه كوچك‌تر تبديل می‌كند. در مرحله دوم از بردار به عنوان ورودی طبقه‌بندی كننده استفاده می‌شود. آزمایش بر روی يك مجموعه داده مقايسه‌ای انجام و مشاهده شد كه مدل دومرحله‌ای كارآمدتر از سيستم‌هایی است كه تنها با یکی از دو مرحله طراحی شده‌اند.

اولووكره و ادوال^۸ (۲۰۲۰) چارچوبی را پيشنهاده می‌كنند كه تكنيك‌های گروه فرا يادگیری و يادگیری حساس

به هزينه را برای كشف تقلب تركيب می‌كند. نتايج اين مطالعه نشان داد كه چارچوب مجموعه حساس به هزينه، طبقه‌بندی‌كننده‌های حساس به هزينه را توليد می‌كند كه در تشخيص تقلب در پایگاه‌های داده پرداخت‌ها كارآمد هستند. مطالعات ديگر بر روی تشخيص‌های خاص‌تر متمرکز شده‌اند. آماراسينگه، آپونسو، و كريشنا رگيا^۹ (۲۰۱۸) يادگیری ماشين انتخاب شده و تكنيك‌های تشخيص قبلی را كه می‌توانند در يك سيستم تشخيص تراكنش مالی تقلبی ادغام شوند، بررسی كردند. نتيجه‌گیری شد كه به منظور شناسایی مؤثرتر تقلب بانکی، دانستن الگوريتم‌های خاص (به عنوان مثال، شبكه‌های بیزی، منطق فازی و غيره) مهم است. دونگ و همكاران^{۱۰} (۲۰۱۸) روی حوزه بسيار جالبی از موضوع تقلب، يعنی تقلب‌های تبليغاتی موبایلی كار كردند و يك رويكرد ترکیبی به نام FraudDroid را برای شناسایی تقلب در برنامه‌های کاربردی در دستگاه‌های اندرویدی پيشنهاده كردند. پس از تجزيه و تحليل ۱۲۰۰۰ برنامه مشکوك، FraudDroid ۳۳۵ مورد تقلب را شناسایی كرد و اين نتيجه تأييد می‌كند كه روش مفيدی برای كشف اين نوع جرم است. علاوه بر اين، برخی محققين، تحقق رأی از طريق دستگاه ATM با ارائه احراز هويت بيومتريك يا احراز هويت تشخيص چهره را پيشنهاده كردند. استفاده از برنامه رأی‌گیری ATM در مقايسه با کارت‌های Aadhar برای امنيت و حفظ حریم خصوصی، آسان‌تر است (سادهارسان، كومار، و تكاسان، ساتياپريا و سارانایا^{۱۱}، ۲۰۱۹)

چالش‌های بانكداري آنلاين

هر ساله تقلب در اشكال مختلف افزايش می‌يابد كه منجر به خسارات مالی قابل توجهی می‌شود (وی، لی، كائو،

- 1- Carminati, et al
- 2- Chen
- 3- Hypersphere
- 4- Wang and Wang
- 5- Shannon entropy
- 6- Chen, Yadav, Khan, & Zhu
- 7- Misra
- 8- Olowookere, & Adewale
- 9- Amarasinghe
- 10- Dong
- 11- Sudharsan, Kumar, Venkatesan, Sathyapreiya, & Saranya

بسیار محدود است و بانک‌ها اغلب آمار سیستم‌های FD را منتشر نمی‌کنند (اسکانسی، گانو^۷، ۲۰۱۷؛ ماراتون، ۲۰۱۳). زیرا بیشتر امنیت توسط شرکت‌های IT شخص ثالث ارائه می‌شود که از مالکیت معنوی در برابر رقبا خود نیز محافظت می‌کنند. بنابراین هم بانک‌ها و هم شرکت‌های امنیتی فناوری اطلاعات بیشتر اطلاعات سیستم‌های امنیتی خود را منتشر نمی‌کنند. بولتون و هند^۸ (۲۰۰۲) نیز تأکید می‌کنند که توسعه روش‌های جدید کشف تقلب دشوار است؛ زیرا تبادل نظر در کشف تقلب بسیار محدود است، اما از این ایده حمایت می‌کنند که تکنیک‌های FD نباید به‌طور عمومی با جزئیات توصیف شوند. در غیر این صورت مجرمان نیز ممکن است به آن اطلاعات دسترسی پیدا کنند (کارمیناتی و همکاران، ۲۰۱۵). فوا و همکاران^۹ (۲۰۱۰) تأکید می‌کنند که کشف تقلب با استفاده از تکنیک‌های داده‌کاوی در صنعت بسیار رایج است.

تقلب در سرمایه‌گذاری سهام و اوراق بهادار

بازار سهام و اوراق بهادار مالی به مردم این امکان را می‌دهد که پول خود را با هدف کسب بازدهی مثبت بر اساس انجام تحقیقات یا فقط یک حدس، سرمایه‌گذاری کنند. با این حال، مشخص است که بخشی از فعالان بازار تقلب می‌کنند و با این کار سودهای کلانی به قیمت سرمایه‌گذاران نهادی و خرد به دست می‌آورند. دستگیری این بازیگران کلاه‌بردار آسان نیست و معمولاً به نیروی کار زیادی برای جمع‌آوری شواهد در مدت زمان طولانی نیاز دارد، به‌ویژه در موارد تجارت داخلی. با این حال، پیشرفت‌های اخیر در کاربردها و تکنیک‌های یادگیری ماشین به شناسایی بازیگران بد به روشی کارآمدتر و سریع‌تر کمک می‌کند. برخی از روش‌های مورد استفاده توسط افرادی که فعالیت سرمایه‌گذاری متقلبانه انجام می‌دهند عبارتند از: دستکاری بازار، تجارت داخلی، پول‌شویی، تأمین مالی تروریسم و بسیاری موارد دیگر. دستکاری بازار

اووو چن^{۱۰} (۲۰۱۳). بر اساس بررسی شاخص ایمنی محاسباتی مایکروسافت (MCSI) در سال ۲۰۱۴، تأثیر سالانه فیشینگ و اشکال مختلف سرقت هویت در سراسر جهان می‌تواند تا ۵ میلیارد دلار آمریکا تخمین زده شود، در حالی که هزینه ترمیم آسیب به شهرت آنلاین افراد می‌تواند بیشتر از ۶ میلیارد دلار آمریکا، یا میانگین تخمینی ۶۳۲ دلار آمریکا به ازای هر ضرر باشد (ماریکان و لیم، ۲۰۱۴). مشاوره PwC در نظرسنجی جهانی جرم اقتصادی در سال ۲۰۱۶ اشاره می‌کند که تقریباً یک سوم شرکت‌های مورد بررسی گزارش داده‌اند که قربانی نوعی از جرائم سایبری بوده‌اند. همچنین، جرائم سایبری دومین نوع رایج جرائم اقتصادی است که در این نظرسنجی تجزیه و تحلیل شده است، در حالی که یک نظرسنجی اخیر گزارش می‌دهد (لاویون^{۱۱}، ۲۰۱۸). از سال ۲۰۱۶ بالغ بر ۱۳ درصد افزایش در تقلب رخ داده است. ۱۲۳ یک منبع ارزشمند برای قربانیان جرائم اینترنتی و مجریان قانون در شناسایی، رسیدگی و تعقیب جرائم است (اف.بی.آی، ۲۰۱۸). ۱۲۳ گزارش می‌دهد که ۱۴۴۰۸ شکایت در سال ۲۰۱۸ دریافت کرده که مربوط به کلاهبرداری پشتیبانی فنی از قربانیان از ۴۸ کشور بود. زیان گزارش شده نشان‌دهنده افزایش ۱۶۱ درصدی زیان نسبت به سال قبل می‌باشد. گزارش نرخ جرائم اقتصادی جهانی توسط (اسکانسی، گانو^{۱۲}، ۲۰۱۷)، نشان می‌دهد که خدمات مالی با جرم اقتصادی ۴۸ درصد بیشترین بخش در معرض خطر بوده و دومین جرم اقتصادی گزارش شده در جرائم سایبری است. رایج‌ترین دامنه‌های تقلب عبارتند از: بانکداری آنلاین، کارت‌های اعتباری، مخابرات، بیمه مراقبت‌های بهداشتی، بیمه آنلاین، نفوذ کامپیوتر، حراجی آنلاین (اسکانسی، گانو، ۲۰۱۷؛ بولتون و هند، ۲۰۰۲؛ جان، آتل، کندی، اولاجید و کندی^{۱۳}، ۲۰۱۶؛ عبدالله، معروف و زینال^{۱۴}، ۲۰۱۶؛ وی و همکاران، ۲۰۱۳). بنابراین، انجام تحقیقات کشف تقلب برای بانکداری آنلاین یک کار بسیار مهم است، اما چالش‌هایی در این زمینه وجود دارد که باید برطرف شوند. دانش مکانیزم کشف تقلب بانک‌ها

1- Wei, Li, Cao, Ou, & Chen

2- Lavion

3- Ocansey, & Ganu

4- John, Anele, Kennedy, Olajide, & Kennedy

5- Abdallah, Maarof, & Zainal

6- Ocansey, & Ganu

7- Bolton & Hand


8- Phua

آوردن پول از راه دور استفاده شود. پول شویی روشی است که توسط مجرمان و افرادی که دارایی‌های «کثیف» یا به طور غیرقانونی از طریق فعالیت‌های مجرمانه به دست آمده‌اند، برای تبدیل این پول‌ها به یک حالت «پاک» یا مشروع از نظر قانون و دولت‌ها استفاده می‌کنند. سرویس دادستانی سلطنتی^۱ (CPS) بریتانیا طرح پول شویی را معمولاً شامل سه مرحله تعریف می‌کند: اول، جایگذاری است که فرآیند واریز پول مجرمانه به سیستم مالی است. دوم، لایه‌بندی است که پول را در سیستم مالی از طریق شبکه‌های پیچیده ترانکشن‌ها با هدف مبهم کردن حرکت می‌دهد. لایه‌بندی معمولاً از طریق شرکت‌های خارج از کشور انجام می‌شود. در نهایت، ادغام، پول مجرمانه‌ای است که از طریق سرمایه‌گذاری‌هایی مانند املاک، خرید سهام و اقلام لوکس در اقتصاد واقعی جذب یا ترکیب می‌شود (هاپتون^۲، ۲۰۱۶). نمونه‌ای از پول شویی با استفاده از قرار دادن، لایه‌بندی و ادغام را می‌توان در شکل شماره (۱) مشاهده کرد.

اقدامی برای فروش یا خرید یک اوراق بهادار مالی با هدف دست‌کاری هدفمند قیمت دارایی یا اوراق بهادار پایه در نظر گرفته می‌شود. تجارت داخلی غیرقانونی زمانی است که «خودی‌ها» یا افرادی که از مطالب شرکت خصوصی و غیردولتی مطلع هستند، از آن اطلاعات قبل از انتشار عمومی برای بهره‌مندی مالی استفاده می‌کنند. این نه تنها شامل معامله اوراق بهادار، بلکه نشت اطلاعات غیر عمومی به اشخاص ثالث نیز می‌شود.

کشف تقلب و مبارزه با پول شویی (AML)

اغلب اوقات، بین تقلب بانکی و سرقت از بانک سردرگمی وجود دارد. دزدی از بانک با تقلب بانکی متفاوت است، چرا که سرقت از بانک شامل خشونت می‌شود، درحالی‌که تقلب بانکی اغلب یک فرآیند آهسته و مخفیانه است که تا زمانی که عمل کامل شود، شناسایی نمی‌شود. تقلب بانکی اغلب مستلزم ترغیب مشتریان به ارائه اطلاعات حساس بانکی خود است که ممکن است برای بدست



شکل (۱): مراحل پول شویی

1- Crown Prosecution Service
2- Hopton

كلاهبرداری در بانكداري اينترنتي، بانكداري تلفن همراه، فيشينگ، كلاهبرداری در سايت خريد و حراجي، كلاهبرداری، هرزنامه، و سرقت هويت انواع مختلفي از كلاهبرداری هاي آنلاين هستند (اي.بي.اف. ۲۰۱۸). تقلب بانكداري اينترنتي نوعي كلاهبرداری است كه با استفاده از هر فناوري آنلاين برای برداشت غيرقانوني پول يا انتقال آن به حساب بانكي ديگر انجام مي‌شود. جرم مالي يا جرائم اقتصادي توسط يوروپل به عنوان «اعمال غيرقانوني انجام شده توسط يك فرد يا گروهی از افراد برای به دست آوردن مزيت مالي يا حرفه‌ای» تعريف شده است (نيكولس، و همكاران، ۲۰۲۱). انگيزه اصلي در چنين جناياتي، منفعت اقتصادي است. مجمع جهاني اقتصاد، جرائم مالي را صنعتي تريليون دلاری مي‌داند (ناندوري، جيا، اوکا، بيوار و ليو، ۲۰۲۰). جرائم مالي در فضاي مجازي با استفاده از ابزارهاي هك و تكنيك‌هاي مهندسي اجتماعي كه امنيت مؤسسات مالي و شركتي را دور مي‌زند، انجام مي‌شود. اين امر باعث مي‌شود كه محققان و شركت‌ها به جرائم مالي از منظر ديگري نگاه كنند، به اين ترتيب كه تمايز بين جرائم مالي، هك و مهندسي اجتماعي برای منافع اقتصادي كمرنگ شده است. اينجاست كه نويسندگان اصطلاح جرائم سايبري مالي را معرفي مي‌كنند كه تركيبي از جرائم مالي، هك و مهندسي اجتماعي است كه در فضاي سايبري تنها با هدف كسب سود اقتصادي غيرقانوني انجام مي‌شود. كشف تقلب در سازمان‌هاي مالي سنتي^۱ بيشتر طول مي‌كشد (پاسكودال، مارچيني، و ميلر^۲، ۲۰۱۷). اين مقدار زمان برای مشتريان و مؤسسات مالي نامطلوب است؛ زیرا ممكن است چندين فعاليت متقلبانه قبل از شناسايي در چنين چارچوب زماني رخ دهد. كلاهبرداری بر بانك‌هايي كه با خدمات پرداخت آنلاين سروكار دارند، به‌ويژه در پيشرفت‌هاي تكنولوجييك معاصر در بخش تجاري، تأثير منفي مي‌گذارد. به عنوان مثال، حدود ۲۰ درصد از مشتريان پس از تجربه كلاهبرداری، بانك را تغيير مي‌دهند (ساندو^۳، ۲۰۲۱). اين تعداد مشترياني كه از يك بانك خاص خارج مي‌شوند، به طور قابل توجهي برای عمليات تجاري يك

كشف تقلب مستلزم فعاليت‌هايي است كه از به دست آوردن پول يا دارايي از طريق جعل نادرست جلوگيري مي‌شود. در بخش بانكي، تقلب مستلزم جعل چك و استفاده از كارت اعتباري سرقت شده است. ممكن است متضمن اغراق زيان يا ايجاد رويدادهای ناگوار مانند تصادفات با هدف صرف پرداخت باشد (شيهم بتسا، ۲۰۲۱). بر اساس گزارش نيلسون (۲۰۲۰)، پيش بيني مي‌شد كه كلاهبرداری مربوط به كارت‌ها تا سال ۲۰۲۰ تنها به مبلغ حيرت‌انگيز ۳۰ ميليارد دلار در سطح جهان برسد. علاوه بر اين، اختلال در فناوري در بانكداري و پرداخت‌ها به دليل افزايش كانال‌هاي پرداخت مانند اعتبار و كارت‌هاي نقدي و گوشي‌هاي هوشمند، تعداد تراكنش‌ها طی سال‌هاي اخير افزايش چشمگيري داشته است (گابينو و همكاران، ۲۰۲۱). تلاش‌هاي كشف تقلب با استفاده از تجزيه و تحليل داده‌ها، نرم‌افزار طراحي شده برای كشف تقلب، و ابزارها، برنامه‌هاي طراحي شده برای كشف تقلب، سازمان‌ها را قادر مي‌سازد تا تكنيك‌هاي رايج كلاهبرداری را پيش بيني كنند، فرآيند ارجاع متقابل داده‌ها را خودكار كنند، تراكنش‌هاي خود را به طور مستمر در زمان واقعي نظارت كنند، و كشف كنند (ويليام، ۲۰۲۲). منابع تشخيص و پيشگيري از تقلب مانند نرم‌افزار در دو نسخه اختصاصي و رايگان موجود است. برخي از ويژگي‌هاي رايج در اين نرم‌افزار عبارتند از: داشبورد، واردات و صادرات داده‌ها، تجسم داده‌ها، يکپارچه‌سازي مديريت ارتباط با مشتري، مديريت تقويم، زمان بندي، بودجه بندي و مديريت رمز عبور. آنها همچنين دارای رابط‌هاي برنامه‌نويسي کاربردي (API)، صدور صورت حساب، احراز هويت دومرحله‌ای و مديريت پايجاه داده مشتري هستند.

سيستم‌هاي تشخيص تقلب در بانكداري

كلاهبرداری يا تقلب آنلاين، تقلب اينترنتي و جرائم سايبري مبناي گسترده‌ای دارند و به روش‌هاي مختلفی رخ مي‌دهند. كلاهبرداری آنلاين را مي‌توان به عنوان هر عمل غيرقانوني انجام شده به صورت آنلاين توصيف كرد.

- 1- Nanduri, Jia, Oka, Beaver, & Liu
- 2- brick-and-mortar financial organizations
- 3- Pascual, Marchini, & Miller
- 4- Sando

پول شویی توسط PRM شناسایی می شود (حفیظ، عقیلی، و زاواراسکی^۴، ۲۰۱۶).

سیستم SAS Fraud Manager: این سیستم عمدتاً راه حل کشف تقلب برای کارت های بدهی و اعتباری است و قابلیت بلادرنگ را دارد. این سیستم کشف تقلب از تکنیک تشخیص ناهنجاری^۵ (AD) استفاده می کند (اس. آی. اس. ۲۰۰۷).

سیستم Kount: یکی دیگر از سیستم های پیشگیری از تقلب، کانت است که از هر دو مدل ML^۶ نظارت شده و بدون نظارتی استفاده می کند. برخی از بزرگ ترین ارائه دهندگان خدمات پرداخت، دروازه ها، کیف پول ها و پردازنده ها از این سیستم استفاده می کنند. تعداد کمی از سیستم های کشف تقلب و پیشگیری دیگر وجود دارند (پاتم سی، ۲۰۱۵؛ فاندنت، ۱۹۹۷؛ ریسک نت، ۱۹۹۸).

- نقاط ضعف سیستم های تشخیص تقلب تجاری

سیستم های کشف تقلب تجاری ذکر شده در بالا به طور گسترده توسط بانک ها و مؤسسات مالی استفاده می شوند. با این حال، هیچ سیستم کشف تقلب به طور ۱۰۰ درصد مؤثر نیست. برخی از کاستی ها در سیستم های کشف تقلب تجاری عبارتند از:

این سیستم ها فاقد امتیازدهی و ردیابی مکان مصرف کننده برای تراکنش دستگاه تلفن همراه هستند. لایه یکپارچه سازی برای این سیستم ها برای وارد کردن داده ها کامل نیست.

همه سیستم ها قابلیت ثبت رمزگذاری داده ها را ندارند.

سیستم ها مبالغ بیشتری از تراکنش ها را در نظر می گیرند و عمدتاً مبالغ کمتر را نادیده می گیرند (دیون^۷، ۲۰۱۴؛ هرسچل، لیدن، و کارت^۸، ۲۰۱۵).

بانک مضر است، به خصوص اگر این روند طی چندین سال ادامه یابد. ضرورت ایجاد رویکردهای مناسب و قوی کشف تقلب در سیستم های مؤسسات مالی برای مهار این عمل وجود دارد. دو رویکرد اصلی کشف تقلب وجود دارد که شامل رویکرد مبتنی بر قانون و تشخیص تقلب یادگیری ماشین است. سیستم های بانکداری آنلاین (OBS) مکانیسم های امنیتی مختلفی برای جلوگیری از دسترسی غیرمجاز کلاه برداران دارند. علیرغم همه این پیشرفت ها، قربانیان بی خبر بازهم اعتبار خود را در برابر کلاه برداران فیشینگ و سارقان هویت آنلاین از دست می دهند. هنگامی که یک کلاه بردار به حساب بانکی کاربر دسترسی پیدا می کند، تشخیص آن فعالیت آسان نیست. بانک های مختلف از سیستم های کشف تقلب مختلفی استفاده می کنند. برخی از سیستم های کشف تقلب شناخته شده تجاری مورد استفاده برای بانکداری آنلاین: FICO، PRM، Kount و SAS Fraud Manager هستند.

سیستم FICO: سیستم FICO یکی از پرکاربردترین سیستم های کشف تقلب مورد استفاده توسط بانک ها در سطح جهان است (اف. آی. سی. او.، ۲۰۱۰؛ باربازون، کاهیل و والش^۲، ۲۰۱۰). این سیستم، از یک شبکه عصبی و یک موتور مبتنی بر قانون استفاده می کند. قابلیت های بلادرنگ دارد. FICO توسط مؤسسات مالی، بانک ها، اتحادیه های تولیدی و اعتباری، عمدتاً برای کشف تقلب بدهی، اعتبار، سپرده و پرداخت الکترونیکی استفاده می شود (کاپتر^۳، ۲۰۱۹).

سیستم PRM: یکی دیگر از سیستم های کشف تقلب پرکاربرد PRM است (آی. سی. آی.، ۲۰۱۱). PRM مانند FICO، از یک شبکه عصبی و یک رویکرد مبتنی بر قوانین نیز استفاده می کند. سیستم PRM در بیش از ۴۰ کشور از جمله هشت بانک از ۲۰ بانک برتر جهان استفاده می شود. انواع تقلب از کارت بدهی و اعتباری، تقلب حساب و تقلب

1- Online Banking Systems

2- Brabazon, Cahill, Keenan, & Walsh

3- Capterra

4- Hafiz, Aghili, & Zavarsky,

5- Anomaly detection

6- Machine learning

7- Dehaven

8- Herschel, Linden, & Kart

سیستم‌های مبتنی بر قانون (RBS)

سیستم‌های مبتنی بر قانون^۱ بخشی از گروه بزرگی از رویکردها هستند که سعی در مدل‌سازی تخصص انسان به نام سیستم‌های مبتنی بر دانش^۲ (KBS) دارند. KBS سنتی از جمله RBS دارای مسائل مشترک KA، شکنندگی^۳ و یادگیری افزایشی^۴ است. اصطلاح شکنندگی توسط لیگ (۲۰۰۷) ابداع شده است و به نرم‌افزاری اطلاق می‌شود که احتمالاً در مواجهه با سناریوی غیرمنتظره به نتیجه نادرستی می‌رسد. درحالی‌که یادگیری افزایشی یکی از راه‌حل‌های ممکن برای مشکل مقیاس‌پذیری است، که در آن داده‌ها در بخش‌هایی پردازش می‌شوند و سپس نتایج را برای کاهش استفاده از حافظه ترکیب می‌کنند (سید، لیو، و سانگ^۵، ۱۹۹۹). فعالیت‌های مربوط به قلب در حوزه مالی با کاوش سیگنال‌های سطحی و واضح قابل شناسایی هستند. با وجود غیرعادی بودن، تراکنش‌های بزرگ و آنهایی که در مکان‌های غیرمعمول اتفاق می‌افتند، باید تأیید قوی‌تری داشته باشند. سیستم‌های مبتنی بر قانون از الگوریتم‌هایی استفاده می‌کنند که موقعیت‌های مختلف کشف قلب را ارزیابی می‌کنند که به صورت دستی توسط تحلیلگران قلب نوشته شده‌اند. در حال حاضر، سیستم‌های حقوقی تقریباً از ۳۰٪ قانون مختلف برای تأیید معاملات استفاده می‌کنند. این توضیح می‌دهد که چرا استفاده از سیستم‌های مبتنی بر قانون یک فرآیند ساده است. این سیستم‌ها نیاز به تنظیم دستی سناریوها و موقعیت‌هایی دارند که قادر به تشخیص همبستگی‌های ضمنی نیستند. علاوه بر این، سیستم‌های مبتنی بر قانون اغلب از نرم‌افزار قدیمی استفاده می‌کنند که به سختی جریان داده‌های بلندرنج را از طریق سیستم‌هایی که در حوزه دیجیتال مهم هستند، پردازش می‌کنند. سیستم‌های مبتنی بر قوانین؛ به قوانین از پیش تعیین شده بستگی دارند تا تغییرات در رفتار را تشخیص دهند. این سیستم‌ها سفت و سخت هستند و قادر به انطباق

با صنایعی مانند خدمات مالی نیستند که برای غلبه بر چالش‌های مرتبط با شناسایی قلب نیاز به پلت‌فرم‌های سبک‌تر و چابک‌تری دارند (مون و کیم^۶، ۲۰۱۷). رویکردهای مبتنی بر قانون زمان بر هستند زیرا به تحلیل گران قلب نیاز دارند تا قوانین مورد استفاده برای کشف قلب را ایجاد کنند. این رویکردها همچنین به کاردستی و چندین فرآیند تأیید نیاز دارند که مانع از تجربه کاربر می‌شود. رویکردهای مبتنی بر قوانین، الگوهای قلب آشکار را شناسایی می‌کنند و بنابراین با تغییرات کلاه‌برداری که با تکامل کلاه‌برداران رخ می‌دهد، سازگار نیستند. از سوی دیگر، مدل‌های مبتنی بر قانون برای نگهداری مجموعه داده‌ها پرهزینه‌تر می‌شوند یا اندازه پایگاه مشتری گسترش می‌یابد.

تشخیص قلب مبتنی بر یادگیری ماشین (ML)

رویدادهای پنهانی در رفتار کاربر وجود دارد که ممکن است کاملاً مشهود نباشد و تراکنش‌های جعلی احتمالی را به نمایش بگذارد. یادگیری ماشین اجازه ایجاد الگوریتم‌هایی را می‌دهد که می‌توانند مجموعه داده‌های بزرگ‌تری را با چندین متغیر پردازش کنند و به شناسایی این همبستگی‌های پنهان بین رفتار اپراتور و احتمال فعالیت‌های متقلبانه کمک می‌کنند. سیستم‌های یادگیری ماشین بهتر از سیستم‌های مبتنی بر قوانین هستند، زیرا در پردازش داده‌ها سریع‌تر هستند و عملیات دستی کمتری دارند. به عنوان مثال، الگوریتم‌های هوشمند با تجزیه و تحلیل رفتار در کاهش مراحل تأیید مورد نیاز مطابقت دارند. شرکت‌هایی که با مقررات خدمات مالی سرو کار دارند در نظارت بر فعالیت‌های قلبی احتمالی درگیر هستند؛ آنها باید در مورد فعالیت‌های علامت‌گذاری شده با یکدیگر ارتباط برقرار کنند. ویلالوبوس^۷ و همکاران (۲۰۱۹) نمونه‌ای را توصیف می‌کنند که در آن یک نمونه اولیه یادگیری ماشین بر روی مجموعه داده‌ای برنامه‌ریزی شد

1- Rule-based systems

2- Knowledge-Based Systems

3- Brittleness

4- Incremental learning

5- Syed, Liu, & Sung

6- Moon, & Kim

7- Villalobos

میزان ایمنی بیشتری را ارائه دهند، اما نسبت به شدت ایمنی، به منابع محاسباتی بسیار بیشتری نیاز دارند (لی، پارک، اوم و چانگ^۲، ۲۰۱۱). نویسندگان یک IDS چند سطحی و مدیریت گزارش را برای IDS مؤثر در رایانش ابری پیشنهاد کردند. این امر با معرفی مقدار قابل توجهی از مسئولیت ایمنی به مشتریان بسته به نوع روش ناهنجاری، که کاربران را بر اساس نرخ ناهنجاری به سازمان‌های ایمنی متمایز متصل می‌کند، به استفاده کارآمد از منابع کمک می‌کند. برخی محققین، بر این باورند که هکرها می‌توانند یک سری از حملات را به یک سیستم مقصد امن در فضای ابری انجام دهند، به عنوان مثال، با فرار از یک دستگاه با استفاده آسان مبتنی بر ابر و سپس از درب پشتی^۳ قبلی برای حمله به سیستم استفاده می‌کنند (چن، گان، هانگ، و کیو^۴، ۲۰۱۲). سیستم تشخیص پیشنهادی لاگ‌های مختلف را از ابر برای به دست آوردن معانی فعالیت‌های گزارش تجزیه و تحلیل می‌کند. برای تعداد کمی از تخلفات، فعالیت‌های مشکوک اغلب توسط مدیر نادیده گرفته می‌شود. مدل پنهان مارکوف^۵ برای مدل‌سازی توالی حملات انجام‌شده توسط هکرها و چنین رخدادهای مخفیانه در یک چارچوب طولانی مدت اجرا می‌شود، زیرا این مدل آگاه از وضعیت می‌باشد. سیستم‌های پیشنهاد شده برای IDS، عمدتاً بر شناسایی رویدادهای بالقوه، ثبت داده‌ها و تلاش‌های نظارتی تمرکز دارند.

تشخیص ناهنجاری (AD)

تشخیص ناهنجاری (AD) شامل استفاده از تکنیک‌های مختلف محاسباتی و ریاضی برای تشخیص نقاط غیرعادی در یک مجموعه داده است. در ادبیات مرتبط، تشخیص ناهنجاری نام‌های مختلفی دارد: تشخیص بیرونی^۶، تشخیص تازگی^۷، تشخیص نویز^۸ و تشخیص انحراف^۹. تشخیص ناهنجاری فرآیند تجزیه و تحلیل مجموعه داده

که تراکنش‌های آن به صورت مجرمانه انجام شده بود. نمونه اولیه مورد استفاده در سیستم مبتنی بر قانون به کشف روابط پنهان بین معاملات و فعالیت‌های مجرمانه کمک کرد. چنین سیستم‌هایی حجم کار را در بانک‌های کوچک‌تر درگیر در نظارت بر تقلب به حداقل می‌رساند. راه حل پیشنهادی نشان داد که ۹۹٫۶ درصد از معاملات پول‌شویی و تراکنش‌های گزارش شده از ۳۰ درصد به ۱ درصد کاهش یافته است. ML به الگوریتم‌هایی بستگی دارد که با افزایش اندازه مجموعه داده‌ها مؤثرتر هستند. هر چه داده‌ها بیشتر باشد، نمونه اولیه ML بیشتر بهبود می‌یابد و می‌تواند شباهت‌ها و تفاوت‌ها را در رفتارهای مختلف تشخیص دهد. هرچه مدل ML تفاوت بین تراکنش‌های مشروع و جعلی را بیشتر شناسایی کند، سیستم‌ها در دسته‌بندی مجموعه‌های داده در دسته‌های مختلف کارآمدتر می‌شوند. بنابراین، سیستم‌های ML با رشد پایگاه داده مشتری، مقیاس‌پذیرتر هستند. در حالی که الگوریتم‌های ML مزایای متعددی را ارائه می‌کنند، اما دارای معایب قابل توجهی هستند که استفاده از آنها را در تشخیص تقلب محدود می‌کند. به عنوان مثال، یکی از اشکالات این است که ML برای دستیابی به دقت، به مقدار قابل توجهی داده نیاز دارد. این حجم داده قابل مدیریت است. با این حال، باید نقاط داده کافی وجود داشته باشد که روابط علی مشروع را در سازمان‌های کوچک‌تر تشخیص دهد. علاوه بر این، مدل‌های یادگیری ماشین بر روی اعمال، رفتار و فعالیت‌ها عمل می‌کنند. این مدل تمایل دارد اتصالات واضح را نادیده بگیرد، چنین کارتی در دو حساب مختلف استفاده می‌شود، از این رو، فعالیت کشف تقلب را بی‌اثر می‌کند.

-سیستم‌های تشخیص نفوذ (IDS)

با توجه به سیستم‌های تشخیص نفوذ^۱ (IDS) می‌توانند

1- Intrusion Detection Systems
2- Lee, Park, Eom, & Chung
3- Backdoor
4- Chen, Guan, Huang, & Ou
5- Hidden Markov Model
6- Outlier Detection
7- Novelty
8- Noise
9- Deviation

تکنیک AD اخطار را برای کاربران سیستم ارسال می‌کند و بیشتر متمرکز بر ابر است و برای اطلاعات بزرگ مناسب نیست (چیو، یه و لی^۱، ۲۰۱۳). برابازون و همکاران^۲ (۲۰۱۰) همچنین استفاده از یک رویکرد مبتنی بر AIS برای AD را برای کاهش تقلب در کارت اعتباری توصیف می‌کنند. تجزیه و تحلیل غیرعادی برای داده‌های گزارش جریانی توسط محققین انجام شده است (مروستی، پوگاسیان، هارتانیان، و گیروگیان^۳، ۲۰۱۴). نویسندگان مفهوم آستانه استراتژیک داده سری زمانی را به هر نوع اطلاعاتی که جریانی از اسناد و فعالیت‌ها هستند، گسترش می‌دهند. آنها مفهوم نرمال بودن آن جریان‌ها را در روش پیشنهادی خود پیاده‌سازی کردند و مکانیزمی را برای تشخیص ناهنجاری آنها در جریان زمان اجرا ایجاد کردند. تحت محدودیت‌های منحصربه‌فرد در پیچیدگی و مقیاس‌پذیری، آنها ساختار تصمیم‌گیری جدیدی را برای بازیابی اطلاعات از جریان داده‌ها پیاده‌سازی کردند. تکنیک پیشنهاد شده فوق، در درجه اول مبتنی بر تجزیه و تحلیل غیرعادی داده‌های رویداد از فایل‌های گزارش و به دست آوردن اطلاعات مفید از منبع و انواع رویدادها است.

الگوریتم‌های تشخیص تقلب بانکی

بسیاری از روش‌های ML برای مبارزه با تقلب توسعه داده شده است. تکنیک‌های متداول کشف تقلب عبارتند از ANN، ES (مبتنی بر دانش (KB))، موتور استنتاج و داده‌کاوی (ماراتون، ۲۰۱۳؛ وی و همکاران، ۲۰۱۳). بیشترین رویکردهای مورد استفاده برای کشف تقلب روش‌های نظارت شده، بدون نظارت، نیمه نظارت شده و ترکیبی هستند (بولتون و هند، ۲۰۲۰؛ جان و همکاران، ۲۰۱۶؛ عبدالله و همکاران، ۲۰۱۶؛ کانادول و بانجری^۴، ۲۰۰۹). کوچا و روجیرو^۵ (۲۰۱۱) یک سیستم کشف تقلب را برای بانکداری آنلاین با تمرکز بر تجزیه و تحلیل محلی و جهانی رفتار کاربران پیشنهاد

برای شناسایی موارد انحرافی است و شامل یک یا دو کار زیر است:

(الف) شناسایی داده‌های غیرعادی، به عنوان مثال، نویز، انحرافات یا نقاط پرت از مجموعه داده اصلی و (ب) کشف نمونه‌های داده جدید بر اساس دانش آموخته شده بر اساس مجموعه داده اصلی، تشخیص ناهنجاری را می‌توان برای اهداف مختلفی استفاده کرد (آگروال^۱، ۲۰۱۷). مانند تشخیص تقلب، تجزیه و تحلیل کیفیت داده‌ها، اسکن امنیتی، نظارت بر فرآیند و سیستم، نظارت تصویر/ویدئو، تشخیص هرزنامه، شناسایی حملات مخرب داخلی، پاک‌سازی داده‌ها قبل از آموزش مدل‌های آماری، تجزیه و تحلیل رفتار انسان (چیو، کیم، کانگ، ویوم^۲، ۲۰۲۱) و تشخیص خطای حسگر (درویشی، کیانزو، عید و راسی^۳، ۲۰۲۰). برخی از محققین، یک تکنیک تشخیص نفوذ مبتنی بر قانون (ID) پیشنهاد و اذعان می‌کنند که AD یکی از اولین رویکردها برای ID است (ایلگان، کیمر و پارس^۴، ۱۹۹۵). سایر محققین نشان دادند که سرقت حساب یا سرویس در رایانش ابری خطرناک‌تر است. نویسندگان چارچوبی با تکنیک AD برای نمایه کردن رفتارهای معمولی کاربر پیشنهاد کردند. هنگامی که یک نمایه کاربر از اطلاعات جمع‌آوری شده کشف می‌شود، هشدارها توسط همه رفتارهای مشکوک شناسایی شده توسط نمایه فعال می‌شوند. هشدارها به پایگاه داده ارسال می‌شود و به صاحب حساب و مدیر ابر اطلاع داده می‌شود. دو جزء اصلی چارچوب وجود دارد: بخش اول جمع‌آوری داده و بخش دوم مازول یادگیری است که تکنیک‌های مختلف ML را برای استخراج روندهای مکرر از داده‌های آموزشی و به دست آوردن محدودیت رتبه‌بندی مشکوک معرفی کرده است. اگر رتبه‌بندی مشکوک از حد تعیین شده بیشتر شود، تراکنش به عنوان یک ناهنجاری توسط طرح گزارش می‌شود. چیو و همکاران^۵ (۲۰۱۳) پیشنهاد می‌کنند که

- 1- Aggarwal
- 2- Choi, Kim, Kang, & Youm
- 3- Darvishi, Ciunzo, Eide, & Rossi
- 4- Ilgun, Kemmerer, & Porras
- 5- Chiu
- 6- Chiu, Yeh, & Lee
- 7- Brabazon
- 8- Marvasti, Poghosyan, Harutyunyan, & Grigoryan
- 9- Chandola, & Banerjee
- 10- Kovach and Ruggiero

اين نتيجه رسيدند كه بالاترين خروجي در كشف قلب روي مجموعه داده تركيبي است. اندازه مجموعه داده مورد بحث قرار نمي گيرد، اما اين تكنيك براي مجموعه داده هاي بزرگ كه در آن مجموعه داده ديگري با تركيبي از مجموعه داده هاي اوليه مورد نياز است، بهينه نيست.

باي (۲۰۱۳) روشي را پيشنهاد مي كند كه در درجه اول يك گزينه جستجوي مؤثر براي اطلاعات بلادرنگ است، اما براي حوزه طبقه بندي مناسب نيست، چرا كه هر عمليات بايد به عنوان قلب يا غير قلب طبقه بندي شود. كواچ و روجيرو (۲۰۱۱) پيشنهاد مي كنند كه سيستم رديابي قلب بر رفتار مشتريان متمرکز است و به شدت به دسترسي دستگاه بستگي دارد كه براي اطلاعات بزرگ و در زمان واقعي مناسب نيست. راه حل كشف قلب كارت اعتباري پيشنهاد شده توسط دومان و اوزچليك (۲۰۱۱) از رويكردهاي فراابتكاري استفاده مي كند. با اين حال، نويسندگان روش هايي براي برخورد با اطلاعات و اطلاعات بزرگ در زمان واقعي ارائه نكرده اند.

وي و همكاران (۲۰۱۳) يك تكنيك كشف قلب را براي داده هاي بسيار نامتعادل با استفاده از الگوريتم Contrast Miner ارائه مي دهند كه الگوهاي تضاد را استخراج مي كند و قلب را از رفتار واقعي متمايز مي كند. كو و همكاران (۲۰۰۴) معتقدند كه تحقيقات كشف قلب عمدتاً از داده كاوي، آمار و هوش مصنوعي استفاده مي كند و قلب از ناهنجاري ها در داده ها و الگوها تشخيص داده مي شود.

چن و همكاران (۲۰۱۹) يك سيستم تشخيص قلب مبتني بر گراف را براي بيمه تجارت الكترونيكي به نام InfDetect مورد بحث قرار دادند. اين آزمون بر روي داده هاي شركت بيمه خصوصي از جمله بيمه سپرده تضميني و بيمه باربري برگشت انجام شد. مدل آنها از تركيبي از گراف ها و ويژگي هاي خام به عنوان داده ورودی، ساخت ويژگي از طريق مدل يادگيري گراف تحت نظارت و بدون نظارت به نام DeepWalk استفاده مي كند. رمزگذار خودكار حذف نويز و پردازش ويژگي نيز پياده سازي شده

مي كنند. ارزيايي افتراقي براي به دست آوردن شواهدی از قلب استفاده می شود که در آن تغییر قابل توجهی از رفتار عادی یک قلب بالقوه را نشان می دهد. شواهد قلب بر تعداد دسترسي هاي کاربر و مقدار احتمالي كه در طول دوره متفاوت است متمرکز می باشد. روش پيشنهادهی كشف قلب آنها بر شناسايي كارآمد دستگاه هاي مورد استفاده براي كنترل حساب ها و ارزيايي احتمال كلاه برداري با نظارت بر تعداد سوابق مجزايي كه هر دستگاه به آن دسترسي دارد، متمرکز دارد. روشي براي شناسايي قلب در كارت اعتباري توسط دومان و اوزچليك^۱ (۲۰۱۱) ارائه شده است. نويسندگان تركيبي از دوروش فراابتكاري معروف را براي رتبه بندي پيشنهاد كردند كه عبارتند از: الگوريتم هاي ژنتيك و جستجوي پراكنده. اين تكنيك بر روي داده هاي واقعي پياده سازي شده است و يافته هاي به دست آمده نسبت به سيستم فعلي در حال استفاده بسيار مؤثر هستند. هر تراكنش با اين رويكرد رتبه بندي می شود و عمليات بسته به نتايج به صورت قلب يا مشروع طبقه بندي می شود. آنها معتقدند كه يك طرح FD بهتر از طرحي است كه بسياري از كلاه برداري هاي كم خطر را شناسايي می كند، كه جرم را حتي از نظر مقدار كمتر اما از نظر ارزش بيشتر كشف می كند. كو و همكاران^۲ (۲۰۰۴) نيز يك مطالعه مبتني بر داده كاوي از تحقيقات كشف قلب را براي دسته بندي تحقيقات مبتني بر چهار روش اصلي شامل رويكردهاي نظارت شده، تركيبي، نيمه نظارتی و بدون نظارت انجام دادند و همچنين رابطه كشف قلب را با ساير زمينه ها شناسايي كردند. يك استراتژي كشف قلب توسط هرلند، خوش گفتار، و بادر^۳ (۲۰۱۸) براي قلب مديكرو^۴ با استفاده از سه مجموعه داده خدمات مديكرو و مديكرو پيشنهاد شده است. روش آنها بر روي مجموعه داده تركيبي با اتصال چندين مجموعه داده آموزشي عمل می كند. نويسندگان از سه طبقه بندي كننده استفاده كردند: مدل هاي جنگل تصادفي، تقويت درخت گرايدان و مدل هاي رگرسيون لجستيك و از متريك ناحيه زير منحنی (ROC) براي اندازه گيري عملکرد FD استفاده كردند. آنها به

1- Duman and Ozelik

2- Kou

3- Berland, Khoshgoftaar, and Bauder

4- Medicare

۳- يافته‌های تحقيق

رگرسيون لجستيك براي تشخيص تقلب

رگرسيون لجستيك^۳ به يك روش يادگيري نظارت شده اشاره دارد كه با تصميمات قطعي استفاده مي‌شود. به اين معني كه نتايج به دست آمده در صورت انجام معامله، تقلب يا غير تقلب محسوب مي‌شود. اين رويکرد از يك رابطه علت و معلولي براي توسعه مجموعه داده‌های سازمان يافته استفاده مي‌كند. تكنيك تحليل رگرسيون زماني كه در تشخيص تقلب مورد استفاده قرار مي‌گيرد به دليل چندين متغير و اندازه مجموعه داده پيچيده تر است. اين مدل (الگوريتم) پيش بيني مي‌كند كه آيا تراكنش‌های جديد به عنوان تقلبي علامت گذاري مي‌شوند يا خير. اين مدل‌ها معمولاً براي مشتريان خود از تجار بزرگ تر دقيق هستند، اما معمولاً مدل‌های عمومي همچنان قابل اجرا هستند.

درخت تصميم براي تشخيص تقلب

الگوريتم‌های درخت تصميم^۴ براي طبقه بندي فعاليت‌های غير معمول در يك تراكنش از يك كاربر مجاز استفاده مي‌شود. اين الگوريتم‌ها داراي محدوديت‌هایی هستند كه در مجموعه داده‌ها در طبقه بندي تقلب استفاده مي‌شوند. الگوريتم‌های درخت تصميم در طبقه بندي يا مشكلات مدل سازي برون يابي رگرسيون استفاده مي‌شوند. آنها اساساً مجموعه قوانيني هستند كه براي استفاده از موارد كلاه برداري شامل مشتريان مهارت دارند. ايجاد يك درخت تصميم ويژگي‌های نامرتب راناديد مي‌گيرد و نياز ي به عادي سازي داده‌های گسترده ندارد. هنگامي كه يك درخت تحت بازرس قرار مي‌گيرد، دليل اينكه چرا يك تصميم خاص بسته به ليست قوانين فعال شده توسط يك مشتري خاص گرفته شده است، درك مي‌شود. خروجي الگوريتم يادگيري ماشين ممكن است مدلي باشد كه ميمون درخت تصميم است. اين يك امتياز احتمالي تقلب را بر اساس شرايط قبلي تعيين

است. آنها سپس يك درخت تصميم گيري مبتني بر گرايدان تقويت شده مبتني بر سرور به نام PSMART را براي خروجي احتمال تقلب اعمال مي‌كنند. محققان ادعا كرده اند كه طرح پيشنهادهي آنها به صرفه جويي ميليون ها دلار در سال براي اين شركت‌های تجارت الكترونيك كمك مي‌كنند. يكي از ويژگي‌های كليدي مهندسي شده توسط محققان، استفاده از اختصاص امتيازهای bin براي مبالغ تراكنش بود كه به بهبود عملکرد كمك كرد.

آرازو و همكاران (۲۰۱۷) الگوريتم "BreachRadar" را توسعه داده اند، يك الگوريتم متناوب توزيع شده كه احتمال در معرض خطر قرار گرفتن كارت بانكي را به مكان‌های مختلف ممكن براي استفاده از كارت اختصاص مي‌دهد. اين نقاط سازش^۱ (POC) نقطه شروع براي تقلب در تراكنش‌های بانكي است. يك مثال مي‌تواند نقض داده‌ها باشد كه منجر به كسب اطلاعات مشتريان بانكي مي‌شود، از جمله اطلاعات كارت اعتباري آنها كه سپس به صورت آنلاين از طريق سايت‌های DarkNet شسته مي‌شود يا شخصاً توسط مجرمان استفاده مي‌شود. مثال ديگر مي‌تواند اسكimming^۲ كارت باشد، كه در آن جزئيات كارت مشتري با استفاده از دستگاهي كه عمداً براي به دست آوردن غيرقانوني اين اطلاعات تغيير داده شده، كپي يا شبیه سازي مي‌شود. هدف از شناسايي POC جلوگيري از استفاده جعلی از داده‌های مشتري است. محققان مدلی با عملکرد بالا با دقت ۹۰ درصد و ياد آوري در برابر مجموعه داده‌ای با ۱۰ درصد كارت‌های اعتباري مشتريان را ارائه كردند. اين تكنيك شامل تشكيل يك مدل گراف دوبخشي براي نشان دادن همه كارت‌ها و مكان آنها است. با اجراي يك الگوريتم در حافظه كه امكان به روزرسانی احتمالات POC را فراهم مي‌كند، محققان اولين روش توزيع شده را توليد كرده اند كه قادر به تشخيص خودكار POC ها مي‌باشد.

1- Points-of-Compromise

2- Skimming

3- Logistic Regression

4- Decision Tree

می‌کند.

جنگل تصادفی برای تشخیص تقلب

جنگل تصادفی^۱ از ترکیبی از درختان تصمیم برای بهبود نتایج استفاده می‌کند. هر درخت معاملات را برای شرایط مختلف ارزیابی می‌کند (آیدیوارا، کی؛ آیدیوارا، وی، ۲۰۸). همچنین مجموعه داده‌های تصادفی آموزش داده می‌شوند. بسته به آموزش درخت تصمیم، هر درخت یک تراکنش را به عنوان تقلبی یا غیر متقلبانه طبقه‌بندی می‌کند. سپس از مدل برای پیش‌بینی نتیجه استفاده می‌شود. این به آشکارسازهای تقلب اجازه می‌دهد تا خطای موجود در درخت را یکسان کنند. دقت مدل عملکرد کلی را افزایش می‌دهد و در عین حال توانایی تفسیر نتایج را حفظ می‌کند و امتیازات قابل توضیحی را برای کاربران ما ارائه می‌دهد.

زمان‌های اجرا جنگل تصادفی سریع هستند و داده‌هایی را که گم شده یا نامتعادل هستند مدیریت می‌کنند. ML های جنگل تصادفی دارای نقاط ضعفی هستند، مثلاً هنگامی که در گرسیون استفاده می‌شوند، قادر به پیش‌بینی فراتر از تنوع در آموزش داده‌ها نیستند و ممکن است مجموعه‌های داده‌ای که نویز در نظر گرفته می‌شوند بیش از حد برآزش کنند.

شبکه‌های عصبی برای تشخیص تقلب

شبکه‌های عصبی^۲ مبتنی بر مغز انسان هستند. آنها از لایه‌های محاسباتی مختلفی استفاده می‌کنند. آنها از محاسبات شناختی استفاده می‌کنند که به ساخت ماشین‌هایی کمک می‌کند که می‌توانند از الگوریتم‌های خودآموزی که شامل داده‌کاوی، تشخیص الگوها و پردازش زبان طبیعی است استفاده کنند (گراپ، ۲۰۱۶). شبکه‌های عصبی برای فرآیند آموزش داده‌ها چندین لایه را پشت سر می‌گذارند. نتایج دقیق‌تری را در مقایسه با مدل‌های دیگر ارائه می‌دهد؛ زیرا از محاسبات شناختی استفاده می‌کند و از الگوهای رفتار مجاز می‌آموزد. بنابراین، بین معاملات «تقلبی» و غیر تقلبی تمایز قائل می‌شود. شبکه‌های

عصبی کاملاً سازگار هستند و از مجموعه الگوهای رفتار مشروع درس می‌گیرند. اینها با تغییر در رفتار آنچه که تراکنش‌های استاندارد تلقی می‌شوند سازگار می‌شوند و اشکال تراکنش‌های تقلب را شناسایی می‌کنند. فرآیند شبکه‌های عصبی سریع است و در زمان واقعی کار می‌کند.

۴- نتیجه‌گیری

فعالیت‌های متقلبانه در طول دوره کرونا افزایش یافته است و سازمان‌هایی با روش‌های سنتی کشف تقلب ثابت کرده‌اند که نتایج چشمگیری داشته‌اند؛ زیرا چشم انسان همیشه ناهنجاری‌ها را در سیستم بانکی تشخیص نمی‌دهد. کلاهبرداری مالی یکی از اصلی‌ترین مشکلاتی است که اعتماد مشتریان را تضعیف می‌کند و همچنین زیان اقتصادی به بانک‌ها و مؤسسات مالی وارد می‌کند. در سال‌های اخیر، هم‌زمان با گسترش تقلب، مؤسسات مالی به دنبال راه‌حلی برای یافتن راه‌حل مناسب در مبارزه با کلاهبرداری بودند. با توجه به تغییرات پیشرفته و متنوع در روش‌های تقلب، تحقیقات گسترده‌ای برای کشف تقلب انجام شده است. تقلب پیچیده بانکداری آنلاین نشان‌دهنده سوء استفاده یکپارچه از منابع در دنیای اجتماعی، سایبری و فیزیکی است. با این حال، اطلاعات بسیار محدودی برای تشخیص کلاهبرداری پویا از رفتار مشتری واقعی در چنین محیط داده‌ای بسیار کم و نامتعادل در دسترس است، که باعث می‌شود تشخیص فوری و مؤثر مهم و چالش برانگیز شود. بانک‌ها به دنبال کاهش زیان‌های هنگفت از طریق سیستم‌های تشخیص و پیشگیری از تقلب هستند. بسیاری از فن‌آوری‌های پیشرفته کلاهبرداری برای شناسایی و پیشگیری از تراکنش‌های بانکی اینترنتی تقلبی استفاده می‌شوند. با این حال، آنها هیچ مکانیسم شناسایی مؤثری برای شناسایی کاربران قانونی و ردیابی فعالیت‌های غیرقانونی آنها ندارند. توجه به نتایج به دست آمده از این مطالعه، توصیه می‌شود که از الگوریتم‌های یادگیری ماشین برای کشف تقلب استفاده شود تا جایگزین سیستم‌های تشخیص تقلب مبتنی بر قانون نادرست شود

1- Random Forest
2- Neural Networks

منابع:

- 5-Abdallah, A., Maarof, M. A., & Zainal, A. (2016). Fraud detection system: A survey. *Journal of Network and Computer Applications*, 68, 90-113.
- 6-ACI.(2011). Proactive Risk Manager. Retrieved from <https://www.aciworldwide.com/products/proactive-risk-manager>.
- 7-Aggarwal, C. C. (2017). Outlier Analysis. 2nd. Cham, Switzerland: Springer.
- 8-Amarasinghe, T., Aponso, A., & Krishnarajah, N. (2018, May). Critical analysis of machine learning based approaches for fraud detection in financial transactions. In *Proceedings of the 2018 International Conference on Machine Learning Technologies* (pp. 12-17).
- 9-APF. (2018). Western Australia Police Force. Retrieved from <https://www.police.wa.gov.au/>
- 10-Araujo, M., Almeida, M., Ferreira, J., Silva, L., & Bizarro, P. (2017, June). Breachradar: Automatic detection of points-of-compromise. In *Proceedings of the 2017 SIAM International Conference on Data Mining* (pp. 561-569). Society for Industrial and Applied Mathematics.
- 11-Ayyadevara, V. K., & Ayyadevara, V. K. (2018). Gradient boosting machine. *Pro machine learning algorithms: A hands-on approach to implementing algorithms in python and R*, 117-134.
- 12-Bao, Y., Hilary, G., & Ke, B. (2022). Artificial intelligence and fraud detection. *Innovative Technology at the Interface of Finance and Operations: Volume I*, 223-247.
- 13-Bilgin, M. H., MARCO LAU, C. K., & Demir, E. (2012). Technology transfer, finance channels, and SME performance: New evidence from developing countries. *The Singapore Economic Review*, 57(03),

1250020.

14-Brabazon, A., Cahill, J., Keenan, P., & Walsh, D. (2010, July). Identifying online credit card fraud using artificial immune systems. In *IEEE Congress on Evolutionary Computation* (pp. 1-7). IEEE.

15-Bolton, R. J., & Hand, D. J. (2002). Statistical fraud detection: A review. *Statistical science*, 17(3), 235-255.

16-Capterra. (2019). Fraud Management Software. Retrieved from <https://www.capterra.com.au/directory/10058/financial-fraud-detection/software>

17-Carminati, M., Polino, M., Continella, A., Lanzi, A., Maggi, F., & Zanero, S. (2018). Security evaluation of a banking fraud analysis system. *ACM Transactions on Privacy and Security (TOPS)*, 21(3), 1-31.

18-Carminati, M., Caron, R., Maggi, F., Epifani, I., & Zanero, S. (2015). BankSealer: A decision support system for online banking fraud analysis and investigation. *computers & security*, 53, 175-186.

Bagga, S., Goyal, A., Gupta, N., & Goyal, A. (2020). Credit card fraud detection using pipeling and ensemble learning. *Procedia Computer Science*, 173, 104-112.

19-Chandola, V., & Banerjee, A. V., K. (2009). Anomaly detection: A survey. *ACM Computing survey*, 41.

20-Chen, C., Liang, C., Lin, J., Wang, L., Liu, Z., Yang, X., ... & Qi, Y. (2019, December). InfDetect: A large scale graph-based fraud detection system for E-commerce insurance. In *2019 IEEE International Conference on Big Data (Big Data)* (pp. 1765-1773). IEEE.

21-Chen, C. M., Guan, D. J., Huang, Y. Z., & Ou, Y. H. (2012, August). Attack sequence detection in cloud using hidden markov model. I

22-Chen, L., Zhang, Z., Liu, Q., Yang, L., Meng, Y., & Wang, P. (2019, May). A method for online transaction fraud detection based on individual behavior. In *Proceedings of the ACM Turing Celebration Conference-China* (pp. 1-8).

23-Chen, K., Yadav, A., Khan, A., & Zhu, K. (2020). Credit Fraud Detection Based on Hybrid Credit Scoring Model. *Procedia Computer Science*, 167, 2-8.

24-Chiu, C. Y., Yeh, C. T., & Lee, Y. J. (2013, December). Frequent pattern based user behavior anomaly detection for cloud system. In *2013 Conference on Technologies and Applications of Artificial Intelligence* (pp. 61-66). IEEE.

25-Choi, S., Kim, C., Kang, Y. S., & Youm, S. (2021). Human behavioral pattern analysis-based anomaly detection system in residential space. *The Journal of Supercomputing*, 77, 9248-9265.

26-CURTIS, C. V. (2012). The Fraud Triangle: Fraudulent Executives, Complicit Auditors and Intolerable Public Injury.

27-Darvishi, H., Ciuonzo, D., Eide, E. R., & Rossi, P. S. (2020). Sensor-fault detection, isolation and accommodation for digital twins via modular data-driven architecture. *IEEE Sensors Journal*, 21(4), 4827-4838.

28-Dehaven, V. R. (2014). Machine learning: Future capabilities and their implications.

29-Dong, F., Wang, H., Li, L., Guo, Y., Bissyandé, T. F., Liu, T., ... & Klein, J. (2018, October). Frauddroid: Automated ad fraud detection for android apps. In *Proceedings of the 2018 26th ACM Joint Meeting on European Software Engineering Conference and Symposium on the Foundations of Software Engineering* (pp. 257-268).

30-Duman, E., & Ozcelik, M. H. (2011). Detecting credit card fraud by genetic algorithm and scatter search. *Expert Systems with Applications*, 38(10), 13057-13063.

31-Eurostat, G. D. P., & Components, M. (2020). Available online: https://ec.europa.eu/eurostat/databrowser/view.NAMQ_10_GDP/default/table.

32-FBI. (2018). Internet Crime Complaint Center, 20182019(20/08/2019). Retrieved from https://pdf.ic3.gov/2018_I_C3_Report.Pdf

33-FICO. (2010). Fico Application Fraud Manager. Retrieved from <https://www.fico.com/en/products/fico-application-fraud-manager>

34-FraudNet. (1997). Enterprise Fraud Prevention. Retrieved from <https://fraud.net>

35-Gbudeanu, L., Brici, I., Mare, C., Mihai, I. C., & cheau, M. C. (2021). Privacy intrusiveness in

- financial-banking fraud detection. *Risks*, 9(6), 104.
- 36-Graupe, D. (2016). *Deep learning neural networks: Design and case studies*. World Scientific Publishing Company.
- 37-Hafiz, K. T., Aghili, S., & Zavorsky, P. (2016, June). The use of predictive analytics technology to detect credit card fraud in Canada. In *2016 11th Iberian Conference on Information Systems and Technologies (CISTI)* (pp. 1-6). IEEE.
- 38-Herland, M., Khoshgoftaar, T. M., & Bauder, R. A. (2018). Big data fraud detection using multiple medicare data sources. *Journal of Big Data*, 5(1), 1-21.
- 39-Herschel, G., Linden, A., & Kart, L. (2015). Magic quadrant for advanced analytics platforms. *Gartner Report G*, 270612.
- 40-Hopton, D. (2016). Proceeds of Crime Act 2002–Part 7: Requirements and Offences. In *Money Laundering* (pp. 53-78). Gower.
- 41-Horák, M., Stupka, V., & Husák, M. (2019, August). GDPR compliance in cybersecurity software: a case study of DPIA in information sharing platform. In *Proceedings of the 14th international conference on availability, reliability and security* (pp. 1-8).
- 42-Ilgun, K., Kemmerer, R. A., & Porras, P. A. (1995). State transition analysis: A rule-based intrusion detection approach. *IEEE transactions on software engineering*, 21(3), 181-199.
- 43-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.
- 44-John, S. N., Anele, C., Kennedy, O. O., Olajide, F., & Kennedy, C. G. (2016, December). Realtime fraud detection in the banking sector using data mining techniques/algorithm. In *2016 international conference on computational science and computational intelligence (CSCI)* (pp. 1186-1191). IEEE.
- 45-Kou, Y., Lu, C. T., Sirwongwattana, S., & Huang, Y. P. (2004, March). Survey of fraud detection techniques. In *IEEE International Conference on Networking, Sensing and Control, 2004* (Vol. 2, pp. 749-754). IEEE.
- 46-Kovach, S., & Ruggiero, W. V. (2011, February). Online banking fraud detection based on local and global behavior. In *Proc. of the Fifth International Conference on Digital Society, Guadeloupe, France* (pp. 166-171).
- 47-Lavion, D. (2018). Global Economic Crime and Fraud Survey 2018, 30. Retrieved from Pulling fraud out of the shadows website: <https://www.pwc.com/gx/en/forensics/global-economic-crime-and-fraud-survey->
- 48-Lee, J. H., Park, M. W., Eom, J. H., & Chung, T. M. (2011, February). Multi-level intrusion detection system and log management in cloud computing. In *13th International Conference on Advanced Communication Technology (ICACT2011)* (pp. 552-555). IEEE.
- 49-Legg, C. (2007). Ontologies on the semantic web. *Annual review of information science and technology*, 41, 407.
- 50-Li, Z., Huang, M., Liu, G., & Jiang, C. (2021). A hybrid method with dynamic weighted entropy for handling the problem of class imbalance with overlap in credit card fraud detection. *Expert Systems with Applications*, 175, 114750.
- 51-Marican, L., & Lim, S. (2014). Microsoft Consumer Safety Index reveals impact of poor online safety behaviours in Singapore. Retrieved from <https://news.microsoft.com/en-sg/2014/02/11/microsoft-consumer-safety-index-reveals-impact-of-poor-online-safety>.
- 52-Maruatona, O. (2013). *Internet banking fraud detection using prudent analysis* (Doctoral dissertation, University of Ballarat).
- 53-Maruti T. (2021). How Machine Learning Facilitates Fraud Detection?. [online] Available at:<<https://marutitech.com/machine-learning-fraud->
- 54-Marvasti, M. A., Poghosyan, A. V., Harutyunyan, A. N., & Grigoryan, N. M. (2014). An enterprise dynamic thresholding system. In *11th International Conference on Autonomic Computing ({ICAC} 14)* (pp. 129-135).

- 55-Misra, S., Thakur, S., Ghosh, M., & Saha, S. K. (2020). An autoencoder based model for detecting fraudulent credit card transaction. *Procedia Computer Science*, 167, 254-262.
- 56-Moon, W. Y., & Kim, S. D. (2017). Adaptive fraud detection framework for fintech based on machine learning. *Advanced Science Letters*, 23(10), 10167-10171.
- 57-Nanduri, J., Jia, Y., Oka, A., Beaver, J., & Liu, Y. W. (2020). Microsoft uses machine learning and optimization to reduce e-commerce fraud. *INFORMS Journal on Applied Analytics*, 50(1), 64-79.
- 58-Nathan, R. J., Victor, V., Gan, C. L., & Kot, S. (2019). Electronic commerce for home-based businesses in emerging and developed economy. *Eurasian Business Review*, 9, 463-483.
- 59-Nicholls, J., Kuppa, A., & Le-Khac, N. A. (2021). Financial cybercrime: A comprehensive survey of deep learning approaches to tackle the evolving financial crime landscape. *Ieee Access*, 9, 163965-163986.
- 60-Orek, M., Örek, E., & Bahtiyar, . (2019, May). A deep learning method for fraud detection in financial systems: Poster. In *Proceedings of the 12th Conference on Security and Privacy in Wireless and Mobile Networks* (pp. 298-299).
- 61-Olowookere, T. A., & Adewale, O. S. (2020). A framework for detecting credit card fraud with cost-sensitive meta-learning ensemble approach. *Scientific African*, 8, e00464.
- 62-Ocansey, E. O. N. D., & Ganu, J. (2017). The role of corporate culture in managing occupational fraud. *Research Journal of Finance and Accounting*, 8(24).
- 63-Pascual, A., Marchini, K., & Miller, S. (2017). Identity fraud: securing the connected life. *Retrieved on January, 20, 2018*.
- 64-PattemSpy. (2015). PattemSpy For Banking - Fraud Management Software. Retrieved from <https://www.pattemspy.tech/>
- 65-Pinto, S. O., & Sobreiro, V. A. (2022). Literature review: Anomaly detection approaches on digital business financial systems. *Digital Business*, 100038.
- 66-Politou, E., Alepis, E., & Patsakis, C. (2019). Profiling tax and financial behaviour with big data under the GDPR. *Computer law & security review*, 35(3), 306-329.
- 67-Phua, C., Lee, V., Smith, K., & Gayler, R. (2010). A comprehensive survey of data mining-based fraud detection research. *arXivpreprintarXiv:1009.6119*.
- 68-Richards, D. (2003). Knowledge-based system explanation: The ripple-down rules alternative. *Knowledge and Information Systems*, 5(1), 2-25.
- 69-RiskNet. (1998). Fraud Managed Services. Retrieved from <https://www.aicorporation.com/products-services/fraud-managed-services/>
- 70-SAS. (2007). SAS Fraud Management. Retrieved from https://www.sas.com/en_au/software/fraud-management.html
- 71-Sando, S., 2021. Consumer Preference Drives Shift in Authentication. [online] Javelin. Available at: <https://www.javelinstrategy.com/coverage-area/>
- 72-cheau, M. C., Gafta, V. N., Achim, M. V., & Cotoc, C. N. B. (2020, October). Cyber Security Reactivity in Crisis Times and Critical Infrastructures. In *2020 24th International Conference on System Theory, Control and Computing (ICSTCC)* (pp. 691-698). IEEE.
- 73-Shihembetsa, E. (2021). *Use of artificial intelligence algorithms to enhance fraud detection in the Banking Industry* (Doctoral dissertation, University of Nairobi).
- 74-Stalla-Bourdillon, S., Pearce, H., & Tsakalakis, N. (2018). The GDPR: A game changer for electronic identification schemes? The case study of Gov. UK Verify. *Computer Law & Security Review*, 34(4), 784-805.
- 75-Stojanov, M. (2019). Protection Against Fraud In Electronic Trade Payments. 21, 9(1-ENG), 48-66.
- 76-Sudharsan, K., Kumar, V. A., Venkatesan, R., Sathyapreiya, V., & Saranya, G. (2019). Two three step authentication in ATM machine to transfer money and for voting application. *Procedia Computer Science*, 165, 300-306.
- 77-Syed, N. A., Liu, H., & Sung, K. K. (1999, August). Handling concept drifts in incremental learning

- with support vector machines. In *Proceedings of the fifth ACM SIGKDD international conference on Knowledge discovery and data mining* (pp. 317-321).
- 78-Wang, Y., & Wang, L. (2019, May). Bot-like Behavior Detection in Online Banking. In *Proceedings of the 4th International Conference on Big Data and Computing* (pp. 140-144).
- 79-Wei, W., Li, J., Cao, L., Ou, Y., & Chen, J. (2013). Effective detection of sophisticated online banking fraud on extremely imbalanced data. *World Wide Web*, 16, 449-475.
- 80-Williams, M. (2022). Elizabeth Holmes and Theranos: A play on more than just ethical failures. *Business Information Review*, 39(1), 23-31.

©Authors, Published by Journal of Intelligent Knowledge Exploration and Processing. This is an open-access paper distributed under the CC BY (license <http://creativecommons.org/licenses/by/4.0/>).

