

کاربست رویکرد داده‌بنیان در پیشگیری از پولشویی

باقر شاملو^۱

سمیه پرهیزکاری^{۲*}

چکیده

رویکرد داده‌بنیان در سال‌های اخیر به عنوان پارادایمی نوین در پیشگیری از جرایم اقتصادی مطرح شده است. گذار از نظام‌های سنتی قاعده‌محور و ریسک‌مدار به سامانه‌های مبتنی بر کلان‌داده، داده‌های جایگزین و الگوریتم‌های یادگیری ماشین، این امکان را فراهم آورده است که فرآیند شناسایی مشتری و بازشناسی تراکنش‌های مشکوک، به عنوان دو رکن اساسی مورد تأکید اسناد بین‌المللی در راستای مبارزه با جرایم اقتصادی (از جمله اسناد گروه ویژه اقدام مالی)، به‌طور کارآمدتری انجام پذیرد. نوشتار حاضر با هدف شناسایی ظرفیت‌ها و چالش‌های کاربردی این رویکرد، به روش توصیفی-تحلیلی و با استفاده از منابع کتابخانه‌ای نگارش یافته است. یافته‌های پژوهش نشان می‌دهد که الگوریتم‌های یادگیری ماشین در شاخه‌های نظارت‌شده و بدون نظارت توانایی قابل توجهی در کشف الگوهای پنهان و ناهنجار تراکنش‌های مالی دارند و نرخ خطاهای مثبت و منفی کاذب را کاهش می‌دهند. در مقابل، کاربردی این رویکرد با چالش‌هایی چون عدم شفافیت الگوریتمی و تعارض آن با حق دفاع و آسیب‌پذیری ادله الگوریتمی در برابر حملات تخصصی مواجه است. نتیجه آنکه اگرچه رویکرد داده‌بنیان مسیری روشن و کارآمد در پیشگیری از جرایم اقتصادی و به‌ویژه پولشویی فراروی نهادهای مالی و عدالت کیفری گشوده است، اما تحقق کامل این ظرفیت‌ها بدون توجه همزمان به طراحی چارچوب‌های قانونی و تنظیم‌گری هوشمندانه امکان‌پذیر نخواهد بود.

واژگان کلیدی: رویکرد داده‌بنیان، پیشگیری، شناسایی مشتری، تراکنش‌های مشکوک، یادگیری ماشین، شفافیت الگوریتمی.

^۱ . استاد گروه حقوق کیفری و جرم‌شناسی، دانشکده حقوق دانشگاه شهید بهشتی، تهران، ایران.

^۲ . دانشجوی دکتری حقوق کیفری و جرم‌شناسی، دانشکده حقوق دانشگاه شهید بهشتی، تهران، ایران. (نویسنده مسئول). ایمیل:

parhizkary1998@gmail.com.

در سال‌های اخیر، مبارزه با جرایم جهانی، به‌ویژه جرایم اقتصادی، در چارچوب هدف شانزدهم توسعه پایدار سازمان ملل متحد، مصوب ۲۰۱۵ مبنی بر تقویت نهادهای مؤثر در جهت شفافیت، عدالت و صلح اهمیت قابل توجهی یافته است. (حجازی و صلح‌چی، ۱۳۹۹، ص ۹) در این میان، پولشویی به‌عنوان یکی از مهم‌ترین جرایم اقتصادی، سهم عمده‌ای از دغدغه‌های نظام‌های عدالت کیفری را به خود اختصاص داده است. هرچه نظام عدالت کیفری در کشف و پیشگیری از پولشویی مؤثرتر عمل کند، مسیر برای جرایم منشاء دشوارتر شده و به‌تبع آن، از حجم این جرایم کاسته خواهد شد. با این حال این هدف زمانی به‌طور مطلوب محقق می‌شود که نظام عدالت کیفری، اولویت خود را به پیشگیری اختصاص دهد. به‌همین دلیل، امروزه پیشگیری به‌عنوان رکن اساسی در ادبیات علوم جنایی مطرح است و اهمیتی فراتر از مقابله کیفری دارد.

این مسئله به‌ویژه از آن رو حائز اهمیت است که در سال‌های اخیر، پولشویی دگرگونی اساسی یافته و از شیوه‌های سنتی به طرح‌های پیچیده‌ای تکامل پیدا کرده است که از فناوری پیشرفته بهره می‌برند. (کدخدایی و نوروزپور، ۱۳۹۹، ص ۷) ظهور عصر دیجیتال، این فضا را به‌طور قابل توجهی تغییر داده است. با افزایش استفاده از رمزارزهایی مانند بیت کوین، پولشویان مسیر تازه‌ای یافته‌اند که گمنامی و سهولت انجام تراکش‌های فرامرزی را بدون سطح نظارتی مشابه با سیستم‌های بانکی سنتی فراهم می‌کند.

باتوجه به تحول چشم‌انداز پولشویی و گذار از روش‌های سنتی به استفاده پیچیده از فناوری، روش‌های تشخیص این فعالیت‌های غیرقانونی نیز ناگزیر باید پیشرفتی قابل توجه پیدا کنند. در این مرحله، داده نیز ارزشی بنیادین یافته و تمامی فرآیندها برپایه آن سامان می‌یابد. در گذشته، تشخیص جرم عمدتاً بر شناسایی بی‌قاعدگی‌ها در جریان‌های نقدی و تراکنش‌های بانکی سنتی متمرکز بود. اما در سال‌های اخیر چابکی ابزارهای فناورانه در تشخیص ناهنجاری‌ها پیش از وقوع جرم، آن‌ها را به ابزاری غیرقابل جایگزین در عصر مدرن تبدیل کرده است.

در این راستا آموزه‌های جرم‌شناختی و کیفرشناختی، در سایه تحولات مستمر پدیده مجرمانه و دگرگونی فضای بزهکاری، مکاتب بسیاری را به‌خود دیده‌اند. برخی از این مکاتب برای سال‌ها به‌عنوان رویکردهای مسلط در نظام عدالت کیفری مطرح بوده‌اند. از جمله رویکردهای تأثیرگذار در مواجهه با بزهکاران خطرناک و دارای سابقه کیفری، عدالت‌سنجشی یا عدالت آماری^۱ است که ریشه در اندیشه‌های مدیریت ریسک و کنترل جرم دارد. (بک، ۱۳۸۸، ص ۵۳) مبنای اصلی این رویکرد، نه اصلاح فرد بزهکار، بلکه کاهش نرخ کلی جرم از طریق پیش‌بینی و مدیریت آماری خطر است. به بیان دیگر، هرچه احتمال وقوع یا

^۱ . Actuarial Justice

تکرار جرم برای یک فرد یا گروه بالاتر ارزیابی شود، سطح نظارت اجتماعی و مداخلات کیفری اعمال شده سخت تر و گسترده تر خواهد بود. (نجفی ابرندآبادی، ۱۳۸۸، صص ۷۲۲-۷۲۳)

این رویکرد در گذشته عمدتاً ماهیتی واکنشی داشت؛ بدین معنا که شاخص‌های خطرناکی نظیر سابقه ارتکاب مجدد جرم یا تمایل به نقض هنجارها، پس از وقوع جرم و در فرآیند پاسخ‌دهی کیفری برآورد می‌شدند. (نجفی ابرندآبادی و ایارگر، ۱۳۹۹، ص ۹) اما امروزه، این مفهوم معنایی پیش‌دستانه و فعالانه یافته است. امروزه نظام عدالت کیفری در صدد است تا با شناسایی پیش‌دستانه شاخص‌های بزه‌کاری و نشانه‌های مشکوک، وقوع جرم را پیش‌بینی و سپس از آن پیشگیری کند؛ (اسماعیلی، ۱۳۹۶، ص ۳۰۵) امری که به دلیل ماهیت پیشگیرانه و شناسایی ریسک، به احتمالات و آمار وابستگی پیدا کرده است.

بر این اساس، آخرین روزآمدسازی راهنمای گروه ویژه اقدام مالی با عنوان «ارزیابی ملی ریسک پولشویی»^۱ (اوت ۲۰۲۵)، در چارچوب توصیه شماره (۱) پیشین خود، بر ضرورت شناسایی، ارزیابی و اتخاذ اقدامات متناسب با ریسک تأکید می‌کند. در این سند، ارزیابی ریسک، فرآیندی مستمر و پویا تلقی شده که باید متناسب با تغییرات محیطی، اطلاعات جدید و ریسک‌های در حال ظهور، به‌طور مستمر مورد بازنگری قرار گیرد. از این‌رو، بر اتخاذ رویکردی ساختاریافته و منسجم برای دستیابی به درکی به‌روز از ریسک تأکید شده و ارزیابی ملی ریسک به‌عنوان یکی از مهم‌ترین ابزارهای تحقق این هدف معرفی شده است. (FATE, 2025, p.4)

در این راستا یکی از این ابزارهای فناورانه، یادگیری ماشین است که در عرصه اقتصاد از به‌گذر قابلیت‌هایی نظیر، بینش‌های داده‌بنیان^۲، خودکارسازی فرآیندهای تحلیلی و قابلیت مقیاس‌پذیری در رویارویی با حجم عظیم داده (اعم از ساختاریافته و بدون ساختار) امکان پیش‌بینی معاملات مالی و همچنین پیشگیری از تقلب، پولشویی و سایر جرایم مالی را پدید آورده است. (Mallika, Ramasubramanian, 2025. P. 386)

این پیشرفت، اشخاص مشمول^۳ در مبارزه با پولشویی را قادر می‌سازد تا روندهای مالی نظیر سرمایه‌گذاری و نقل و انتقالات مالی را با دقت بیشتری در نظر گیرند، ریسک را کاهش دهند، بی‌نظمی‌ها را شناسایی کرده و در کوتاه‌ترین زمان ممکن به تراکنش‌های مشکوک واکنش نشان دهند. (خیرانی و دیگران، ۱۴۰۱، ص ۳۹) به‌عنوان مثال، سیستم‌های کشف تقلب که برپایه یادگیری ماشین طراحی شده‌اند، با بهره‌گیری از الگوریتم‌های پیشرفته طبقه‌بندی و شبکه‌های عصبی، الگوهای پنهان در

^۱ Money Laundering National Risk Assessment Guidance

^۲ Data-driven insights

^۳ منظور از شخص مشمول هر شخص اعم از حقیقی یا حقوقی است که ملزم به اجرای تدابیر پیشگیرانه معرفی شده توسط گروه ویژه اقدام مالی در برابر پولشویی است. این اشخاص شامل بانک‌ها، موسسات اعتباری، صرافی‌ها، حسابداران و... می‌شود.

تراکنش‌های مشکوک را آشکار می‌سازند.^۱ این قابلیت، افزون بر کاهش چشمگیر زیان‌های مالی، اعتماد عمومی به سیستم‌های بانکداری و پرداخت آنلاین را نیز تقویت می‌کند (Abdulalem. et al. 2022, p.1) لذا شناسایی ظرفیت‌ها و چالش‌های مدل‌های هوشمند موثر در پیش‌گیری از جرم، به‌منظور کاربست آن در نظام عدالت کیفری ضروری می‌نماید.

بر این اساس، پرسش اصلی نوشتار حاضر آن است که رویکرد داده‌بنیان، با بهره‌گیری از ابزارهای مبتنی بر یادگیری ماشین، تا چه اندازه ظرفیت ارتقای فرآیند شناسایی و ارزیابی ریسک پولشویی را داراست و در عین حال، کاربست این فناوری با چه چالش‌ها و ملاحظات حقوقی مواجه است. اهمیت این پرسش از آن جهت است که با وجود گسترش کاربرد ابزارهای مبتنی بر یادگیری ماشین در حوزه مبارزه با پولشویی، ابعاد حقوقی و الزامات حاکم بر کاربست آن‌ها هنوز به‌صورت منسجم مورد تحلیل قرار نگرفته و همچنان نیازمند بررسی است.

بدین‌سان و در راستای پاسخ به این پرسش، مقاله حاضر در سه بخش سامان یافته است. در بخش نخست، مبانی و چارچوب حقوقی رویکرد داده‌بنیان در پرتو تحول نظام پیشگیری از پولشویی مورد تحلیل قرار می‌گیرد. بخش دوم، به بررسی مهم‌ترین ابزارها و کارکردهای فنی این رویکرد در فرآیند شناسایی و ارزیابی ریسک اختصاص دارد و در بخش سوم، چالش‌ها و ملاحظات حقوقی ناشی از به‌کارگیری این فناوری تحلیل می‌شود. همچنین، تلاش خواهد شد رویکرد نظام حقوقی ایران در قبال این تحولات و میزان همگامی آن با رویکردهای نوین مبارزه با پولشویی نیز مورد بررسی قرار گیرد.

پیشینه پژوهش: پولشویی از موضوعاتی است که در ادبیات حقوق کیفری و جرم‌شناسی، از ابعاد مختلف مورد توجه قرار گرفته است. بخش قابل توجهی از پژوهش‌های موجود، به تبیین ابعاد کیفری و جرم‌شناختی پولشویی، تحلیل سیاست‌های جنایی در قبال آن و نیز بررسی تطبیقی مقررات داخلی با کنوانسیون‌ها و اسناد بین‌المللی اختصاص یافته است. با این حال، در سال‌های اخیر، توجه به نقش «ریسک» و «اطلاعات» در طراحی سازوکارهای پیشگیرانه نیز در برخی مطالعات مورد توجه قرار گرفته است.

در این میان، شاملو و خلیلی پاجی (۱۳۹۹) در مقاله «رویکرد ریسک‌مدار سیاست جنایی در برابر پولشویی»، با تمرکز بر ماهیت فراملی پولشویی، رویکرد ریسک‌مدار را در سیاست جنایی مقابله با این جرم مورد بررسی قرار داده‌اند. نویسندگان، ضمن توجه به نقش اسناد و سازوکارهای بین‌المللی در مبارزه با پولشویی، بر اهمیت اطلاعات مالی در مدیریت ریسک تأکید کرده و نقش واحدهای اطلاعات مالی و گروه اگمونت را در ارزیابی ریسک و اتخاذ تدابیر متناسب پیشگیرانه مورد توجه قرار

^۱ . به‌عنوان نمونه نهادهای نظارتی ایالات متحده، از جمله از طریق قانون ضد پولشویی ۲۰۲۰ و راهبردهای مقابله با جرایم مالی، بانک‌ها را به‌پذیرش فناوری‌های پیشرفته از جمله یادگیری ماشین و کاهش موانع نظارتی تشویق کرده‌اند.

داده‌اند. این پژوهش از حیث تبیین مبانی رویکرد ریسک‌مدار و جایگاه اطلاعات مالی در سیاست جنایی مبارزه با پولشویی، برای پژوهش حاضر اهمیت دارد؛ با این حال، تمرکز آن بر ظرفیت‌های فناورانه و تحلیل داده در تحقق این رویکرد نیست.

در منبع دیگری نیز ثالث مؤید و همکاران در کتاب «نکات کاربردی جرم پولشویی»، با رویکردی حقوقی، تطبیقی و کاربردی، مقررات مربوط به جرم پولشویی را به صورت ماده‌به‌ماده بررسی کرده‌اند. این اثر از منظر تبیین چارچوب قانونی حاکم بر مبارزه با پولشویی در ایران، از منابع قابل توجه در تدوین پژوهش حاضر به شمار می‌رود؛ هرچند موضوع بهره‌گیری از داده و فناوری‌های نوین برای شناسایی و ارزیابی ریسک پولشویی در کانون بحث آن قرار ندارد.

در ادبیات بین‌المللی، پیوند میان فناوری‌های نوین و مبارزه با پولشویی، با انتشار گزارش «فرصت‌ها و چالش‌های فناوری‌های نوین برای مبارزه با پولشویی و تأمین مالی تروریسم» از سوی گروه ویژه اقدام مالی (FATF, 2021) با توجه بیشتری مواجه شده است. این گزارش، ضمن اشاره به چالش‌هایی که فناوری‌های نوین از حیث پیچیدگی و سرعت تراکنش‌های مالی ایجاد می‌کنند، ظرفیت همین فناوری‌ها را برای تقویت سازوکارهای مبارزه با پولشویی نیز مورد توجه قرار می‌دهد. اهمیت این گزارش برای پژوهش حاضر از آن جهت است که امکان پیوند میان فناوری‌های نوین و اجرای مؤثرتر رویکرد مبتنی بر ریسک را مطرح می‌سازد.

همچنین، برخی پژوهش‌های تخصصی‌تر نیز به قابلیت تحلیل داده در مبارزه با پولشویی پرداخته‌اند. برای نمونه، Hu و همکاران (۲۰۲۲) در پژوهشی با عنوان «تحلیل کلان‌داده برای مبارزه با پولشویی: مطالعه موردی کاربرد گرین پلوم متن‌باز» ظرفیت تحلیل کلان‌داده در پردازش و تحلیل اطلاعات مرتبط با پولشویی بررسی کرده‌اند. این دسته از مطالعات، از حیث تبیین ظرفیت‌های فنی داده و فناوری‌های نوین برای تحلیل الگوهای مالی و شناسایی فعالیت‌های مشکوک، زمینه مناسبی برای بررسی رویکرد داده‌بنیان فراهم می‌کنند.

همچنین (Vududala, 2024, p. 2) در مقاله با عنوان «ارتقای انطباق با مبارزه با پولشویی با استفاده از نئیس اکتی مایز: رویکردی داده‌محور» با تمرکز بر یک سامانه خاص، ظرفیت رویکرد داده‌بنیان را در ارتقای فرایندهای انطباق و مبارزه با پولشویی بررسی کرده است. این پژوهش نشان می‌دهد که بهره‌گیری از تحلیل داده و سامانه‌های هوشمند می‌تواند با بهبود پایش تراکنش‌ها و شناسایی الگوهای مشکوک، کارآمدی سازوکارهای مبارزه با پولشویی را ارتقا دهد. با این حال، تمرکز اصلی پژوهش مزبور بر کاربست یک سامانه مشخص و ابعاد اجرایی انطباق است و مسئله را از منظر حقوقی و پیشگیرانه به صورت جامع بررسی نمی‌کند.

مرور این مطالعات نشان می‌دهد که اگرچه هر یک از پژوهش‌های پیشین بخشی از مسئله، از مبانی رویکرد ریسک‌مدار و الزامات حقوقی مبارزه با پولشویی تا ظرفیت‌های فناوری و تحلیل کلان‌داده، را مورد توجه قرار داده‌اند، میان این حوزه‌ها همچنان فاصله‌ای قابل مشاهده وجود دارد. به بیان دیگر، در پژوهش‌های مورد بررسی، کمتر تلاش شده است تا رویکرد

داده‌بنیان به‌عنوان حلقه اتصال میان شناسایی و ارزیابی ریسک از یک سو و پیشگیری از پولشویی از سوی دیگر، در یک چارچوب واحد مورد تحلیل قرار گیرد و هم‌زمان الزامات حقوقی و ابزارهای فنی تحقق آن نیز بررسی شود. از این رو، وجه تمایز پژوهش حاضر، صرفاً معرفی فناوری‌های نوین در مبارزه با پولشویی نیست؛ بلکه تلاش می‌شود با تمرکز بر کاربریست رویکرد داده‌بنیان، ابتدا جایگاه آن در تحول سازوکارهای پیشگیرانه و شناسایی و ارزیابی ریسک تبیین شود، سپس ابزارهای فنی، به‌ویژه گونه‌های یادگیری ماشین، مورد بررسی قرار گیرد و در نهایت، چالش‌های حقوقی و اجرایی ناشی از این تحول تحلیل شود. افزون بر این، با توجه به ضرورت سنجش امکان تحقق این رویکرد در نظام حقوقی ایران، مقررات داخلی و زیرساخت‌های موجود نیز مورد توجه قرار گرفته است تا تصویری منسجم‌تر از ظرفیت‌ها و محدودیت‌های کاربریست رویکرد داده‌بنیان در پیشگیری از پولشویی ارائه شود.

۱. مبانی نظری و الزامات کاربریست رویکرده داده بنیان در پیشگیری از پولشویی

اولین نسل از سامانه‌های مبارزه با پولشویی بر مبنای رویکرد قاعده‌محور^۱ استوار بود. در این رویکرد، فرایند نظارت بر تراکنش‌های مالی، رفتار مشتریان و سایر کنش‌های مالی بر اساس قوانین و آستانه‌های ازپیش تعیین‌شده هدایت می‌شد؛ به گونه‌ای که هرگونه تراکنش یا رفتاری که فراتر از این آستانه‌ها قرار می‌گرفت، به‌طور خودکار به‌عنوان مورد مشکوک به پولشویی یا جرایم مالی نشانه‌گذاری می‌گردید. (Ai, 2012, p. 200)

به‌عبارتی، این رویکرد فاقد هرگونه توانایی برای تمایز قائل شدن میان زمینه‌ها و بافت‌های متفاوت رفتاری یا تراکنشی است. برای نمونه، اگر قاعده‌ای مقرر دارد که «هر تراکنش نقدی بالای ۱۰۰۰۰ دلار باید گزارش شود»، سیستم بدون در نظر گرفتن نحوه فعالیت قانونی مشتری، سابقه شغلی او، الگوی مالی متعارف و یا هرگونه توجیه اقتصادی روشن، صرفاً براساس عبور از آستانه عددی، هشدار تولید می‌کند.^۲

^۱ Rule Based Approach.

^۲ این انعطاف‌ناپذیری افزون بر آنکه موجب قضاوت یکسان در موقعیت‌های ناهمسان می‌شود، این آسیب را نیز به‌همراه دارد که پولشویان با شناسایی دقیق همان قوانین، از خلاء قانونی سوء استفاده کنند. (مانند اسمورفینگ؛ به معنای شکستن مبلغ تراکنش به واحدهای کوچک‌تر زیر آستانه گزارش‌دهی). همچنین چالش دیگر، نرخ بالای هشدارهای مثبت کاذب^۲ در این رویکرد است. از آنجا که قوانین در این رویکرد عمدتاً بر پایه آستانه‌های عددی تعریف می‌شوند، شمار قابل توجهی از تراکنش‌های کاملاً قانونی که صرفاً با یکی از آن آستانه‌ها یا الگوها مطابقت ظاهری پیدا می‌کنند، به‌عنوان مشکوک علامت‌گذاری می‌شوند. در این وضعیت، حجم انبوه هشدارهای بی‌نتیجه، ظرفیت پردازشی محدود تیم‌های تطبیق را مختل می‌کند؛ امری که منجر به هدررفت منابع محدود پردازشی و ناکارآمدی در شناسایی تهدیدهای اصلی می‌شود. (Omoseebi, et.al. 2025, p.17)

با توجه به چالش‌های موجود و عدم کارآمدی لازم، رویکرد قاعده‌محور کنار گذاشته شد و به جای آن در سال ۲۰۰۳، رویکرد ریسک‌مدار^۱ متعاقب اصلاحات توصیه‌های گروه ویژه اقدام مالی^۲ در توصیه شماره یک، معرفی شد و به مرور زمان ارتقاء یافت. (Koker, 2009, p.335) اتخاذ رویکرد ریسک‌مدار در برابر پولشویی از مزیت‌هایی برخوردار است. مهم‌ترین مزیت این رویکرد، استفاده کاراتر از منابع و عملکرد مؤثرتر است. بر این اساس، از یک سو، حوزه‌های پولی و مالی و مشتریان پرریسک مورد نظارت بیشتر قرار می‌گیرند و از سوی دیگر هزینه کمتری صرف مشتریان کم ریسک می‌شود. مزیت دیگر این رویکرد، انعطاف‌پذیری و پویایی آن است. از آنجاکه ریسک حوزه‌های پولی و مالی ایستا نیست و با سرعت، روزآمد می‌شود، اتخاذ این رویکرد و سامانه پایش آن، با سرعتی بیشتر قادر به شناسایی ریسک‌های نوین خواهد بود. (شاملو؛ خلیلی پاجی، ۱۳۹۹، ص ۱۳۴) با این حال این تحول، صرفاً به دگرگونی شیوه‌های مبارزه با پولشویی محدود نمانده، بلکه در سطحی کلان‌تر، بر مبانی مداخله نظام عدالت کیفری نیز اثرگذار بوده است. در پرتو رویکرد مبتنی بر ارزیابی ریسک، حقوق کیفری به تدریج از الگوی صرفاً واکنشی فاصله گرفته و به سوی رویکردی احتمال‌محور حرکت کرده است. در این چارچوب، هدف اصلی دیگر صرفاً واکنش به جرم تحقق یافته نیست، بلکه شناسایی موقعیت‌های پرخطر و مداخله پیش از تحقق کامل رفتار مجرمانه نیز اهمیت می‌یابد.

با این حال با پیچیده‌تر شدن روش‌های ارتکاب جرم و به ویژه پولشویی، اتکای صرف به روش‌های سنتی ناکارآمد خواهد بود. رویکرد ریسک‌مدار اگرچه تحولات مثبتی ایجاد کرد و به کارآمدی فرآیند شناسایی مرتکبان انجامید، اما به دلیل ماهیت پنهان جرم پولشویی، که همواره در اشکالی نوظهور بروز می‌یابد و بخشی از داده‌های مرتبط با آن هیچ‌گاه کشف نمی‌شود، با کاستی‌هایی مواجه است. در واقع اعتبار و کارآمدی این رویکرد، وابستگی مستقیمی به کیفیت داده‌های مورد استفاده و دقت ابزارهای تحلیل آن‌ها دارد. (Massimiliano, 2025, p.2) در نتیجه، هر اندازه امکان گردآوری، پردازش و تحلیل داده‌های مرتبط با ریسک پولشویی افزایش یابد، زمینه برای اتخاذ تصمیم‌های پیشگیرانه دقیق‌تر نیز فراهم خواهد شد.

از سوی دیگر، اساس رویکرد ریسک‌مدار بر پایه ره‌نگاشت‌های گروه‌ویژه شکل می‌گیرد که در آن، به عنوان نمونه ملاحظات سیاسی به ویژه در فرآیند تدوین فهرست سیاه، اثرگذار است. (Riccardi, 2022, p.1) بدین سان ممکن است کشوری نه به دلیل ریسک واقعی پولشویی، بلکه به دلایل سیاسی در این فهرست قرار گیرد. بنابراین، با وجود ارزیابی کلی مثبت رویکرد ریسک‌مدار، تا زمانی که این رویکرد با رویکرد داده‌محور^۳ که توانایی درک الگوهای مجرمانه برای پیشگیری از جرم از طریق تحلیل طیف گسترده‌ای از داده را داراست، تلفیق نشود، نمی‌توان بر کارآمدی آن به طور کامل تکیه کرد.

درواقع ظهور تحلیل داده‌های بزرگ^۴ سرآغاز دوران تازه‌ای در نظام مبارزه با پولشویی با رویکرد مبتنی بر داده است. (Hu, et.al. 2022, p.637) این رویکرد از قدرت الگوریتم‌های پیچیده برای غربالگری مجموعه داده‌های بزرگ بهره می‌گیرد تا الگوها،

1. Risk Based Approach

2. FATF

3. Data Based Approach

4. Big Data Analytics

همبستگی‌ها و ناهنجاری‌هایی را که می‌توانند نشانه‌هایی از فعالیت مشکوک باشند، جستجو کند. (موسوی فر، نجفی، ۱۴۰۴، ص ۱۸۰) برخلاف رویکردهای پیشین که صرفاً به قوانین ایستای متکی بودند، این رویکرد با ابزارهای خود قادر است تا روابط پنهان و غیرخطی میان تراکنش‌ها را آشکار سازد. در این راستا ادغام یادگیری ماشین و هوش مصنوعی جدیدترین مرز در توسعه سامانه‌های ضد پولشویی را نمایان ساخت و قابلیت‌های بی‌سابقه‌ای در تحلیل داده ارائه نمود. این سیستم‌های هوشمند با یادگیری از داده‌های تاریخی، الگوهای نوظهور پولشویی را شناسایی کرده و رویکردی فعالانه در برابر جرم اتخاذ می‌کنند. بدین ترتیب نظام عدالت کیفری بیش از گذشته بر ریل پیش‌بینی حرکت خواهد کرد. در واقع این گونه از عدالت با اتکاء بر تجزیه و تحلیل حجم عظیم داده بر پایه محاسبه احتمالات (ابراهیمی، ۱۴۰۱، ص ۳۶) تا حد امکان به کشف جرایم خواهد انجامید. لذا پیشگیری با تعریفی عام تر قابل طرح است: انجام اقداماتی مبتنی بر پیش‌بینی، شناسایی و ارزیابی علمی خطر یا امکان وقوع جرم برای جلوگیری از وقوع یا کاهش یا به تعویق انداختن یا حتی تعدیل آثار، تغییر آماج، زمان، مکان یا شیوه ارتکاب جرم. (ابوذری؛ ۱۴۰۳، ص ۴۲)

بر این اساس، دو رکن بنیادین نظام پیشگیری از پولشویی، یعنی شناسایی مشتری (مطابق با توصیه‌نامه شماره ۱۰) و «شناسایی و گزارش تراکنش‌های مشکوک» (مطابق با توصیه‌نامه شماره ۲۰) گروه ویژه اقدام مالی^۱، در چارچوب رویکرد داده‌محور مورد واکاوی قرار خواهد گرفت.

۱.۱. شناسایی مشتری داده‌بنیان

از نخستین و اساسی‌ترین ارکان توصیه‌شده توسط گروه ویژه، شناسایی مشتری است. به عبارتی احراز هویت دقیق مشتری و ایجاد یک شناسه ریسک متناسب با فعالیت مشتری، در پیشگیری از پولشویی نقش موثری دارد. بند ۳۳ ماده ۱ آیین‌نامه اجرایی مقابله و پیشگیری از جرایم پولشویی و تأمین مالی تروریسم مصوب ۱۳۹۸/۰۷/۲۱ هیات وزیران نیز شناسایی مشتری را به عنوان یکی از مهم‌ترین ارکان پیشگیری از جرم به شمار آورده و آن را متناسب با سطح ریسک ارباب رجوع که مستمراً می‌بایست مورد ارزیابی قرار گیرد به سه سطح ساده، معمول و مضاعف تقسیم نموده است. این تقسیم‌بندی و لزوم پایش مستمر ریسک مشتری نشان می‌دهد که اطلاعات و داده در شناسایی ریسک مشتری اهمیتی بنیادین دارد.

این الزام، امروزه و در بطن رویکرد داده‌بنیان، با کیفیتی به مراتب دقیق‌تر از گذشته، انجام می‌پذیرد. در این راستا بهره‌گیری از انواع داده اعم از کلان داده^۲ و داده جایگزین^۳ اهمیت انکارناپذیری در پروفایل سازی ریسک مشتریان و دسته‌بندی ایشان خواهد

^۱ . FATF (2012-2018), International Standards on Combating Money Laundering and the Financing of Terrorism & Proliferation, FATF, Paris, Franc.

^۲ . Big Data

به مجموعه‌ای از داده‌های ساختاریافته، نیمه ساختار یافته یا بدون ساختار اطلاق می‌شود که برای ذخیره سازی، پردازش و تحلیل به فناوری‌ها و رویکردهای خاصی نیاز دارد و در مقایسه با داده‌های سنتی، از چهار ویژگی حجم، سرعت، تنوع و دقت برخوردار است.

^۳ . Alternative Data

داشت. در واقع امروزه صنعت مالی به طور ذاتی، حجم عظیمی از داده‌ها را تولید می‌کند که شامل داده‌های مصرف‌کننده، گزارش‌های محصولات مالی و جزئیات تراکنش‌ها می‌شود. در سطح اجرایی، لایه جذب داده^۱ داده‌های تراکنش مالی را از منابع متعددی از جمله سیستم‌های بانکی، درگاه‌های پرداخت، شبکه‌های بلاک چین و تأمین‌کنندگان داده‌های مالی شخص ثالث جمع‌آوری و یکپارچه می‌سازد. این لایه به طور همزمان شامل داده‌های ساختاریافته (مانند اطلاعات تراکنش) و داده‌های بدون ساختار (مانند ایمیل‌ها و تعاملات مشتری) می‌شود. (Husnaningtyas, et.al. 2023, p.100)

این داده‌ها در صورت ترکیب با منابع اطلاعاتی مکمل نظیر داده‌های شبکه‌های اجتماعی (مانند فیسبوک) و آدرس‌های وب؛ که از آن به عنوان داده جایگزین نیز یاد می‌شود می‌توانند با فراهم آوردن امکان درک عمیق‌تر از ترجیحات خرید و نیز شناسایی نوع رفتارهای مالی هر مشتری، این قابلیت را به اشخاص مشمول بدهند که رفتارهای نامنظم و مشکوک را براساس پروفایل شخصی سازی شده هر مشتری شناسایی کنند. سیستم‌های مبتنی بر کلان داده با بهره‌گیری از هوش مصنوعی، به صورت بلادرنگ علائم تقلب را بررسی کرده، کاربران یا تراکنش‌های غیرمجاز را پیش‌بینی و هشدارهای احتیاطی صادر می‌کنند.

شناسایی دقیق مشتری برپایه داده‌های کلان و جایگزین از آن رو حائز اهمیت است که از منظر علت شناس جنایی نیز، بسیاری از جرایم اقتصادی، به دلیل خلاء اطلاعاتی ناشی از شناسایی دقیق مشتری رخ می‌دهند. این امر به ویژه درخصوص موسسات مالی چندلایه و فرامرزی که شناسایی دقیق ذی‌نفع اصلی دشوار است، پیچیده‌تر می‌شود.

به عنوان نمونه اصل شفافیت در شناسایی ذی‌نفع^۲ نقش اساسی در پیشگیری، کشف و تعقیب جرایم مرتبط با پولشویی و تأمین مالی تروریسم دارد. ذی‌نفع نهایی به شخص حقیقی اطلاق می‌شود که مالکیت اصلی وجوه یا سهام یک شرکت را در اختیار دارد. با این حال، در موارد متعددی هویت این شخص در اختیار نهادهای قانونی برای پایش اطلاعات قرار نمی‌گیرد و او فاقد هرگونه اختیار ظاهری در اداره شرکت است. چنین وضعیتی موجب می‌شود که هویت مالک واقعی، به رغم اعمال کنترل مؤثر بر دارایی‌ها، در ساختار رسمی شرکت مخفی بماند. در این شرایط، داده‌های کلان و جایگزین می‌توانند به عنوان ابزاری کارآمد، شکاف اطلاعاتی یادشده را پر کنند.

یکی از اصلی‌ترین داده‌های قابل دسترسی در این زمینه، داده‌های مالکیت مؤثر است. در این راستا گروه ویژه اولین استانداردهای بین‌المللی درخصوص شفافیت مالکیت ذی‌نفع را در سال ۲۰۰۳ منتشر نمود که مطابق با آن کلیه اشخاص مشمول ملزم به شناسایی و تأیید اطلاعات درباره مالکیت نهایی اشخاص حقوقی شدند. (FATF, 2003, pp.11-12). در این میان کلان داده

به مجموعه داده‌های غیرسنتی و غیرمالی اطلاق می‌شود که از منابعی مانند شبکه‌های اجتماعی، آدرس‌های وب، صورتحساب‌های تلفن همراه یا داده‌های مکان‌محور گردآوری می‌شوند و یکی از کاربردهای آن تکمیل پروفایل ریسک مشتری است.

^۱. Data Ingestion Layer

^۲. Beneficial ownership transparency

و داده‌های گزین بادرستری به داده‌های تلفن همراه، داده‌های موقعیت جغرافیایی، شاخص‌های تحرک^۱ مبتنی بر حسگرهای تلفن هوشمند؛ داده‌های شعاع چرخش^۲ و آنتن‌هایی که تلفن همراه بیشترین اتصال را با آنها داشت؛ تا حد زیادی می‌توانند نسبت به هویت کاربر مشکوک و شاخص‌های ارتباطی او اطلاع پیدا کرده و تدابیر کنشی را در برابر او اتخاذ کنند.^۳

۱/۲. بازشناسی تراکنش‌های مشکوک از رهگذر داده‌های رفتاری

یکی دیگر از ارکان اساسی در پایش نظام اقتصادی و پیشگیری از وقوع جرم، که توصیه‌های گروه ویژه اقدام مالی نیز بر آن تاکید نموده‌اند، ردیابی تراکنش‌های مشکوک و گزارش به موقع آنها^۴ به نهادهای ناظر همچون مرکز اطلاعات مالی^۵ است. در واقع، گزارش به هنگام عملیات مشکوک در بازه‌های معقول، نقشی تعیین کننده در رهگیری به موقع عواید مجرمانه، کشف جرایم، تعقیب و مجازات مجرمان حرفه‌ای ایفا می‌کند. ماده ۱۳۵ آیین‌نامه اجرایی مقابله و پیشگیری از جرایم پولشویی و تأمین مالی تروریسم نیز در همین راستا، اشخاص مشمول را مکلف کرده است که هرگاه پس از بررسی اولیه، ظن به وقوع پولشویی، تأمین مالی تروریسم یا سایر جرایم منشأ حاصل شود، بدون اطلاع ارباب رجوع و مطابق سازوکار اعلامی مرکز اطلاعات مالی، مراتب را گزارش کنند. بدین ترتیب، تشکیل ظن معقول به وقوع جرم، یکی از مهم‌ترین مبانی آغاز فرآیند گزارش دهی در نظام حقوقی ایران به شمار می‌رود. با این حال، پرسش اساسی آن است که این ظن بر چه مبنایی شکل می‌گیرد و چه معیارهایی می‌تواند آن را از یک حدس یا گمان صرف متمایز سازد؟

در ادبیات مبارزه با پولشویی و همچنین در ضوابط حاکم بر نظام حقوقی ایران، شکل‌گیری ظن معمولاً بر پایه مجموعه‌ای از شاخص‌های خطر صورت می‌گیرد.^۶ برای نمونه، معاملاتی که از حیث مبلغ یا ساختار، غیر متعارف باشند، فاقد هدف اقتصادی یا مشروعیت ظاهری به نظر برسند، یا با الگوی شناخته شده فعالیت، وضعیت مالی و نیمرخ مشتری سازگار نباشند، می‌توانند از

^۱. mobility

^۲. radius of gyration

^۳. یکی از بزرگترین پرونده‌های کلاهبرداری مالی در جنوب شرق آسیا، مربوط به ترونگ می‌لان، رئیس گروه وان‌تین فات است. او با استفاده از بیش از ۷۰ سهامدار صوری، بدون آنکه نامش در هیچ سند رسمی مالکیتی قید شود، توانست کنترل پنهانی بر بانک سایگون کامرشال بانک (SCB) که بزرگترین بانک ویتنام از نظر دارایی است، به دست گیرد. طی یک دهه، بیش از ۱۲ میلیارد پوند وام کلاهبرداری شده از طریق ساختارهای پیچیده مالکیت هدایت شد و از شرکت‌های پسته، مدیران اسمی و هلدینگ‌های فراساحلی برای پنهان کردن کنترل واقعی استفاده گردید. در واقع اتکای صرف به آستانه‌های درصدی مالکیت (مانند ۲۵ درصد) کافی نیست، زیرا این آستانه‌ها از طریق خردسازی سهام، سهامداران اسمی و شرکت‌های پسته قابل دور زدن هستند. شناسایی مؤثر مالک نهایی مستلزم بررسی مالکیت یکپارچه، روابط غیرمستقیم و ساختارهای حاکمیتی است. همچنین کنترل واقعی ممکن است بدون هیچ گونه مالکیت قانونی و از طریق روابط تاریخی یا غیررسمی با مدیران یا سهامداران اعمال شود. در چنین بافتاری، داده‌های جایگزین نظیر داده‌های ثبت شرکتی فرامرزی و الگوهای شبکه‌ای روابط مدیریتی، می‌توانند لایه‌های پنهان مالکیت مؤثر را که در ساختارهای صوری نامرئی باقی مانده‌اند آشکار سازند.

AsiaVerify. (2025). Discover how hidden UBO links can derail deals and how to spot them with registry-backed data. <https://asiaverify.com/resources/insights/the-hidden-ubo-web-uncover-business-ownership-risk/>

^۴. Suspicious Transaction Report (STR)

^۵. Financial Intelligence Units (FIUs)

^۶. تبصره ماده ۷ قانون مبارزه با پولشویی اصلاحی ۱۳۹۷.

جمله نشانه‌های ایجاد ظن به وقوع پولشویی تلقی شوند. با وجود این، اتکای صرف به چنین شاخص‌هایی، به‌ویژه هنگامی که ارزیابی آن‌ها بر قضاوت انسانی یا قواعد از پیش تعیین‌شده استوار باشد، همواره از دقت و جامعیت کافی برخوردار نیست. پیچیده‌تر شدن الگوهای پولشویی و استفاده از شیوه‌های نوین پنهان‌سازی عواید مجرمانه، موجب شده است که بسیاری از معاملات مشکوک از فرآیند شناسایی خارج بمانند یا در مقابل، تعداد قابل توجهی هشدار کاذب تولید شود.

به همین دلیل امروزه تلاش می‌شود تا شناسایی داده‌های مبهم و مشکوک به صورت تحلیل هوشمند بر روی تراکنش‌های در حال اجرا با بهره‌گیری از یادگیری ماشین انجام شود.^۱ در گذشته، به دلیل محدودیت در ابزارها و حجم داده، تنها چند مؤلفه محدود در الگوگذاری معاملات مشکوک استفاده می‌شد، حال آنکه امروزه به دلیل وجود حجم وسیعی از کلان‌داده و داده‌های جایگزین، همزمان تمامی مؤلفه‌ها در سنجه ارزیابی قرار گرفته و متعاقباً تصویر واقع‌بینانه‌تری از تراکنش‌های مشکوک به دست می‌آید.

آمارها نیز حاکی از آن است که به کارگیری روش‌های مبتنی بر هوش مصنوعی در کشف جرم، منجر به افزایش دقت تشخیص و کاهش هشدارهای اشتباه می‌شود، به گونه‌ای که ابزارهای هوش مصنوعی حدود ۳۰ تا ۵۰ درصد تراکنش‌های مشکوک بیشتری را نسبت به مدل‌های سنتی تشخیص می‌دهند که از گذر آن، صدور هشدارهای اشتباه در خصوص تشخیص تراکنش به عنوان مشکوک/غیرمشکوک (منفی و مثبت کاذب) تا حدود ۶۰ درصد کاهش یافته است. (Vududala, 2024, p.3)

ازجمله مؤلفه‌های کلیدی در کارآمدی رویکرد داده‌محور و پیش‌بینی الگوریتم‌های مشکوک توسط یادگیری ماشین، همانا بهره‌گیری از منابع داده‌ای غنی و روزآمد است. در این راستا کیفیت، تنوع و کامل بودن داده‌ها به طور قابل توجهی بر دقت و پایایی سیستم تأثیر می‌گذارد. از مهم‌ترین اطلاعات استخراج‌شده از مجموعه داده‌ها می‌توان به این موارد اشاره نمود: (Mukhamadiyev, et.al.2025: pp. 3,4.)

الف) شناسه‌یکتای تراکنش: برپایه اصول «قابلیت ردیابی و «حفظ مسیر حسابرسی» که همواره از مهم‌ترین مؤلفه‌های پیشگیری از پولشویی بوده‌اند، هر تراکنش مالی باید به شناسه‌ای یکتا و تغییرناپذیر مجهز باشد تا در صورت وقوع تخلف، امکان ارجاع دقیق به آن رخداد برای مراجع قضایی میسر گردد.

^۱ . بیش از ۸۰٪ از مدیران ضدپولشویی بانک‌های بزرگ آمریکای شمالی در حال پیاده‌سازی یادگیری ماشین هستند. این رویکرد در مؤسسات پیشرو، کشف تراکنش‌های مشکوک را ۴۰٪ و کارایی را تا ۳۰٪ افزایش داده است.

ب) شناسه کاربر:^۱ این ویژگی نه فقط برای ردیابی الگوهای فردی، بلکه برای کشف تغییر ناگهانی رفتار کاربر حیاتی است؛ چرا که اگر تراکنشی از الگوی همیشگی یک کاربر منحرف شود، یکی از قوی‌ترین نشانه‌های هشدار است.

پ) شناسه کارمند:^۲ ردیابی ویژگی‌های منحصربه‌فرد هر کارمند امکان شناسایی «همدستی درونی» یا «سوءاستفاده از دسترسی» را فراهم می‌کند؛ عاملی که بسیاری از سیستم‌های متعارف از آن غافل می‌مانند.

ت) مبلغ تراکنش:^۳ اهمیت این مولفه هنگامی آشکار می‌شود که به‌نسبت با میانگین مبلغ تراکنش‌های پیشین همان کاربر یا انحراف معیار مقادیر در یک بازه‌زمانی کوتاه سنجیده شود. جهش ناگهانی در مبلغ، یکی از نشانه‌های هشدار را در الگوریتم‌های تشخیص ناهنجاری به‌خود اختصاص می‌دهد.

ث) زمان تراکنش:^۴ تحلیل الگوهای زمانی محدود به ساعتی از شبانه‌روز نیست؛ بلکه با استخراج ویژگی‌های مشتق شده مانند فاصله‌زمانی از آخرین تراکنش، تعداد تراکنش‌ها در دقیقه آخر یا تفاوت زمانی تراکنش با الگوی خواب و بیداری کاربر؛ می‌تواند نشانگر تلاش غیرمجاز یا سوءاستفاده از اطلاعات کاربر در جهت مقاصد نامشروع باشد.

ج) روش پرداخت:^۵ ارزش اصلی این ویژگی نه در ریسک ثابت هر روش پرداخت، بلکه در تغییر غیرمنتظره روش پرداخت توسط یک کاربر خاص نهفته است. درواقع، مدل یادگیری ماشین باید برای هر کاربر، روش‌های پرداخت او را به‌عنوان الگوی مبنا در نظر بگیرد. هر انحراف معنادار از این الگو، (مثلاً کاربری که همیشه از کارت نقدی استفاده می‌کرده، ناگهان از حواله بانکی استفاده کند)، نسبت به حالتی که کاربری همیشه از یک روش پرداخت استفاده می‌کند، هشدار قوی‌تری ایجاد می‌کند.

چ) موقعیت مکانی:^۶ اهمیت این ویژگی در تشخیص ناسازگاری مکانی-زمانی نهفته است. یک موقعیت جغرافیایی به‌تنهایی نشانه هشدار نیست، مگر آنکه با ویژگی‌های زمان تراکنش ترکیب شود. معیار تشخیصی عدم امکان فیزیکی جابه‌جایی میان دو موقعیت در بازه زمانی ثبت شده میان دو تراکنش متوالی است. افزون بر این، عدم تطابق موقعیت تراکنش با آدرس صورت حساب یا محدوده جغرافیایی غالب فعالیت کاربر، به عنوان یک شاخص مستقل، احتمال ارتکاب جرم را افزایش می‌دهد.

¹ . user- Id

² . Merchant-Id

³ . transaction amount

⁴ . timestamps

⁵ . payment method

⁶ . Location

ح) **نشانی پروتکل اینترنت (آی پی):**^۱ بررسی تعلق آی پی به شبکه‌های پنهان‌ساز نظیر Tor^۲، (خلیلی پاچی، ۱۴۰۱، ص ۱۰۸) پروکسی‌های عمومی و وی‌پی‌ان‌های تجاری رایگان حائز اهمیت است؛ چه آنکه حضور در چنین شبکه‌هایی در تراکنش‌های عادی نادر می‌نماید، اما در فعالیت‌های مشکوکی همچون پولشویی یا کلاهبرداری بسامدی قابل توجه دارد.

در صورتی که هر یک از موقعیت‌های یادشده در داده‌های موجود در سامانه‌های پرداخت رخ دهند، اقدامات قانونی به صورت مرحله‌ای انجام خواهد پذیرفت. این اقدامات در مرحله نخست شامل انسداد حساب‌ها و توقیف وجوه یا دارایی‌های شخص به علت ریسک بالا است و در مراحل بعدی ممکن است با آغاز اقدامات قضایی ادامه یابد. (شاملو، خلیلی پاچی، ۱۳۹۹، ص ۱۳۳) ویژگی‌های فوق، در صورت بررسی توانان نشانه‌های دقیقی فراهم می‌آورند که می‌توان با تکیه بر آن‌ها تراکنش‌های مشکوک را شناسایی کرد

در این راستا، سامانه‌های یادگیری ماشین وجود چندین نوع ویژگی را به عنوان الگوهای مشکوک و جرم‌زا شناسایی کرده‌اند. این الگوها که غالباً مبتنی بر سابقه پرونده‌های پیشین استخراج شده‌اند، نشانه‌هایی از تقلب و خروج از چارچوب قانونی را ارائه می‌دهند و بدین ترتیب، بازشناسی تراکنش‌های مشکوک را از فعالیت‌های مالی قانونی تسهیل می‌کنند. (Mukhamadiyev, et.al, 2025, p.3) از جمله این ویژگی‌ها می‌توان به تراکنش‌های به‌طور غیرعادی بزرگ اشاره کرد؛ تراکنش‌هایی که به مراتب بزرگ‌تر از الگوی معمول هزینه کرد مشتری هستند. همچنین مجموعه‌ای از تراکنش‌های کوچک که در بازه زمانی کوتاهی انجام می‌شوند نیز می‌توانند مشکوک تلقی شوند، به‌ویژه آن دسته که ممکن است از استانداردهای پنهان برای دور زدن آستانه‌های تراکنش^۳ استفاده کنند. از دیگر نشانه‌های مهم، ناهنجاری‌های جغرافیایی است، تراکنش‌هایی که از مناطقی سرچشمه می‌گیرند که مشتری پیش از این هرگز در آنها فعالیت تجاری نداشته است. همچنین تراکنش‌هایی که با کشورهای شناخته‌شده در زمینه تقلب یا پول‌شویی در ارتباط باشند^۴، در زمره تراکنش‌های پرخطر طبقه‌بندی می‌شوند. زمان‌بندی غیرعادی نیز یکی دیگر از شاخص‌های هشداردهنده است؛ برای نمونه، تراکنش‌هایی که در ساعات یا روزهای غیرمعمول برای مشتری انجام می‌شوند،

^۱ . Ip_Address

^۲ . Tor در اصل یک شبکه توزیع رایانه‌ای است که آدرس IP واقعی کاربر را پنهان می‌کند و به همین علت هویت کاربران شبکه را با مسیریابی ارتباطات/معاملات از طریق چندین رایانه در سراسر جهان از شناسایی مصون می‌سازد و آن‌ها در چندین لایه رمزگذاری شده قرار می‌دهد.

^۳ . آستانه‌های تراکنش به مقادیر از پیش تعیین‌شده‌ای اطلاق می‌شوند که فراتر از آن‌ها، یک تراکنش به‌طور خودکار جهت بررسی بیشتر مورد جداسازی قرار می‌گیرد.

^۴ . گروه ویژه اقدام مالی در تفسیر توصیه شماره (۱۰)، برخی حوزه‌های قضایی را به‌عنوان عوامل مؤثر در ارزیابی ریسک مورد توجه قرار داده است. این موارد عبارت‌اند از: الف) کشورهایی که دارای کاستی‌های راهبردی در نظام مبارزه با پولشویی و تأمین مالی تروریسم هستند؛ ب) کشورهایی که مشمول تحریم‌ها، محدودیت‌ها یا سایر اقدامات مشابه، از جمله تحریم‌های شورای امنیت سازمان ملل متحد، قرار گرفته‌اند؛ پ) کشورهایی که به دلیل شیوع فساد یا فعالیت‌های مجرمانه، در معرض ریسک بالاتری قرار دارند؛ و ت) کشورها یا مناطق جغرافیایی که به‌عنوان تأمین‌کننده یا حامی فعالیت‌های تروریستی شناخته می‌شوند یا سازمان‌های تروریستی مشمول تحریم در قلمرو آن‌ها فعالیت دارند.

به‌طور بالقوه مشکوک‌اند. در نهایت، تراکنش‌هایی با ویژگی‌های غیرعادی نظیر انتقال وجه بین چندین حساب بدون دلیل آشکار، همواره یکی از کلاسیک‌ترین الگوهای مشکوک به‌شمار می‌روند.

۲. ابزارهای فنی کاربردی رویکرد داده‌بنیان

در این راستا، برخی از الگوریتم‌های پیشرفته در این حوزه توانایی بالایی در پیش‌بینی دقیق و پیشگیری مؤثر از جرایم اقتصادی دارند. به‌طور کلی، الگوریتم‌های یادگیری ماشین بر اساس ماهیت داده‌های ورودی و روش یادگیری، به دو دسته اصلی تقسیم می‌شوند. (Alloghani, et.al. 2020, p.4) در این قسمت ضمن بررسی فرصت‌ها و چالش‌های این دو شاخه اصلی به تحلیل زیرشاخه‌های هریک از رویکردها نیز پرداخته خواهد شد.

در سال‌های اخیر، این رویکرد در نظام مبارزه با پولشویی ایران نیز تا حدودی مورد توجه قرار گرفته است. از جمله، مرکز اطلاعات مالی با راه‌اندازی سامانه جامع و هوشمند مبارزه با پولشویی (سامان) و سامانه برخط استعلامات (سبا)، گام‌هایی در جهت بهره‌گیری از ابزارهای داده‌بنیان برداشته است. (<https://www.fiu.gov.ir/sa2ma1>) سامانه «سامان» با اتصال برخط به پایگاه‌های اطلاعاتی دستگاه‌های مختلف، امکان تجمیع و پردازش یکپارچه داده‌های مالی، ارزیابی و امتیازدهی گزارش‌های معاملات مشکوک بر مبنای رویکرد مبتنی بر ریسک و ارائه تحلیل‌های هوشمند برای تصمیم‌گیری کارشناسان مرکز اطلاعات مالی را فراهم می‌آورد. همچنین، این سامانه با بهره‌گیری از فناوری‌های هوش مصنوعی و یادگیری ماشین، درصدد افزایش دقت تحلیل داده‌ها و کاهش زمان رسیدگی به گزارش‌های دریافتی است. در کنار آن، سامانه «سبا» نیز با فراهم ساختن دسترسی برخط به پایگاه‌های اطلاعاتی دستگاه‌های اجرایی و قضایی، امکان تکمیل و تقویت تحلیل گزارش‌های معاملات مشکوک را فراهم کرده است. هرچند ارزیابی میزان کارآمدی این سامانه‌ها مستلزم انتشار داده‌ها و گزارش‌های عملکردی است، راه‌اندازی آن‌ها را می‌توان نشانه‌ای از حرکت نظام مبارزه با پولشویی ایران به سوی بهره‌گیری از رویکردهای داده‌بنیان و ابزارهای هوشمند در شناسایی و ارزیابی ریسک دانست.

۲/۱. یادگیری نظارت‌شده

یادگیری نظارت‌شده یکی از متداول‌ترین رویکردها در سیستم‌های مبتنی بر یادگیری ماشین برای انطباق با مقررات ضد پولشویی به‌شمار می‌رود. در این رویکرد، الگوریتم با استفاده از یک مجموعه داده برچسب‌خورده^۱ آموزش داده می‌شود؛ بدین معنا که به هر نمونه، برچسب مشکوک یا غیرمشکوک نسبت داده می‌شود. الگوریتم با یادگیری تابع بین ویژگی‌های داده و برچسب‌ها، قادر خواهد بود بر روی داده‌های جدید، وظیفه پیش‌بینی یا دسته‌بندی را انجام دهد. (Zhang, & Trubey. 2019, p.1050)

^۱ . Labeled Dataset

این الگوریتم‌ها با به‌روزرسانی مداوم مبتنی بر داده‌های برجسب‌خورده جدید، دقت تشخیص خود را در طول زمان افزایش می‌دهند.^۱

هدف اصلی در این رویکرد، کشف تقلب و متوقف کردن آن در مرحله شروع به‌جرم است. با این حال کارآمدی این روش به‌طور قابل‌توجهی به‌وجود تمایز آشکار و قابل تشخیص میان الگوهای فعالیت‌های مجاز و غیرمجاز وابسته است.

در ذیل این رویکرد چندین زیرشاخه الگوریتمی صورت‌بندی می‌شود که عبارتند از:

۲/۱/۱. **رگرسیون لجستیک**^۲: این الگوریتم یک مدل طبقه‌بندی از نوع احتمالاتی است و وظیفه اصلی آن، تولید

یک خروجی دودویی (۰ یا ۱) براساس ویژگی‌های ورودی می‌باشد. به‌عنوان نمونه برای طبقه‌بندی تراکنش‌های مشکوک از ۱ و برای تراکنش‌های عادی از ۰ استفاده می‌شود. رگرسیون لجستیک با دریافت داده‌های ورودی همچون مبلغ تراکنش، زمان انجام تراکنش، موقعیت جغرافیایی، سابقه حساب، نوع پایانه و تعداد تراکنش‌های قبلی در بازه کوتاه، احتمال قانونی یا غیرقانونی بودن هر تراکنش را محاسبه می‌کند. این مدل با اعمال تابع ریاضی روی ترکیب خطی این ویژگی‌ها، عددی بین ۰ و ۱ خروجی می‌دهد. سپس با آستانه‌ای مانند ۰.۵ تراکنش‌هایی با احتمال بالاتر از آستانه را در دسته مشکوک (۱) و مابقی را در دسته عادی (۰) طبقه‌بندی می‌کند.

با این حال اگرچه این مدل قادر به دریافت همزمان چندین ویژگی (مانند مبلغ، ساعت، موقعیت جغرافیایی، آی‌پی و...) است، اما مهم‌ترین محدودیت آن درماهیت خطی این مدل نهفته است. به عبارت دیگر، رگرسیون لجستیک فرض می‌کند که هر ویژگی به‌طور مستقل و بدون توجه به سایر ویژگی‌ها، سهم خطی خود را در خروجی نهایی اعمال می‌کند. در حالی که، در بسیاری از الگوهای تقلب، شرط وقوع تراکنش مشکوک به صورت غیرخطی و وابسته به چند ویژگی است؛ برای مثال، یک تراکنش تنها زمانی مشکوک محسوب می‌شود که همزمان مبلغ آن بالا، ساعت انجام آن غیرعادی و آی‌پی کاربر ناشناس باشد. درنتیجه، درمواجه با چنین الگوهای پیچیده‌ای، ممکن است خطای تشخیص به ویژه منفی کاذب^۳ افزایش یابد (Fei, et al, 2025, p.9).

۲،۱،۲ **کا-میانگین**^۴: این مدل براساس این اصل ساده عمل می‌کند که نقاط نزدیک به هم در فضای ویژگی‌ها، معمولاً متعلق به یک دسته هستند. به عبارتی، برای آنکه مدل تشخیص دهد یک تراکنش جدید مشکوک است یا عادی،

^۱ Financial Crime Academy, "Safeguarding Against Money Laundering: Essential Machine Learning Algorithms for AML," July 13, 2026, <https://financialcrimeacademy.org/machine-learning-algorithms-for-aml/>.

^۲ Logistic Regression

^۳ False Negatives

وضعیتی که در آن یک تراکنش یا رفتار مشکوک واقعی توسط سیستم شناسایی نمی‌شود و به‌اشتباه به‌عنوان عادی تلقی می‌گردد.

^۴ K-Nearest Neighbors (KNN)

کافی است نزدیک‌ترین تراکنش‌های موجود در مجموعه داده را به آن بررسی کند. به عنوان نمونه اگر مقدار K برابر ۵ انتخاب شده باشد؛ مدل به دنبال ۵ تراکنشی می‌گردد که از همه نظر (از نظر ویژگی‌هایی مانند مبلغ، زمان و...) به تراکنش جدید شباهت بیشتری دارند. اگر از میان این ۵ نمونه، سه مورد از آن‌ها برچسب مشکوک و دو مورد از آنها برچسب عادی داشته باشند، مدل رأی اکثریت را می‌پذیرد و تراکنش جدید را در دسته مشکوک طبقه‌بندی می‌کند. چالش اصلی این مدل آن است که با افزایش حجم داده‌ها، کند عمل می‌کند. (Halder. et al, 2024, pp.4-6)

۲،۱،۳. **درخت‌های تصمیم:**^۱ درخت تصمیم ساختاری شبیه به نمودار درختی برای طبقه‌بندی داده‌ها ایجاد می‌کند. این الگوریتم با پرسش درخصوص مواردی از ویژگی‌های یک تراکنش (مانند آیا مبلغ تراکنش بیشتر از ۱۰۰ میلیون تومان است؟ یا آدرس آی‌پی کاربر در محدوده کشورهای پرخطر قرار دارد؟) در هر گام، داده‌ها را به طور مکرر به زیرمجموعه‌های کوچک‌تر تقسیم می‌کند. هر پرسش در یک گره^۲ قرار می‌گیرد و پاسخ به آن، مسیر حرکت به سمت شاخه بعدی را مشخص می‌کند. (Vorobyev and Krivitskaya. 2022, pp.2-3) این فرآیند تا رسیدن به یک برگ ادامه می‌یابد که برگ نهایی، حاوی تصمیم قطعی مدل یعنی مشکوک یا عادی بودن تراکنش است. مزیت اصلی این روش شفافیت کامل آن است، به گونه‌ای که مسیر طی شده از ریشه تا برگ را می‌توان به مجموعه‌ای از قوانین ساده «اگر-آنگاه» تبدیل کرد. برای نمونه، مدل تشخیص تقلب می‌تواند به این صورت باشد: اگر مبلغ تراکنش بالای ۱۰۰ میلیون باشد و آی‌پی کاربر خارج از کشور باشد و ساعت انجام تراکنش بین ۲ تا ۴ بامداد باشد، آنگاه تراکنش مشکوک است.

با این حال این مدل مستعد بیش‌برازش^۳ است. وضعیتی که در آن مدل، به جای یادگیری الگوهای عمومی حاکم بر داده‌ها، جزئیات تصادفی، نویزها و نقاط پرت مجموعه آموزشی را به طور کامل به خاطر می‌سپارد. در چنین حالتی، مدل توانایی تعمیم به داده‌های جدید و دیده‌نشده را از دست می‌دهد، به ویژه زمانی که عمق درخت افزایش یافته و ساختار آن پیچیده می‌شود. در واقع این مدل در مواجهه با داده‌های جدید و دیده‌نشده نرخ تشخیص بسیار ضعیفی خواهد داشت.^۴

۲،۱،۴. **جنگل تصادفی:**^۵ این مدل ترکیبی از تعداد زیادی درخت تصمیم را برای طبقه‌بندی معاملات مشکوک به کار می‌گیرد. این مدل در مقایسه با مدل‌های پایه مانند رگرسیون لجستیک یا کا-میانگین، دقت بالاتری در شناسایی تراکنش‌های مشکوک دارد. دلیل اصلی این امر، توانایی جنگل تصادفی در شناسایی الگوهای غیرخطی و

1. Decision Trees

2. Node

3. Overfitting

4. Fraud Detection Handbook. (2021). *Chapter 5: Model Validation and Selection - Introduction*. GitHub. Available at: https://github.com/Fraud-Detection-Handbook/fraud-detection-handbook/blob/main/Chapter_5_ModelValidationAndSelection/Introduction.md

5. Random Forest

تعاملات پیچیده میان ویژگی‌ها و بهره‌گیری از تعداد بالای درخت‌های تصمیم است. در این راستا جنگل تصادفی با ترکیب تعداد زیادی درخت و میانگین گرفتن از پیش‌بینی‌های آن‌ها، ضمن حفظ توانایی در کشف الگوهای پیچیده، مشکل بیش‌برازش را به‌طور چشمگیری کاهش می‌دهد. (Liaw, et.al. 2002, pp.18-22)

با این حال، یکی از نقاط ضعف این رویکرد آن است که ممکن است در مواجهه با داده‌هایی که دامنه وسیعی از مقادیر یا متغیرهایی با سطوح متعدد دارند، بیش از حد حساس عمل کرده و به‌سرعت آن‌ها را به‌عنوان تراکنش تقلبی تشخیص دهد. به عبارت دیگر، گاهی اوقات مدل بیش از اندازه محتاط بوده و تعداد زیادی تراکنش عادی را به اشتباه مشکوک اعلام می‌کند. (Ibid)

۲،۱،۵. شبکه‌های عصبی بازگشتی: این مدل در حوزه یادگیری عمیق^۲ برای مسائل مبتنی بر داده‌های توالی محور طراحی شده است. در واقع این مدل با دریافت تراکنش‌های تاریخی که برچسب عادی یا مشکوک دارند، رابطه بین ویژگی‌ها را یاد می‌گیرد. تفاوت اساسی این روش با سایر مدل‌های نظارت شده در رویکرد آن به وابستگی‌های زمانی است؛ به این معنا که برخلاف مدل‌هایی که هر تراکنش را مستقل فرض می‌کنند، شبکه‌های عصبی بازگشتی تراکنش‌های یک حساب را به صورت زنجیره‌ای و در توالی زمانی خود بررسی می‌کنند. (Girish, et.al. 2024, pp.2-3) این ویژگی به مدل امکان می‌دهد الگوهای رفتاری مشکوک را که در گذر زمان شکل می‌گیرند (مانند افزایش ناگهانی تعداد یا مبلغ تراکنش‌ها در بازه کوتاه) شناسایی کند.^۳ با این حال این مدل از نظر محاسباتی سنگین و پرهزینه هستند چرا که آموزش آن‌ها زمان‌بر بوده و به حافظه قابل توجهی نیاز دارند. همچنین به دلیل ساختار پیچیده و لایه‌های پنهان خود به عنوان یک جعبه سیاه تفسیرناپذیر شناخته می‌شوند.

۲/۲. یادگیری بدون نظارت^۴

یادگیری بدون نظارت به عنوان یکی دیگر از رویکردهای یادگیری ماشین، در تقابل با رویکرد نظارت شده قرار دارد. تمایز اصلی این دو رویکرد در بهره‌گیری یا عدم بهره‌گیری از داده برچسب خورده است. در حالی که یادگیری نظارت شده به طور کامل به مجموعه داده‌هایی متکی است که پیشاپیش برچسب مشکوک یا غیر مشکوک به آن‌ها نسبت داده شده، یادگیری بدون نظارت

^۱ . Recurrent Neural Networks (RNN)

^۲ . Deep Learning

^۳ . به عنوان نمونه، یک حساب بانکی عادی بامیانگین تراکنش روزانه ۵۰۰ هزار تومان شروع می‌شود. یک فرد فعال در حوزه پولشویی طی دو هفته، به تدریج مبلغ تراکنش‌ها را از ۵۰۰ هزار به ۵ میلیون تومان افزایش می‌دهد تا رفتار حساب را به سطوح بالای مالی عادت دهد. در روز پانزدهم، یک تراکنش ۵۰ میلیون تومانی در ساعت ۳ بامداد انجام می‌دهد که هدف آن وارد کردن وجوه نامشروع به سیستم مالی است. سایر مدل‌های نظارت شده که هر تراکنش را مستقل می‌بینند، تنها تراکنش بزرگ روز پانزدهم را به دلیل مبلغ بالا و ساعت غیرعادی مشکوک تشخیص می‌دهند، اما قادر به شناسایی الگوی «افزایش تدریجی» در روزهای قبل نیستند. در مقابل، این مدل با حفظ حافظه از تراکنش‌های قبلی و به دلیل شناسایی الگوی صعودی در روزهای قبل (که نشانه «عادی سازی» رفتار حساب برای پولشویی است)، تراکنش را مشکوک اعلام می‌کند.

^۴ . Unsupervised Learning

هیچ گونه اطلاع پیشینی از برچسب نمونه‌ها را در اختیار ندارد. این رهیافت، تمامی بار شناختی خود را بر کشف ساختارهای درونی، الگوهای نهفته و روابط پنهان در داده‌ها متمرکز می‌سازد.^۱

مزیت اصلی این رویکرد، شناسایی سناریوهای مجرمانه ناشناخته‌ای است که به دلیل نبود سابقه قبلی، هیچ برچسبی به آن‌ها تعلق نگرفته است. بر این اساس یادگیری بدون نظارت، به عنوان مکمل ضروری رویکرد نظارت‌شده، می‌تواند خلأ رویکرد نظارت‌شده را مرتفع کند. یکی از مهم‌ترین شاخه‌های اصلی این رویکرد الگوریتم خوشه‌بندی K-Means^۲ است.

این مدل بدون نیاز به داده‌های برچسب‌خورده تاریخی، تراکنش‌های مالی را براساس معیارهای شباهت (مانند مبلغ، زمان، جغرافیا و الگوی رفتاری) گروه‌بندی می‌کند. از آنجا که تراکنش‌های عادی و تکراری به نسبت تراکنش‌های مشکوک، درصد بیشتری را به خود اختصاص می‌دهند، این مدل آن‌ها را در قالب یک یا چند خوشه بزرگ و متراکم دسته‌بندی می‌کند. در مقابل، تراکنش‌های مرتبط با پولشویی و جرایم مالی به دلیل ویژگی‌های ناهنجار خود در فاصله قابل توجهی از این خوشه‌های اصلی قرار گرفته و به عنوان پرت^۳ یا خوشه‌های بسیار کوچک ظاهر می‌شوند. (Mubalalike, & Adali, 2018, pp. 598-600)

ماهیت غیرنظارتی این مدل، آن را برای کشف پدیده‌های پنهان جرایم مالی و اقتصادی و به ویژه پولشویی، مناسب ساخته است. به عبارتی داده‌های برچسب‌خورده تاریخی از جرایم اقتصادی معمولاً نسبت زیادی را تشکیل نمی‌دهند. افزون بر این، شیوه‌های پولشویی همواره در حال تغییر است و الگوهای جدیدی پدیدار می‌شوند که ممکن است در داده‌های گذشته بازنمایی نشده باشد. در چنین بستری، روش‌های غیرنظارت‌شده، بدون نیاز به داده‌های برچسب‌خورده و صرفاً با تکیه بر ساختار ذاتی داده‌ها، می‌توانند الگوهای ناهنجار را شناسایی کنند.

نقاط پرت به عنوان الگوهای رفتاری ناهنجار، اولویت نخست بررسی‌های تکمیلی را به خود اختصاص می‌دهند. در چنین فرآیندی، این الگوریتم با تفکیک خودکار ساختار داده، حجم وسیع تراکنش‌های روزانه را به دو زیرمجموعه متمایز کاهش می‌دهد. در نتیجه منابع محدود نظارتی صرفاً به موارد پرخطر اختصاص می‌یابند و هزینه‌های پایش تراکنش‌های عادی کاهش می‌یابد. (Naif and Qayyum, 2025, p.3658)

بنابراین این مدل با شناسایی زودهنگام رفتارهای ناهنجار قبل از تکمیل چرخه پولشویی، امکان مداخله پیش‌دستانه برای توقیف فعالیت‌های غیرمجاز را فراهم می‌آورد.

روش خوشه‌بندی اگرچه در دسته‌بندی اولیه تراکنش‌های مشکوک مفید است، اما با کاستی‌هایی نیز مواجه است. نخست آنکه این روش عملکرد همه‌جانبه‌ای در شناسایی روابط شبکه‌ای میان حساب‌های مختلف ندارد، حال آنکه پولشویی معمولاً از طریق

^۱ . Financial Crime Academy, "Safeguarding Against Money Laundering: Essential Machine Learning Algorithms for AML," July 13, 2026, <https://financialcrimeacademy.org/machine-learning-algorithms-for-aml/>.

^۲ . K-Means Clustering Algorithm

^۳ . Outlier

چندین حساب و تراکنش‌های مرتبط انجام می‌شود. دوم آنکه نتایج این روش همیشه پایدار و یکسان نیست و به نقاط شروع الگوریتم وابسته است؛ لذا نیاز به تفسیرپذیری خواهد داشت. (Pelckmans, 2020, p.37)

۳. چالش‌های کاربردی رویکرد داده بنیان

علی‌رغم مزایای مثبتی که روش‌های یادگیری ماشین در کشف، پیش‌بینی و پیشگیری از جرم دارند، این فناوری به دلیل نوظهور بودن و تحولات سریع، چالش‌هایی را در حوزه مبارزه با جرایم ایجاد نموده است. بنابراین برای بهره‌مندی کامل از توانمندی‌های یادگیری ماشین در بخش مالی، مسیر تحقیقات آینده باید بر سه محور اصلی متمرکز شود: نخست، توسعه چارچوب‌هایی برای هوش مصنوعی قابل اعتماد که کارایی را با رعایت اصول حقوقی پیوند می‌زند؛ دوم، طراحی عامل‌های خودمختار مبتنی بر یادگیری ماشین که قابلیت تطبیق پویا با شرایط لحظه‌ای را داشته باشند و سوم، تقویت همکاری‌های میان‌بخشی با هدف تدوین و استانداردسازی حکمرانی هوش مصنوعی در اکوسیستم مالی. محورهای دوم و سوم به ترتیب به ملاحظات فنی و سیاست‌گذاری در حوزه هوش مصنوعی مربوط می‌شوند. با این حال محور نخست، بحث اصلی را در چگونگی تنظیم‌گری هوش مصنوعی به خود اختصاص می‌دهد؛ امری که نیازمند تطبیق با اصول بنیادین حقوق کیفری و اصول دادرسی عادلانه است. الگوی دادرسی عادلانه، نمونه‌آرامانی از نحوه عملکرد سیستم عدالت کیفری است که بر مبنای حاکمیت قانون بنا شده است و از طریق سازمان قضایی قانونی، مستقل و بی‌طرف با قواعد دادرسی مصفا شده همچون حق بردفاع، حق بهره‌مندی از اصل براءت و شفافیت در دادرسی محقق می‌شود. این اصول کلی و دائمی بوده که وجود آن باعث پایداری و دوام و نبود آن موجب از هم گسیختگی حیات دادرسی و مشروعیت آن می‌گردد. (تدین و باقری نژاد، ۱۳۹۹، ص ۲۱۴) در این قسمت از نوشتار به مهم‌ترین چالش‌های کنونی رویکرد داده بنیان پرداخته خواهد شد.

۳/۱. عدم شفافیت الگوریتمی؛^۱ نقض حق دفاع

مدل‌های پیشرفته یادگیری ماشین، به‌ویژه مدل‌های مبتنی بر یادگیری عمیق، علی‌رغم دقت بالا در کشف الگوهای پیچیده و غیرخطی در داده‌های مالی، با چالش اساسی عدم شفافیت الگوریتمی مواجه‌اند. این عدم شفافیت ریشه در معماری این مدل‌ها دارد؛ وجود لایه‌های پنهان متعدد و تعداد بسیار زیاد پارامترها (از میلیون‌ها تا میلیاردها مؤلفه) باعث می‌شود تابع تصمیم‌گیری نهایی چنان پیچیده باشد که حتی برای طراحان و توسعه‌دهندگان سیستم نیز غیرقابل درک مستقیم است. به عبارتی، درحالی‌که مدل یک تراکنش را به عنوان «مشکوک» طبقه‌بندی می‌کند، مکانیسم درونی «چرا» و «بر اساس چه ترکیب خاصی از ویژگی‌ها» به این نتیجه رسیده است، در ابهام باقی می‌ماند. (Rudin, 2019, p. 208) این ابهام به‌ویژه در فرایند شناسایی و تعقیب ذی‌نفع اصلی در ارتکاب جرم، چالش برانگیزتر است، زیرا الگوریتم قادر به توضیح دقیق و پیوسته روابط بین تراکنش‌ها و شخص مشکوک نیست.

^۱ . Algorithmic Opacity

از سوی دیگر، نهادهای مبارزه با پولشویی اساساً بر پایه اصل پاسخگویی و شفافیت عمل می‌کنند، اما به کارگیری الگوریتم‌ها این تناقض را آشکار می‌سازد که چگونه می‌توان شفافیت را تأمین کرد. اسناد فرادستی و بین‌المللی نیز بر این ضرورت تأکید دارند؛ برای نمونه، ماده ۱۴ میثاق بین‌المللی حقوق مدنی و سیاسی مقرر می‌دارد که متهم حق دارد در اسرع وقت و به تفصیل، به‌زبانی که می‌فهمد، از نوع و علل اتهام مطلع شود. این امر ضرورت شفافیت در علل اتهامی و چرایی آن را در چارچوب دادرسی منصفانه و عادلانه یادآور می‌شود. در این میان، دیجیتالی شدن بستر ارتکاب جرم، علاوه بر تغییر در کنش مجرمانه، منجر به دگرگونی در ساختار ادله شده است؛ امروزه از این پدیده با عنوان «ادله الگوریتمی»^۱ یاد می‌شود. با این حال، تحول در قالب و ساختار ادله به هیچ وجه به معنای تغییر یا تعلیق اصول بنیادین حقوق کیفری نیست. این اصول، به مثابه سنگ بنای حقوق کیفری، چارچوب ارزیابی هر نوع دلیل جدیدی را تعیین می‌کنند. (Quattrocolo, et.al, 2020, pp.2-3)

از این رو، الگوریتم در نظام ادله اثبات دعوا صرفاً به عنوان یک منبع استدلالی، پذیرفته می‌شود و مشمول همان الزامات ناظر بر دادرسی عادلانه است. بر این اساس، متهم، علی‌رغم تغییر شکل ادله، همچنان از حق دفاع برخوردار است که دستیابی شایسته به این حق، شامل آگاهی از فرآیند استنتاج الگوریتم نیز، می‌شود. لذا کنشگران عدالت کیفری در صورت استناد به ادله الگوریتمی موظفند اطلاعات معنادار در مورد منطق حاکم بر تصمیم الگوریتم را به گونه‌ای ارائه کنند که امکان فهم، ارزیابی، اعتراض و در یک کلام، حق بر دفاع متهم میسر گردد.

این الزام با تأکید بر ماده ۲۲ مقررات عمومی حفاظت از داده‌های اتحادیه اروپا^۲ تقویت می‌شود؛ چرا که بر اساس این ماده، هرگاه نتیجه بررسی‌های الگوریتمی به‌طور قابل توجهی بر حقوق افراد تأثیر بگذارد، حق توضیح خواهی برای افراد در برابر تصمیمات خود کار الگوریتمی به رسمیت شناخته می‌شود.^۳ در این مرحله، آنچه ضروری است «اطلاعات معنادار» یعنی توضیحی شفاف، مختصر و قابل فهم برای افراد عادی، درباره چگونگی تأثیر داده‌های شخصی بر تصمیم اتخاذ شده است؛ زیرا بدون آگاهی از منطق پشت الگوریتم، شخص نمی‌تواند از چگونگی پردازش داده‌های خود مطلع شود و در نتیجه، از خود دفاع شایسته به عمل آورد.

^۱ . Algorithmic Evidence

^۲ . European Regulation on General Data Protection (GDPR)

^۳ . این ماده مقرر می‌دارد: شخص موضوع داده، این حق را خواهد داشت که مشمول تصمیمی مبتنی بر پردازش صرفاً خودکار، از جمله نمایه‌سازی (پروفایلینگ)، که نسبت به او آثار حقوقی ایجاد کند یا به‌طور مشابه به نحو قابل توجهی بر او تأثیر بگذارد، نباشد.

کنترل‌کننده داده باید تدابیر مناسبی برای حفظ حقوق، آزادی‌ها و منافع مشروع شخص موضوع داده اجرا کند، که حداقل شامل حق دریافت مداخله انسانی از سوی کنترل‌کننده، حق بیان دیدگاه خود و حق اعتراض به تصمیم است.

فراتر از مقررات عمومی حفاظت از داده‌ها، قانون هوش مصنوعی اتحادیه اروپا (EU) 2024/1689 نیز با معرفی ماده ۸۶، حق توضیح‌خواهی^۱ افراد را گسترش داده است. بر اساس این ماده، زمانی که تصمیمات با استفاده از سیستم‌های هوش مصنوعی پرخطر گرفته می‌شوند که به‌طور قابل‌توجهی بر حقوق، سلامت یا ایمنی افراد تأثیر می‌گذارند، مستقرکنندگان آن فناوری موظف به ارائه توضیحات واضح و معنادار درباره نقش سیستم هوش مصنوعی در رویه تصمیم‌گیری و عناصر اصلی تصمیم گرفته‌شده هستند.

۳.۲. نقض اصل اصالت و تمامیت دلیل در پروتو حملات تخصصی^۲

حملات تخصصی به دستکاری عمدی و هوشمندانه داده‌های ورودی اطلاق می‌شود که برای چشم انسان عادی یا سیستم‌های ساده غیرقابل تشخیص است، اما مدل یادگیری ماشین را فریب می‌دهد و آن را به خروجی اشتباه وامی‌دارد. (Anthi, et.al, 2021, p.1) این آسیب‌پذیری ریشه در ماهیت مدل‌های یادگیری ماشین دارد و برخلاف شکاف‌های امنیتی مرسوم، از نحوه یادگیری خود مدل سوءاستفاده می‌کند.

در واقع مجرمان حرفه‌ای که از وجود سیستم‌های هوشمند کشف تقلب مطلع هستند، می‌توانند با استفاده از تکنیک‌های تخصصی، تراکنش‌های غیرقانونی خود را طوری تغییر دهند که مدل آن‌ها را عادی تشخیص دهد. مانند آنکه شخص مقادیر عددی یک تراکنش را به اندازه‌ای ناچیز تغییر دهد، که مبلغ از آستانه تشخیص مشکوک به عادی تغییر کند. همچنین با استفاده از الگوریتم‌های تخصصی، مجرمان می‌توانند تراکنش غیرقانونی را در میان الگوهای تراکنش‌های روزمره و کم‌خطر استتار کنند. این کار از طریق شبیه‌سازی رفتار کاربران عادی نظیر عادات هزینه، نوع دستگاه و الگوهای موقعیت جغرافیایی انجام می‌شود؛ به گونه‌ای که فعالیت مجرمانه برای سیستم‌های تشخیص ناهنجاری مبتنی بر هوش مصنوعی، عادی و روزمره به نظر می‌رسد.^۳

بدین‌سان، حملات تخصصی که از رهگذر دستکاری عمدی و غیرقابل تشخیص داده‌ها، تمامیت دلیل الگوریتمی را مخدوش می‌سازند، با اصول دادرسی منصفانه و مبانی حاکم بر نظام ادله کیفری که همواره بر صحت و اصالت ادله، تأکید دارد، ناسازگار می‌نمایند. در واقع، در ادبیات حقوق کیفری بحث پیرامون انتساب جرم و احراز رابطه سببیت همواره امری دشوار و وابسته به عواملی چندگانه بوده است. نظام‌های الگوریتمی مبتنی بر یادگیری ماشین، اگرچه تا اندازه‌ای توانسته‌اند از دشواری‌های سنتی

1. the right to explanation of individual decision-making

2. Adversarial Attacks

۳. یک بررسی جهانی در سال ۲۰۲۴ نشان داد که نزدیک به یک چهارم مؤسسات فناوری مالی (Fintech) زبانی بیش از یک میلیون دلار را به دلیل حملات دیپ‌فیک متحمل شده‌اند.

احراز رابطه سببیت بکاهند، لیکن خود این فناوری‌ها دچار آسیب‌پذیری‌های ساختاری‌اند؛ امری که می‌تواند اصالت ادله الگوریتمی را با چالش مواجه کند.

به عنوان یک بایسته فرائقننی، اساسنامه رم دیوان کیفری بین‌المللی (۱۹۹۸) در بند ۷ ماده ۶۹ خود چنین مقرر داشته است که ادله‌ای که از راه نقض حقوق بشر به‌دست آمده باشند، در دو حالت قابلیت طرح در دادرسی کیفری بین‌المللی را نخواهند داشت: نخست، آنگاه که نقض مذکور، تردید عمده‌ای در اعتبار دلیل ایجاد کند؛ و دوم، زمانی که پذیرش دلیل با اصالت دادرسی ناسازگار بوده و به آن لطمه‌ای جدی وارد سازد.

در نظام حقوقی ایران نیز، اگرچه «اصل اصالت و تمامیت دلیل» به عنوان یک اصل مستقل و با همین عنوان تصریح نشده است، اما می‌توان مؤلفه‌های آن را که در قوانین مرتبط با ادله الکترونیکی انعکاس یافته است، مشاهده کرد. در این راستا قانون تجارت الکترونیکی با تفکیک «داده‌پیام مطمئن» از «داده‌پیام عادی» عملاً این پیش‌فرض را بنیان نهاده که یک دلیل الکترونیکی، زمانی از اعتبار و قابلیت اتکای لازم برخوردار است که امکان کشف تغییرات و احراز انتساب آن به صورت مطمئن فراهم باشد.^۱ با این حال، آنچه در این مقررات دیده می‌شود، عمدتاً ناظر به داده‌های ایستا و فرایندهای سنتی جمع‌آوری ادله است؛ داده‌هایی که از سیستم‌های بسته و شناخته‌شده استخراج می‌شوند و خاستگاه و زنجیره انتقال آن‌ها قابل پیگیری است. اما آنچه امروزه تحت عنوان ادله الگوریتمی در قانون توجه قرار دارد، ماهیتی متفاوت دارد.

درواقع مقررات موجود عمدتاً بر حفاظت از داده در برابر جعل و تغییر آشکار متمرکز شده‌اند، اما در برابر تغییرات هوشمندانه‌ای که برای فریب الگوریتم طراحی می‌شوند، دچار خلأ هستند. در نتیجه، حتی اگر داده‌های ورودی اصیل و دست‌نخورده باشند، فرآیند تولید خروجی ممکن است به واسطه حملات تخصصی تمامیت دلیل الگوریتمی را مختل و سبب شود. از این رو به نظر می‌رسد نهادهای قضایی ناگزیر از اعمال استانداردهای سختگیرانه‌تر برای احراز اصالت و تمامیت این دسته از ادله هستند؛ چه در غیر این صورت، حق بنیادین متهم بر دادرسی منصفانه نقض خواهد شد.

۳.۳. اصل برائت؛ چالش کیفیت و دسترسی به داده

رویکرد داده‌بنیان در شناسایی تراحش‌های مشکوک به پولشویی، علیرغم توانمندی قابل توجه در کشف الگوهای پیچیده، به همان میزان که به داده وابسته است، از آسیب‌پذیری‌های ناشی از کیفیت و دسترسی به داده نیز متأثر می‌گردد. مدل‌های یادگیری ماشین، فارغ از پیچیدگی معماری خویش، قادر به ارائه کیفیتی فراتر از داده‌ای که بر آن آموزش دیده‌اند نمی‌باشند. از این رو، چنانچه داده‌های ورودی از کیفیت مطلوب برخوردار نباشند؛ چه به دلیل خطاهای کدگذاری، چه به دلیل کم‌نمایی برخی

^۱ ماده ۱۰ امضای الکترونیکی مطمئن باید دارای شرایط زیر باشد: الف) نسبت به امضاءکننده منحصر به فرد باشد. ب) هویت امضاءکننده داده‌پیام را معلوم نماید ج) به وسیله امضاءکننده و یا تحت اراده انحصاری وی صادر شده باشد. د) به نحوی به یک داده‌پیام متصل شود که هر تغییری در آن داده‌پیام قابل تشخیص و کشف باشد.

گروه‌ها. (Caglayan, et.al . 2022, p.857) و چه به دلیل سوگیری‌های ناخواسته در مرحله گردآوری داده، خروجی مدل نیز به طریق اولی معیوب و غیرقابل اتکا خواهد بود.

چالش کیفیت داده در نظام‌های مبارزه با پولشویی به ویژه می‌تواند ظهور کند. بدین معنا که اگر صرفاً بر اساس معیارهای اعلام‌شده از سوی نهادهایی چون گروه ویژه اقدام مالی، تمرکز داده‌ها بر تراکنش‌های اشخاص ساکن در مناطق جغرافیایی موسوم به «پرخطر» معطوف گردد، یا دسته‌خاصی از افراد (بر اساس ملیت، شغل یا نوع فعالیت) با فراوانی بیشتری نسبت به دیگران در فرایند ثبت و بررسی تراکنش‌ها قرار گیرند، در آن صورت احتمال وجود دارد که مجموعه داده‌ای ناقص و حامل سوگیری آماری به الگوریتم آموزش داده شود. مدلی که بر چنین داده‌هایی استوار خواهد شد، ممکن است به جای کشف الگوهای عینی و معتبر پولشویی، به همبستگی‌های تصادفی ناشی از همان سوگیری‌های اولیه گرایش پیدا کند و آن‌ها را به عنوان ویژگی‌های مشکوک بازآموری نماید. (Gupta, et. al. 2021, p.553) نتیجه آنکه مدل به طور نظام‌مند، وزن پیش‌بینی بالاتری را به تراکنش‌های متبسط به مناطق جغرافیایی خاص یا دسته‌های اجتماعی معین اختصاص می‌دهد و در نتیجه، این دسته از افراد با احتمالی بیشتر در زمره ورودی‌های مشکوک طبقه‌بندی شوند.

این پدیده با اصل برائت که در ماده ۱۴ میثاق بین‌المللی حقوق مدنی و سیاسی و نیز اصل ۳۷ قانون اساسی تصریح شده است، تعارضی آشکار دارد. اصل برائت ایجاب می‌کند که هیچ فردی مجرم انگاشته نشود، مگر آنکه جرم او برپایه ادله‌ای معتبر، قابل انتساب و بی‌طرفانه در مرجع قضایی به اثبات رسد. اما هنگامی که الگوریتم‌های یادگیری ماشین به سبب کیفیت داده‌ها، برچسب مشکوک را به افرادی اختصاص می‌دهند که صرفاً به دلیل ویژگی‌های جمعیت‌شناختی یا موقعیتی خاص در مجموعه داده با فراوانی بیشتری بازنمایی شده‌اند، عملاً بار اثبات به طور ضمنی به آنان منتقل می‌گردد؛ امری که با اصل برائت مغایرت دارد.

با این حال قانون‌گذار ایران در راستای افزایش کارآمدی نظام مبارزه با پولشویی، با الحاق تبصره‌های سه‌گانه به ماده (۲) قانون مبارزه با پولشویی، در برخی فروض، زمینه تعدیل بار اثبات را فراهم ساخته است. تبصره ۱: «هرگاه ظن نزدیک به علم به عدم صحت معاملات و تحصیل اموال وجود داشته باشد مانند آنکه نوعاً و باتوجه به شرایط امکان تحصیل آن میزان درایی در یک زمان مشخص وجود نداشته باشد مسئولیت اثبات صحت آن‌ها بر عهده متصرف است.»

تبصره ۲ نیز مقرر می‌دارد: «دارا شدن اموال موضوع این قانون منوط به ارائه اسناد مثبت است. علاوه بر این چنانچه ارزش اموال مزبور بیش از ده میلیارد ریال برای سال پایه و معادل افزایش یافته آن بر اساس نرخ تورم برای سال‌های بعد باشد وجود سابقه از آن در سامانه‌های مربوطه مطابق قوانین و مقررات لازم است. عدم تقدیم اسناد مثبت که قابل راستی‌آزمایی باشد به حکم دادگاه مستوجب جزای نقدی به میزان یک‌چهارم ارزش آن اموال خواهد بود، در این صورت اصل مال موضوع قانون تا زمان

رسیدگی قضائی توقیف می‌شود. چنانچه پس از رسیدگی اثبات شود دارا شدن مشروع بوده از مال رفع توقیف و در غیراین صورت ضبط می‌شود.»

و تبصره ۳ نیز مقرر می‌دارد: «چنانچه ظن نزدیک به علم بر تحصیل مال از طریق نامشروع وجود داشته باشد در حکم مال نامشروع محسوب و مرتکب در صورتی که مشمول مجازات شدیدتری نباشد به حبس درجه شش محکوم می‌شود. در هر صورت مال مزبور ضبط خواهد شد مگر اینکه تحصیل مشروع آن اثبات شود.»

بدین سان همگام با پیشرفت‌های بین‌المللی در زمینه نظام مقابله با پولشویی و افزایش اختیارات نهادهای نظارتی در جهت مبارزه با ورود و گردش وجوه نامشروع در نظام اقتصادی کشورها و در پی تغییرات مثبت قانون مبارزه با پولشویی، تبصره ۱ الحاقی به ماده ۲ قانون مبارزه با پولشویی اقدام به تعدیل بار اثبات در پرونده‌های پولشویی نموده است. برای مثال اگر در یک پرونده، فردی متهم پولشویی از طریق تحصیل مال حاصل از جرم باشد، به طور معمول دادستان باید سه موضوع را ثابت کند؛ نخست، تحصیل مال توسط متهم، دوم؛ حاصل از جرم بودن مال و سوم علم و اطلاع متهم از این که مال حاصل از جرم بوده است. اما با الحاق این تبصره به ماده ۲ قانون مبارزه با پولشویی، موضوع دوم به لحاظ اثباتی تغییراتی پیدا کرده است. بر اساس این تبصره بنا به خطر (ریسک) ایجاد شده توسط خود متصرف اموال، لازم نیست «حاصل از جرم بودن مال» توسط دادستان اثبات شود، بلکه اگر شرایط تبصره مذکور فراهم باشد، این متهم است که باید ثابت کند که مال را از راه مشروع و قانونی به دست آورده است. لیکن باید در نظر داشت کماکان اثبات موضوع اول و سوم یعنی ارتکاب رفتار فیزیکی تحصیل توسط متهم و علم و اطلاع او از مجرمانه بودن مال تحصیل شده (که به طور معمول بر اساس فرائین عینی محرز می‌شود) بر عهده دادستان بوده و دستخوش تغییر قرار نگرفته است. حال پرسش این است که چه شرایطی باید وجود داشته باشد که بار اثبات «حاصل از جرم بودن مال» معکوس شود؟ تبصره ۱ الحاقی به ماده ۲ قانون مبارزه با پولشویی مبنای تغییر بار اثبات را «به وجود آمدن ظن نزدیک به علم بر عدم صحت معاملات و تحصیل اموال» عنوان کرده و برای تبیین آن به ذکر یک مثال اکتفا نموده است. این مثال به این شرح است: «نوعاً و با توجه به شرایط امکان تحصیل آن میزان دارایی در یک زمان مشخص وجود نداشته باشد.» البته باید توجه داشت که این مثال تنها جنبه تبیینی داشته و مبنا همان «به وجود آمدن ظن نزدیک به علم بر عدم صحت معاملات و تحصیل اموال است» که این ظن ممکن است از طرق دیگر به دست آید؛ برای مثال به علت ارتباط مالی شخص با مرتکبان جرایم ممکن است ظن مذکور حاصل شود؛ لیکن به نظر می‌رسد تشخیص قضایی در این زمینه بسیار با اهمیت است، اما به هر حال منشأ ظن باید معتبر و مستند باشد. (ثالث موید و همکاران، ۱۴۰۳، صص. ۶۶-۶۷)

بدین ترتیب، قانون‌گذار، ایجاد «ظن نزدیک به علم» را مبنای تعدیل بار اثبات قرار داده است. در چنین چارچوبی، کیفیت و اعتبار داده‌هایی که منشأ شکل‌گیری این ظن هستند، اهمیتی دوچندان پیدا می‌کند. هرچه این ظن بر پایه تحلیل جامع‌تر داده‌های مالی، الگوهای رفتاری مشتری و روابط میان تراکنش‌ها استوار باشد، اتکاپذیری آن نیز افزایش خواهد یافت. از این منظر،

سامانه‌های مبتنی بر یادگیری ماشین، با پردازش حجم گسترده‌ای از داده‌های رفتاری و مالی و شناسایی الگوهایی که به سادگی از طریق روش‌های سنتی قابل تشخیص نیستند، می‌توانند زمینه شکل‌گیری ظنی مستندتر و نزدیک‌تر به واقع را فراهم آورند. در نتیجه، در مواردی که قانون‌گذار آثار حقوقی مهمی همچون تعدیل بار اثبات را بر وجود چنین ظنی مترتب ساخته است، بهره‌گیری از رویکردهای داده‌بنیان، در صورت رعایت الزامات قانونی و تضمین کیفیت داده‌ها، می‌تواند در جهت افزایش کارآمدی نظام مبارزه با پولشویی و صیانت از امنیت اقتصادی، نقشی مؤثر ایفا کند.

۳،۴. محدودیت‌های زیرساختی در استقرار رویکرد داده‌بنیان در ایران

تحقق رویکرد داده‌بنیان در پیگیری از پولشویی، افزون بر وجود چارچوب‌های حقوقی، مستلزم فراهم بودن زیرساخت‌های فنی و اطلاعاتی متناسب است. هرچند قانون مبارزه با پولشویی و آیین‌نامه اجرایی آن با پذیرش رویکرد مبتنی بر ریسک، بر شناسایی، ارزیابی و مدیریت ریسک تأکید دارند، اما اجرای مؤثر این رویکرد در عصر داده، بدون دسترسی به سامانه‌های یکپارچه، داده‌های قابل اتکا و امکان تبادل برخط اطلاعات میان اشخاص مشمول و نهادهای ناظر با دشواری همراه خواهد بود. از همین رو، اگر چه در سال گذشته مرکز اطلاعات مالی ایران با راه‌اندازی سامانه جامع و هوشمند مبارزه با پولشویی (سمام) و سامانه برخط استعلامات (سبا)، گام مهمی در جهت تقویت زیرساخت‌های داده‌محور برداشته است؛ اما با وجود این، به نظر می‌رسد این زیرساخت‌ها هنوز در مرحله توسعه قرار دارند و تا دستیابی به یک نظام داده‌بنیان جامع، فاصله قابل توجهی وجود دارد. مطابق برنامه اعلام‌شده توسط مرکز اطلاعات مالی، در مرحله نخست اتصال سامانه «سمام» به شبکه بانکی پیش‌بینی شده و الحاق سایر اشخاص مشمول قانون^۱، از جمله مشاغل غیرمالی، شرکت‌های بیمه، بازار سرمایه و ...، به مراحل بعدی موكول شده است. این در حالی است که کارآمدی رویکرد داده‌بنیان، در گرو دسترسی به داده‌های جامع و برقراری ارتباط یکپارچه میان تمامی اشخاص مشمول است؛ زیرا هرگونه گسست اطلاعاتی می‌تواند اثربخشی تدابیر پیشگیرانه را کاهش دهد. از این رو، توسعه تدریجی این زیرساخت‌ها، در کنار تقویت سازوکارهای تبادل داده و اتصال کامل تمامی اشخاص مشمول، یکی از الزامات اساسی تحقق رویکرد داده‌بنیان در نظام مبارزه با پولشویی ایران به شمار می‌رود.

^۱. بند «ت» ماده یک قانون مبارزه با پولشویی اشخاص مشمول را با ارجاع به مواد (۵) و (۶) همین قانون، تعیین نموده است. مطابق با ماده ۵، کلیه صاحبان مشاغل غیرمالی و مؤسسات غیرانتفاعی و همچنین اشخاص حقیقی و حقوقی از جمله بانک مرکزی جمهوری اسلامی ایران، بانک‌ها، مؤسسات مالی و اعتباری، بیمه‌ها، بیمه مرکزی، صندوق‌های قرض‌الحسنه، بنیادها و مؤسسات خیریه، شهرداری‌ها، صندوق‌های بازنشستگی، نهادهای عمومی غیردولتی، تعاونی‌های اعتباری، صرافی‌ها، بازار سرمایه (بورسهای اوراق بهادار) و سایر بورسها، شرکت‌های کارگزاری، صندوق‌ها و شرکت‌های سرمایه‌گذاری و همچنین مؤسساتی که شمول قانون بر آنها مستلزم ذکر نام می‌باشد از قبیل شرکت ملی نفت ایران، سازمان گسترش و نوسازی ایران و غیر آنها، مکلفند آیین‌نامه‌های اجرائی هیأت‌وزیران در ارتباط با این قانون و قانون مبارزه با تأمین مالی تروریسم را اجراء کنند. همچنین مطابق با ماده ۶، کلیه اشخاص موضوع ماده (۵) این قانون، از جمله گمرک جمهوری اسلامی ایران، سازمان امور مالیاتی کشور، سازمان ثبت اسناد و املاک کشور، دفاتر اسناد رسمی، وکلای دادگستری، حسابرسان، حسابداران، کارشناسان رسمی دادگستری و بازرسان قانونی مکلفند اطلاعات مورد نیاز در اجرای این قانون را طبق مصوبات هیأت‌وزیران حسب درخواست شورا یا مرکز اطلاعات مالی به آنها ارائه نمایند.

نتیجه گیری

در نظم کنونی جهان، داده به مثابه یکی از ارکان بنیادین، ساختار نظام‌های نظارتی و حتی فرایندهای عدالت کیفری را دچار دگرگونی اساسی ساخته است. گذار از اقتصاد سنتی به زیست‌بوم دیجیتال و فراگیر شدن تراکنش‌های برخط و سازوکارهای نوین پرداخت، منجر به دگرگونی اشکال بزهکاری شده است. در این میان، جوامع معاصر به ویژه در برابر جرایم اقتصادی سازمان یافته و فرامرزی به تدریج به سمت رویکرد کنترل جرم پیش رفته‌اند. رویکردی که در آن، انتظار از نظام عدالت کیفری دیگر محدود به واکنش آتی نسبت به جرم ارتکاب یافته و اعمال مجازات پس از وقوع نیست، بلکه پیشگیری از راه پیش‌بینی به عنوان محوری اساسی در سیاست جنایی مطرح می‌گردد. در این رویکرد پیش‌بینی، نه به مثابه ابزاری برای تحدید آزادی‌ها، بلکه به عنوان ضرورتی بنیادین برای مدیریت علمی خطر و پیشگیری مؤثر از جرم، جایگاهی محوری یافته است. در چنین وضعیتی، هزینه تحمل خطا به مراتب بالاست و هرگونه تأخیر در شناسایی الگوهای مجرمانه می‌تواند به منزله تسهیل مسیر برای شبکه‌های پیچیده پولشویی و سایر جرایم اقتصادی تلقی گردد. در این راستا کاربست رویکرد داده‌بنیان و به ویژه بهره‌گیری از ابزارهای یادگیری ماشین، صرفاً به ارتقای دقت فنی در شناسایی تراکنش‌های مشکوک محدود نمی‌شود، بلکه می‌تواند الگوی پیشگیری از پولشویی را نیز دستخوش تحول سازد. در واقع، هرچه فرآیند شناسایی و ارزیابی ریسک از جامعیت، دقت و روزآمدی بیشتری برخوردار باشد، امکان اتخاذ تدابیر پیشگیرانه متناسب نیز افزایش یافته و مداخله نظام مبارزه با پولشویی از مرحله واکنش پس از وقوع جرم، به مرحله پیشگیری و مدیریت ریسک نزدیک‌تر می‌شود. با این حال، یافته‌های پژوهش نشان می‌دهد که بهره‌گیری از این فناوری، بدون فراهم شدن الزامات حقوقی و فنی، لزوماً به افزایش کارآمدی نظام مبارزه با پولشویی منجر نخواهد شد. کارآمدی این رویکرد، علاوه بر کیفیت الگوریتم‌ها، به وجود داده‌های قابل اعتماد، زیرساخت‌های اطلاعاتی یکپارچه، چارچوب‌های حقوقی متناسب و نظارت مؤثر بر فرآیندهای تصمیم‌گیری وابسته است. از این رو، توسعه ابزارهای هوشمند باید هم‌زمان با تقویت تضمین‌های حقوقی و الزامات اجرایی دنبال شود. بررسی نظام حقوقی ایران نیز نشان می‌دهد که هرچند قانون مبارزه با پولشویی و آیین‌نامه اجرایی آن، با پذیرش رویکرد مبتنی بر ریسک، زمینه حرکت به سوی بهره‌گیری از تحلیل داده را فراهم ساخته‌اند و ایجاد سامانه‌هایی نظیر «سمام» نیز بیانگر آغاز این تحول است، اما این روند همچنان در مراحل اولیه قرار دارد. محدود بودن دامنه عملیاتی برخی زیرساخت‌ها و ضرورت اتصال تمامی اشخاص مشمول به سامانه‌های هوشمند، نشان می‌دهد که تحقق کامل رویکرد داده‌بنیان، مستلزم توسعه زیرساخت‌های فنی، تکمیل نظام تبادل داده و بازنگری مستمر در مقررات متناسب با تحولات فناوری است.

فهرست منابع

۱. ابراهیمی، شهرام. (۱۴۰۱). پیشگیری از تکرار جرم از طریق هوش مصنوعی؛ مقتضیات و محدودیت‌ها، **آموزه‌های**

۲. ابوذری، مهنوش. (۱۴۰۳). مقابله با بزهکاری در عصر هوش مصنوعی: پیش‌بینی به مثابه پیشگیری، **دوفصلنامه تحقیق و توسعه در حقوق کیفری و جرم‌شناسی**، ۱ (۲)، ۶۸-۳۴، 10.22034/jclc.2025.720961
۳. اسماعیلی، محمد. (۱۳۹۶). عدالت پیشگیرنده: مهار جرم در بستر نظام حقوقی، **مطالعات حقوق کیفری و جرم‌شناسی**، ۴ (۲)، ۳۲۶-۲۹۷، 10.22059/jqclcs.2018.239944.1232
۴. بک، اولریش، (۱۳۸۸). **جامعه در مخاطره جهانی**، ترجمه محمدرضا مهدی، تهران: انتشارات: کویر.
۵. تدیس، عباس؛ باقری نژاد، زینب. (۱۳۹۹) هستی‌شناسی اصول بنیادین دادرسی کیفری. **فصلنامه پژوهش حقوق کیفری**، ۹ (۳۳). ۱۸۷-۲۱۹. 10.22054/JCLR.2020.49838.2060
۶. ثالث موید، احمدعلی، خلیلی پاجی، عارف، ملکوتی‌زاده، مصطفی. (۱۴۰۳) **نکات کاربردی جرم‌پولشویی**، مرکز اطلاعات مالی دبیرخانه شورای عالی مقابله و پیشگیری از جرایم پولشویی و تأمین مالی تروریسم، چاپ اول، نشر میزان.
۷. حجازی، سید امرالدین، صلح چی، محمد علی. (۱۳۹۹) شورای امنیت سازمان ملل متحد و تأثیر آن در ایجاد امنیت و عدالت کیفری بین‌المللی، **فصلنامه پژوهش حقوق کیفری**، ۹ (۳۳). ۴۶-۹. doi: 10.22054/jclr.2020.45294.1967
۸. خلیلی پاجی، عارف. (۱۴۰۳) **ارزهای مجازی؛ جهانی شدن بزهکاری و سیاست جنایی**، چاپ دوم، تهران، میزان.
۹. خیرانی، روح اله، زرنشان، شهرام، سلیمانیان، محمدهادی. (۱۴۰۱) ارزیابی وضعیت ایران در ارتباط با مقررات بین‌المللی مرتبط با پولشویی، **پژوهش‌های حقوقی**، ۲۱ (۴۹). ۶۹-۳۹. 10.48300/jlr.2022.148310
۱۰. شاملو، باقر، خلیلی پاجی، عارف. (۱۳۹۹). رویکرد ریسک‌مدار سیاست جنایی در برابر پولشویی، **پژوهشنامه حقوق کیفری**، ۱۱ (۱)، ۱۵۲-۱۲۷، 10.22124/jol.2020.12409.1649
۱۱. کدخدایی، عباسعلی، نوروزپور، حسام. (۱۳۹۹). چالش ارزهای مجازی در مبارزه با پولشویی و تأمین مالی تروریسم با تأکید بر اقدامات و توصیه‌های کارگروه ویژه اقدام مالی، **مجله حقوقی بین‌المللی**، ۳۷ (۶۲). ۲۹-۷. 10.22066/cilamag.2019.101998.1647
۱۲. موسوی‌فر، نجفی. (۱۴۰۴) تأملی در روند هوش مصنوعی در پیشگیری از جرم، **تمدن حقوقی**، ۸ (۲۳)، ۱۹۰-۱۷۱. 10.22034/LC.2025.512833.1612

۱۳. نجفی ابرند آبادی، علی حسین، ایارگر، حسین. (۱۳۹۹) نظارت بر مجرمان خطرناک: چالش ها و راهکارها، **فصلنامه**

پژوهش حقوق کیفری، ۲ (۶). ۳۷-۹.

۱۴. نجفی ابرند آبادی، علی حسین، (۱۳۸۸) **کیفرشناسی نو-جرم شناسی نو درآمدی بر سیاست جنایی**

مدیریتی خطر مدار، تازه های علوم جنایی (مجموعه مقاله ها)، ۷۱۷-۷۵۰، میزان.

15. Ai, Lishan. (2012). "Rule-based but risk-oriented" approach for combating money laundering in Chinese financial sectors. **Journal of Money Laundering Control**, 15(2), 198–209. <https://doi.org/10.1108/13685201211218225>.
16. Ali, Abdulaleem, Shukor Abd Razak, Siti Hajar Othman, Taiseer Abdalla Elfadil Eisa, Arafat Al-Dhaqm, Maged Nasser, Tusneem Elhassan, Hashim Elshafie, and Abdu Saif. 2022. Financial fraud detection based on machine learning: a systematic literature review. **Appl. Sciences** 12 (19), 9637. <https://doi.org/10.3390/app12199637>.
17. Alloghani, Mohamed & Al-Jumeily Obe, Dhiya & Mustafina, Jamila & Hussain, Abir & Aljaaf, Ahmed. (2020). **A systematic review on supervised and unsupervised machine learning algorithms for data science. Supervised and unsupervised learning for data science**, 3-21. https://doi.org/10.1007/978-3-030-22475-2_1.
18. Anthi, Eirini & Williams, Lowri & Rhode, Matilda & Burnap, Pete & Wedgbury, Adam. (2021). Adversarial attacks on machine learning cybersecurity defences in Industrial Control Systems. **Journal of Information Security and Applications**, *57*, 102717. <https://doi.org/10.1016/j.jisa.2020.102717>.
19. AsiaVerify. (2025). Discover how hidden UBO links can derail deals and how to spot them with registry-backed data. <https://asiaverify.com/resources/insights/the-hidden-ubo-web-uncover-business-ownership-risk/>
20. Caglayan, Mehmet., & Bahtiyar, Şerif. (2022). Money Laundering Detection with Node2Vec. **Gazi University Journal of Science**, 35(3), 854-873. <https://doi.org/10.35378/gujs.854725>
21. FATF (2021), Opportunities and Challenges of New Technologies for AML/CFT, FATF, Paris, France, <https://www.fatf-gafi.org/publications/fatfrecommendations/documents/opportunities-challenges-new-technologies-aml-cft.html>,
22. FATF (2025), Money Laundering National Risk Assessment Guidance, FATF, Paris, <https://www.fatf-gafi.org/en/publications/Methodsandtrends/Money-Laundering-National-Risk-AssessmentGuidance.html>. P. 4.
23. FATF. High-risk and other monitored jurisdictions <https://www.fatf-gafi.org/en/topics/high-risk-and-other-monitored-jurisdictions.html>
24. Fei Yin, Qiang Li, Huihui Song, and Wen Lu. 2025. Addressing Digital Finance Challenges: The Application and Op-timization of Logistic Regression Models in Fraud Detection Sys-tems. **In Proceedings of the 2025 2nd International Conference on Innovation Management and Information System (ICIIS '25)**. Association for

Computing Machinery, New York, NY, USA, 8–14.
<https://doi.org/10.1145/3745676.3745678>

25. Financial Crime Academy, "Safeguarding Against Money Laundering: Essential Machine Learning Algorithms for AML," July 13, 2026, <https://financialcrimeacademy.org/machine-learning-algorithms-for-aml/>.
26. Fraud Detection Handbook. (2021). *Chapter 5: Model Validation and Selection - Introduction*. GitHub. Available at: https://github.com/Fraud-Detection-Handbook/fraud-detection-handbook/blob/main/Chapter_5_ModelValidationAndSelection/Introduction.md
27. Girish K., & Bhowmik, B. (2024). "Money Laundering Detection in Banking Transactions using RNNs and Hybrid Ensemble." **15th International Conference on Computing Communication and Networking Technologies (ICCCNT)**, pp. 1-7, IEEE
28. Gupta, Dwijendra Nath Dwivedi & Jigar Shah & Ashish Jain. (2021). Data quality issues leading to sub optimal machine learning for money laundering models. **Journal of Money Laundering Control**, 25(3), 551–555. <https://doi.org/10.1108/JMLC-05-2021-0049>
29. Halder, Rajib & Uddin, Mohammed & Uddin, Md Ashraf & Aryal, Sunil & Khraisat, Ansam. (2024) Enhancing K-nearest neighbor algorithm: a comprehensive review and performance analysis of modifications. **Journal of Big Data** 11, 113. <https://doi.org/10.1186/s40537-024-00973-y>
30. Hu, Chaochen & Li, Ran & Li, Chao & Miao, Hengshuo & Yang, Zongyou & Zhang, Tengda (2022, September). Big Data Analysis for Anti-Money Laundering: A Case of Open Source Greenplum Application. In **International Conference on Web Information Systems and Applications** (pp. 638-645). Cham: Springer International Publishing.
31. Husnaningtyas, Nadia & Hanin, Ghalizha & Dewayanto, Totok & Malik, Muhammad. (2023). A systematic review of anti-money laundering systems literature: Exploring the efficacy of machine learning and deep learning integration. JEMA: **Jurnal Ilmiah Bidang Akuntansi dan Manajemen**. 20. 91-116. 10.31106/jema.v20i1.20602.
32. Koker, Louis. (2009). Identifying and managing low money laundering risk: Perspectives on FATF's risk-based guidance. **Journal of Financial Crime**. 16. 334-352. 10.1108/13590790910993717.
33. Liaw, Andy & Wiener, Matthew (2002). Classification and Regression by randomForest. **R News**, 2(3), 18–22.
34. Mallika, B.K., Ramasubramanian, V.H., 2025. Anti money laundering system in detecting and preventing money laundering activities: a systematic review. **J. Money Laund. Control** 28 (2), 385-407. doi: <https://doi.org/10.1108/JMLC-07-2024-0108>
35. Massimiliano Marletta, 2025, Probabilities, costs, and justice: rethinking precautionary measures in civil and criminal law, **Law, Probability and Risk**, Volume 24, Issue 1, mgaf007, <https://doi.org/10.1093/lpr/mgaf007>. P.2.
36. Mubalalike, A. M., & Adali, E. (2018, September). Deep learning approach for intelligent financial fraud detection system. In 2018 3rd **International Conference on Computer Science and Engineering (UBMK)** (pp. 598-603). IEEE.

37. Mukhamadiyev, A.; Nazarov, F.; Yarmatov, S.; Cho, J. (2025) Intelligent Algorithms for the Detection of Suspicious Transactions in Payment Data Management Systems Based on LSTM Neural Networks. **Sensors**, 25, 6683.
38. Naif Almusallam, Junaid Qayyum, (2025) A Hybrid Feature Selection and Clustering-Based Ensemble Learning Approach for Real-Time Fraud Detection in Financial Transactions, **Computers, Materials and Continua**, Volume 85, Issue 2, Pages 3653-3687, <https://doi.org/10.32604/cmc.2025.067220>
39. Omoseebi, Adetoyese & Ola, Godwin & Tyler, Jackson. (2025). Rule-Based Systems in AML. P.17.
40. Pelckmans, K. (2020). Monitoring High-Frequency Data Streams in FinTech: FADO Versus K-Means. **IEEE Intelligent Systems**, 35(2), 36-42
41. Quattrocchio, S., Anglano, C., Canonico, M., & Guazzone, M. (2020). Technical Solutions for Legal Challenges: Equality of Arms in Criminal Proceedings. *Global Jurist*, 20(1), 20190058. De Gruyter
42. Regula. (2024, October 30). Deepfake fraud costs the financial sector an average of \$600,000 for each company, Regula's survey shows [Press release]. Retrieved from <https://regulaforensics.com/news/deepfake-fraud-costs/>
43. Riccardi, Michele. (2021). Money Laundering Blacklists. 10.4324/9781003212867.
44. Rudin, C. (2019) Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. *Nat Mach Intell* 1, 206–215. <https://doi.org/10.1038/s42256-019-0048-x>
45. Vorobyev, Ivan, Krivitskaya, Anna Krivitskaya, (2022). "Reducing false positives in bank anti-fraud systems based on rule induction in distributed tree-based models." **Computers & Security**, Volume 120, 102786
46. Vududala, Santosh Kumar, (2024) "Enhancing Anti-Money Laundering (AML) Compliance using NICE Actimize: A Data-driven Approach," **International Journal of Computer Techniques**, Volume 11 Issue 2, April 2024. ISSN 2394-2231.
47. Zhang, Y., & Trubey, P. (2019). Machine Learning and Sampling Scheme: An Empirical Study of Money Laundering Detection. **Computational Economics**, 54(3), 1043–1063. <https://doi.org/10.1007/s10614-018-9864-z>

پ) وبسایت

1. www.fiu.gov.ir/sa2ma1
2. www.mckinsey.com/capabilities/risk-and-resilience/our-insights/the-fight-against-money-laundering-machine-learning-is-a-game-changer.