



به کارگیری روش شبکه‌های هوشمند عصبی در شناسایی و رتبه‌بندی رفتاری مشتریان مظنون به پول‌شویی (مورد مطالعه: بانک ملت)

عبدالمهدی ارجمند نژاد^۱

رضا حبیبی^۲

مسعود بابائی کیاپی*^۳

چکیده

پول‌شویی به‌عنوان پدیده‌ای مجرمانه می‌تواند ضمن ایجاد اختلال در عملکرد بانک‌ها، هزینه‌های بسیاری بر آن‌ها تحمیل نماید. استراتژی کنونی اکثر بانک‌های ایران شناسایی این دسته از مشتریان با استفاده از قوانین عمومی می‌باشد که دارای پاسخ‌های مثبت کاذب فراوان بوده و کشف عملیات پول‌شویی را با مشکل مواجه می‌نماید. هدف از این پژوهش فراهم نمودن معیارهایی جهت تشخیص مشتریان بانک با بالاترین احتمال ظن به پول‌شویی با استفاده از الگوریتم‌های هوشمند می‌باشد. در این تحقیق از یک الگو و مدل دو مرحله‌ای برای تجزیه و تحلیل رفتار مشتریان با استفاده از پایگاه داده‌ای در خصوص ویژگی‌های مشتریان و داده‌های مالی آن‌ها در بازه زمانی شش ماهه دوم منتهی به اسفند ۱۴۰۱ و از تکنیک‌هایی همچون نگاهت خود سازمان دهنده (SOM) و قوانین وابستگی برای ایجاد پروفایل جامعی از مشتریان، استفاده شده است. متغیرهای تحقیق شامل داده‌های جمعیت شناختی، سرویس‌های بانکی، تراکنش‌های مالی مشتریان می‌باشند که از پایگاه داده‌ای بانک ملت استخراج شده است. نتایج نشان می‌دهد که مدل پژوهشی به‌خوبی قادر به شناسایی و تحلیل مشتریان مظنون به پول‌شویی می‌باشد که قبلاً توسط بانک عامل، بررسی شده است. با استفاده از هر دو مدل پیشنهادی، نتایج، تفاوت معناداری را نشان نمی‌دهند.

واژه‌های کلیدی: شبکه‌های عصبی مصنوعی، نقشه خودسازمان دهنده، رتبه‌بندی رفتاری، رتبه‌بندی مشتریان بر مبنای ریسک پول‌شویی.

طبقه‌بندی JEL: E42, M15, G21 و C88.

۱. مدرس، مؤسسه عالی آموزش بانکداری ایران، تهران، ایران؛ am.arjmand@cbi.ir
۲. استادیار، مؤسسه عالی آموزش بانکداری ایران، تهران، ایران؛ r_habibi@ibi.ac.ir
۳. دکتری، بانک ملت، تهران، ایران (نویسنده مسئول)؛ masoudbabae1355@gmail.com

مقدمه

واژه پول شویی بیشتر متوجه تطهیر درآمدهای ناشی از اختلاس، رشوه، دزدی، تقلب در بانک‌ها، بیمه‌ها و بازارهای سرمایه، دایر کردن قمارخانه و خانه‌های فساد، قاچاق انسان و کالا، تجارت اسلحه، شرکت در شبکه‌های کلاهبرداری و تأمین مالی تروریسم و غیره می‌باشد که همه این موارد توسعه اجتماعی را هدف قرار داده‌اند (چن و ماتا، ۲۰۱۱).

یکی از جرم‌هایی که منجر به ایجاد اختلال در حوزه‌های اقتصادی و نهادهای مالی به‌ویژه در عملکرد بانک‌ها می‌شود، جرم پول شویی است که هزینه‌های بسیاری بر بانک‌ها تحمیل می‌نماید (لوکارانا، ۲۰۱۹). از این رو فرایند پول شویی می‌تواند آثار منفی زیادی بر فعالیت‌های مالی و اقتصادی داشته باشد. بنابراین شناسایی و پیش‌بینی آن دارای اهمیت بسیار زیادی می‌باشد (پلکیسی و همکاران، ۲۰۱۸). در ایران تا به حال اکثر تحقیقات انجام شده در زمینه رتبه‌بندی مشتریان مظنون به پول شویی کشف قوانین عمومی بوده است. مطالعات بسیار کمی از نقطه نظر رتبه‌بندی رفتاری این دسته از مشتریان در بانک صورت پذیرفته است (کوثری، ۱۳۹۲).

در این زمینه، بانک مرکزی جمهوری اسلامی ایران به‌عنوان مرجع رسمی و ناظر بر عملکرد بانک‌ها در خصوص مبارزه با پول شویی، اقدام به ابلاغ دستورالعمل‌های مبارزه با پول شویی و پیاده‌سازی قواعد ۲۸ گانه‌ای نموده است که در عمل، مستلزم پردازش حجم وسیعی از داده‌ها و اطلاعات در هر روز می‌باشد. به‌عنوان مثال، در بانک ملت و به‌طور متوسط، هر یک از این قواعد با حجم تراکنشی در حدود ۵۰ میلیون در هر روز، دارای خروجی ۴۵۰ الی ۵۰۰ تراکنش مظنون به پول شویی می‌باشد که تعداد آن بالغ بر ۱۲۶۰۰ گزارش (۲۸*۴۵۰) می‌شود. این گزارش‌ها باید در هر روز در واحد مبارزه با پول شویی بانک توسط کارشناسان مربوطه مورد بررسی قرار گرفته و زنجیره عملکرد مالی این دسته از مشتریان از سامانه‌های مختلف استخراج شده و بررسی گردد.

از سوی دیگر، محدودیت تعداد کارشناسان خبره، کندی سیستم‌ها، تراکم پاسخ‌های مثبت کاذب فراوان در هر روز، فرسایشی و پیچیده بودن عملیات شناسایی رفتار مشتریان مظنون به پول شویی و طولانی بودن تهیه گزارشات مربوط به این اشخاص و ارسال آن به مقامات ذی‌ربط، ضرورت استفاده از تکنیک‌های جایگزین مانند الگوریتم‌های هوشمند را نمایان می‌سازد.

1. Chen & Mathe
2. Lokanan
3. Plaksiy et al

در این تحقیق از یک الگو و مدل دو مرحله‌ای برای تجزیه و تحلیل رفتار مشتریان با استفاده از پایگاه داده‌ای در خصوص ویژگی‌های مشتریان و داده‌های مالی آن‌ها استفاده شده است.

مبانی نظری پژوهش

الگوریتم‌ها و روش‌های یادگیری ماشین برای تشخیص تراکنش‌های مشکوک، به‌عنوان یک راه‌حل برای شناسایی، تحلیل ارتباطات، مدل‌سازی رفتار، امتیاز ریسک و تشخیص ناهنجاری مورد استفاده قرار می‌گیرد (ماگومدو و پاولیو^۱، ۲۰۱۸). رویکرد ریسک محور مبارزه با پولشویی، دارای سناریویی مبتنی بر طبقه‌بندی ریسک است. بدین صورت که افراد، مناطق، مشاغل، زمان‌ها و غیره، شناسایی و طبقه‌بندی می‌شوند و بر مبنای تحلیل‌های صورت گرفته سناریوهای کنترلی، تعیین یا بازبینی می‌شوند (روچا- سالازار و همکاران^۲، ۲۰۲۱).

شرایط موجود سیستم ضد پول‌شویی

در حال حاضر رایج‌ترین روش‌های مورد استفاده مؤسسات مالی ایران برای شناسایی و گزارش‌دهی موارد مشکوک مبتنی بر سیستم‌های قانون محور می‌باشند که از سوی مراجع نظارتی مانند بانک مرکزی ج.ا.و ف.ا. (واحد اطلاعات مالی) مستقر در وزارت اقتصاد تدوین می‌گردد. سیستم مبتنی بر قانون (رول‌های ۲۸ گانه)، مجموعه‌ای از قوانین از پیش تعریف شده می‌باشند که معاملات و یا تراکنش‌هایی که با شرایط تعریف شده مطابقت دارند، هشدارهایی را ایجاد می‌کند که باعث تحقیقات و بررسی‌های بیشتر توسط کارشناسان ادارات مبارزه با پول‌شویی بانک‌ها می‌شود. یک اشکال عمده از سیستم‌های قانون محور، تولید حجم قابل توجهی از هشدارهای مثبت اشتباه می‌باشد که از نظر زمان و منابع برای ردیابی موارد، نیاز به بررسی و دارای هزینه هستند (گواورا و همکاران^۳، ۲۰۱۹).

بر مبنای تخمین از هشدارهای اشتباه صادره در سیستم‌هایی بانکی ایران که معمولاً توسط FIU و از طریق پورتال محرمانه اعلام می‌شوند بیش از ۸۰ درصد از کل هشدارهای صادره توسط این سیستم‌های قانون محور اشتباه می‌باشند. در نتیجه، همیشه افزایش تمایل به توسعه ابزارهای پیشرفته‌تر برای

1. Magomedov & Pavelyev
2. Rocha-Salazar et al
3. Guevara et al

تشخیص دقیق تر پول شویی در معاملات وجود داشته تا در کمترین زمان و با بیشترین دقت تراکنش های مشکوک به پول شویی شناسایی گردند.

رتبه بندی ریسک محور مشتریان از منظر پول شویی (RBA) در بانک ملت

رویکرد ریسک محور مبارزه با پول شویی در بانک ملت، دارای سناریویی مبتنی بر طبقه بندی ریسک مشتریان در سه خوشه یا طبقه (۱- دارای ریسک بالا، ۲- دارای ریسک متوسط و ۳- دارای ریسک پایین) می باشد. بدین صورت که مشتریان بر مبنای شاخص های متعدد، امتیاز ریسک متناسب با آن را دریافت خواهند نمود و با توجه به جمع امتیازهای مربوطه در یکی از طبقات ریسک اشاره شده قرار خواهند گرفت. نحوه توزیع امتیاز به گونه ای است که اگر دامنه امتیاز به دست آمده تا ۳۳ باشد، مشتریان عادی و با ریسک کم قلمداد می گردند و در صورتی که جمع امتیازهای به دست آمده در دامنه ۳۳ تا ۶۶ باشد جزء مشتریان با ریسک متوسط بوده و از ۶۶ به بالا جزء مشتریان پر خطر محسوب می گردند. در نهایت بر مبنای تحلیل های صورت گرفته، سناریوهای کنترلی تعیین و استراتژی های نحوه تعامل با دسته های مختلف مشتریان اعمال می شوند.

جدول ۱: رتبه بندی مشتریان مظنون به پول شویی در بانک ملت

رتبه بندی مشتری	امتیاز	رتبه
	بین ۱ تا ۳۳	کم ریسک
	بین ۳۳ تا ۶۶	ریسک متوسط
	بالتر از ۶۶	ریسک بالا

داده کاوی و روش های کشف دانش

داده کاوی عبارت است از "استخراج اطلاعات و دانش و کشف الگوهای پنهان از یک پایگاه داده های بسیار بزرگ". این دانش و الگوها معمولاً مستتر در داده می باشند. از داده کاوی می توان برای انجام کارهایی مثل دسته بندی^۱، پیش بینی^۲، تخمین^۳ و خوشه بندی^۴ داده ها استفاده نمود. برای انجام این کارها تکنیک هایی توسعه یافته اند که با توجه به پیشرفت کامپیوتر و این علم همه روزه بر تعداد و

1. Classification
2. Prediction
3. Estimation
4. Clustering

کیفیت این تکنیک‌ها افزوده می‌شود. تعدادی از معروف‌ترین این تکنیک‌ها عبارتند از: الگوریتم‌های خوشه‌بندی، شبکه‌های عصبی^۱، الگوریتم‌های ژنتیک^۲، نزدیک‌ترین همسایگی^۳ و درخت تصمیم‌گیری^۴ (کیم^۵، ۲۰۰۷). ویژگی‌های داده‌کاوی سبب شده که امروزه در تجارت و کسب‌وکار از آن بسیار استفاده شود. شرکت‌های مخابراتی، بانک‌ها، شرکت‌های بازاریابی و تبلیغاتی و کلیه شرکت‌هایی که از بانک‌های اطلاعاتی بزرگی برخوردار بوده و از اهمیت اطلاعات و آگاهی در بازار خبر دارند می‌توانند از داده‌کاوی به‌عنوان ابزار بسیار قوی برای رشد و پیشرفت در بازار استفاده کنند (چن^۶، ۲۰۱۸).

فعالیت‌های پایگاه داده‌ها

- ۱- **دریافت داده:** سیستم‌های انبار داده مختلف، نیاز به دریافت داده در بازه‌های زمانی متفاوتی را دارند ولی معمولاً داده‌های کل مجموعه هر ماه یا هر چندماه یکبار برای انبار فرستاده می‌شوند.
- ۲- **پاک‌سازی:** پاک‌سازی داده‌ها عبارت است از شناسایی و حذف خطاها و ناسازگاری‌های داده‌ای به‌منظور دستیابی به داده‌هایی با کیفیت بالاتر.
- ۳- **یکپارچه‌سازی:** این فاز شامل ترکیب داده‌های دریافتی از منابع اطلاعاتی مختلف، استفاده از متاداده‌ها برای شناسایی و حذف افزونگی داده‌ها، تشخیص و رفع برخوردهای داده‌ای می‌باشد.
- ۴- **تبدیل داده‌ها:** در این فاز، داده‌های ورودی طی مراحل زیر به شکلی که مناسب عمل داده‌کاوی باشند، در می‌آیند:
 - هموارسازی^۷: منظور از داده‌های نویزی، داده‌هایی هستند که در خارج از بازه مورد نظر قرار می‌گیرند.
 - ادغام^۸: ادغام داده‌ها به معنی به‌دست آوردن اطلاعات جدید از ترکیب داده‌های موجود می‌باشد.
 - کلی‌سازی^۹: کلی‌سازی به معنی دسته‌بندی داده‌های موجود براساس ماهیت و نوع آن‌ها است.

-
1. Neural Network
 2. Genetic Algorithm
 3. Nearest Neighboring
 4. Decision Tree
 5. kim
 6. Chen
 7. Smoothing
 8. Aggregation
 9. Generalization

- نرمال سازی^۱: منظور از نرمال سازی، تغییر مقیاس داده‌ها است. به عنوان مثالی از نرمال سازی، می‌توان به تغییر بازه یک فیلد از مقادیر موجود به بازه ۰ تا ۱ اشاره کرد.
- افزودن فیلدهای جدید: گاهی اوقات برای سهولت عمل داده‌کاوی می‌توان فیلدهایی به مجموعه فیلدهای موجود اضافه کرد (چن و وانگ، ۲۰۱۸).

معرفی بعضی از روش‌های داده‌کاوی

هرگاه داده‌ها دارای خصیصه‌ای خاص باشند که مستقیماً از دیگر خصایص بوجود نیامده باشند اما بین آن مشخصه و دیگر ابعاد رابطه وابستگی وجود داشته باشد، در این صورت می‌توان با کشف مدلی بر مبنای دیگر مشخصه‌ها، آن بعد مذکور (که نشان‌دهنده دسته خاصی از داده‌ها است) را شناسایی نمود (هسو^۲، ۲۰۰۸).

خوشه‌بندی

از نظر مفهومی خوشه‌بندی یعنی گروه‌بندی یک‌سری موجودیت در گروه‌های مختلف به طوری که این گروه‌ها نشان دهنده مفهوم یا معنی خاصی باشند و یا به عبارت ساده‌تر به یکدیگر شبیه باشند. از دیدگاهی علمی‌تر خوشه‌بندی یعنی دسته‌بندی داده‌ها به k گروه مختلف به طوری که داده‌هایی که در یک دسته قرار می‌گیرند به یکدیگر شبیه باشند و داده‌های دسته‌های مختلف با یکدیگر تفاوت داشته باشند (کیم، ۲۰۰۶).

قوانین وابستگی^۳

قوانین وابستگی داده‌کاوی که ابتدا توسط آگراول^۴ (۱۹۹۳) توسعه داده شدند، یکی از معروف‌ترین تکنیک‌های داده‌کاوی بوده و کاربردهای وسیعی در کسب و کار سنتی و کسب و کارهای الکترونیکی پیدا کرده‌اند. فروش، طراحی کاتالوگ، تعیین چیدمان فروشگاه و بخش‌بندی مشتریان و همچنین، بهبود و شخصی‌سازی صفحات وب سایت، نمونه‌هایی از کاربرد قوانین وابستگی داده‌کاوی در کسب و کارهای سنتی و الکترونیکی می‌باشند (چن، ۲۰۱۸).

1. Normalization
2. Hsu
1. Association Rules
4. Agrowal

شبکه‌های عصبی مصنوعی

شبکه عصبی مصنوعی یک سیستم پردازش اطلاعات است که ویژگی‌های عملکردی مشابه شبکه عصبی بیولوژیکی دارد. شبکه‌های عصبی مصنوعی به‌عنوان مدل‌های ریاضی تعمیم یافته از نورون‌های بیولوژیکی یا شناخت انسان براساس مفروضات زیر توسعه یافته است:

- ❖ پردازش اطلاعات در واحدهای بسیار ساده‌ای که نورون نامیده می‌شوند، رخ می‌دهد.
- ❖ سیگنال‌های نورون‌ها از طریق اتصالات، انتقال می‌یابد.
- ❖ هر ارتباط وزنی دارد که در یک شبکه عصبی متداول، در سیگنال ورودی ضرب می‌شود.
- ❖ هر نورون یک تابع فعال‌سازی (که عمدتاً غیرخطی است) دارد (چن، ۲۰۱۸).


اجزا و ساختار شبکه‌های عصبی مصنوعی

یک شبکه از عناصر پردازشی تشکیل می‌شود. این عناصر پردازشی را می‌توان به طرق مختلف یا در معماری‌های گوناگون سازماندهی کرد.

عناصر پردازشی: یک شبکه عصبی مصنوعی متشکل از نورون‌های مصنوعی (که به‌طور خلاصه به آن‌ها نورون می‌گویند) می‌باشد که در واقع همان عناصر پردازشی (PE^1) هستند. هر کدام از این نورون‌ها، درون داده‌ها را دریافت و پردازش می‌کنند و در نهایت، یک برون‌داد از آن ارائه می‌دهند. درون‌داد می‌تواند داده‌های خام یا برون‌داد دیگر عناصر پردازشی باشد. برون‌داد می‌تواند محصول نهایی یا درون‌دادی برای یک نورون دیگر باشد.

شبکه: هر ANN از مجموعه نورون‌هایی تشکیل می‌شود که در قالب لایه‌هایی گروه‌بندی می‌شوند. شبکه متشکل از سه لایه می‌باشد؛ لایه ورودی، لایه میانی (که به آن لایه پنهان نیز گفته می‌شود) و لایه خروجی.

متغیرها با وزن و اهمیت خود به‌عنوان محرک‌های ورودی از طریق لایه ورودی وارد شبکه شده و در صورتی که نورون‌های عصبی به آستانه تحریک برسند، پیام عصبی ایجاد شده از طریق نورون‌های خروجی یا به‌عنوان محصول نهایی و یا به‌عنوان محرکی برای نورون‌های عصبی دیگر عمل خواهند نمود.



شکل ۱: ساختار لایه‌های شبکه عصبی مصنوعی

ساختار شبکه: همانند شبکه‌های بیولوژیکی، هر کدام از ANN ها را نیز می‌توان با توپولوژی‌های^۱ مختلف سازماندهی کرد؛ به عبارت دیگر، نورون‌ها می‌توانند به طرق مختلف به هم متصل شوند و با هم ارتباط داشته باشند. بنابراین ANN ها در اشکال گوناگون پدیدار می‌شوند. بسیاری از عناصر پردازشی اطلاعات، محاسباتشان را به‌طور همزمان انجام می‌دهند. این پردازش موازی^۲ شبیه روشی است که مغز عمل می‌کند و در مغایرت با پردازش متوالی^۳ در محاسبات سنتی است (کیم^۴، ۲۰۰۶).

تابع مجموع (جمع‌کننده)

از طریق تابع مجموع می‌توان میانگین موزون تمامی عناصر درون‌داد را در هر یک از عناصر پردازشی محاسبه کرد. یک تابع مجموع، ارزش‌های مربوط به درون‌دادها (X_i) را در وزن‌های (W_s) مربوطه ضرب و سپس مجموع آن‌ها (Y) را محاسبه می‌کند. به‌عنوان مثال برای n درون‌داد i که به عنصر پردازشی j وارد می‌شوند، رابطه ۱ برقرار است:

1. Topologies
2. Parallel Processing
3. Serial Processing
4. Kim

$$Y_i = \sum_i^n X_i * W_{ij} \quad \text{رابطه (۱)}$$

تابع تبدیل (انتقالی)

تابع جمع‌کننده، تحریک داخلی یا سطح فعال شدن داخلی از یک نورون را محاسبه می‌کند. گاهی اوقات به تابع جمع‌کننده، تابع فعال‌سازی می‌گویند) بر مبنای این سطح، نورون ممکن است یک برون‌داد تولید کند یا برون‌دادی تولید نکند. رابطه بین سطح فعال شدن داخلی و برون‌داد، ممکن است خطی یا غیرخطی باشد. چنین رابطه‌ای توسط تابعی بنام تابع تبدیل، توصیف می‌شود. این تابع انواع مختلفی دارد. انتخاب نوع خاصی از این تابع است که عملیات شبکه را تعیین می‌کند. یکی از توابع غیر خطی بسیار مشهور، تابع سیگموئیدی^۱ نام دارد:

$$Y_t = \frac{1}{1 + e^{-y}} \quad \text{رابطه (۲)}$$

که Y_t عبارت از ارزش تبدیل‌شده (نرمال شده Y) است (چن، ۲۰۱۸).

یادگیری

یک شبکه عصبی مصنوعی از اشتباهاتش، یادگیری به عمل می‌آورد. معمولاً فرآیند یادگیری یا آموزش شامل سه وظیفه (فعالیت) می‌باشد: ۱. محاسبه کردن برون‌دادها ۲. مقایسه برون‌دادها با پاسخ‌های مطلوب (مورد نظر) ۳. تعدیل وزن‌ها و تکرار فرآیند معمولاً فرآیند یادگیری با انتخاب تصادفی وزن‌ها آغاز می‌شود. تفاوت بین برون‌داد واقعی (Y_t یا Y) و برون‌داد مورد نظر (Z)، دلتا (Δ) نامیده می‌شود. در اینجا هدف حداقل کردن دلتا (یا حتی بهتر، به صفر رساندن آن) می‌باشد. کاهش دلتا از طریق ایجاد تغییرات تدریجی در وزن‌ها انجام می‌گردد. پردازش اطلاعات با استفاده از شبکه عصبی مصنوعی شامل تجزیه و تحلیل الگوهای فعالیت (شناسایی الگو) می‌باشد.

یادگیری با ناظر

در یادگیری با ناظر به قانون یادگیری مجموعه‌ای از زوج داده‌ها به نام (داده‌های یادگیری) $\{(P^i, t^i); i = 1, 2, \dots, L\}$ می‌دهند که در آن ورودی به شبکه و t^i خروجی مطلوب شبکه برای ورودی P^i است. پس از اعمال ورودی به شبکه عصبی در خروجی شبکه a^i با t^i مقایسه شده و سپس خطای یادگیری محاسبه و از آن جهت تنظیم پارامترهای شبکه استفاده می‌شود. به گونه‌ای که اگر دفعه بعد به شبکه همان ورودی P^i اعمال شود خروجی شبکه به t^i نزدیک‌تر می‌گردد. پارامترهای شبکه عصبی توسط دو سیگنال ورودی و خطا تنظیم می‌شوند. به این صورت که پس از چند تکرار، الگوریتم یادگیری به پارامترهایی در فضای پارامترهای شبکه، همگرا می‌شوند (یانگ، ۲۰۱۹).

یادگیری بدون ناظر

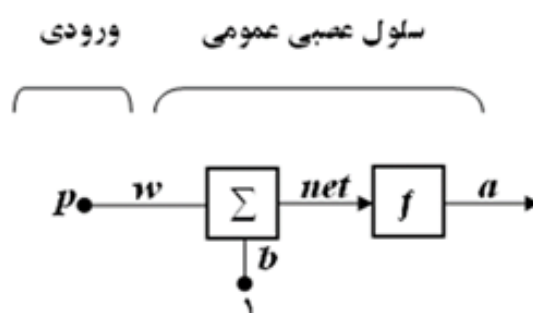
در یادگیری بدون ناظر یا یادگیری خود سازمانده^۱ پارامترهای شبکه تنها توسط پاسخ سیستم اصلاح و تنظیم می‌شوند. به عبارتی دیگر تنها اطلاعات دریافتی از محیط به شبکه را بردارهای ورودی تشکیل می‌دهند و بردار جواب مطلوب به شبکه اعمال نمی‌شود. در این حالت، شبکه وزن‌های خود را طوری تنظیم می‌کند که داده‌هایی که بیشترین شباهت را نسبت به هم دارند به خروجی یا طبقه یکسانی اختصاص داده می‌شوند. شبکه‌های خود سازمانده نمونه‌ای از این یادگیری را انجام می‌دهد که معروف‌ترین آن‌ها شبکه‌های کوهونن^۲ هستند (فوست^۳، ۲۰۱۹).

1. Self -Organized
2. Kohonen
3. Fausett

مدل ریاضی نورون

- مدل تک ورودی

اسکالرهایی p و a به ترتیب ورودی و خروجی می‌باشند.



شکل ۲: مدل سلول عصبی تک ورودی

میزان تأثیر p روی a بوسیله مقدار اسکالر w تعیین می‌شود. ورودی دیگر که مقدارش ثابت 1 است در جمله تورش b ضرب می‌شود و سپس با wp جمع می‌شود، این حاصل جمع ورودی خالص n برای تابع محرک (تابع تبدیل) f خواهد بود. بدین ترتیب خروجی نورون با معادله ۳ تعریف می‌شود.

$$a = f(wp+b) \quad \text{رابطه ۳}$$

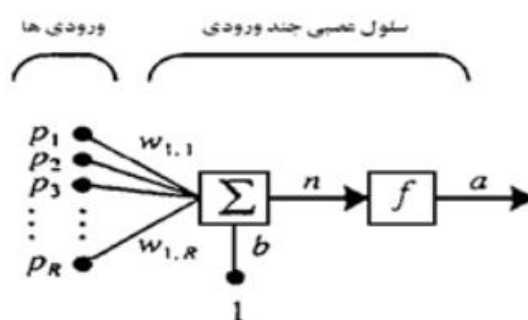
با مقایسه این نورون تک ورودی با یک نورون بیولوژیکی عملاً w معادل شدت سیناپس^۱ جمع‌کننده و تابع محرک معادل هسته سلول و سیگنال خروجی نورون a معادل سیگنال گذرنده از اکسون خواهند بود. نکته‌ای که باید به آن توجه شود، اهمیت و تأثیر جمله تورش b است. این جمله را می‌توان مانند وزنه w در نظر گرفت با این تصور که میزان تأثیر ورودی ثابت 1 را روی نورون منعکس می‌سازد. اهمیت جمله b بیشتر جهت افزایش محدوده پیش‌بینی نورون‌ها به کار می‌رود. باید توجه داشت که پارامترهای b و w قابل تنظیم هستند و تابع محرک f نیز توسط طراح انتخاب می‌شود. بر مبنای انتخاب f و نوع

1. Synapse

الگوریتم یادگیری پارامترهای b و w تنظیم می‌شوند. یادگیری بدین معنی است که b و w طوری تغییر می‌کنند تا رابطه ورودی و خروجی نورون با هدف خاصی مطابقت نماید.

- مدل چند ورودی

عموماً یک نورون، بیش از یک ورودی دارد شکل زیر یک مدل نورون با R ورودی را نمایش می‌دهد (چونگ، ۲۰۱۷).



شکل ۳: مدل سلول عصبی چند ورودی

- نگاشت خودسازمانده کوهونن

شبکه‌های خود سازمانده به‌طور گسترده‌ای در داده‌کاوی، نمایش فضاهای پیچیده و خوشه‌بندی فضاهای با ابعاد بالا و به‌طور خاص در پردازش تصویر، کنترل فرآیند، مدیریت پروژه، آنالیزهای مالی و تشخیص‌های صنعتی و پزشکی مورد استفاده قرار می‌گیرند (چن، ۲۰۲۰).

این شبکه از انواع شبکه‌های عصبی با قابلیت یادگیری با ناظر و بدون ناظر^۱ می‌باشد که در تحلیل فضاهای پیچیده، توانایی زیادی دارد. این مدل از شبکه‌های عصبی اولین بار توسط کوهونن (۱۹۸۱) و با الگوبرداری از عصب‌های شبکیه چشم، معرفی و در سال ۱۹۸۴ برای تشخیص صدا به‌طور عملی مورد استفاده قرار گرفت (کوهونن، ۱۹۹۸).

قابلیت این شبکه در ارائه خروجی در قالب نقشه‌های گرافیکی گویا و قابل فهم برای مدیران سازمان-ها، توانایی نمایش روابط خطی و غیرخطی بین متغیرها، قدرت بالا در دسته‌بندی دادگان، عدم حساسیت

شبکه به تعداد دادگان تعلیم و حساسیت کم این نوع شبکه‌ها به وجود نوین در دادگان تعلیم، این ابزار را به ابزاری کارآمد جهت استفاده در مدل‌سازی تبدیل نموده است. (یانگ و چونگ، ۲۰۱۸)


یک نقشه خود سازمان‌دهنده نوعی شبکه عصبی مصنوعی است که با استفاده از یادگیری هدایت‌نشده یا هدایت‌شده برای تولید نمایش‌گر با ابعاد کم نمونه‌های آموزشی استفاده می‌شود، درحالی‌که ویژگی‌های توپولوژیکی فضای ورودی را حفظ می‌کند. از این‌رو، نگاشت خود سازمان‌دهنده برای به تصویر کشیدن مناظری با ابعاد کم از داده‌های با ابعاد زیاد جهت مقیاس‌گذاری چند بعدی مفید است. این نقشه‌ها می‌توانند طبقه‌بندی بردارهای ورودی را یاد بگیرند به گونه‌ای که آن‌ها را در فضای ورودی گروه‌بندی نمایند. نورون‌های همسایه در نقشه خود سازماندهنده تشخیص بخش‌های همسایه فضای ورودی را یاد می‌گیرند. بنابراین، نقشه‌های خودسازمانده، هم توزیع و هم توپولوژی بردارهای ورودی را در زمان آموزش یاد می‌گیرند (یانگ، ۲۰۱۸).

نورون‌ها در لایه‌ای از یک نگاشت خود سازمان‌دهنده اصولاً در موقعیت‌های فیزیکی براساس یک تابع توپولوژی آرایش داده می‌شوند. نورون‌ها در توپولوژی‌های شطرنجی، شش ضلعی یا تصادفی آرایش می‌یابند. فواصل بین نورون‌ها از موقعیت‌هایشان با یک تابع فاصله محاسبه می‌شوند.

شبکه نگاشت خود سازمان‌دهنده معمولاً دو لایه از گروه‌ها دارد: یک لایه ورودی و یک لایه خروجی. نورون‌ها در لایه خروجی در یک شبکه مرتب می‌شوند و از همسایه‌هایشان در این شبکه تأثیرپذیر هستند. هدف خوشه‌بندی خودکار نمونه‌های ورودی به روشی است که نمونه‌های مشابه توسط نورون‌ها خروجی مشابهی نشان داده می‌شوند (چونگ، ۲۰۱۸).

از آن‌جا که هر یک از متغیرهای مشخصه به هر نورون خروجی توسط یک اتصال وزنی مرتبط می‌شود، هر نورون خروجی j ($j = 1, \dots, K$) تعداد مشابهی وزن w_j هم بسته به تعداد متغیرهای ورودی دارد که با وزن‌های اولیه تصادفی شروع کرده و تعدیل وزن‌هایش را براساس نمونه‌های ورودی به صورت ذیل یاد می‌گیرد. زمانی که یک نمونه ورودی، x_i به شبکه نگاشت خود سازمان‌دهنده وارد می‌شود، نورون‌ها فاصله بین بردارهای وزنی $w_j = (w_{j1}, w_{j2}, \dots, w_{jp}, \dots, w_{jp})$ و ورودی $x = (x_{i1}, x_{i2}, \dots, x_{ip}, \dots, x_{ip})$ را محاسبه می‌کنند. سپس، نورون با حداقل فاصله به نام برند با استفاده از فرمول ۳ تعیین می‌شود. نمونه‌ای از معماری یک شبکه نگاشت خود سازمان‌دهنده در شکل ۴ نشان

داده شده است، در این شکل اجزا و ساختار آن به صورت شبکه دو لایه‌ای با اسکالره‌های ورودی و خروجی نشان داده شده است.



شکل ۴: معماری نمونه یک شبکه نگاشت خودسازمان دهنده (چونگ، ۲۰۱۸)

$$\text{Min } D_j = \sqrt{\sum_{p=1}^p [x_{ip} - w_{jp}]^2} \quad \text{رابطه ۳}$$

که w_{jp} وزن j امین نورون پیوند داده شده به P امین متغیر است (یانگ^۱، ۲۰۱۸).

پیشینه پژوهش‌های خارجی

چوا^۲ (۲۰۱۹) برای شناسایی تراکنش‌های مشکوک منجر به پول شویی از روش خوشه‌بندی بر درخت پوشای مینیمم بهبود یافته که براساس معیار عدم شباهت ساخته می‌شود، استفاده کرد. در این تحقیق از یک مجموعه داده تجاری جهت پیاده‌سازی نتایج استفاده شده است. مزیت این روش ارائه یک پارامتر نامتجانس جهت اندازه‌گیری تفاوت درجات پرت و سپس طراحی الگوریتم کشف پول شویی است.

1. Yang

2 Chao

جولوم و همکاران^۱ (۲۰۲۰) با به کارگیری الگوریتم‌های یادگیری ماشین جهت شناسایی فعالیت‌های پول شویی با استفاده از الگوریتم خوشه‌بندی (k-mean و BIRCH) توانسته‌اند به صورت کارآمدتر تراکنش‌های مشکوک را شناسایی کنند. بدین ترتیب که برای هر داده مالی از گره تا برگ را جستجو کرده و در برگ، درباره اینکه در گروه بماند یا خیر تصمیم گرفته می‌شود که البته روی دامنه محدودی قابل اجراست. در این تحقیق از یک مجموعه داده خاص جهت پیاده‌سازی و آزمایشات استفاده شده که به نام و منبع آن اشاره‌ای نشده است.

در مقاله لو^۲ (۲۰۱۴) با استفاده از الگوهای تکرار و قواعد انجمنی برای آشکارسازی فعالیت‌های ضد پول شویی (AML) و تمرکز روی کشف تراکنش‌های مشکوک در جریان تراکنش‌های تجاری کار شده است. در این روش، به تراکنش‌های تجاری به عنوان جریانی از داده‌ها توجه شده و روش به دست آوردن پویایی برای آشکارسازی الگوهای مشکوک روی جریان تراکنش‌ها به کار برده است؛ مخصوصاً یک الگوریتم دسته‌بندی (کلاس‌بندی) بر اساس قوانین ارتباط چند کلاسی روی جریان‌های داده‌ها با ایجاد یک درخت الگوی تکرار^۳ برای بهبود زمان و فضای کارآمد و سپس کاهش تکرار قوانین بوسیله حد هاؤفدینگ^۴ (محدود کردن جمع تعدادی متغیر تصادفی مستقل کران‌دار) روی جریان‌های پویای داده‌ها پیشنهاد شده است. از مزایای این روش، مقیاس‌پذیری در مجموعه داده‌های بزرگ می‌باشد. در این تحقیق، به مجموعه داده استفاده شده در پیاده‌سازی الگوریتم اشاره نشده است. ضمن آن که این روش در مقیاس پایین، از دقت مناسبی برخوردار نیست.

شیخ و همکاران^۵ (۲۰۱۸) در مقاله خود مدلی را جهت شناسایی اجتماع و روابط بین تراکنش‌ها و مشتریان با استفاده از تحلیل شبکه‌های اجتماعی ارائه دادند. با کمک این مدل، گروه‌ها و باندهای مافیایی که نقش اصلی در فعالیت‌های پول شویی بازی می‌کنند، شناسایی می‌شوند. در این روش یک شبکه اجتماعی با استفاده از گراف شبکه‌ای معنایی و فعالیت‌های شبکه‌هایی از قبیل درجه مرکزیت و خوشه‌بندی و غیره جهت شناسایی مشتریان مشکوک ساخته می‌شود. درجه مرکزیت جهت شناسایی سرشاخه‌ها در گروه‌های اجتماعی کاربرد دارد و هدف از خوشه‌بندی، جداسازی گروه‌هایی با شخصیت‌های مشابه و یا مبتنی بر شاخص‌های ویژه از شاخه‌ها که با دیگر خوشه‌ها نسبت دارند، می‌باشد. شناسایی گروه‌های

1. Jullum et al

2. Luo

3. FP-Tree

4. Hoeffding

5. Shaikh et al

مشکوک در شبکه‌های اجتماعی از مزایای این روش تلقی می‌شود ولی این مورد که هیچ ارتباط خاصی در تحلیل بین حساب‌های بانکی و عملیات انجام شده دیده نمی‌شود از نقاط ضعف این روش می‌باشد.

پیشینه پژوهش‌های داخلی

در مقاله کوثری و همکاران (۲۰۱۲) با به‌کارگیری الگوریتم‌های تصمیم‌گیری جهت کشف رفتارهای مشکوک امکان مدل‌سازی رفتار کاربران در پنج دسته مختلف بوجود آمده که با دقت بیشتری نوع رفتار کاربر را پیش‌بینی می‌کند؛ ولی این نظریه در حد تئوریک بوده و عملیاتی نشده است. داده‌های آموزشی این پژوهش به تعداد ۱۰۰،۰۰۰ رکورد اولیه به‌عنوان نمونه واقعی از یک بانک خصوصی دریافت شده است. این مقاله با پژوهش محقق دارای وجه تمایز و تشابهی به شرح ذیل می‌باشد:

وجه تشابه: ۱- هر دو تحقیق در زمینه کشف رفتارهای مشکوک و تحلیل رفتار آن‌ها در بانک، به‌کار برده شده است. ۲- تعداد داده‌های هر دو پژوهش تقریباً یکسان بوده است. ۳- هر دو محقق از تکنیک‌ها و الگوریتم‌های شبکه هوشمند عصبی استفاده نموده‌اند.

وجه تفاوت: ۱- داده‌های به‌کار گرفته شده در تحقیق آقای کوثری آموزشی بوده درحالی‌که داده‌های این پژوهش دارای الگو (مشتریان مظنون به پول‌شویی و معرفی شده از سوی FIU) و مبتنی بر عملیات تراکنشی مشتریان بوده‌اند. ۲- الگوریتم به‌کار گرفته شده در این تحقیق، نگاشت خود سازمان‌دهنده از نوع یادگیری با ناظر بوده درحالی‌که الگوریتم به‌کار گرفته شده در تحقیق آقای کوثری و همکاران از نوع درخت تصمیم بوده است. ۳- در تحقیق آقای کوثری داده‌ها در پنج خوشه قرار می‌گیرند، درحالی‌که در این پژوهش در چهار خوشه قرار گرفته است.

در مقاله حیدری‌نیا و همکاران (۲۰۱۴) با مطالعه‌ی پروفایل کاربران، تعدادی از ویژگی‌ها شامل معاملات مالی حجیم در مناطق ریسک‌پذیر از دیدگاه پول‌شویی، فعال شدن حساب راکد با مقادیر قابل توجه و غیره استخراج شدند. آموزش شبکه با استفاده از طراحی یک سیستم فازی، توسعه‌ی یک سیستم استنتاج عصبی - فازی وفقی و اضافه کردن بردار ویژگی‌های کاربران به آن انجام شده است. سپس خروجی شبکه می‌تواند میزان ریسک رفتار کاربر را تعیین نماید. این روش ترکیبی با توجه به صحت و سرعت قابل قبول برای مجموعه داده‌های حجیم انتخاب مناسبی خواهد بود. روش پیشنهادی مبتنی بر ¹ANFIS است که یک روش ترکیبی فرا ابتکاری می‌باشد؛ چراکه ویژگی‌ها و قابلیت‌های مناسبی دارد. سیستم استنتاج عصبی - فازی وفقی، الگوریتم‌های منطق فازی و شبکه عصبی را به‌کار می‌گیرد تا بین

حوزه‌های ورودی و خروجی نگاشت غیر خطی ایجاد کند. با استفاده از قدرت زبان فازی و قدرت عددی شبکه‌های عصبی، ANFIS در مدل‌سازی فرایندهای پیچیده بسیار قدرتمند خواهد بود. سیستم فازی با استفاده از ویژگی‌های مستخرج از داده‌های بانکی و برخی از قواعد فازی، طراحی شده و با استفاده از الگوهای بهینه‌ی ایجاد شده در یک سیستم ANFIS، پول‌شویی هوشمندانه را مشخص می‌کند. دقت ناشی از این سیستم پیشنهادی ۹۶ درصد است. پیاده‌سازی این روش بر روی مجموعه داده‌های یک بانک (به نام آن اشاره‌ای نشده است) صورت گرفته است. از مزایای این روش می‌توان به مناسب بودن برای داده‌های حجیم، سرعت قابل قبول و دقت بالا اشاره نمود.

روش شناسایی تحقیق:

در این تحقیق ابتدا با مطالعه ادبیات موضوع از چندین مقاله معتبر، متغیرهای مهم برای دسته‌بندی مشتریان مظنون به پول‌شویی تعیین شده است و چهار مجموعه از داده‌ها شامل داده‌های تراکنش‌های مالی و داده‌های جمعیت شناختی مشتریان و نیز مجموعه داده‌های سایر مراجع یعنی واحد اطلاعات مالی (FIU)، قواعد ۲۸ گانه بانک مرکزی و سرویس‌های بانکی، جهت خوشه‌بندی مشتریان مورد استفاده قرار گرفته است. در ادامه تحقیق پس از تعیین متغیرها، با استفاده از روش خود سازمان‌دهنده شبکه‌های عصبی، مشتریان طبقه‌بندی شده و با استفاده از قوانین وابستگی، رابطه مشتریان مظنون به پول‌شویی با دیگر گروه‌های مشتریان تعیین می‌گردد.

در رتبه‌بندی به دسته‌بندی مشتریان براساس نرم‌افزار Spss Clementin و ماژول Som¹ پرداخته شده است. پس از تعیین دسته‌های مشتریان و شناسایی مشتریان مظنون به پول‌شویی، استراتژی‌هایی که بانک در برخورد با هر یک از دسته‌ها باید به کار برد، مورد بررسی قرار گرفته است. نقشه خود سازمان‌دهنده یک الگوریتم یادگیرنده بدون نظارت و یا بانظر می‌باشد که داده‌های چند بعدی را به‌عنوان بردارهای ورودی مشابه به مکان‌های مشابه از نقشه عصبی ارتباط می‌دهد و قوانین همبستگی را برای پیدا کردن ارتباطات بین اقلام یا ویژگی‌هایی که به‌صورت هم‌زمان در یک پایگاه داده رخ می‌دهند، استفاده می‌کند. از طریق رتبه‌بندی رفتاری مشتریان به پیش‌بینی گروه‌های مشتریان مظنون به پول‌شویی و پیش‌بینی مدل‌های رفتاری آنان پرداخته شده است. پس از شناسایی مشتریان مظنون به پول‌شویی، نماینده هر مورد در هر گروه از مشتریان، خدمات دریافت شده را به‌عنوان ابزاری برای پایه‌گذاری برنامه‌های استراتژیک بانک در نحوه تعامل با این دسته از مشتریان شرح می‌دهد. تخصیص رتبه‌های رفتاری

1. Self-organizing map

به هر مشتری و گروه‌بندی این مشتریان در دسته‌های با ارزش مرتبه‌ای برابر توسط تکنیک‌های فوق صورت می‌پذیرد. در این تحقیق از شاخص‌های اسمی رفتار تراکنش مالی و شاخص‌های عملکردی برای رتبه‌بندی مشتریان استفاده شده است.

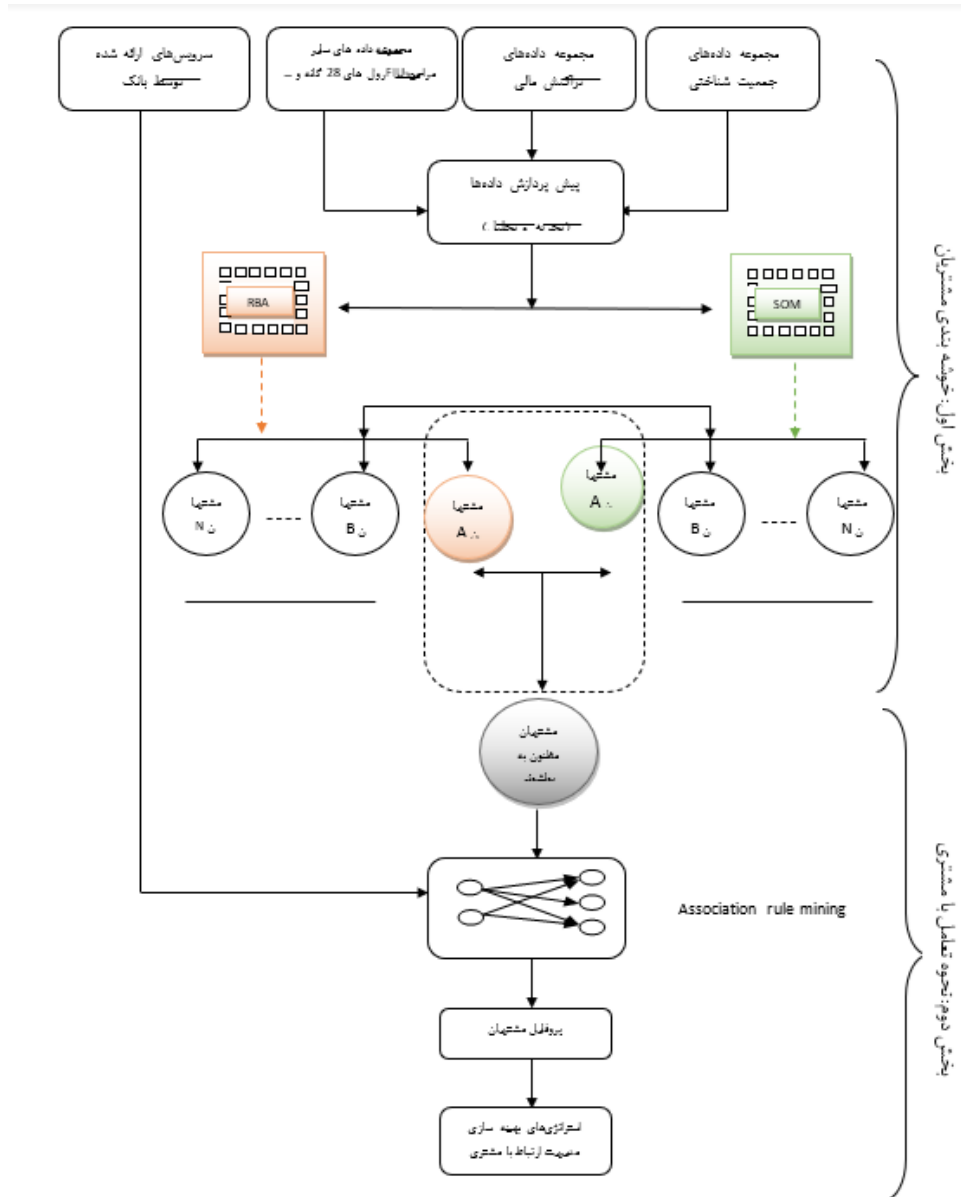
سرانجام با استفاده از شاخص‌های عملکردی تعیین شده می‌توان درستی و مناسب بودن نتایج برای بانک در جهت تعیین استراتژی‌های تعامل با این دسته از مشتریان را مشخص ساخت. این تحقیق قصد دارد از طریق به‌کارگیری مدل‌های رتبه‌بندی رفتاری برای تجزیه و تحلیل رفتار مشتریان که شامل ضرورت پیش‌پردازش از مجموعه داده‌های واقعی (داده‌های حساب‌ها و تراکنش‌های مالی) است و همچنین با به‌کارگیری تکنیک‌های شبکه عصبی مانند نقشه خود سازمان‌دهنده و نیز با به‌کارگیری تکنیک قوانین همبستگی و تشکیل پروفایل مشتریان به رتبه‌بندی مشتریان با ریسک‌های متفاوت از منظر پول‌شویی بانک بپردازد. در نهایت، نتایج به‌دست آمده در روش مبتنی بر شبکه‌های هوشمند عصبی با داده‌های یکسان با شرایط موجود در بانک ملت جهت رتبه‌بندی ریسک محور مشتریان از منظر پول‌شویی (RBA) مورد مقایسه قرار خواهد گرفت.

در این تحقیق از یک الگو و مدل دو مرحله‌ای برای تجزیه و تحلیل رفتار مشتریان با استفاده از پایگاه داده‌ای درخصوص ویژگی‌های مشتریان و داده‌های مالی آن‌ها استفاده شده است.

موضوع بحث شامل: پیش‌پردازش داده‌ها، مدل‌های رتبه‌بندی رفتاری (نگاشت خود سازمان‌دهنده و رتبه‌بندی مشتریان از منظر ریسک پول‌شویی در بانک ملت)، گام دو مرحله‌ای درخصوص رتبه‌بندی رفتاری مشتریان می‌شود.

ویژگی اصلی از مدل‌های رتبه‌بندی رفتاری دو مرحله‌ای: یکی، مرحله نقشه خود سازمان‌دهنده و دیگری کشف قوانین همبستگی می‌باشد.

شکل ۵ نشان‌دهنده چارچوب مفهومی تحقیق می‌باشد که برای دستیابی به اهداف تحقیق طراحی گردیده است. این شکل نشان می‌دهد که دو جز بخش‌بندی مشتری و تشکیل پروفایل مشتریان، اهداف اصلی تحقیق می‌باشند.



شکل ۵: به کارگیری تکنیک‌های شبکه‌های عصبی و رتبه‌بندی مشتریان از منظر ریسک پول‌شویی جهت شناسایی مشتریان هدف

قلمرو زمانی، مکانی و موضوعی تحقیق

قلمرو زمانی تحقیق: پژوهش حاضر مربوط به دوره زمانی شش ماهه ۱۴۰۱/۰۷/۰۱ تا ۱۴۰۱/۱۲/۲۸ می‌باشد. یعنی بررسی پایگاه داده‌های مربوط به حساب‌های کلیه مشتریان حقیقی نزد بانک ملت در مقطع زمانی فوق را شامل می‌شود.

قلمرو مکانی تحقیق: شامل شعب ممتاز بانک ملت در مدیریت شعب تهران و شهرستان‌ها (مشتمل بر ۵۶ شعبه) می‌باشد. علت انتخاب شعب ممتاز بعنوان قلمرو مکانی تحقیق این است که توزیع پراکندگی مشتریان هدف بانک در این شعب بیشتر می‌باشد. از اینرو تابع هدف قلمرو مکانی محقق شعب ممتاز مناطق تهران و شهرستان‌ها بخصوص مناطق آزاد تجاری و صنعتی و همچنین مناطق پرخطر از سوی مرکز اطلاعات مالی^۱ (FIU) می‌باشد.

فرضیه‌ها یا سؤال‌های تحقیق

با توجه به اینکه در این پژوهش قصد بر آن است تا با استفاده از تکنیک‌ها و الگوریتم‌های داده‌کاوی و (RBA) به تحلیل الگوی رفتاری مشتریان مظنون به پول‌شویی پرداخته شود و با کشف این الگوها و روندهای رفتاری مشتریان، مدلی جهت طبقه‌بندی مشتریان ارائه گردد، لذا این پژوهش فاقد فرضیه می‌باشد. سؤالات تحقیق به قرار زیر می‌باشد:

- ۱- مدل‌های رتبه‌بندی رفتاری مشتریان چگونه به کشف الگوهای رفتاری مشتریان و شناسایی مشتریان مظنون به پول‌شویی و یا مشتریان با ریسک بالای پول‌شویی کمک می‌کند؟
- ۲- نگاشت خود سازمان دهنده چگونه می‌تواند، طبقه بندی بهتری را نسبت به مفهوم (RBA) در خصوص رتبه‌بندی این دسته از مشتریان در بانک ملت ارائه نمایند؟
- ۳- استراتژی‌های مناسب بانک جهت برخورد با هر یک از دسته‌های مشتریان با درجات ریسک پول‌شویی متفاوت (بالا- متوسط و کم) چگونه است؟

نوع روش تحقیق

براساس اهداف پژوهش، تحقیق حاضر از نوع تحقیق کاربردی و براساس نحوه گردآوری داده‌ها، روش مورد استفاده در آن، از نوع توصیفی-تحلیلی می‌باشد.

1. Financial Intelligence Unit; FIU

روش گردآوری اطلاعات و داده‌ها

در این تحقیق از مطالعات کتابخانه‌ای به طور گسترده‌ای استفاده شده است.

پایگاه اطلاعاتی مشتریان بانک ملت: در این روش از اطلاعات ذخیره شده در سیستم‌های اطلاعاتی بانک ملت استفاده شده است. بنابراین برای جمع‌آوری این داده‌ها می‌بایست پایگاه داده در سرورهای شرکت به‌سازان ملت و همچنین شرکت به پرداخت ملت، مورد تحلیل قرار گیرد.

جامعه آماری

در این تحقیق، تجزیه و تحلیل بر روی داده‌های خام پایگاه داده بانک ملت که شامل داده‌های خام مشتریان حقیقی شعب ممتاز (الف و ب) تهران و مناطق استان‌ها می‌باشد، صورت پذیرفت. این داده‌ها دارای حجم بالایی بوده که در بازه تاریخ شش ماه ذخیره گردیده‌اند. در این تحقیق با استفاده از روش نمونه‌گیری تصادفی، داده‌های جمعیت شناختی و تراکنش‌های مالی مشتریان حقیقی بانک که در پایگاه داده‌های بانک موجود می‌باشند، انتخاب شده و مورد بررسی قرار گرفتند.

متغیرهای تحقیق

داده‌های جمعیت شناختی: این متغیرها شامل جنسیت، سن، تحصیلات، وضعیت تاهل، شغل و غیره می‌باشد.

سرویس‌های ارائه شده توسط بانک: سرویس‌های مورد مطالعه در این تحقیق در حوزه‌های مختلف بانکداری مانند (ارزی، اعتباری، سرویس‌های بانکداری الکترونیک و سایر خدمات) می‌باشد. این سرویس‌ها بستری تعاملی مناسبی را بین بانک و مشتریان فراهم آورده است. در هر کدام از این کانال - های ارتباطی، طیف وسیعی از خدمات بانکی ارائه می‌گردد. هر کدام از این سرویس‌ها براساس سطح و کلاس ریسک پول‌شویی مشتری، می‌تواند از سوی مشتری استفاده گردد.

تراکنش‌های مالی مشتریان: این متغیر شامل مبالغ برداشت یا واریز مشتری در بازه زمانی مورد تحقیق است. برای بررسی الگوی رفتاری مشتری و طبقه‌بندی مشتریان بانک در تحقیقات مختلف از روش‌های متنوعی استفاده شده است. از آنجاکه تراکنش‌های مالی مشتری می‌تواند به‌عنوان شاخص خوبی برای بررسی الگوی رفتاری مشتری باشد، در این تحقیق از این متغیر برای رفتارشناسی مشتری استفاده شده است. این متغیرها در پایگاه اطلاعاتی وجود دارند و از طریق پردازش داده‌های تراکنشی مشتریان محاسبه می‌شوند.

در این پژوهش از مدل Max-Min جهت نرمال سازی داده‌ها استفاده شده است. نرمال سازی داده‌ها می‌تواند موجب بهتر شدن مدل سازی شود و از مشکلات عددی پیشگیری کند. نرمال سازی Max-Min، یک الگوریتم مقیاس گذاری خطی است؛ به طوری که محدوده ورودی اصلی را به یک محدوده داده‌ای جدید (نوعاً ۰-۱) تبدیل می‌کند. در این پژوهش از نرم افزار Spss Clementin استفاده شده است.

جدول ۲: نمونه متغیرهای تحقیق

نوع	نام فارسی	ستون
smallint	نوع کلاس رتبه مشتری (۱ بالا، ۲ متوسط، ۳ پائین)	CLASSTYPE
smallint	امتیاز مظنونین به پول شویی	SUSPECTEDSCR
smallint	امتیاز سهام‌داران بیش از ۵٪	MNGSTOCKSCR
smallint	امتیاز وکیل چند مشتری بطور همزمان	LAWYERSCR
smallint	امتیاز ذینفع واحد	BENUNITSCR
smallint	امتیاز صندوق امانات	SAFEBOXSCR
smallint	امتیاز فرد داخلی در معرض مخاطرات سیاسی	IRNPOLRSKSCR
smallint	امتیاز فرد خارجی در معرض مخاطرات سیاسی	FRNPOLRSKSCR
smallint	امتیاز مشتری مهجور	SEPERATEDSCR
smallint	امتیاز مبدأ واریز وجه داخل کشور	IRNSRCDEPSCR

نمونه‌ای از داده‌های نرمال و وزن داده شده که با استفاده از تکنیک‌های مختلف همچون تلخیص، تجمیع و غیره پیش پردازش‌های لازم بر روی آن‌ها صورت پذیرفته است.

جدول ۳: نمونه‌ای از داده‌های پردازش شده

ID	Birthdate	Age	Gender	Education	Job	Birth-L	BANKAmeI	HesabMagsad	CIHPoolshoeI
1	1343/10/14	۴۸	F	L	تعمیرات	تهران	Melli	1301829	1936246
2	1359/11/13	۴۴	F	Bemetary	فصلک بشک / لوز	تهران	Sepah	123436112	1936247
3	1361/01/31	۴۱	F	Diplom	رئوس	مشهد	Mashan	123432001	1936248
4	1342/12/17	۴۰	M	Cycle	سایر خدمات	فرمان	Solezat	12456364666	1936249
5	1354/07/17	۴۸	F	FL	Unimployer	قز	Dey	7266410	1936250
6	1344/08/15	۴۸	F	Cycle	نظامی و نظامی	چلیهار	Tejarat	126628111	1936251
7	1359/07/19	۴۱	F	Filp	تلویزی	ساری	Refah	12161920	1936252
8	1347/06/29	۴۴	M	Filp	فشار اماتک و سفطان	همان	Shahr	1762000	1936253
9	1359/12/12	۴۴	F	Filp	حمل و نقل	آباد	Sarmaje	1762266	1936254
10	1359/08/12	۴۴	M	L	Unimployer	زاک	Parsan	76542236	1936255
11	1329/04/27	۴۹	F	Filp	تلویزی	تهران	Pastradi	12640	1936256
12	1360/06/01	۴۴	F	Filp	فشار اماتک و سفطان	زیند	Keshavazi	1301829	1936257
13	1332/01/28	۴۰	F	FL	رئوس	تهران	Melli	66624171	1936258
14	1349/09/06	۴۴	M	Filp	ویل و امالی	قشخره آند	Sina	4714662	1936259
15	1361/10/20	۴۱	F	L	مطالعاتک بلنگاه	نورد	Mashan	12146236	1936260
16	1359/09/30	۴۱	F	FL	ویل و امالی	ککلی	Solezat	146622966	1936261
17	1349/09/13	۴۴	M	L	حمل و نقل	تهران	Tejarat	45462124	1936262
18	1371/07/25	۴۹	F	L	خورو	نورد	Dey	123216546	1936263
19	1362/01/22	۴۰	M	Diplom	پیکر و نامپیکر	شت	Refah	1234766	1936264
20	1360/01/27	۴۴	M	Diplom	وکالت مشاوره خدمات بیمه	سیریل	Shahr	11141623	1936265
21	1366/11/16	۴۴	M	Diplom	مقصد	نانی	Sarmaje	146225	1936266
22	1369/07/11	۴۴	M	FL	لوز، قشخره نیک	زاک	Parsan	1234366	1936267
23	1345/05/19	۴۱	M	L	Manager	سفر	Keshavazi	9213632	1936268
24	1359/05/23	۴۱	M	Bemetary	Manager	فرمان	Pastradi	1452662	1936269
25	1359/08/25	۴۴	M	Filp	پوشک و سفطان	ککلی	Solezat	12347662	1936270
26	1360/10/19	۴۴	F	FL	شوروی	بیشیر	Dey	466666	1936271
27	1371/01/10	۴۹	M	Diplom	پیکر و نامپیکر	گولگ	Tejarat	410432032	1936272
28	1369/09/16	۴۱	M	Cycle	عاب	قز	Refah	7463966	1936273
29	1349/11/12	۴۴	F	FL	فصلک بشک / لوز	نصف آند	Shahr	7413621	1936274
30	1394/07/26	۴۸	F	Filp	Unimployer	ککلی	Sarmaje	4662262	1936275
31	1341/08/22	۴۱	F	Bemetary	فشار اماتک و سفطان	ساری	Parsan	74166633	1936276
32	1344/08/01	۴۸	F	Diplom	رئوس	نریسایه	Pastradi	4713632	1936277
33	1361/09/06	۴۱	M	Diplom	سایر خدمات	تهران	Sina	145266	1936278
34	1363/08/20	۴۸	F	Cycle	مطالعاتک بلنگاه	تهران	Melli	466239211	1936279
35	1360/06/12	۴۴	F	Cycle	مقصد	قشخره	Sepah	146232362	1936280

در این تحقیق مطالعه بر روی داده‌های خام مشتریان حقیقی شعب ممتاز (مشمول بر ۵۶ شعبه ممتاز الف و ب، با شناسه‌های چهار رقمی و رقم کنترلی واحد) مدیریت شعب تهران و شهرستان‌ها در بازه زمانی شش ماهه صورت پذیرفته است. تعداد کل داده‌های دریافتی از پایگاه داده‌های شرکت‌های تابعه بانک ملت (به‌سازان ملت، به‌پرداخت) مشتمل بر ۹۲,۶۸۶ رکورد بوده که پس از به‌کارگیری تکنیک‌های آماده‌سازی داده‌ها همچون (تجمیع، تلخیص، یکپارچه‌سازی، نرمال‌سازی و غیره) تعداد ۵۰,۰۰۰ رکورد اطلاعاتی جهت انجام پژوهش حاضر فراهم گردیده است.

یافته های پژوهش

نتایج حاصل از خوشه بندی داده های مربوط به مشتریان حقیقی (۵۰,۰۰۰ رکورد اطلاعاتی) براساس روش RBA به شرح جدول ۴ می باشد:

جدول ۴: نتایج حاصل از رتبه بندی مشتریان براساس مدل RBA در بانک ملت

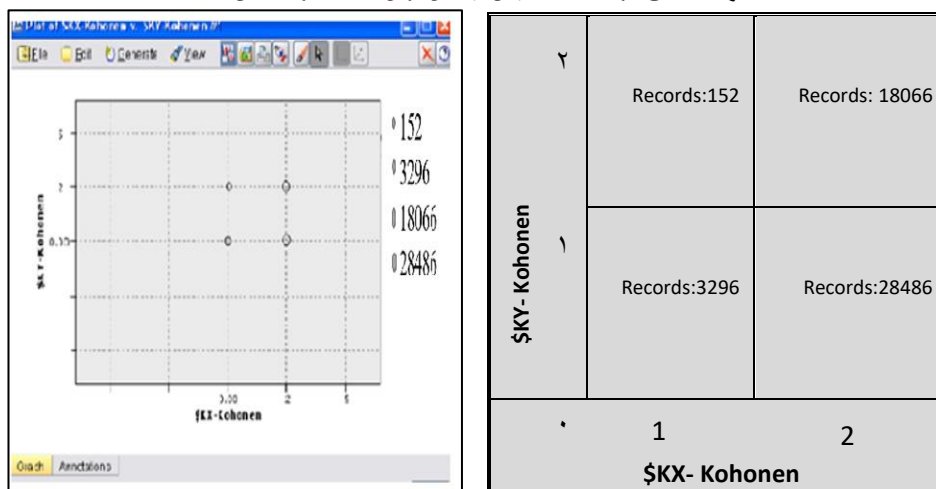
Cluster	Cluster type	Range Of Points	Number of Cases in each Cluster	%Percent
۱	High Risk	۱۰۰-۶۷	۱۶۸	۰/۳
۲	Middle Risk	۶۶-۳۳	۲,۳۹۲	۴/۷
۳	Low Risk	۳۳-۱	۱۱,۰۵۲	۲۲
۴	Free Risk	۰	۳۶,۳۸۸	۷۳
	Valid		۵۰,۰۰۰	۱۰۰/۰۰
	Missing		۰۰۰	

نتایج حاصله در خوشه بندی مشتریان در مدل RBA بانک ملت نشان از وجود ۱۶۸ مشتری مظنون به پول شویی در کلاس A (۰.۳ درصد) و ۲,۳۹۲ مشتری با ریسک متوسط در کلاس B (۴.۷ درصد)، ۱۱,۰۵۲ مشتری با ریسک کم در کلاس C (۲۲ درصد) و ۳۶,۳۸۸ مشتری فاقد ریسک در کلاس D (۷۳ درصد) قرار گرفته اند. پس از امتیازدهی مشتریان و طبقه بندی آنها در چهار کلاس یاد شده، به تحلیل رفتاری مشتریان در کلاس A که مظنون به پول شویی می باشد پرداخته شد. سپس نتایج حاصل از تحلیل این دسته از مشتریان با تحلیل مشتریان کلاس A که از روش شبکه هوشمند عصبی به دست آمده اند، مورد مقایسه قرار خواهند گرفت.

در تحقیق حاضر از نگاشت خود سازمان دهنده کوهون به علت استفاده از روش یادگیری با ناظر و نمای گرافیکی آن برای خوشه بندی استفاده شده است. ورودی شبکه دارای ۲۸۶ متغیر در ۲۵ جدول (Table) می باشد. برای انجام خوشه بندی از ماژول نگاشت خود سازمان دهنده کوهون و نرم افزار SPSS Clementine استفاده شده است. خروجی حاصل از شبکه به صورت یک ماتریس ۲*۲ می باشد که مشتریان براساس میانگین متغیرهای بدست آمده برای هر کدام از قسمت های ماتریس خوشه بندی می شوند و براساس شباهت خود در این معیارها در خوشه مشابه قرار می گیرند. خوشه بندی مشتریان در این قسمت کمک می کند تا خصوصیات مشتریان مشابه را ارزیابی کرده و ترجیحات هر گروه مشخص شود. خروجی خوشه بندی مشتریان که در جدول ۵ آورده شده است نشان دهنده ۴ (ماتریس ۲*۲) خوشه از مشتریان می باشد که هر خوشه بر روی نمودار در محل تقاطع محور x, y قرار دارد.

براساس جدول ۵ تعداد ۱۵۲ نفر از مشتریان جزء مشتریان کلاس A محسوب می‌شوند. به‌طور کلی با توجه به نگاه کاربردی بانک می‌توان مشتریان بانک را به چهار گروه براساس میزان ریسک پول‌شویی آن‌ها دسته‌بندی نمود.

جدول ۵: نتایج خوشه‌بندی مشتریان براساس روش نگاشت خود سازمان‌دهنده



براساس خروجی مدل شبکه عصبی هوشمند (SOM)، ۱۵۲ مشتری (۳٪ درصد) جزء کلاس A مطلقاً به پول‌شویی می‌باشند. همچنین ۳،۲۹۶ نفر (۵/۶ درصد) جزء کلاس B یا مشتریان دارای ریسک متوسط، ۱۸،۰۶۶ نفر (۳۶ درصد) جزء مشتریان کلاس C یا مشتریان با ریسک کم و در نهایت ۲۸،۴۸۶ نفر (۵۷/۲ درصد) مشتریان فاقد هرگونه ریسک در حوزه پول‌شویی می‌باشند. نتایج حاصل از خوشه‌بندی مشتریان بانک با توجه به نگاشت خود سازمان‌دهنده کوهون که در جداول فوق نشان داده شده است، بیانگر دسته‌بندی مشتریان در ۴ خوشه می‌باشد. تعداد نوروهای خروجی مدل ۲*۲ با توجه به الگوی رفتاری مشتریان توسط مدل تشخیص داده شده است. خوشه‌بندی مشتریان بدین طریق کمک می‌کند تا مشتریانی که دارای مشابه‌ترین الگوی رفتاری برحسب متغیرهای تراکنشی مالی و متغیرهای جمعیت‌شناختی هستند، در گروه‌های واحدی دسته‌بندی شده و برای هر گروه سرویس‌های مناسب به تفکیک خصوصیات آن‌ها در نظر گرفته شود. در ادامه تحقیق به بررسی الگوی رفتاری و کشف قوانین وابستگی در هر خوشه پرداخته شده است. در این پژوهش برای بررسی الگوی رفتاری و کشف قوانین

وابستگی در خوشه‌های ایجاد شده از مشتریان، تنها یکی از خوشه‌ها برای تحلیل انتخاب گردید. برای این منظور خوشه $X=1, Y=2$ به لحاظ اینکه جزء مشتریان با سطح بالاترین ریسک پول شویی می‌باشند، انتخاب می‌گردد. و از سوی دیگر جهت مقایسه نیز مشتریان کلاس A دو روش فوق با یکدیگر در نظر گرفته شده است. بررسی و تحلیل رفتاری و کشف قوانین وابستگی بین سرویس‌ها و این دسته از مشتریان به مدیریت ارشد بانک جهت تدوین استراتژی‌های نحوه تعامل با این مشتریان کمک بسیاری می‌نماید. بنابراین خوشه‌ی $X=1, Y=2$ با تعداد ۱۵۲ مشتری و متغیرهای مربوطه آن به عنوان خوشه‌ی هدف در نظر گرفته شده است.

بخش دوم: سرویس‌های بانکی مورد استفاده توسط مشتریان با ریسک بالا

نتایج حاصل از خوشه‌بندی مشتریان به عنوان ورودی این مرحله برای شناسایی سرویس‌های مورد علاقه هر خوشه استفاده شده است. در این مرحله با استفاده از الگوریتم **Apriori** که یکی از تکنیک‌های رایج مورد استفاده در قوانین وابستگی است، رابطه میان سرویس‌های مختلف در خوشه مورد نظر شناسایی می‌گردد و در نهایت با استفاده از خصوصیات مشتریان در خوشه $X=1, Y=2$ و سرویس‌های مورد علاقه این دسته از مشتریان، استراتژی مناسب برای نحوه ادامه همکاری با آن‌ها انتخاب می‌گردد.

کشف قوانین وابستگی بین سرویس‌های هر خوشه

برای شناسایی رابطه میان گروه‌های مختلف مشتریان و سرویس‌های مورد علاقه آن‌ها از قوانین وابستگی استفاده شده است. در این مرحله ابتدا خوشه مورد نظر از مشتریان انتخاب شده و براساس اطلاعات سرویس‌های استفاده شده توسط هر کدام از مشتریان در این خوشه، قوانین وابستگی محاسبه می‌گردد. با شناسایی رابطه سرویس‌ها و خوشه مزبور می‌توان علایق مشتریان هدف را بدست آورد. در الگوریتم‌های موجود برای قوانین وابستگی، **Apriori** یکی از پرکاربردترین الگوریتم‌ها می‌باشد (لیو و همکاران، ۲۰۱۸). در این مطالعه از این تکنیک برای شناسایی رابطه میان سرویس‌های مختلف مورد علاقه در خوشه یاد شده، استفاده شده است.

جدول ۶: قوانین وابستگی در خوشه انتخاب شده

	Antecedent	Support %
LC	Presentation of heavy documents - Failure to repay the loan	17.51
Total number of transactions	Above the level of activity- Rules AML28	19.41
RTGS	Unusual transactions- Combined tools	18.21
Current account	spider web- Same zip code- Joint IP	18.91
Dangerous OR free areas	Money transfer network- High currency transfer activity	10.61
List Of FIU	Obtaining AML information	13.21
High Amount Check	Concentration of money-spider web	11.71
The amount of facilities and obligations	Gold transactions-Non-financial jobs	14.71
Internet sales portals	Sudden deactivation of active -Multiple change of address accounts	13.11
Age between 45 and 65	Unusual transactions- High turnover accounts	12.51
Account opening branches	Reactivation of inactive accounts	10.21
Shared account holders	Safe box- High turnover accounts	11.31
Joint attorney	Above the level of activity-spider web	9.61
tax fraud	Communication with employees who have a financial violation case	8.71
Major shareholders	Combined tools- RTGS	10.11
Number of access cards	Unusual transactions-spider web	15.11
Safe box	Multiple withdrawals of significant amounts	10.11
Transaction tools in branches	High currency transfer activity	18.91
Rules AML	High turnover accounts-Joint IP	18.21
Daily limit of interbank remittance	Dangerous OR free areas- Unusual transactions	13.11
Cash transaction report over the limit	Combined tools-Newly opened account	19.51
Combined tools	spider web- Zero time- Joint IP	11.71
Zero time	false statement-spider web	17.14
A real customer with a legal background	Trading precious metals- B to C transactions	12.81

	Antecedent	Support %
Joint IP	Major shareholders- Combined tools	8.91
spider web	Political personality- Combined tools	16.91
Rental accounts	spider web -Joint IP- Combined tools	15.61
Use of children's accounts	Newly opened account-Joint IP	19.21
Newly opened account	Presentation of heavy documents - Failure to repay the loan-tax fraud	12.21
High amounts in limited time returns	spider web-List Of FIU	11.91
settlement of facilities	virtual interlocutors-Joint IP	17.15
Same zip code	Daily limit of interbank remittance	18.31
Contract termination without reason	Rules AML- Rental accounts- Number of access cards	19.41

در این مرحله برای شناسایی رابطه میان سرویس‌های مورد استفاده در خوشه انتخابی از الگوریتم Apriori با حداقل درجه پشتیبانی ۲۰ درصد و حداقل اطمینان ۸۰ درصد استفاده شده است. قوانین ایجاد شده در این خوشه در جدول ۶ آورده شده است، قوانین بدست آمده نشان‌دهنده رابطه میان سرویس‌های مختلف در خوشه مورد بررسی است. برای مثال قانون شماره سه بیان می‌کند افرادی که از طریق تسویه ناخالص آنی (RTGS) انتقال وجه انجام می‌دهند، با ضریب اطمینان ۷۸٪ و پشتیبانی (تکرار شونده) ۱۸٪ دارای تراکنش‌های مالی غیر معمول (با مبالغ بسیار بالا و یا خارج از سطح فعالیت مالی مورد انتظار) بوده و همچنین از ابزارهای ترکیبی (مدیاهای مختلف) برای نقل و انتقال وجوه خود استفاده می‌نمایند. با توجه به قوانین ایجاد شده مشخص شد که مشتریان مظنون به پول‌شویی در میان سرویس‌های بانکی از خدماتی چون: حساب‌های اجاره‌ای، IP‌های مشترک، ابزارهای نوع ترکیبی و نقل و انتقال شبکه‌ای، بیشتر از سایر سرویس‌ها استفاده خواهند نمود.

تحلیل سرویس‌های مورد استفاده مظنونین موجود، جهت پیش‌بینی و شناسایی مظنونین احتمالی

با شناسایی سرویس‌های مورد علاقه مظنونین در خوشه مشتریان با ریسک پول‌شویی بالا می‌توان با تحلیل، مشتریانی که به تازگی وارد شبکه بانک شده‌اند و رفتار مشابهی مانند این دسته از مشتریان در استفاده از این سرویس‌ها و خدمات بانکی دارند، را شناسایی نمود. در قسمت قبل، با ضریب اطمینان مشخص و با میزان خاصی از تکرار شون‌دگی، سرویس‌های مورد علاقه خوشه مورد نظر از مشتریان، شناسایی شدند. در ادامه با تحلیل اختلاف میان محصولات و سرویس‌های مورد استفاده توسط هر مشتری در خوشه مشتریان مظنون به پول‌شویی و علاقه مشتریان جدید به استفاده از همان محصولات و سرویس‌ها، می‌توان به شناخت جامع‌تری از مشتری دست یافت. به‌گونه‌ای که مشتریانی که خصوصیات مشابه با خوشه مورد بررسی را دارند، ممکن است به سرویس‌های مورد نیاز این خوشه علاقه‌مندی نشان دهند. با استفاده از این تحلیل می‌توان مشتریان جدید را نیز مورد بررسی قرار داده و متناسب با خصوصیات آن‌ها، سرویس‌های مورد استفاده ایشان را شناسایی نمود. همان‌گونه که اشاره شد، با استفاده از قوانین وابستگی، سرویس‌های مورد علاقه خوشه مظنونین مشخص گردیده است. در این مرحله برای شناسایی مشتریانی که رفتار مشابهی در استفاده از محصولات، خدمات و همچنین سرویس‌های مورد استفاده مشتریان مظنون به پول‌شویی داشتند، شناسایی می‌شود و می‌توان با تحلیل اختلاف میان سرویس‌های مورد علاقه و سرویس‌های مورد استفاده، پیشنهادات سیستم را استخراج کرد. به‌گونه‌ای که ممکن است یک مشتری مظنون به عملیات پول‌شویی در استفاده از سرویس‌ها، رفتار خلاقانه‌ی متفاوتی ارائه نماید که در نهایت منجر به کشف قانون جدیدی گردد که می‌بایستی به قوانین قبلی اضافه گردد.

با استفاده از حروف T و F نشان داده شده است که آیا مشتری مورد نظر از سرویس‌ها استفاده می‌کند یا خیر؛ بدین صورت که برای سرویس‌های مورد استفاده مشتری حرف T در نظر گرفته شده است. N-ID یک New ID می‌باشد که رفتار مشابهی با ID مربوطه دارد.

تشکیل پروفایلی از مشتریان هدف جهت تسهیل در تدوین استراتژی‌های مناسب

در نظام بانکداری، با توجه به ریسک شهرتی که مشتریان پول‌شویی به بانک تحمیل می‌نمایند، شناسایی مشتریان مظنون به پول‌شویی از اهمیت بسیار بالایی برخوردار می‌باشد. در این پژوهش با تحلیل مشتریان هدف (کلاس A- مشتریان مظنون به پول‌شویی در بانک ملت) می‌توان به اطلاعات ارزشمندی دست یافت. بنابراین مهمترین دسته از نظر الگوی رفتاری جهت تحلیل رفتار و تشکیل پروفایل جامعی از اطلاعات، مشتریان کلاس A می‌باشند. بنابراین بانک باید هزینه‌های بیشتری جهت شناسایی و تحلیل رفتار این دسته از مشتریان جهت جلوگیری از هزینه‌های پیش‌بینی نشده آتی، بپردازد. با توجه به تعداد کم این مشتریان نسبت به کل مشتریان (تعداد ۱۶۸ نفر مشتری مظنون به پول‌شویی براساس روش RBA و ۱۵۲ نفر براساس روش (SOM))، بانک می‌تواند، نسبت به شناسایی و تحلیل رفتار جامع آنان اقدام نماید تا در دوره‌های بعد، مشتریانی با الگوهای رفتاری مشابه را شناسایی نماید.

ضمناً مشتریانی با الگوی رفتاری فوق در گروه مشتریان کلاس A در بین خدمات بانکی، به یکسری خاصی از خدمات، از جمله: استفاده از حساب‌های اجاره‌ای، استفاده از IP‌های مشترک، استفاده از ابزارهای نوع ترکیبی و نقل و انتقال شبکه‌ای، اشتیاق خاصی پیدا نموده‌اند. نکته قابل توجه در تحلیل رفتاری این گروه از مشتریان این است که تمایل ایشان به استفاده از خدمات در حوزه بانکداری اینترنتی رو به تزايد می‌باشد.

مقایسه نتایج حاصل از رتبه‌بندی مشتریان از طریق RBA و SOM

در جداول ذیل تعداد و درصد مشتریان در روش‌های مختلف محاسبه شده است. در تحلیل رفتار مشتریان با توجه به اینکه مشتریان کلاس‌های C و D (مشتریان با ریسک کم و مشتریان فاقد ریسک) دارای رفتار نزدیک به هم می‌باشند، می‌توان آن‌ها را با هم در نظر گرفت. در نهایت می‌توان بیان نمود که نتایج حاصل، از یک همگرایی جامعی نسبت به هر دو روش مطرح شده در پژوهش حاضر برخوردار می‌باشد. خلاصه نتایج به شرح جدول ۸ می‌باشد.

جدول ۸: مقایسه تعداد مشتریان مظنون به پول شویی در دور روش RBA و SOM

Ranking	Cluster	Number of RBA	Number of SOM	Total gaps
۱	۱	۱۶۸	۱۵۲	۱۶
۲	۲	۲۳۹۲	۳۲۹۶	۹۰۴
۳	۳	۱۱۰۵۲	۱۸۰۶۶	۷۰۱۴
۴	۴	۳۶۳۸۸	۲۸۴۸۶	۷۹۰۲
جمع		۵۰۰۰۰	۵۰۰۰۰	۱۵۸۳۶

نتایج جدول فوق نشان دهنده این است که مشتریان مظنون به پول شویی (کلاس A) دارای کمترین درصد (در حدود ۳/۰ درصد) و مشتریان فاقد ریسک و یا دارای ریسک کم دارای بیشترین میزان فراوانی (در حدود بیش از ۹۰ درصد) می باشند.

همچنین، نتایج حاصل در این پژوهش در دو روش (RBA و SOM) در شناسایی اشخاص مظنون به پول شویی، از یک همگرایی خاصی برخوردار می باشد. در این پژوهش جهت ارزیابی صحت نتایج به دست آمده از توزیع مشتریان در کلاس های مختلف، از آزمون ANOVA استفاده شده است. براساس نتایج آزمون مقدار P-Value نشان دهنده معنی دار بودن نتایج آزمون بوده و همچنین مقدار Chi-squared نشان می دهد توزیع فراوانی مورد انتظار و مورد مشاهده یکسان می باشند.

پاسخ سوال اول

مدل های رتبه بندی رفتاری مشتریان چگونه به کشف الگوهای رفتاری مشتریان و شناسایی مشتریان مظنون به پول شویی و یا مشتریان با ریسک بالای پول شویی کمک می کند؟
با به کارگیری تکنیک های هوشمند داده کاوی، الگوریتم (SOM) و رتبه بندی مشتریان بر پایه ریسک پول شویی (RBA) از یک پایگاه داده ای مشترک که از پایگاه داده ای بانک ملت استخراج گردید به این سوال که طبقه بندی مشتریان بانک براساس روش های هوشمند و شرایط موجود در بانک ملت، چگونه است؛ بدین طریق پاسخ داده شده است:

۱- در مدل شبکه عصبی هوشمند (ANN):

با استفاده از متغیرهای پژوهش برای بررسی الگوی رفتاری مشتریان و همچنین با استفاده از شبکه عصبی کوهونن، ماتریس نورون های خروجی شبکه ۲*۲ تشخیص داده شده و مشتریان در ۴ خوشه

دسته‌بندی گردیدند. این طبقات هر کدام با توجه به بیشترین شباهت در الگوی رفتاری دسته‌بندی گردیدند. از میان خوشه‌های ایجاد شده خوشه با مختصات $(X=1, Y=2)$ با تعداد ۱۵۲ مشتری برای انجام تحلیل بیشتر و تشخیص قوانین انجمنی بین سرویس‌های این گروه انتخاب شده‌اند.

۲- با استفاده از مدل موجود در بانک ملت (RBA)

از سوی دیگر با به کارگیری تکنیک رتبه‌بندی مشتریان مبتنی بر ریسک پول‌شویی و با استفاده از همان متغیرها و براساس مدل امتیازدهی، به تحلیل خوشه‌بندی مشتریان در ۴ دسته پرداخته شد. مشتریان فاقد ریسک (بدون امتیاز) که دامنه امتیازی آن‌ها (بین ۱ تا ۳۳) بوده، مشتریان با ریسک کم و مشتریانی که دامنه امتیازی آن‌ها (بین ۳۳ تا ۶۶) بوده مشتریان با ریسک متوسط و مشتریانی که جمع امتیازهای آن‌ها بالاتر از ۶۶ بوده مشتریان با ریسک بالا می‌باشند. تعداد ۱۶۸ نفر از مشتریان براساس این مدل در گروه کلاس (A) قرار گرفته‌اند. سپس براساس میزان امتیاز بدست آمده، هر یک از دسته‌های مشتریان تعیین شده است. خوشه با ریسک بالا (کلاس A) شناسائی شده و با استفاده از قوانین انجمنی بین سرویس‌های بانکی به تحلیل رفتار این دسته از مشتریان پرداخته شد.

پاسخ سوال دوم

نگاشت خود سازمان دهنده (SOM) چگونه می‌تواند، طبقه‌بندی بهتری را نسبت به مفهوم (RBA) در خصوص رتبه‌بندی این دسته از مشتریان در بانک ملت ارائه نمایند؟ در این پژوهش جهت ارزیابی صحت نتایج بدست آمده از توزیع مشتریان در کلاس‌های مختلف، از آزمون ANOVA استفاده شده است. براساس نتایج آزمون مقدار P-Value نشان‌دهنده معنی‌دار بودن نتایج آزمون بوده و همچنین مقدار Chi-squared نشان می‌دهد توزیع فراوانی مورد انتظار و مورد مشاهده یکسان می‌باشند.

$$H_0: \mu_1 = \mu_2$$

$$H_1: \text{حداقل یکی از میانگین‌ها باهم برابر نیستند}$$

براساس آزمون فوق مقدار $\text{Sig}=1$ بیانگر این است که نمی‌توان فرض یکسان بودن میانگین دو گروه مشتریان با ریسک پول‌شویی بالا را که از دو روش (RBA و SOM) بدست آمده‌اند، رد نمود؛ از طرفی

مقدار F بدست آمده از جدول فوق کمتر از مقدار F با درجه آزادی $K-1=3$ و $N-K=49997$ می باشد
($1.07 < 3.18$) لذا در سطح معنی داری 0.05 نمی توان فرض H_0 را رد نمود.

نتایج حاصل از آزمون ANOVA

در این روش تغییرات کل به دو بخش تجزیه می شود :

تغییرات کل = تغییرات بین گروهی + تغییرات داخل گروهی

با استفاده از نسبت تغییرات بین گروهی به تغییرات داخل گروهی معیار F بدست خواهد آمد که مبنای تصمیم گیری در مورد فرض صفر و فرض مقابل است. در صورتی که میانگین k گروه مورد مقایسه باشد در این صورت می توان فرض صفر و فرض مقابل را به صورت آماری زیر بیان نمود:

میانگین k گروه مورد مقایسه با هم برابرند: H_0

حداقل یک جفت از میانگین ها باهم برابر نیستند: H_1

برای قضاوت در مورد فرض صفر بالا همان گونه که گفته شد از روش تحلیل واریانس استفاده می شود.

جدول ۹: نتایج حاصل از آزمون ANOVA

منابع تغییرات	مجموع مربعات	درجه آزادی	میانگین مربعات	نسبت F^*	سطح معنی داری
بین گروهی	SSB	K-1	MSB	MSB/MSW	$P_r(F^* > F)$
داخل گروهی	SSW	N-K	MSW		
جمع	SST	N-1			

تحلیل واریانس برای مقایسه میانگین K گروه

فرض صفر هنگامی رد می شود که مقدار F بدست آمده بیشتر از F جدول با $k-1$ و $n-k$ درجه آزادی باشد یا مقدار سطح معناداری کمتر از 0.05 باشد.

جهت مقایسه نتایج حاصل از رتبه بندی مشتریان در هر دو روش از آزمون فوق استفاده می شود.

$H_0: \mu_1 = \mu_2$

H_1 : حداقل یکی از میانگین ها باهم برابر نیستند

جدول ۱۰: تحلیل واریانس برای مقایسه میانگین ۴ گروه از مشتریان

	Sum of Squares	df	Mean Square	F	Sig.
Between Groups	۲۸۵۹۶۸۱۳	۳	۷۱۴۹۲۰۳	۱/۰۷	۱
Within Groups	۲۶۷۱۷۳۱۹	۴۹۹۹۷	۶۶۷۹۳۲۹		
Total	۵۵۳۱۴۱۳۲		۱۳۸۲۸۵۳۲		

نتایج بدست آمده در جدول فوق نشان دهنده اختلاف ناچیز پیشنهادات در دو روش به کار گرفته شده می‌باشد. بر این اساس می‌توان استدلال کرد که چارچوب طراحی شده برای ارائه طبقه‌بندی مشتریان در بانک از عملکرد مطلوبی برخوردار است و استفاده از هریک از روش‌های دوگانه فوق تقریباً نتایج یکسانی ارائه خواهد نمود.

نتایج حاصل از پژوهش از اختلاف معنی‌داری بین شرایط موجود و نتایج مطلوب حاصل از تحقیق برخوردار نمی‌باشد. براساس مدل RBA تعداد ۱۶۸ نفر از مشتریان دارای بیشترین امتیاز ریسک پول‌شویی بوده و در گروه مشتریان کلاس A قرار گرفتند. همچنین، براساس مدل شبکه عصبی تعداد ۱۵۲ نفر نسبت به دیگر مشتریان دارای ریسک پول‌شویی بالاتری بوده‌اند. با نگاهی به آمار و ارقام فوق و مقایسه آن‌ها با هم، استنباط می‌شود که از دو روش فوق نتایج تقریباً مشابهی بدست آمده است که حاکی از یکسان بودن هر یک از روش‌های فوق در رتبه‌بندی مشتریان بانک می‌باشد و می‌توان ادعا نمود که روش‌های مطرح شده در پژوهش حاضر (غیر از مزیت‌های خاص) طبقه‌بندی بهتری را نسبت به شرایط جاری در بانک ملت ارائه نمی‌نمایند.

پاسخ سوال سوم

استراتژی‌های مناسب بانک جهت برخورد با هر یک از دسته‌های مشتریان با درجات ریسک پول‌شویی متفاوت (بالا- متوسط و کم) چگونه است؟

در ادامه استراتژی مناسب بانک در ارتباط با مشتریان هدف شرح داده شده و در نتیجه جهت تسهیل در تدوین استراتژی نحوه تعامل با این دسته از مشتریان، پیشنهادهای خاصی به شرح ذیل به مدیریت ارشد بانک ارائه شده است:

۱- مشتریان کلاس A بدون محدودیت در ارائه خدمات بانکی، به صورت کاملاً کنترل شده، توسط واحد مبارزه با پول‌شویی و ضد تأمین مالی تروریسم، تحت مراقبت ویژه قرار گیرند.

- ۲- متناسب با نزدیک شدن رفتار مشتریان جدید الورود به رفتار مشتریان مظنون به پول شویی، طیفی از محدودیت‌های لازم در نظر گرفته شود.
- ۳- محدودیت کامل در ارائه خدمات بانکی به این دسته از مشتریان، ملحوظ نظر واقع گردد.
- ۴- معرفی این دسته از مشتریان به عنوان خروجی سامانه مظنونین به پول شویی به مرکز اطلاعات وزارت امور اقتصادی و دارایی (FIU).

نتیجه‌گیری و پیشنهادات

- ✓ با شناسایی خصوصیات مشتریان در طبقات مختلف، به راحتی می‌توان مشتریانی را که دارای خصوصیات مشابهی هستند و یا رفتاری مشابه رفتار مشتریان مظنون به پول شویی دارند را شناسایی نمود. با شناسایی این گروه از مشتریان و شناخت الگوهای رفتاری آنها، با اتخاذ استراتژی‌های مناسب، می‌توان ضریب امنیت را به شدت بالا برد.
- ✓ با تحلیل یکی از خوشه‌ها که دارای مشتریانی با ریسک پول شویی بالا می‌باشد، مشخص گردید که این دسته از مشتریان از سرویس‌های حوزه بانکداری الکترونیک، ارائه شده توسط بانک، بیشتر از سایر موارد استفاده می‌کنند و کارشناسان اداره مبارزه با پول شویی بانک می‌توانند ضمن کسب مهارت‌های لازم در این حوزه با همکاری واحدهای IT بانک، نسبت به شناسایی رفتار این دسته از مشتریان اقدام نمایند و یا اینکه بانک نسبت به برگزاری تخصصی دوره‌های مربوطه برای کارشناسان و مدیران مبارزه با پول شویی اقدام نماید.
- ✓ با تحلیل سایر خوشه‌ها با استفاده از الگوی ارائه شده، می‌توان به نتایج مشابهی دست یافت و سرویس‌های مورد علاقه آنها را نیز شناسایی نمود. نتیجه حاصل از تحقیق نشان دهنده کاربرد گسترده و مؤثر تکنیک‌های داده کاوی در این ارتباط می‌باشد.
- ✓ پایگاه داده‌های بانک جزیره‌ای بوده و داده‌های بانک در شرکت‌های مختلف (سه شرکت وابسته به بانک، بنام‌های شرکت بهسازان ملت (متولی سوئیچ Core Banking)، شرکت یاس ارغوانی (گزارشات BI مشتریان)، شرکت به پرداخت ملت (متولی سوئیچ Pos-Vpos) ذخیره گردیده است. پیشنهاد می‌شود جهت اخذ تصمیمات بهینه و سریع استراتژیکی، بانک پایگاه داده‌ای متمرکزی را ایجاد نماید.

✓ پیشنهاد می‌شود به تحلیل رفتاری مشتریان گروه (B) مشتریان با ریسک پول‌شویی متوسط، پرداخته و با تحلیل رفتار مناسب این دسته از مشتریان، مشتریانی که دارای طیف امتیازی بالاتری و یا رفتار مشابه بیشتری نسبت به مشتریان گروه هدف هستند را شناسایی نمود. پیشنهاد می‌شود با توجه به مزایای روش‌های مطرح شده در پژوهش حاضر (توصیف جامع از جامعه آماری مشتریان) از یک روش ادغامی جهت رتبه‌بندی مشتریان استفاده شود.

منابع و مأخذ

الف. فارسی

خاکی، غلامرضا (۱۳۸۶). روش تحقیق در مدیریت، تهران: مرکز انتشارات دانشگاه آزاد اسلامی.

انگلیسی

Agrawal R., Imielinski T., & Swami A. (1993). *Mining Association Rules between Sets of Items in Large Databases*. In Proceedings of the ACM SIGMOD Conference on Management of Data, 207-216.

Chao, X., Kou, G., Peng, Y., & Alsaadi, F. (2019) *Behavior Monitoring Methods for Trade-based Money Laundering Integrating Macro and Micro Prudential Regulation: A case from China*. Technological and Economic Development of Economy 25(6), 1-16.

Chen, Z. (2018). *Machine Learning Techniques for Anti-money Laundering (AML) Solutions in Suspicious Transaction Detection: A Review*. Knowledge and Information Systems, 57(2), 245-285.

Chen, Z., Van Khoa, L.D., Nazir, A., Teoh, E. N., & Karupiah, E. K. (2014). *Exploration of the Effectiveness of Expectation Maximization Algorithm for Suspicious Transaction Detection in Anti-money Laundering*. IEEE Conference on Open Systems (ICOS), 145-149. doi:10.1109/icos.2014.7042645

Chen Y-T., & Mathe, J. (2011) *Fuzzy Computing Applications for Anti-money Laundering and Distributed Storage System Load Monitoring*. World conference on soft computing.

Heidarinia, N., Harounabadi, A., & Sadeghzadeh, M. (2014). *An Intelligent Anti-Money Laundering Method for Detecting Risky Users in the Banking Systems*. International Journal of Computer Applications, 97(22), 35-39.

Guevara, J., Garcia-Bedoya, O., & Granados, O. (2020). *Machine Learning Methodologies against Money Laundering in Non-banking Correspondents*. in Applied

Informatics (Communications in Computer and Information Science), H. Florez and S. Misra, Eds. Ota, Nigeria, 1277, 72_88.

Jullum, M., Løland, A., Huseby, R. B., Ånonsen, G., & Lorentzen, J. (2020). *Detecting money laundering transactions with machine learning*. Journal of Money Laundering Control, 23(1), 173-186.

Kim, M. (2007). *An Effective Under-sampling Method for Class Imbalance Data Problem*. in Proceedings of the 8th Symposium on Advanced Intelligent Systems, 825-829.

Kohonen, T. (2013). *Essentials of the Self-organizing Map*. Neural Networks, 37, 52-65.

Hsu, M-H. (2008). *A personalized English Learning Recommender System for ESL Students*. Expert Systems with Applications, 34, 683-688.

Magomedov, S., Pavelyev, S., Ivanova, I., Dobrotvorsky, A., Khrestina, M., & Yusubaliev, T. (2018). *Anomaly Detection with Machine Learning and Graph Databases in Fraud Management*. International Journal of Advanced Computer Science and Applications (IJACSA), 9(11), 33-38.

Plaksy, K., Nikiforov, A., & Miloslavskaya, N. (2018). *Applying Big Data Technologies to Detect Cases of Money Laundering and Counter Financing of Terrorism*. In Proceedings – 2018 IEEE 6th International Conference on Future Internet of Things and Cloud Workshops, W-FiCloud 2018 (pp. 70-77). Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/W-FiCloud.2018.00017>

Rocha-Salazar, J.-d.-J., Segovia-Vargas, M.-J., & Camacho-Miñano, M.-d.-M. (2021). *Money Laundering and Terrorism Financing Detection using Neural Networks and an Abnormality Indicator*. Expert Systems With Applications, 169, 114470.

Shaikh, A.K., & Nazir, A. (2018). *A Model for Identifying Relationships of Suspicious Customers in Money Laundering using Social Network Functions*. Proceedings of the World Congress on Engineering, WCE 2018 - London, United Kingdom.

Yang, Y., Lian, B., Li, L., Chen, C., & Li, P. (2019). *DBSCAN Clustering Algorithm Applied to Identify Suspicious Financial Transactions*. International Conference on Cyber-Enabled Distributed Computing and Knowledge Discovery, 60-65, <https://api.semanticscholar.org/CorpusID:9956948>

Luo, X. (2014). *Suspicious Transaction Detection for Anti-Money Laundering*, International Journal of Security and Its Applications, 8(2), 157-166.