

کشف تقلب در سامانه های پرداخت الکترونیک با استفاده از یادگیری عمیق

شیما اشرفی^۱، محمد طهرانی^۲، بابک مجیدی^۳

۱- دانشجوی کارشناسی ارشد رشته کامپیوتر (نرم افزار)، دانشگاه خاتم، تهران، ایران

۲- استادیار گروه کامپیوتر، دانشگاه خاتم، تهران، ایران

۳- استادیار گروه کامپیوتر، دانشگاه خاتم، تهران، ایران

نویسنده مسئول: m.tehrani@khatam.ac.ir

خلاصه

یکی از مهم ترین موانع برای استفاده از بانکداری الکترونیک، عدم امنیت تراکنش ها و بروز تقلب در مسیر انجام مبالغه مالی است. با توجه به رشد روزافزون تقلب که باعث از دست دادن سرمایه های زیادی در سطح جهان و ایران شده و نظر به اینکه از یک سو روش های زیادی برای کشف تقلب ارائه شده است ولی روش های تقلب هم مدرن تر شده و در حوزه های مختلف در حال رشد هستند و از سوی دیگر حجم بالای داده و شباهت زیاد بین آن ها باعث می شود طبقه بندی داده به متقلبان و سالم کار بسیار دشواری باشد و نیز یکی از مشکلات در تشخیص تقلب، تنوع و تغییر مداوم شیوه های تقلب است و موفقیت در پیشگیری و یا تشخیص یک نوع تقلب باعث به وجود آمدن روشی دیگر می شود. بنابراین در این مقاله بر آن شد که روشی برای کشف تقلب در حوزه پرداخت با کلمات کلیدی اعتباری ارائه شود و در این حوزه تمرکز را بر روی تقلب هایی که از سوی پذیرنده صورت می گیرد قرار داده شد. در این پژوهش برای شناسایی تقلب از روش ترکیبی یادگیری عمیق با شبکه های عصبی (ANN) به همراه متد خودرمزگذار^۱ به شناسایی ناهنجاری ها در مجموعه داده پرداخته شد که با دقت بالایی تراکنش ها به دو دسته متقلبان و مجاز طبقه بندی شد.

کلمات کلیدی: تشخیص تقلب، شبکه عصبی، یادگیری عمیق، خودرمزگذارها

۱. مقدمه

با پیشرفت روزافزون فناوری های نوین در علوم کامپیوتری، بانکها و موسسات مالی و اعتباری نیز دستخوش این پیشرفت ها شده اند. هر آنچه این فناوری ها باعث سهولت در کارها و مدیریت بهتر فرآیندها شده اند ولی مشکلاتی به همراه داشته اند، که از آن جمله می توان به بروز تقلب در تراکنش های مالی و الکترونیکی اشاره کرد که سالانه هزینه ها و خسارات زیادی را برای بانک و موسسات دربرداشته است. [۱]

در سال های اخیر پیشرفت زیادی در استفاده از بانکداری الکترونیک و سامانه های مدرن بانکی در ایران دیده می شود. در نتیجه بروز تقلب و سوء استفاده های مالی نیز افزایش می یابد و از آنجا که حجم این داده ها و تراکنش ها بسیار بالا است پیدا کردن ناهنجاری و تقلب در این حجم بالای داده کار بسیار مشکلی است که با به میدان آمدن روش های داده کاوی و هوش عملیاتی، روش هایی برای کشف تقلب به صورت خودکار پیاده سازی شده است. [۲]

¹ Artificial Neural Network

² .Autoencoder

در سیستم های بانکی کشور، سیستم جامعی برای کشف تقلب تراکنش های مبتنی بر کارت به صورت برخط وجود ندارد و به همین دلیل شیوه هایی از تقلب ها شناسایی نمی شوند و متقلبان سال های زیادی از این روش ها استفاده می کنند [۱]. از این رو بر آن شد که به شناسایی تقلب در تراکنش های بانکی مبتنی بر کارت که از سوی پذیرنده صورت می گیرد پرداخته شود. اگر بتوان به صورت برخط، شناسایی تقلب های صورت گرفته از سوی پذیرنده را افزایش داد، می توان در بالا بردن اعتماد مشتریان و میزان رضایت آنان نقش بسزایی داشت که این یکی از اهداف و چشم اندازهای هر سیستم خدمت گذار می تواند باشد. بنابراین مهم ترین بخش تحقق این آرمان شناسایی ناهنجاری ها در این حجم بالای داده و طبقه بندی داده در دو بخش مجاز و متقلبانه است. البته باید به این موضوع هم توجه داشت که اگر یک تراکنش سالم هم متقلبانه تشخیص داده شود باعث می شود اعتماد به سیستم کم شده و رضایت مشتریان پایین بیاید. پس کار بسیار دقیق و حساسی باید صورت گیرد تا داده ها به درستی طبقه بندی شوند. تراکنش های زیادی توسط دستگاه های POS در ساعت مختلف روز به سمت سوئیچ های بانکی سرازیر می شود به همین دلیل به زیرساخت بسیار قوی نیاز است تا با حداقل زمان ممکن تراکنش های غیر مجاز شناسایی و به کاربران اخطار داده شود [۲].

در این مقاله از شبکه عصبی عمیق برای آموزش و طبقه بندی داده ها استفاده شده است، و برای کاهش اندازه داده از متد خودرمزگذار استفاده شد که پس از ساخت مدل و پردازش آن با دقت بالغ بر ۸۳٪ موارد تقلب و تقریباً ۱۰۰٪ موارد غیر تقلب را شناسایی شد.

در ادامه به بیان موضوع و لزوم انجام کار پرداخته و کارهای پیشین انجام شده مورد بررسی قرار گرفته است و بعد از آن شبکه عصبی عمیق و الگوریتم های خودرمزگذار توضیح داده شده و در انتها مدل پیشنهادی ارائه داده شده و نتیجه بدست آمده، شرح داده می شود.

dataacademy.ir

۲. کارهای انجام شده در زمینه کشف تقلب با استفاده از شبکه های عصبی عمیق

وئوق و همکارانش در سال ۱۳۹۳ در پژوهش خود برای تشخیص تقلب در تراکنش های بانکی از مدل شبکه های عصبی مصنوعی پرسپترون چندلایه ی جلورونده استفاده کرده اند. آن ها از داده های یکی از بانک های داخلی استفاده کردند، و با دقت نسبتاً خوبی توانستند داده ها را طبقه بندی کنند.

اولزووسکی (۲۰۱۴) برای تشخیص تقلب روشی براساس نقشه های خود سازمان ده و شبکه عصبی پیشنهاد کرده است. او با کمک شبکه عصبی خود سازمان ده (SOM) و یک روش آستانه تشخیص بر اساس ماتریس UOM سیستمی پیشنهاد داده و اثربخشی روش پیشنهادی را تایید می کند [۳].

فهیمه قبادی و همکاران (۱۳۹۵) در پژوهش خود یک مدل تشخیص تقلب کارت های اعتباری مبتنی بر شبکه های عصبی مصنوعی و چند هزینه ای برای کاهش ریسک و خطر از دست دادن داده های واقعی ارائه دادند و با توجه به ماهیت نامتعادل داده (موارد تقلب و غیر تقلب)، شناسایی معاملات جعلی بسیار دشوار بوده و برای مقابله با مشکل داده های نامتعادل، به مدل خود روش چند هزینه را اضافه کرده اند. مدل پیشنهادی که شبکه عصبی حساس به هزینه (CSNN) نامیده می شود، مبتنی بر روش تشخیص سوء استفاده است. در این مدل در مقایسه با مدل مبتنی بر سیستم ایمنی مصنوعی (AIS) [۴]، صرفه جویی در هزینه و افزایش میزان تشخیص نشان داده شده است. در خصوص کشف ناهنجاری در بزرگ داده ها، نیز می توان به کار سلطانی حلوائی و اکبری (۲۰۱۴) با استفاده از سیستم های ایمنی مصنوعی و مدل نگاشت کاهش در محیط پردازش ابری به کشف ناهنجاری در بزرگ داده پرداخته است اشاره کرد.

1. Self Organization Map

2. Cost Sensitive Neural Network

3. Artificial Immune System

سلیک و همکاران (۲۰۱۷) معتقدن نرمال بودن داده ها برای استفاده در شبکه های عصبی مصنوعی اغلب نیاز به تجزیه و تحلیل آماری گسترده دارد و یک بررسی اولیه از یک مطالعه موردی شامل شناسایی تقلب کارت اعتباری، که در آن تجزیه خوشه ای به منظور نرمال بودن استفاده شده است، ارائه داده اند. نتایج حاصل از استفاده ی شبکه های عصبی مصنوعی و تجزیه و تحلیل خوشه های در شناسایی تقلب در پژوهش آن ها نشان می دهد که ورودی های عصبی توسط ویژگی های خوشه های کاهش می یابد. [۱]

تمام کارهای قبلی در زمینه ی کشف تقلب، بر روی یادگیری ماشین و شبکه ی عصبی با یادگیری نظارت شده (با سرپرست) بوده است. اما بر آن شد که از یادگیری ماشین بدون سرپرست یا ناظر استفاده شود. به عنوان مثال برای خوشه بندی و کاهش (غیر خطی) اندازه ی داده از خودرمزگذارها و در تشخیص ناهنجاری ها از یادگیری عمیق ماشین، برای تجزیه و تحلیل تقلب استفاده شد.


شبکه ی عصبی مصنوعی در سال ۱۹۴۰ با الگو گرفتن از عملکرد مدل نورون های عصبی مغز انسان مطرح شده است و داده ها به اجزایی به نام نورون تقسیم می شود و اطلاعات بین نورون ها رد و بدل می شود و هر یک از این رابطه ها دارای وزنی می باشند که به مرور آموزش داده می شوند و وزن ها در شبکه تنظیم می شود.

در پایین، نشان داده می شود که چگونه می توان از خودرمزگذارها در تشخیص ناهنجاری ها استفاده نمود. تا قبل از آموزش یک مدل، با استفاده از خودرمزگذارها طبقه بندی و نحوه عملکرد مدل در داده های نامتعادل را اندازه گیری کنید. خودرمزگذارها، شبکه های عصبی مصنوعی با یادگیری عمیق هستند که برای رمزگذاری داده ها در شبکه از آن ها استفاده می شود تا اندازه داده ها را کاهش دهند و برای داده ها با حجم بالا به کار برده می شود [۲].

در شبکه ی خودرمزگذار حداقل سه لایه وجود دارد که در صورت داشتن تعداد بیشتری لایه فقط می توان لایه های میانی (پنهان) را افزایش داد. ترتیب لایه ها به صورت زیر می باشد.

- لایه ورودی (یک لایه)
- لایه (ها) ی پنهان (یک یا تعداد بیشتر)
- لایه خروجی (یک لایه)

همانطور که در شکل ۱ نشان داده شده است نورون های ورودی رمزگذاری می شوند و لایه های میانی را تشکیل می دهند و لایه های مخفی میانی هم رمزگشایی می شوند تا خروجی را بسازند.



شکل ۱ - نحوه کارکرد شبکه های خودرمزگذار



شبکه‌ی چند لایه هنگام کار در حالت خودرمزگذار، گاهی اوقات یک انتخاب عالی برای انجام فشرده‌سازی داده‌ها یا کاهش ابعاد فضای ویژگی در برنامه‌های پردازش اطلاعات می‌باشد و نشان می‌دهد که برای ارتباط خودکار، غیرخطی بودن واحدهای پنهان بی‌فایده است [۱].

۳. یادگیری عمیق برای تشخیص تخلف بانکی

داده‌های اصلی پژوهش از تراکنش‌های ثبت شده کارت‌های بانکی در پایگاه داده‌ی یکی از بانک‌های خصوصی داخلی کشور و با رعایت ملاحظات اخلاقی و با اخذ مجوز از آن بانک، به دست آمد و از آن برای طراحی مدل شناسایی تقلب در کارت‌های بانکی بهره‌جویی شد. لذا تراکنش‌های حدود ۸۶ هزار کارت در بازه‌ی زمانی تقریبی یک ماه، با حدود بیش از ۲۵۰ هزار تراکنش استخراج شده است. با توجه به تعدد فیله‌های اطلاعاتی و کاربردی نبودن برخی از آن‌ها برای این پژوهش، پس از تحلیل آن‌ها به کمک خبرگان و در نظر گرفتن تقلب‌های صورت‌گرفته و شناسایی فیله‌های تحت تأثیر تقلب‌های مختلف، پارامترهای مؤثر در طراحی مدل پژوهش استخراج شد و فیله‌های ناکاراز از پایگاه اطلاعاتی کنار گذاشته شد.

مجموعه‌ی داده‌ها حدود ۲۵۰,۰۰۰ مورد از تراکنش‌های کارت‌های اعتباری را ارائه می‌دهد و برای هر تراکنش می‌توان مشخص نمود که آیا تراکنش جعلی است یا نه. داده‌های مجموعه‌ای مانند این، هنگام انجام یادگیری ماشین دارای رفتار خاصی هستند، زیرا آن‌ها به شدت ناسازگار و نامتوازن می‌باشند. در این مورد مطالعه فقط ۰,۱۰۱٪ از همه‌ی معاملات جعلی بوده و برچسب گذاری شدند.

هنگام برخورد با چنین عدم تعادل شدید در پایگاه داده در زمان اندازه‌گیری عملکرد مدل، باید مراقب بود تا اشتباه نشود. از آنجا که فقط تعداد بسیار اندکی از موارد، متقلبانه هستند، مدلی که با دقت بالای ۹۹٪ تراکنش‌های مجاز را شناسایی کند، با وجود دقت بالای آن، چنین مدلی لزوماً به ما کمک نمی‌کند که موارد جعلی را با دقت بالا پیدا کنیم. برای ایجاد شبکه‌ی عصبی چندلایه به منظور شناسایی تقلب در کارت‌های بانکی، پس از آزمایش حالت‌های مختلف ایجاد شده برای شبکه‌ی عصبی (تعداد لایه‌های مختلف، تعداد گره‌های مختلف در هر لایه و توابع تبدیل مختلف)، بهترین حالت انتخاب شد. این کار با مقایسه‌ی میانگین مربعات خطا (MSE) در هریک از حالات انجام گرفت.

برای بررسی داده‌ها و متغیرهای مدل، متغیرهای ورودی شبکه‌ی عصبی، شامل ۶ متغیر مستقلی است که در تعیین رفتار دارنده‌ی کارت و ترمینال پذیرنده‌ی کارت نقش دارند. برای متغیر خروجی در سیستم نیز یک پارامتر تعیین شده است. شش متغیر ورودی را فیله‌های اطلاعاتی انتخابی از میان تمامی فیله‌های مربوط به تراکنش‌های ثبت شده در سیستم بانکی تشکیل می‌دهند. این فیله‌ها از انواع مختلفی مانند عددی، رشته‌ای، تاریخ، زمان و غیره هستند که برای تبدیل به متغیرهای قابل استفاده در مدل‌سازی باید به نوع عددی تبدیل شوند. یک مدل شبکه عمیق عصبی با استفاده از فرم‌های تشکیل شده برای شبکه‌ی عصبی چند عاملی روبه جلو با لایه‌های مخفی به سایز (۱۰,۲,۱۰) ساخته شده است. برای ایجاد مدل شناسایی تقلب در تراکنش‌های کارت‌های اعتباری بانکی، یک متغیر افزاز ایجاد شد تا بتوان داده‌ها را به دو بخش آموزش و اعتبارسنجی تقسیم‌بندی کرد. به واسطه‌ی تعریف متغیر افزاز و انتخاب داده‌هایی که برای آموزش و آزمون استفاده خواهند شد، از مجموع ۲۵۶,۵۵۹ داده، ۲۰۵,۲۴۶ داده (۸۰ درصد) برای آموزش و ایجاد مدل اختصاص یافت و ۵۱,۳۱۳ داده (۲۰ درصد) برای اعتبارسنجی مدل به صورت تصادفی تخصیص داده شد. از مجموع

1. Mean Square Error



دومین کنفرانس بین المللی پژوهش های دانش بنیان در مهندسی کامپیوتر و فناوری اطلاعات

با مجوز به شماره ۱۶/۲۸۰۷۳۸ از وزارت علوم، تحقیقات و فناوری

2nd International Conference on Knowledge-Based Research in Computer Engineering & Information Technology

شهریور ماه ۹۶، تهران، ایران



۲۰۵,۲۴۶ داده‌های آموزشی که به دو قسمت مساوی (۱۰۲,۶۲۳) تقسیم شد، ۴۰ درصد از کل داده برای داده آموزشی با ناظر (سرپرست) و ۴۰ درصد باقی مانده از کل داده، داده آموزشی بدون ناظر تعیین شد.

تابع تبدیل انتخاب برای تمامی نوروهای لایه‌های پنهان، تابع تانژانت هیپربولیک است. رابطه‌ی ۱، تابع تبدیل استفاده شده را نشان می‌دهد. این تابع، مقادیر وزن‌ها را پس از دریافت به مقداری در بازه‌ی (۱,۱) تبدیل می‌کند.

$$\tanh(x) = 2\delta(2x) - 1 \quad (1)$$

که در آن $\sigma(X)$ به صورت زیر تعریف می‌شود:

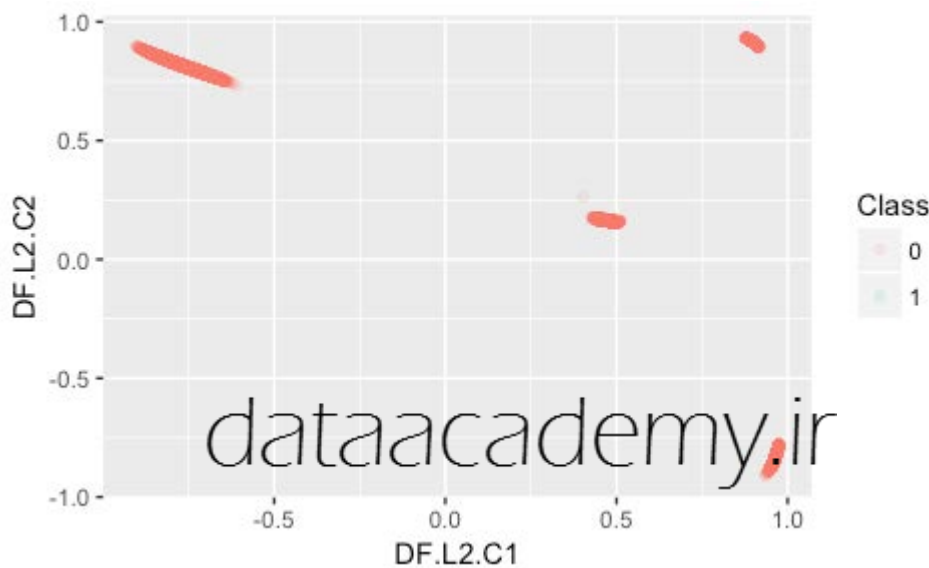
$$\delta(x) = \frac{e^x}{1 + e^x} \quad (2)$$

با بررسی داده‌ها توسط فرد خبره، الگوریتمی طراحی شد که داده‌های متقلبانه را شناسایی و برچسب گذاری کرده و ستونی به داده‌ها اضافه شد که در آن مقدار ۱ به ما می‌گوید که این تراکنش تقلب بوده است.

dataacademy.ir

مدل خودمزمگذار، الگوهای داده های ورودی را بدون در نظر گرفتن برجسب های داده، یاد می گیرد. در این مورد باید یاد بگیرد که کدام تراکنش های کارت اعتباری شبیه هستند و کدام تراکنش ها بی نظیر هستند یا ناهنجاری ها هستند. باید در نظر داشت که مدل های خودمزمگذار در داده های نامتقارن بسیار پیچیده و حساس هستند، که ممکن است الگوهای غیرمعمول را شناسایی کنند و ما را گمراه کنند.

در مرحله بعد به کاهش اندازه داده با لایه های پنهان پرداخته شد، از آنجایی که از مدل گلوگاه با دو گره در لایه مخفی و در میانه مدل شبکه عصبی استفاده شده است، می توانیم از این کاهش اندازه داده، برای کشف فضای ویژگی ها استفاده شود (مشابه آنچه که می توان با تجزیه و تحلیل مولفه اصلی انجام داد). می توانیم این ویژگی لایه های پنهان را از عملکرد الگوریتم استخراج کرد و آن را برای نمایش داده های ورودی استفاده نمود.




شکل ۳- طبقه بندی داده ها بر اساس مجاز و متقلبانه

در نمودار شکل ۳، همان طور که مشاهده می نماید، یک دسته بندی از تراکنش های تقلبی که از نمونه های مجاز متمایز نشده است دیده می شود، بنابراین کاهش اندازه داده با مدل خودمزمگذار به تنهایی نمی تواند برای شناسایی تقلب در این مجموعه داده کافی باشد. اما راه حلی که به نظر می رسد این است که می توان داده های انتخاب شده، که از کاهش اندازه های لایه های پنهان به دست آمده است، را به عنوان ویژگی هایی برای آموزش مدل مورد استفاده قرار داد. به عنوان مثال می تواند از ۱۰ ویژگی موجود در لایه اول یا سوم لایه مخفی استفاده شود. برای این منظور برای اندازه گیری عملکرد مدل در داده های آزمون، باید داده های آزمون را به همان اندازه ی کاهش یافته ی داده های آموزش تبدیل کرد. در این مرحله، به نظر می رسد شناسایی موارد تقلب با درصدی بالای ۹۲٪ بسیار خوب است. با این حال، بسیاری از موارد مجاز نیز به عنوان تقلب محسوب شده است و این موضوع برای دنیای واقعی، یک مدل خوب به شمار نمی آید. بنابراین بر آن می شویم که برخی از تکنیک های دیگر را امتحان کنیم [۱].

در ادامه به تشخیص ناهنجاری پرداخته شده است، سوالی که اینجا مطرح می شود اینست که از نمونه هایی که در مجموعه داده های آزمون وجود دارد کدام داده ها ناهنجار هستند؟ که برای این منظور می توان از الگوریتم خودمزمگذاری استفاده کرد. بر اساس مدل خودمزمگذار که قبلاً آموزش دیده بود، داده های ورودی بازسازی شدند و برای هر نمونه میانگین


خطای مربع (MSE) بین مقدار واقعی و بازسازی شده محاسبه شد. در نتیجه‌ی محاسبه میانگین مربعات، برای هر دو برچسب کلاس، نمودار زیر بدست آمد.



شکل ۴ - میزان میانگین خطای مربعات برای طبقه‌بندی مدل

همانطور که در نمودار شکل ۴ مشاهده می‌نمایید، یک طبقه‌بندی خوب در موارد داده‌های تقلب و مجاز وجود ندارد، اما میانگین خطای مربعات برای تفکیک کردن تراکنش‌های تقلبی از مجاز قابل قبول است. در این مرحله می‌توان نمونه‌های ناهنجار را با استفاده از آستانه MSE برای آنچه که در نظر گرفته می‌شود، شناسایی کرد. به عنوان مثال هر نمونه که دارای $MSE > 0.02$ (مطابق با نمودار بالا) است، به عنوان یک ناهنجاری در نظر گرفت. در این قسمت به این نتیجه می‌توان رسید که، تشخیص درست ناهنجاری با طبقه‌بندی تراکنش‌های جعلی کارت اعتباری (با حداقل با این مجموعه داده‌ها) مهیا نیست [۴].

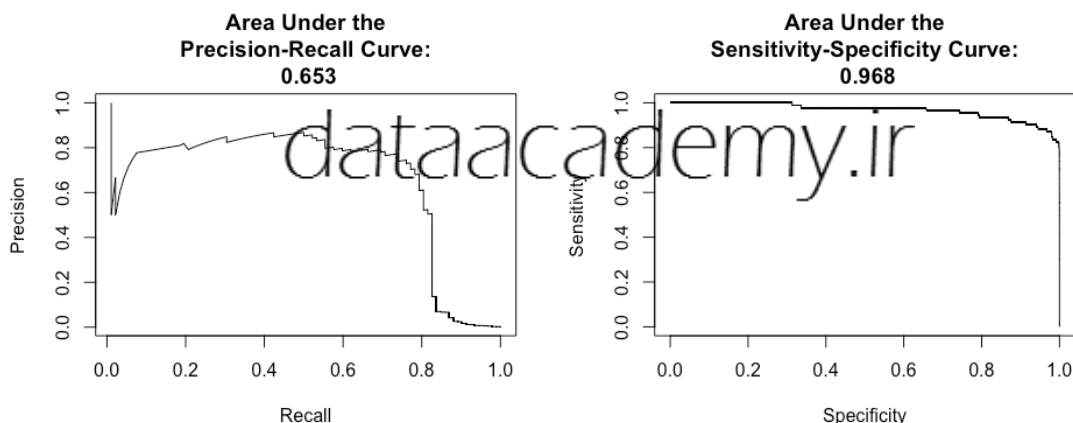
در ادامه مدل تحت نظارت پیش آموزش دیده شده را بررسی کرده و سپس از مدل خودرمزگذار به عنوان ورودی از قبل آموزش دیده برای یک مدل تحت نظارت استفاده خواهد شد. در اینجا، دوباره از یک شبکه‌ی عصبی استفاده شده است. این مدل از وزن مدل خودرمزگذار برای تنظیم گره‌های مدل استفاده کرده است.



شکل ۵ - نسبت میزان پیش بینی های مدل به کل داده

با این روش نتیجه بهتری بدست آمد. آنچه از نمودار شکل ۵ نمایان است، این است که ۱۷ درصد از موارد تقلب از دست داده شده، اما برای تعداد زیادی از موارد مجاز طبقه بندی به درستی انجام شده است. در حقیقت، اکنون اعتماد بیشتری می توان به مدل داشت زیرا پارامترهای مدل دقیق تر طراحی شدند، به عنوان مثال، زمان هایی که برای جستجو در شبکه برای بهینه سازی پارامترها، بازگشت به ویژگی های اصلی و تلاش هایی که برای محاسبه ویژگی ها و الگوریتم های مختلف صرف شد موثر واقع شدند.

اندازه گیری عملکرد مدل در داده های بسیار نامتعادل صورت گرفته است و با توجه به اینکه شناسایی موارد مجاز از حساسیت بالایی برخوردار است، نمی توان از معیارهای عملکرد مانند دقت و یا سطح زیر منحنی (AUC) استفاده کرد، زیرا نتایج بسیار خوش بینانه را براساس درصد بالایی از طبقه بندی های صحیح طبقه اکثریت ارائه می دهند. یک جایگزین خوب برای AUC استفاده از منحنی یادآوری دقیق^۱ یا یادآوری حساسیت^۲ است. روش های مختلفی برای محاسبه مساحت زیر یک منحنی وجود دارد، اما در این مقاله از یک تابع ساده استفاده شده است که محدوده بین هر جفت نقطه متوالی X را محاسبه می کند (یعنی $x_1 - x_0$ ، $x_2 - x_1$ ، و غیره) و نسبت به فضای تحت مقادیر مربوطه Y بیان می شود^۳].



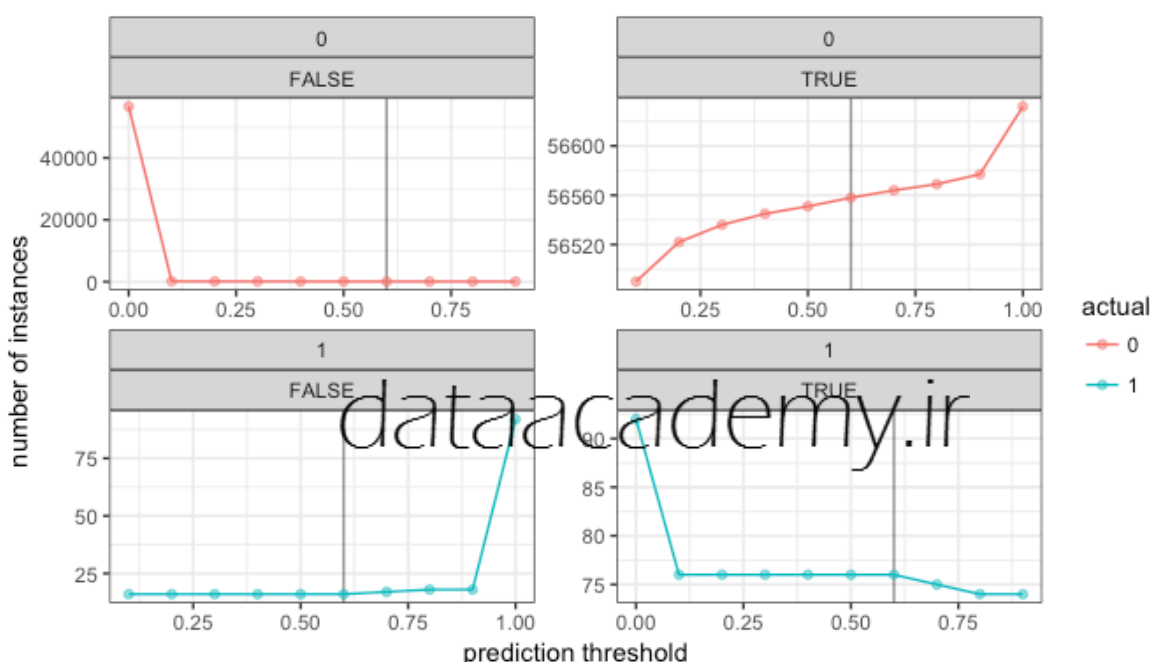
شکل ۶- نمودار ارزیابی نهایی مدل

در نمودار شکل ۶ دو شاخص حساسیت و صحت برای ارزیابی مدل نمایش داده شده است. از آنجایی که اطلاعات مدل به دو قسمت متقالبانه و مجاز تقسیم می شود می توان برای ارزیابی مدل از نمودارهای حساسیت و صحت استفاده نمود. زیرا این نمودارها برای مدل های دودویی کاربرد دارند. صحت^۴ در این مدل نسبت موارد مورد آزمایش پیش بینی شده متقالبانه که در واقع جعلی هستند بیان می شود (یعنی همان پیش بینی های مثبت واقعی^۵)، در حالی که حساسیت^۶

1 . area under the curve
2 . precision-recall curve
3 . Sensitivity recall-specificity curve
4 . Precision
5 . True Negative Rate
6 . Sensitivity

نسبت موارد سالم است که به عنوان غیرمقلبانه شناخته شده اند^۱ و مشخصه یا ویژگی نسبت موارد غیر تقلب است که به عنوان عدم تقلب شناخته شده است^۳.

منحنی یادآوری صحت نسبت تقلب واقعی به موارد تقلب که شناسایی شده است را نشان می دهد. (به عنوان مثال مواردی از تقلب، و همچنین مواردی از موارد مجاز که پیش بینی کرده ایم که تقلب است و بالعکس). منحنی حساسیت به این ترتیب ارتباط بین دسته بندی هایی که به درستی شناسایی شده برای هر دو برچسب را بیان می کند (یعنی اینکه ما موارد تقلب را به درستی تقلب پیش بینی کرده باشیم و موارد مجاز را هم به درستی مجاز تشخیص داده باشیم)^۲. همچنین می توان با نگاهی متفاوت به این مسئله و دقت به آستانه های پیش بینی های مختلف و محاسبه تعداد موارد درست در دو کلاس، داده ها را طبقه بندی کرد.



شکل ۷ - نمودارهای حساسیت و دقت نتیجه مدل

این نمودار نشان می دهد که می توان تعداد موارد به درستی طبقه بندی شده ی موارد غیر تقلب را بدون از بین بردن موارد طبقه تقلب، درست طبقه بندی کرد، هنگامی که آستانه پیش بینی را از پیش فرض ۰,۵ تا ۰,۶ افزایش داد. و در آخر مدل نهایی به درستی ۸۳٪ موارد تقلب و تقریباً ۱۰٪ موارد غیر تقلب را شناسایی کرده است.

۴. نتیجه گیری

1. True Positive Rate
2. Specificity
3. True Negative Rate

از آنجایی که تقلب مانع پیشرفت فناوری های نوین در سیستم های بانکی شده است و با توجه به رشد روزافزون تقلب که باعث از دست دادن سرمایه های زیادی در حوزه بانکداری الکترونیک شده و روش های تقلب در تراکنش های بانکی روز به روز افزایش یافته و تغییر می کنند، در این مقاله بر آن شد که روشی برای کشف تقلب در حوزه پرداخت با کارت های اعتباری ارائه شود و در این حوزه تمرکز بر روی تقلب هایی که از سوی پذیرنده صورت می گیرد قرار داده شد. در این پژوهش برای شناسایی تقلب از روش ترکیبی یادگیری عمیق با شبکه های عصبی (ANN) به همراه متد خودمزمگذار به شناسایی ناهنجاری ها در مجموعه داده پرداخته شد و داده های آموزش شامل دو دسته با ناظر و بدون ناظر بودند که با دقت بالایی تراکنش ها به دو دسته متقلبانه و مجاز طبقه بندی شدند. و با دقت بالای ۸۳ درصد موارد متقلبانه به درستی تشخیص داده شد و نیز با دقت تقریباً ۱۰۰ درصد موارد مجاز طبقه بندی و تشخیص داده شد.

۵. مراجع

۱. حاتمی راد، علی؛ شهریاری، حمید رضا (۱۳۹۰)؛ «روش ها و راهکارهای شناسایی تقلب در بانکداری الکترونیک»؛ فصل نامه تازه های اقتصاد، شماره ۱۳۴، سال نهم، ص ۲۱۹-۲۲۸.
۲. بنائی، هادی؛ خوش نیت، حسام (۱۳۹۰)؛ «نقش و کاربرد هوش عملیاتی و داده کاوی در کشف تقلب بر خط»؛ ششمین همایش ملی تجارت و اقتصاد الکترونیکی.
۳. وثوق، م و تقوی فرد، م. ت والبرزی، م. شناسایی تقلب در کارت های بانکی با استفاده از شبکه های عصبی مصنوعی. نشریه مدیریت فناوری اطلاعات ۶ (۶) ۲۴۶-۲۲۱
۴. سلطانی حلوائی، ندا؛ اکبری، محمد کاظم و سرگلزایی جوان، مرتضی؛ (۱۳۹۱) ارائه مدل پیاده سازی سیستم کشف تقلب کارت های اعتباری در محیط ابری با استفاده از نگاشت-کاهش، اولین کارگاه ملی رایانش ابری، تهران، دانشگاه صنعتی امیرکبیر.
- ۵ Olszewski, D. (2014). Fraud detection using self-organizing map visualizing the user profiles. Knowledge-Based Systems, 70: 324-334.
۶. Celik, E. (2017) & Kondiloglu, A. Detection of fake banknotes with Artificial Neural Networks and Support Vector Machines, 2165-0608.
- ۷ Modeling word perception using the Elman network, Liou, C. -Y. , Huang, J. -C. and Yang, W. -C. Neurocomputing, Volume 71, 3150-3157 (2008), doi:10.1016/j.neucom.2008.04.030.
- ۸ Auto-association by multilayer perceptrons and singular value decomposition, H. Bourlard and Y. Kamp Biological, Cybernetics Volume 59, Numbers 4-5, 291-294, doi: 10.1007/BF00332918.
- ۹ Huang, R., Tawfik, H., Nagar, A.K. (2010). A novel hybrid artificial immune inspired approach for online break-in fraud detection. Procedia Computer Science, 1(1): 2733-2742.
- ۱۰ Ogwueleka, F. N. (2011). Datamining application in credit card fraud detection system. Journal of Engineering Science and Technology, 6(3): 311-322.
- ۱۱ Patidar, R. & Sharma L. (2011). Credit card fraud detection using neural network. International Journal of Soft Computing and Engineering, 1 (NCAI2011): 2231-2307.



دومین کنفرانس بین المللی پژوهش های دانش بنیان در مهندسی کامپیوتر و فناوری اطلاعات

با مجوز به شماره ۱۶/۲۸۰۷۳۸ از وزارت علوم، تحقیقات و فناوری

2nd International Conference on Knowledge-Based Research in Computer Engineering & Information Technology

شهریور ماه ۹۶، تهران، ایران



۱ Sakharova, I. (2012). Payment card fraud: Challenges and solutions .Proceedings of IEEE International Conference on Intelligence and Security Informatics (ISI), 227-234.

dataacademy.ir