سال چهارم ، شماره ۳، ۱۴۰۴، صفحات ۱۴۲۵ الی ۱۴۳۸
پژوهشنامه علم مدیریت در صنعت

ادغام نظارت ریسک و تکنیک‌های یادگیری ماشین در پیشگیری از کلاهبرداری در بیمه‌های خودرو

دکتر ایمان عزیزی[1]

[1] دکتری مدیریت بازرگانی، گرایش مدیریت بازاریابی، دانشگاه پیام نور، تهران، ایران.

Aziziiman93@yahoo.com

تاریخ دریافت: ۱۴۰۴/۰۷/۲۵ تاریخ پذیرش: ۱۴۰۴/۰۸/۱۰ تاریخ انتشار: ۱۴۰۴/۰۸/۱۵

Integrating risk monitoring and machine learning techniques in fraud prevention in auto insurance

Dr. Imam Azizi

[1] PhD in Business Administration, Marketing Management Major, Payam Noor University, Tehran, Iran.

چکیده

تقلب در بیمه، به ویژه تقلب در بیمه خودرو، یک موضوع رایج در زمینه تقلب است که باعث ضررهای مالی قابل توجهی برای شرکت‌های بیمه می‌شود. ادعاهای نادرست، فشار مالی قابل توجهی را بر شرکت‌های بیمه تحمیل می‌کند که بر کل صنعت تأثیر می‌گذارد. به همین دلیل، بیمه‌گران دائماً به دنبال سیستم‌های تشخیص مؤثرتری هستند تا از محدودیت‌های تکنیک‌های سنتی فراتر روند. بنابراین، ایجاد یک مدل تشخیص تقلب قابل اعتماد و مؤثر برای حفظ ثبات مالی و اعتبار ارائه دهندگان بیمه بسیار مهم است. هدف اصلی پژوهش بررسی ادغام نظارت ریسک و تکنیک‌های یادگیری ماشین در پیشگیری از کلاهبرداری در بیمه‌های خودرو است. این مطالعه به‌صورت توصیفی–پیمایشی و با استفاده از پرسشنامه معتبر، با نظرخواهی از ۹۹ نفر از مدیران و کارشناسان ارشد بیمه های خودرو در شرکت‌های بیمه انجام شد. برای آزمون مدل و فرضیه‌ها از نرم‌افزار SmartPLS 3 استفاده گردید. یافته‌ها نشان می‌دهد که بهبود سیستم های نظارت بر رسیک، تأثیر مثبتی بر پیشگیری از کلاهبرداری در بیمه‌های خودرو در شرکت‌های بیمه دارند و استفاده از تکنیک‌های یادگیری ماشین میزان تأثیر نظارت بر ریسک بر پیشگیری از کلاهبرداری در بیمههای خودرو را به میزان قابل توجهی افزایش می‌دهد.

کلید واژه: نظارت بر ریسک، پیشگیری از کلاهبرداری، تقلب در بیمه خودرو، تکنیک‌های یادگیری ماشین، شرکت‌های بیمه.

Abstract

Insurance fraud, especially auto insurance fraud, is a common fraud issue that causes significant financial losses for insurance companies. False claims impose significant financial pressure on insurance companies, affecting the entire industry. For this reason, insurers are constantly looking for more effective detection systems to overcome the limitations of traditional techniques. Therefore, developing a reliable and effective fraud detection model is crucial to maintaining the financial stability and reputation of insurance providers. The main objective of the research is to investigate the integration of risk monitoring and machine learning techniques in fraud prevention in auto insurance. This descriptive-survey study was conducted using a validated questionnaire, surveying 99 senior auto insurance managers and experts in insurance companies. SmartPLS 3 software was used to test the model and hypotheses. The findings show that improving risk monitoring systems have a positive impact on preventing fraud in auto insurance in insurance companies, and the use of machine learning techniques significantly increases the impact of risk monitoring on preventing fraud in auto insurance.

Keywords: Risk monitoring, fraud prevention, auto insurance fraud, machine learning techniques, Insurance companies.

۱. مقدمه

تشخیص تقلب یک نگرانی اساسی برای شرکت‌ها و مؤسسات دولتی در حوزه‌های مختلف، از جمله صنعت بیمه است. ادعاهای کلاهبرداری در بخش بیمه خودرو می‌تواند منجر به خسارات مالی قابل توجهی برای بیمه‌گران شود. تشخیص فعالیت‌های کلاهبرداری در صنعت بیمه خودرو برای به حداقل رساندن خسارات مالی برای بیمه‌گران بسیار مهم است (تانگ و همکاران[1]، ۲۰۲۰). یکی از حوزه‌هایی که در زمینه تشخیص تقلب توجه قابل توجهی را به خود جلب کرده است، بیمه خودرو است. کلاهبرداری در بیمه خودرو می‌تواند به اشکال مختلفی مانند تصادفات ساختگی، ادعاهای اغراق‌آمیز و اسناد جعلی رخ دهد (پالاکیو[2]، ۲۰۱۸). ادعاهای کلاهبرداری در صنعت بیمه خودرو می‌تواند منجر به خسارات مالی قابل توجهی برای بیمه‌گران شود. بیمه‌گران تیم‌هایی را برای شناسایی و مبارزه با ادعاهای کلاهبرداری اختصاص داده‌اند، اما تشخیص کلاهبرداری به دلیل ماهیت پیچیده آن و وجود مجرمان خبره می‌تواند چالش برانگیز باشد (مولر و همکارن[3]، ۲۰۱۶). ادعاهای کلاهبرداری بیمه خودرو نگرانی قابل توجهی را برای شرکت‌های بیمه ایجاد می‌کند. طبق گزارش‌ها، ممکن است جنبه‌هایی از کلاهبرداری مشکوک در بین ۲۱ تا ۳۶ درصد از ادعاهای بیمه خودرو وجود داشته باشد؛ با این وجود، کمتر از ۳ درصد از این موارد منجر به پیگرد قانونی می‌شود (تانگ و همکاران، ۲۰۲۰). با توجه به اینکه ادعاهای کلاهبرداری بیمه پنج تا ده درصد از کل ادعاها را تشکیل می‌دهد و سالانه حدود ۳۱ میلیارد دلار برای شرکت‌های بیمه هزینه دارد، این امر فشار مالی سنگینی را بر آن‌ها وارد می‌کند (مون و همکاران[4]، ۲۰۱۹). انواع مختلفی از کلاهبرداری بیمه وجود دارد که شامل کلاهبرداری داخلی است که شامل کلاهبرداری انجام شده توسط کارمندان و بیمه‌گران و کلاهبرداری خارجی است که از سوی بیمه‌گذار یا ذینفعی که مستقیماً با بیمه‌گر مرتبط است، انجام می‌شود. شرکت‌های بیمه باید سیستم‌های کارآمد تشخیص کلاهبرداری را برای مقابله با این مسئله رو به گسترش راه‌اندازی کنند. بیمه‌گران از روش‌های مختلفی برای تشخیص و جلوگیری از کلاهبرداری، مانند تحقیقات دستی، تجزیه و تحلیل داده‌ها و استفاده از تجزیه و تحلیل پیش‌بینی‌کننده استفاده می‌کنند (تانگ و همکاران، ۲۰۲۰). فرآیند نظارت بر ریسک مالی، جزء مهمی از چارچوب کلی نظارتی برای شرکت‌های بیمه است. عناصر نظارت بر ریسک مالی عبارتند از گزارشگری مالی، تجزیه و تحلیل و بررسی‌های هشدار اولیه و همچنین مداخله. محیط اقتصادی، ریسک‌هایی را ایجاد می‌کند که باید توسط سیستم‌های نظارت مالی مورد توجه قرار گیرند. شرکت‌های بیمه از ابزارهای پیشگیری از کلاهبرداری و پیشرفت‌های فناوری بهره برده‌اند. در این زمینه، شرکت‌های بیمه برای ایجاد پایگاه داده صنعت بیمه تلاشهایی برای کاهش کلاهبرداری در صنعت انجام داده اند. با این حال، این پایگاه داده فقط یک دسته از بیمه‌های غیرعمر را پوشش داده است. علاوه بر این، گزارش شده است که از نسبت‌های مالی کلیدی برای تجزیه و تحلیل و نظارت بر سلامت مالی صنعت و شیوه‌های مدیریت ریسک در بین بیمه‌گران استفاده می شود. فرآیندهای مختلف مدیریت ریسک شامل شناسایی، ارزیابی و نظارت بر ماهیت و میزان ریسکی است که یک شرکت متحمل می‌شود. چالش‌های زیادی پیش روی صنعت بیمه در کشور وجود دارد، از جمله کلاهبرداری توسط مشتریان و کارمندان، تأخیر در تسویه خسارت، خسارت‌های بالا، ضعف‌های ساختاری، تأخیر در وصول حق بیمه، حاکمیت ضعیف، رشد اقتصادی پایین، اشباع صنعت، نفوذ کم خدمات بیمه و کمبود نقدینگی که منجر به فروپاشی

[1] . Tang et al
[2] . Palacio
[3] . Müller et al
[4] . Moon et al

برخی از شرکت‌ها شده است (جاگدیش و همکاران[1]، ۲۰۲۰). یکی از رویکردهایی که نویدبخش تشخیص کلاهبرداری در صنعت بیمه خودرو بوده است، استفاده از تکنیک‌های یادگیری ماشین است. تکنیک‌های یادگیری ماشین پتانسیل تجزیه و تحلیل مقادیر زیادی از داده‌ها و شناسایی الگوهایی را دارند که ممکن است نشان‌دهنده فعالیت کلاهبرداری باشند. با استفاده از داده‌های تراکنش‌های تاریخی، اطلاعات شبکه‌های اجتماعی و سایر منابع خارجی، مدل‌های یادگیری ماشینی می‌توانند برای تشخیص ناهنجاری‌ها، استثنائات و داده‌های پرت که ممکن است نشان‌دهنده تقلب بالقوه باشند، آموزش داده شوند(زانده و همکاران[2]، ۲۰۱۹). تکنیک‌های یادگیری ماشینی در سال‌های اخیر به عنوان ابزارهای قدرتمندی برای تشخیص تقلب ظهورکرده‌اند. استفاده از یادگیری ماشینی در تشخیص تقلب در سال‌های اخیر به موضوعی جالب و امیدوارکننده تبدیل شده است (جاین و کهان[3]، ۲۰۱۷). بنابراین این پژوهش به بررسی چگونگی تأثیر نظارت بر ریسک بر پیشگیری از کلاهبرداری در بین شرکت‌های بیمه با نقش تعدیلگری تکنیک‌های یادگیری ماشین می پردازد.

۲. مبانی نظری پژوهش

کلاهبرداری در بیمه

کلاهبرداری بیمه به یک عمل عمدی و نادرست در ارائه ادعاهای نادرست یا گمراه‌کننده، یا مشارکت در هرگونه فعالیت جعلی دیگر با هدف فریب دادن یک شرکت بیمه در مورد کالاهای پرداختی اشاره دارد. همه بیمه‌گذاران می‌توانند به دلیل کلاهبرداری بیمه، حق بیمه بسیار بالاتری بپردازند که برای شرکت‌های بیمه هزینه زیادی دارد. در مطالعه‌ای که در سال ۲۰۲۲ توسط CAIF انجام شد، ائتلاف علیه کلاهبرداری بیمه کشف کرد که کلاهبرداری بیمه می‌تواند سالانه حدود ۳۰۸ میلیارد دلار برای مصرف‌کنندگان آمریکایی هزینه داشته باشد (جاگدیش و همکاران، ۲۰۲۰). اگرچه کلاهبرداری بیمه می‌تواند اشکال مختلفی داشته باشد، اما به طور کلی به دو دسته تقسیم می‌شود:

کلاهبرداری سخت: ادعاها کاملاً ساختگی هستند یا وقایع به گونه‌ای صحنه‌سازی می‌شوند که به طور متقلبانه پول بیمه دریافت شود. برای دریافت پول بیمه، یک بیمه‌گذار می‌تواند، برای مثال، یک تصادف یا سرقت خودرو را جعل کند.

کلاهبرداری نرم: این نوع کلاهبرداری شایع‌تر و نامحسوس‌تر است. این نوع کلاهبرداری زمانی اتفاق می‌افتد که افراد برای به دست آوردن بیشترین پول از یک ادعای بیمه معتبر، حقایق را جعل می‌کنند یا ادعاهای خود را بیش از حد بیان می‌کنند. این می‌تواند شامل بزرگنمایی سطح جراحات وارده در یک تصادف یا افزایش ارزش کالاهای دزدیده شده باشد (ماناوالان[4]، ۲۰۲۰).

نظارت بر ریسک

این مطالعه با نظریه مدیریت ریسک هدایت شده است. طبق گفته اسمیت و استولز (۱۹۸۵)، پوشش ریسک می‌تواند با محدود کردن زیان‌های سنگین ورشکستگی منجر به حداکثرسازی ارزش شرکت شود. مدل‌های پوشش ریسک فقط رفتار مدیریت ریسک پیش‌بینی‌شده از سوی شرکت را توجیه می‌کنند. نظریه مدیریت ریسک شرکتی با مرتبط کردن ویژگی‌های شرکت، مانند سررسید پروژه، اهرم مالی و زیان‌های سنگین به انگیزه‌های مدیریت ریسک، پیش‌بینی ایجاد می‌کند. این نظریه معتقد است که سهامداران تصمیمات مدیریت ریسک را می‌گیرند و این فرصت را دارند که ریسک دارایی‌ها را بدون تأیید دارنده اوراق قرضه تغییر دهند. این نظریه فرض می‌کند که سهامداران شرکت‌های اهرمی ممکن است به دلیل انگیزه‌های تغییر ریسک، مشارکت در فعالیت‌های پوشش ریسک را بهینه ندانند. علاوه بر

[1] . Jagdish et al
[2] . Zande et al
[3] . Jain & Khan
[4] . Manavalan

این، مدیریت ریسک یک شرکت تا زمانی انجام می‌شود که ارزش فعلی جریان نقدی مورد انتظار شرکت را افزایش دهد. فرض کلیدی این نظریه، تمایز بین بحران مالی و ورشکستگی است. این نظریه همچنین دانش کامل در مورد تمام پارامترهای تصمیم‌گیری مربوطه را فرض می‌کند. با این حال، با توجه به پیچیدگی شرکت‌ها و ماهیت پویای اقتصاد جهان، بدیهی است که مدیران برای درک میزان مواجهه خود با ریسک‌ها تلاش می‌کنند. نظریه پرتفوی همچنین نشان می‌دهد که از آنجایی که سرمایه‌گذاران می‌توانند ریسک غیرسیستماتیک را از طریق تنوع‌بخشی به راحتی مدیریت کنند، نرخ بازده یک شرکت به ریسک کل بستگی ندارد، بلکه به ریسک سیستماتیک جریان نقدی آن بستگی دارد. شرکت‌های بیمه برخلاف سایر شرکت‌ها، نسبت به اکثر افراد در تحمل ریسک‌ها مزیت نسبی دارند. بنابراین، ضروری است که شرکت‌ها سازوکارهای قوی مدیریت ریسک را برای شناسایی، ارزیابی و نظارت بر ریسک به منظور بهبود ارزش شرکت ایجاد کنند. شرکت‌ها همچنین باید کنترل‌های داخلی قوی و حاکمیت شرکتی خوبی را تضمین کنند تا اطمینان حاصل شود که ریسک‌ها به درستی نظارت می‌شوند و خسارت‌ها دقیقاً برای هدفی که بیمه کرده‌اند به مشتریان شایسته داده می‌شود (زانده و همکاران، ۲۰۱۹).

تکنیک‌های یادگیری ماشین

به گفته یکی از پیشگامان حوزه یادگیری ماشین، آرتور ساموئل، "یادگیری ماشین یک حوزه مطالعاتی است که به کامپیوترها توانایی یادگیری بدون برنامه‌ریزی صریح را می‌دهد". در هسته خود، به روشی اشاره دارد که در آن یک سیستم می‌تواند از داده‌ها یاد بگیرد و عملکرد خود را بهبود یا بهینه کند. این امر به سیستم‌های کامپیوتری توانایی رشد هوش و تصمیم‌گیری منطقی را می‌دهد. در بنیادی‌ترین سطح خود، یادگیری ماشین زیرشاخه‌ای از هوش مصنوعی است که بر توسعه الگوریتم‌هایی تمرکز دارد که به کامپیوترها اجازه می‌دهد بدون برنامه‌نویسی صریح، از الگوها و داده‌ها یاد بگیرند و پیش‌بینی کنند یا بر اساس آنها اقدام کنند (ماناوالان، ۲۰۲۰). سه مرحله اصلی یادگیری ماشین عبارتند از نمایش، ارزیابی و بهینه‌سازی. هر مرحله برای ایجاد مدل‌های موفق حیاتی است.

بازنمایی: توسعه یک مدل ریاضی مناسب برای شناسایی و درک موفقیت‌آمیز الگوهای اساسی در داده‌ها، هدف اصلی این مرحله اول است. دستگاه از این مدل به عنوان راهنمایی برای یادگیری و انجام پیش‌بینی‌ها استفاده می‌کند (موشونجه[1]، ۲۰۱۹).

ارزیابی: مرحله ارزیابی، میزان تطابق مدل با داده‌های واقعی که قرار است نمایش دهد را اندازه‌گیری می‌کند. این امر مستلزم سنجش دقت پیش‌بینی و ارزیابی تعمیم‌پذیری مدل به داده‌های تازه و آزمایش نشده است. اطمینان از اینکه مدل نه underfit (ساده‌سازی بیش از حد مسئله) و نه overfit (برازش بیش از حد به داده‌های آموزشی) است، مستلزم تکمیل این مرحله حیاتی است.

بهینه‌سازی: آخرین مرحله، بهینه‌سازی است که بر بهبود عملکرد مدل تمرکز دارد. این مرحله به دنبال پر کردن شکاف دقت و قابلیت اطمینان بین پیش‌بینی‌های مدل و داده‌های واقعی است. برای افزایش اثربخشی کلی مدل، این روش اغلب مستلزم تغییر طراحی مدل، آزمایش با الگوریتم‌های مختلف و تنظیم دقیق پارامترهای آن است (کوباک و راجوانی[2]، ۲۰۲۱). الگوریتم‌های یادگیری ماشین می‌توانند بسیاری از مشکلات از جمله طبقه‌بندی، رگرسیون و خوشه‌بندی را حل کنند. این الگوریتم‌ها در درجه اول بر اساس نوع داده‌های قطار به چهار دسته اساسی طبقه‌بندی می‌شوند. این دسته‌ها عبارتند از: یادگیری تحت نظارت، یادگیری بدون نظارت، یادگیری نیمه نظارتی و یادگیری تقویتی (روی و جورج[3]، ۲۰۱۷).

[1] . Mushunje
[2] . Kabak & Rajouani
[3] . Roy & George

در سال‌های اخیر، یادگیری ماشین به عنوان ابزاری قدرتمند با کاربردهایی در زمینه‌های مختلف ظهور کرده است. تکنیک‌های یادگیری ماشین با موفقیت برای بهبود دقت پیش‌بینی و فرآیندهای تصمیم‌گیری در این حوزه‌ها به کار گرفته شده‌اند. تحقیقاتی که از یادگیری ماشین و یادگیری عمیق استفاده می‌کنند، اکنون در زمینه‌های مختلف گسترده شده‌اند (پارک و همکاران[1]، ۲۰۲۱).

روش‌های مبتنی بر یادگیری ماشین به طور فعال در تجزیه و تحلیل مشتری و بازاریابی، مانند پیش‌بینی خرید مشتری در صنعت گردشگری، پیش‌بینی ریسک ریزش مشتری در صنایع مخابرات و بانکداری و بهبود کارایی فروش و بازاریابی، مورد استفاده قرار گرفته‌اند سائینی و جارگ[2]، ۲۰۱۷). علاوه بر این، مدل‌های یادگیری ماشین در حمل و نقل برای پیش‌بینی تصادفات رانندگی کاربرد پیدا کرده‌اند. برای مثال، محققان مدل‌هایی را توسعه داده‌اند که می‌توانند احتمال تصادفات رانندگی را بر اساس عوامل مختلفی مانند شرایط آب و هوایی، حجم ترافیک و شرایط جاده به طور دقیق پیش‌بینی کنند (رادر و همکاران[3]، ۲۰۱۶). الگوریتم‌های یادگیری ماشین برای تجزیه و تحلیل تراکنش‌های مالی و شناسایی الگوهایی که نشان‌دهنده رفتار متقلبانه بالقوه هستند، مورد استفاده قرار گرفته‌اند. این الگوریتم‌ها می‌توانند به شرکتها کمک کنند تا به طور پیشگیرانه فعالیت‌های متقلبانه را شناسایی و از آنها جلوگیری کنند و در زمان و هزینه صرفه‌جویی کنند (سائینی و پاندی[4]، ۲۰۲۲).

یادگیری ماشین به عنوان ابزاری قدرتمند در حوزه‌های مختلف، از جمله تشخیص تقلب در صنعت بیمه خودرو، ظهور کرده است. استفاده از الگوریتم‌های یادگیری ماشین در سیستم‌های تشخیص تقلب در شناسایی ناهنجاری‌ها، استثنائات و داده‌های پرت در داده‌های مربوط به خسارت‌های بیمه مؤثر بوده است (حسن و همکاران[5]، ۲۰۲۱). یکی از ویژگی‌های کلیدی یادگیری ماشین، توانایی آن در ساخت مدل‌هایی است که می‌توانند دانش تولید کنند و موارد جدید و دیده نشده را بر اساس داده‌های تاریخی پیش‌بینی کنند (وانگ و ایکسائو[6]، ۲۰۱۸). با استفاده از داده‌های تاریخی در مورد ادعاهای بیمه، الگوریتم‌های یادگیری ماشین می‌توانند الگوها را یاد بگیرند و فعالیت‌های کلاهبرداری را در زمان واقعی تشخیص دهند. به عنوان مثال، در مطالعه‌ای در مورد تشخیص کلاهبرداری بیمه خودرو، نویسندگان از تکنیک‌های یادگیری ماشین مانند شبکه‌های عصبی، یادگیری بیزی، سیستم‌های ایمنی مصنوعی و ماشین‌های بردار پشتیبان برای ساخت یک سیستم جامع تشخیص کلاهبرداری استفاده کردند (جاین و کهان[7]، ۲۰۱۷). این سیستم عوامل مختلفی از جمله اطلاعات مدعی، جزئیات وسیله نقلیه، گزارش‌های تصادف و تاریخچه ادعاهای قبلی را برای شناسایی موارد کلاهبرداری بالقوه تجزیه و تحلیل کرد. این مطالعه نشان داد که سیستم تشخیص کلاهبرداری مبتنی بر یادگیری ماشین در تشخیص و جلوگیری از ادعاهای کلاهبرداری بیمه خودرو به دقت بالایی دست یافته است .یکی دیگر از پیاده‌سازی‌های عملی یادگیری ماشین در تشخیص کلاهبرداری بیمه خودرو، استفاده از تحلیل خوشه‌ای است که یک تکنیک یادگیری ماشین بدون نظارت است. تحلیل خوشه‌ای شامل گروه‌بندی ادعاهای بیمه مشابه بر اساس الگوها و ویژگی‌ها است. این تکنیک به شناسایی خوشه‌های ادعاهای بالقوه جعلی کمک می‌کند و به شرکت‌های بیمه اجازه می‌دهد تا تلاش‌های تحقیقاتی خود را اولویت‌بندی کنند. علاوه بر این، مدل‌های یادگیری ماشین تحت نظارت مانند رگرسیون لجستیک، درخت‌های تصمیم‌گیری و ماشین‌های بردار

[1] . Park et al
[2] . Saini & Garg
[3] . Ryder et al
[4] . Saini & Pandey
[5] . Hassan et al
[6] . Wang & Xu
[7] . Jain & Khan

پشتیبان نیز به طور گسترده در ارزیابی ریسک در صنعت بیمه خودرو مورد مطالعه قرار گرفته‌اند (سان و همکاران، ۲۰۲۱). بر اساس ادبیات مورد بحث، چارچوب مفهومی پیشنهادی در شکل ۱ ارائه شده است:

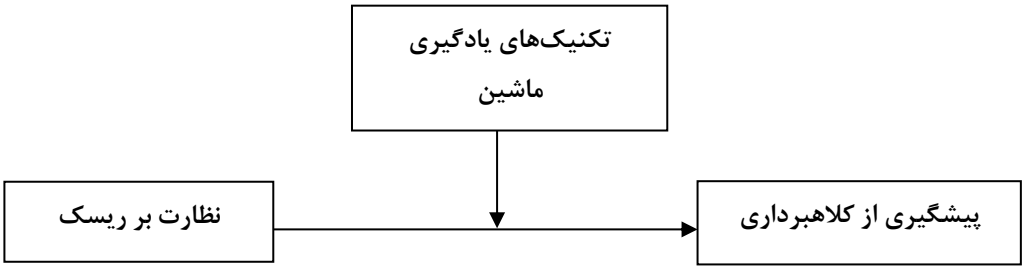

شکل ۱: مدل مفهومی پژوهش

۳. روش‌شناسی پژوهش

روش تحقیق به کار گرفته شده در این پژوهش، روش توصیفی از نوع همبستگی است. این تحقیق از این جهت یک تحقیق توصیفی است که به توصیف جزء به جزء یک موقعیت و یا یک رشته از شرایط پرداخته است. همچنین در تحقیق همبستگی متغیرهای مستقل را شناسایی و چگونگی تأثیر آن ها را بر متغیر وابسته مورد تجزیه و تحلیل قرار می دهند. در این تحقیق جامعه هدف کلیه مدیران و کارکنان ارشد بیمه های خودرو از مجموع ۳۳ شرکت بیمه ای است که از هر شرکت ۴ نفر که در مجموع جامعه آماری پژوهش تعداد آن‌ها ۱۳۲ نفر می‌باشد. در این پژوهش، محققین از روش نمونه گیری تصادفی ساده برای انتخاب جامعه نمونه استفاده کردند. سپس پرسشنامه تحقیق به صورت تصادفی بین مدیران و کارکنان ارشد بیمه های خودرو در شرکت های بیمه اجرا شد. روش نمونه گیری تصادفی ساده یکی از ساده ترین و قدیمی ترین روش های نمونه گیری با احتمالات مساوی است. به طور گسترده ای در کاربردهای عملی استفاده می شود. هنگامی که جمعیتی با اندازه N با نمونه ای به اندازه n نمونه برداری می شود و هر نمونه ممکن با اندازه n شانس مساوی برای انتخاب شدن داشته باشد، به این نمونه گیری تصادفی ساده گفته می شود. نمونه گیری تصادفی ساده را می توان به دو صورت اجرا کرد: نمونه گیری با جانمایی و نمونه گیری بدون جانمایی. با این حال، در عمل، نمونه برداری با قرار دادن چندان مفید نیست. با توجه به حجم محدود جامعه آماری که دقیقاً ۱۳۲ نفر می باشد، انتخاب حجم نمونه با استفاده از فرمول کوکران انجام شد. بنابراین، تعداد افرادی که در این تحقیق خاص مورد بررسی قرار گرفته اند، در مجموع معادل ۹۹ نفر است. متغیرهای تحقیق با استفاده از پرسشنامه استاندارد اندازه گیری شدند. جدول (۱)، خلاصه ای از سازه ها، و تعداد گویه های اندازه‌گیری هر یک از متغیرهای پژوهش را نشان می دهد. مطابق با این جدول، ضریب آلفای کرونباخ برای کلیه متغیرها بالاتر از ۷/ ۰ است که پایایی پرسشنامه را تایید می کند.

جدول ۱: سنجش عملیاتی و پایایی متغیرهای پژوهش

	متغیر	مقدار آلفای کرونباخ	تعداد سوال
متغیر مستقل	نظارت بر ریسک	۰/۸۲۳	۶
متغیر وابسته	پیشگیری از کلاهبرداری	۰/۸۷۹	۷
متغیر تعدیلگر	تکنیک‌های یادگیری ماشین	۰/۸۷۳	۵
کل پرسشنامه		۰/۸۹۸	۱۸

۴. یافته‌ها پژوهش

به منظور تجزیه و تحلیل داده‌ها با استفاده از نرم افزار PLS، از روش دو مرحله ای هالاند (۱۹۹۹) برای مدل‌یابی به روش حداقل مربعات جزئی استفاده می‌شود. در مرحله اول از برآورد روایی و پایایی به منظور بررسی مدل اندازه‌گیری استفاده می‌شود که روش‌های تاییدی هماهنگی داده‌ها با یک ساختار عاملی معین را بررسی می‌نمایند. در واقع، تحلیل عاملی تاییدی شایستگی گویه‌هایی که برای معرفی متغیرها برگزیده شده‌اند را بررسی می‌کند. در مرحله دوم از تحلیل مسیر شاخص‌های برازش مدل و ضریب تعیین جهت بررسی مدل ساختاری استفاده می‌شود. به زعم پژوهشگران مدل سازی معادلات ساختاری به روش حداقل مربعات جزئی برخلاف روش کواریانس محور (نرم افزارهای لیزرل، آموس) فاقد شاخص‌های برازش مدل مبتنی بر کای دو، جهت بررسی میزان مطابقت مدل نظری با داده‌های گردآوری شده است.

جدول ۲: سنجش روایی و پایایی متغیرهای پژوهش

متغیرها	آلفای کرونباخ	پایایی مرکب	AVE
نظارت بر ریسک	۰/۸۵۵	۰/۸۴۹	۰/۵۹۶
پیشگیری از کلاهبرداری	۰/۸۹۷	۰/۸۹۲	۰/۵۲۵
تکنیک‌های یادگیری ماشین	۰/۹۱۵	۰/۹۳۹	۰/۷۱۷

این، مدل‌های یادگیری ماشین تحت نظارت مانند رگرسیون لجستیک، درخت‌های تصمیم‌گیری و ماشین‌های در این روش از تمامی گویه‌ها در برآورد روایی استفاده می‌شود. مبنای آن، سازگاری درونی گویه‌ها است. در این خصوص، گویه‌هایی می‌توانند پایا باشند که با همدیگر در رسیدن به هدف مورد نظر که همان اندازه‌گیری است، هم‌نوا باشند. نتایج بررسی مقادیر آلفای کرونباخ برای متغیرهای اصلی مدل در جدول زیر آمده است. همانطور که مشاهده می‌گردد مقادیر آلفای کرونباخ برای تمام متغیرها بالای ۰.۷ میباشد. بر اساس ضرایب آلفای به دست آمده می‌توان استنباط نمود که مدل از پایایی سازگاری درونی خوبی برخوردار است.

جدول زیر مقادیر ضرایب دیلون- گلدشتاین(پایایی مرکب) را نشان می‌دهد. در جدول زیر همانطور که مشاهده می‌گردد تمامی مقادیر در این جدول بالای ۰.۷ می‌باشند که نشان می‌دهد مدل از پایایی ترکیبی خوبی برخوردار است. برای روایی همگرا باید میانگین واریانس استخراج شده (AVE) محاسبه شود. در جدول همبستگی متغیرها با یکدیگر همانطور که مشاهده می‌گردد، مقادیر جذر AVE قرار گرفته بر روی قطر ماتریس همبستگی از مقادیر همبستگی آن متغیر با سایر متغیرها بزرگتر میباشد که نشان دهنده مناسب بودن روایی واگرایی مدل میباشد.

جدول ۳: سنجش عملیاتی و پایایی متغیرهای پژوهش

متغیر	نظارت بر ریسک	پیشگیری از کلاهبرداری	تکنیک‌های یادگیری ماشین
نظارت بر ریسک	۰/۷۷۲		
پیشگیری از کلاهبرداری	۰/۳۳۶	۰/۷۲۴	
تکنیک‌های یادگیری ماشین	۰/۴۲۶	۰/۳۱۸	۰/۸۴۷

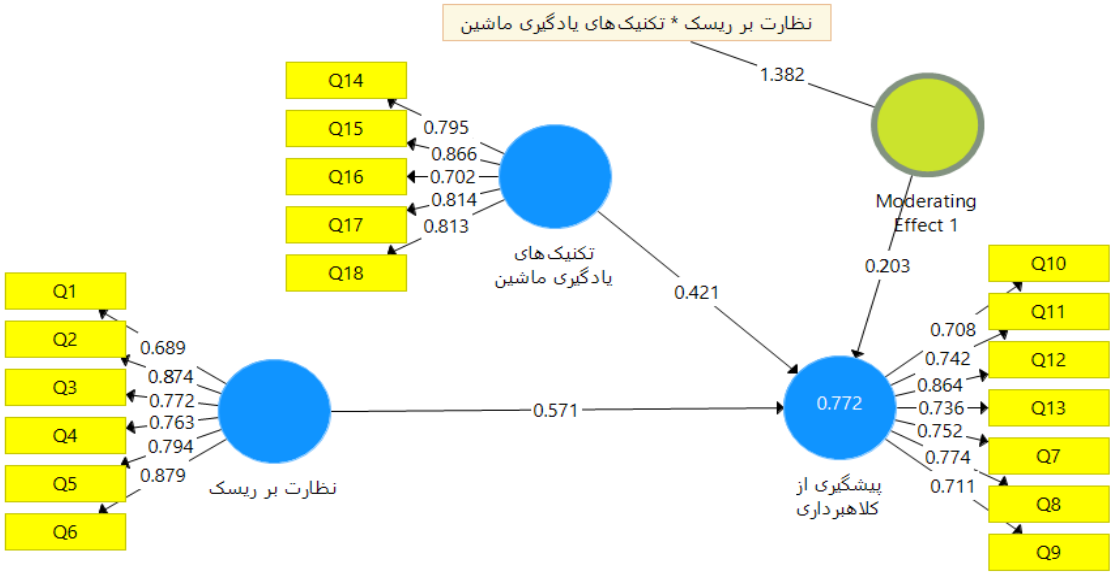

شکل ۲: خروجی نرم‌افزار- مدل آزمون شده پژوهش (ضرایب مسیر و بارهای عاملی)

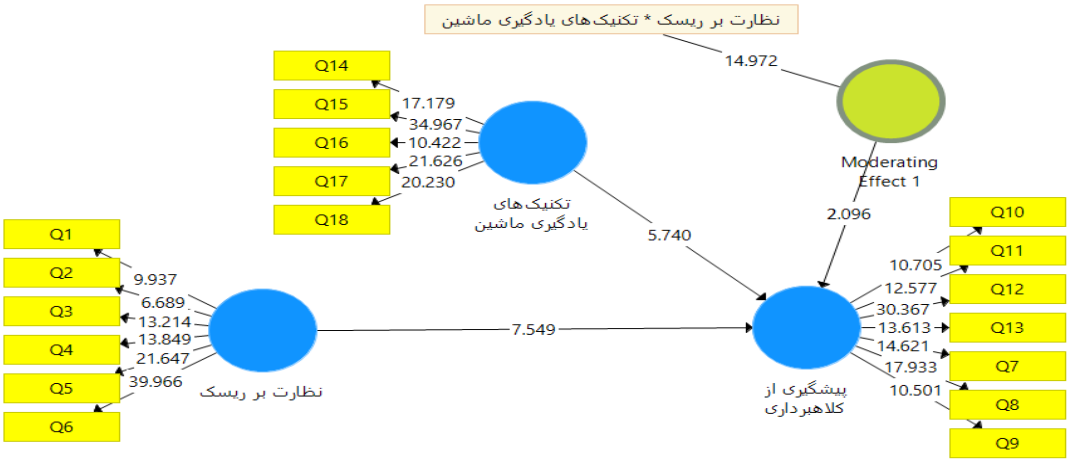

شکل ۳: خروجی نرم‌افزار- ضرایبt

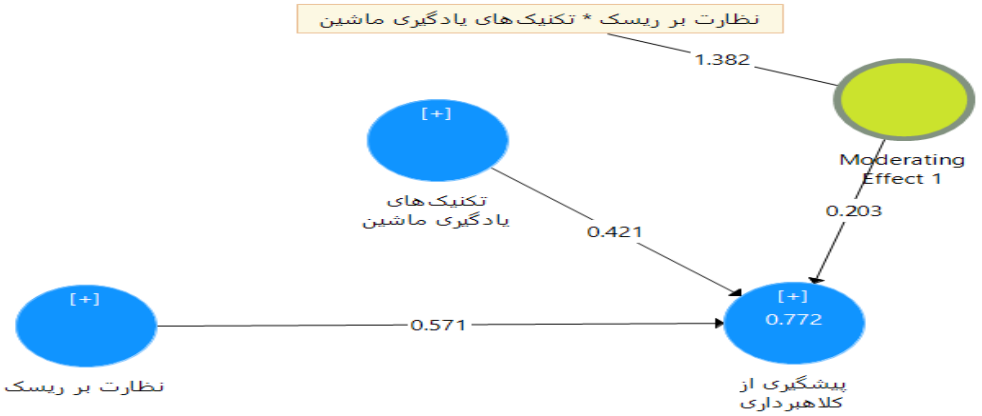

شکل ۴: ارزیابی مدل‌های سنجش شکل دهنده

یکی از خروجی های مهم در نرم افزار های کمترین مربعات جزئی، آماره t در pls است. آماره t که گاها در گزارش ها به t-value معروف است؛ یکی از شاخص های برازش مدل ساختاری است. شاخص قابل قبول برای حفظ و معنی داری بار های عاملی و معنی داری یک فرضیه علی بین دو متغیر مستقل و وابسته، کسب مقدار بالای ۱.۹۶ در سطح اطمینان ۹۵ درصد یا سطح خطای ۰.۰۵ درصد است. بر اساس ضریب تعیین مدل، می‌توان بیان کرد که نظارت بر ریسک و پیشگیری از کلاهبرداری در مجموع توانستند ۰/۷۷۲ واریانس را در متغیر تکنیک‌های یادگیری ماشین تبیین کنند؛ محققان سه مقدار متمایز ۰.۱۹، ۰.۳۳ و ۰.۶۷ را به عنوان مقادیر آستانه برای نمونه های ضعیف، متوسط و قوی R2 در نظر گرفته اند. ممکن است از این استنباط شود که این مدل استعداد قابل ستایشی برای پیش‌بینی نشان می‌دهد، با هر مقدار باقی‌مانده که به خطای پیش‌آگهی و تأثیر بالقوه عوامل دیگری که ممکن است بر تکنیک‌های یادگیری ماشین تأثیر بگذارد، نسبت داده می‌شود. نتایج مدلسازی معادلات ساختاری با استفاده از نرم‌افزار Smart PLS در سطح اطمینان ۹۵ درصد در جدول ۶ آمده است. بر اساس نتایج حاصل از نظارت بر رسیک بر پیشگیری از کلاهبرداری در بیمه‌های خودرو تاثیر مثبت و معنی داری دارند و همچنین تکنیک‌های یادگیری ماشین نقش تعدیل‌کننده ای در این تاثیر ایفا می نمایند.

جدول ۴: اثرات مستقیم، آماره t و نتیجه فرضیات پژوهش

فرضیه ها	ضریب مسیر استاندارد شده β	آماره t	معنی داری	قبول یا رد فرضیه
نظارت بر رسیک ← پیشگیری از کلاهبرداری	۰/۵۷۱	۷/۵۴۹	Sig<0.05	قبول
نظارت بر رسیک ← پیشگیری از کلاهبرداری با نقش تعدیل کننده تکنیک‌های یادگیری ماشین	۰/۵۷۱ + ۰/۲۰۳= ۰/۷۷۴	۲/۰۹۶	Sig<0.05	قبول

۵. بحث و نتیجه گیری کلی

این پژوهش با هدف بررسی دقیق و جامع تأثیر نظارت بر ریسک بر پیشگیری از کلاهبرداری در صنعت بیمه خودرو در شرکت‌های بیمه‌ای ایران، و با تمرکز ویژه بر نقش تعدیل‌کننده و تقویتی تکنیک‌های یادگیری ماشین، به انجام رسید. یافته‌های این تحقیق، نه تنها فرضیه‌های اصلی پژوهش را تأیید نمودند، بلکه چارچوبی عملیاتی برای ادغام هوش مصنوعی در فرآیندهای حاکمیت ریسک ارائه دادند که می‌تواند تأثیر بسزایی بر کاهش زیان‌های ناشی از تقلب داشته باشد. نتایج به‌دست آمده به‌طور قاطع و آماری معناداری تأیید کردند که تقویت و توسعه فرآیندهای نظارت بر ریسک، عاملی ضروری و مثبت در کاهش نرخ وقوع و میزان خسارات ناشی از ادعاهای کلاهبردارانه در بخش بیمه خودرو محسوب می‌شود. این کشف کاملاً با ادبیات کلاسیک مدیریت ریسک همسو است که تأکید می‌کند پایش مستمر فعالیت‌ها و محیط عملیاتی برای شناسایی سریع ناهنجاری‌ها حیاتی است. در غیاب نظارت کارآمد، فرصت‌های سوءاستفاده و تقلب به‌سرعت افزایش می‌یابد. با این حال، داده‌ها نشان دادند که اثربخشی صرف نظارت سنتی، به‌ویژه در مواجهه با حجم عظیم داده‌ها و پیچیدگی فزاینده شیوه‌های کلاهبرداری نوین، دچار محدودیت‌های جدی است. سیستم‌های مبتنی بر قواعد ثابت[1] اغلب با مشکل آستانه حساسیت[2] مواجه می‌شوند و در شناسایی رفتارهای پیچیده و کمتر آشکار تقلب (مانند کلاهبرداری‌های سازمان‌یافته یا تقلب‌های ظریف) عملکرد ضعیفی دارند.

دستاورد محوری و نوآورانه این تحقیق، اندازه‌گیری کمی نقش تعدیل‌کننده تکنیک‌های یادگیری ماشین بود. نتایج نشان دادند که هنگامی که الگوریتم‌های پیشرفته یادگیری ماشین (مانند شبکه‌های عصبی عمیق یا مدل‌های تقویت‌کننده گرادیان) در زیرساخت‌های نظارتی ادغام می‌شوند، توانایی سیستم در تشخیص و پیشگیری از کلاهبرداری به‌طور چشمگیری افزایش می‌یابد. این افزایش اثربخشی، از طریق افزایش ضریب تأثیر مسیر استاندارد شده در مدل‌های ساختاری اندازه‌گیری شد و بدان معناست که یادگیری ماشین نه تنها یک ابزار کمکی است، بلکه یک کاتالیزور برای بهینه‌سازی فرآیند نظارت بر ریسک عمل می‌کند و رابطه بین نظارت و کاهش تقلب را تقویت می‌نماید. از منظر نظری، این پژوهش با موفقیت شکاف موجود در ادبیات تحقیقاتی ایران را پر کرده است؛ زیرا پیش از این، مطالعات کمتری به صورت تجربی به تلفیق مستقیم چارچوب‌های نظارت بر ریسک با مدل‌های یادگیری ماشین در زمینه مبارزه با تقلب بیمه خودرو پرداخته بودند. این تحقیق، یک چارچوب تجربی عملیاتی برای درک نحوه تعامل این دو حوزه ارائه می‌دهد. بر اساس یافته‌های حاصل از تجزیه و تحلیل آماری و مدل‌سازی معادلات ساختاری، پیشنهادات زیر برای ارتقاء سطح پیشگیری از تقلب در صنعت بیمه خودرو ایران ارائه می‌گردد:

تغییر پارادایم سرمایه‌گذاری: شرکت‌ها باید سرمایه‌گذاری‌های خود را به‌طور استراتژیک از سیستم‌های دستی، مبتنی بر فرم‌های کاغذی و روش‌های سنتی بررسی ادعاها، به سمت پیاده‌سازی سیستم‌های تحلیلی قدرتمند مبتنی بر کلان‌داده‌ها سوق دهند.

ایجاد تیم‌های چند تخصصی: تیم‌های مبارزه با تقلب باید شامل متخصصان بیمه، تحلیل‌گران ریسک، و مهندسان علم داده باشند تا بتوانند هم ابعاد فنی مدل‌ها و هم پیچیدگی‌های عملیاتی خسارت را مدیریت کنند.

استانداردسازی داده‌های ورودی: قبل از هرگونه پیاده‌سازی مدل یادگیری ماشین، باید یک فرآیند داخلی برای استانداردسازی، پاک‌سازی و غنی‌سازی داده‌های تاریخی ادعاها و خسارات ایجاد شود. کیفیت

[1] . Rule-based systems
[2] . Threshold setting

داده‌ها مستقیماً بر عملکرد مدل تأثیر می‌گذارد. اگر داده‌های آموزشی با برچسب‌گذاری دقیق همراه نباشند، مدل قادر به یادگیری صحیح نخواهد بود.

تدوین چارچوب‌های قانونی تسهیل‌گر: نهادهای ناظر باید با تعریف استانداردهای داده‌ای مشخص و پروتکل‌های حریم خصوصی، زیرساختی را فراهم آورند که امکان اشتراک‌گذاری ایمن و ناشناس‌سازی شده داده‌های تقلب بین شرکت‌های مختلف بیمه‌ای میسر شود. این امر برای آموزش مدل‌های یادگیری ماشینی قوی و فراگیر (که با تقلب‌های سازمانی بزرگ مقابله کنند) ضروری است، زیرا یک شرکت به تنهایی ممکن است داده‌های کافی برای شناسایی الگوهای پیچیده را نداشته باشد.

تشویق به نوآوری فناورانه: باید مشوق‌هایی (مانند کاهش نسبی سهم نظارتی یا اعطای گواهینامه‌های خاص) برای شرکت‌هایی در نظر گرفته شود که سرمایه‌گذاری قابل توجهی در فناوری‌های پیشرفته هوش مصنوعی برای مدیریت ریسک انجام می‌دهند.

سیاست‌گذاری در مورد استفاده از مدل‌های "جعبه سیاه": با توجه به ماهیت مدل‌های پیچیده یادگیری ماشین (مانند شبکه‌های عمیق)، نهادهای نظارتی باید راهبردهایی را برای شفاف‌سازی و توضیح‌پذیری مدل‌های هوش مصنوعی توسعه دهند تا در صورت رد یک ادعا بر اساس تصمیم یادگیری ماشین، امکان ممیزی و دفاع قانونی فراهم باشد.

این تحقیق به روشنی نشان داد که در محیط پرتلاطم بیمه خودرو ایران، نظارت بر ریسک باید بر پایه هوش مصنوعی استوار شود. صرفاً نظارت کافی نیست؛ بلکه نظارت هوشمند، پویا و مبتنی بر تحلیل داده‌های بزرگ است که می‌تواند محافظی مؤثر در برابر زیان‌های ناشی از کلاهبرداری باشد. اجرای پیشنهادات عملیاتی و ادامه‌دار نمودن پژوهش‌های آینده، کلید دستیابی به ثبات مالی و افزایش اعتماد عمومی به صنعت بیمه کشور خواهد بود.

سپاسگزاری

بدینوسیله از کلیه مدیران و کارشناسان ارشد بیمه های اتومبیل در شرکتهای بیمه تقدیر و تشکر می‌شود.

منابع:

- Hassan, Ch. A. ul., J. Iqbal, S. Hussain, H. AlSalman, M. A. A. Mosleh, and S. Sajid U. (2021). A Computational Intelligence Approach for Predicting Medical Insurance Cost, Mathematical Problems in Engineering, vol. 2021, pp. 1–13, Dec. 2021, doi:https://doi.org/10.1155/2021/1162553.

-Jagdish, S., Singh, M. and Yadav, V. (2020). Credit Card Fraud Detection System: A Survey, Journal of Xidian University, vol. 14, no. 5, May 2020, doi:https://doi.org/10.37896/jxu14.5/599.

-Jain, N. and Khan, V. (2017). Survey on Credit Card Fraud Detection using Recurrent Attributes," IJARCCE, vol. 6, no. 1, pp. 376–379, Jan. 2017, doi: https://doi.org/10.17148/ijarcce.2017.6175

-Manavalan, M., (2020). Intersection of Artificial Intelligence, Machine Learning, and Internet of Things – An Economic Overview, Global Disclosure of Economics and Business, vol. 9, no. 2, pp. 119–128, Dec. 2020, doi:https://doi.org/10.18034/gdeb.v9i2.584.

-Moon, H., Y. Pu, and Ceglia, C. (2019). A Predictive Modeling for Detecting Fraudulent Automobile Insurance Claims, Theoretical Economics Letters, vol. 09, no. 06, pp. 1886–1900, 2019, doi:https://doi.org/10.4236/tel.2019.96120.

-Mousavi, A., Z. Gao, Han, L. and Lim, A. (2022). Quadratic surface support vector machine with L1 norm regularization, Journal of Industrial and Management Optimization, vol. 18, no. 3, p. 1835, 2022, doi: https://doi.org/10.3934/jimo.2021046

-Müller, K., Schmeiser, H. and Wagner, J. (2016). The impact of auditing strategies on insurers' profitability, The Journal of Risk Finance, vol. 17, no. 1, pp. 46–79, Jan. 2016, doi: https://doi.org/10.1108/jrf-05-2015-0045.

-Mushunje, L., (2019). Fraud Detection and Fraudulent Risks Management in the Insurance Sector Using Selected Data Mining Tools, American Journal of Data Mining and Knowledge Discovery, vol. 4, no. 2, p. 70, 2019, doi:https://doi.org/10.11648/j.ajdmkd.20190402.13.

-Palacio, S. M., (2018). Detecting Outliers with Semi-Supervised Machine Learning: a Fraud Prediction Application, SSRN Electronic Journal, 2018, doi: https://doi.org/10.2139/ssrn.3165318

-Park, S.-H., Kim, M.-Y. Kim, Y.-J. and Park, Y. H. (2022). A Deep Learning Approach to Analyze Airline Customer Propensities: the Case of South Korea, Applied Sciences, vol. 12, no. 4, p. 1916, Feb. 2022, doi:https://doi.org/10.3390/app12041916.

-Ryder, B., Dahlinger, A. Gahr, B. Zundritsch, P. Wortmann, F. and Fleisch, E. (2019). Spatial prediction of traffic accidents with critical driving events – Insights from a nationwide field study, Transportation Research Part A: Policyand Practice, vol. 124, pp. 611–626, Jun. 2019, doi:https://doi.org/10.1016/j.tra.2018.05.007.

-Saini, N., Monika, and Garg, K. (2017). Churn Prediction in Telecommunication Industry using Decision Tree, InternationalJournal of Engineering Research and, vol. V6, no. 04, Apr. 2017, doi: https://doi.org/10.17577/ijertv6is040379.

-Sun, S., Bi, J. Guillen, M. and Pérez-Marín, A. M. (2021). Driving Risk Assessment Using Near-Miss Events Based onPanel Poisson Regression and Panel Negative Binomial Regression, Entropy, vol. 23, no. 7, p. 829, Jun. 2021,doi:https://doi.org/10.3390/e23070829.

-Tang, D. Wu, Q., M. Fung, W. and Tian, G. (2020). Poisson item count techniques with noncompliance, Statistics inMedicine, vol. 39, no. 29, pp. 4480–4498, Sep. 2020, doi: https://doi.org/10.1002/sim.8736.

-Wang, Y. and Xu, W. (2018). Leveraging deep learning with LDA-based text analytics to detect automobile insurance fraud, Decision Support Systems, vol. 105, pp. 87–95, Jan. 2018, doi: https://doi.org/10.1016/j.dss.2017.11.001.

-Zande, J., K. Teigland, S. Siri, and R. Teigland, v. (2020). The digital transformation of labor : automation, the gigeconomy and welfare. Abingdon, Oxon ; New York, Ny: Routledge, 2020.