

UMJETNA INTELIGENCIJA U DETEKCIJI PREVARA U OSIGURANJU AUTOODGOVORNOSTI

Sažetak

Prezare u osiguranju autoodgovornosti predstavljaju ozbiljan finansijski i operativni problem za osiguravajuća društva, naročito zbog njihove rastuće učestalosti i sve veće složenosti. Tradicionalne metode detekcije prevara, koje se uglavnom oslanjaju na ručnu obradu prijava i subjektivnu procjenu zaposlenih, često su spore, skupe i nedovoljno efikasne u otkrivanju sofisticiranih i organizovanih oblika zloupotreba. Razvoj digitalnih tehnologija i povećana dostupnost podataka dodatno naglašavaju potrebu za savremenijim pristupima.

Ovaj rad analizira primjenu umjetne inteligencije u detekciji prevara u osiguranju autoodgovornosti, s posebnim fokusom na mašinsko učenje, obradu prirodnog jezika i računarsku viziju. Prikazani su izazovi koji su postojali prije implementacije UI sistema, kao i nove metode prevara koje koriste digitalne alate i umjetnu inteligenciju za generisanje lažnih dokaza. Posebna pažnja posvećena je ulozi kvaliteta i integracije različitih izvora podataka u procesu treniranja modela.

U praktičnom dijelu rada opisan je konkretan projekat razvoja klasifikacijskog UI modela za rano prepoznavanje sumnjivih zahtjeva za naknadu štete iz autoodgovornosti. Model je treniran na historijskim podacima osiguravajućeg društva i postigao je makro tačnost od 0,9596, čime je potvrđena njegova visoka preciznost. Rezultati pokazuju da primjena umjetne inteligencije može značajno unaprijediti efikasnost detekcije prevara, uz zadržavanje ključne uloge stručnih timova u donošenju konačnih odluka.

Ključne riječi: Osiguranje vozila, Detekcija prevara, Umjetna inteligencija, Mašinsko učenje, Obrada prirodnog jezika (NLP), Računarska vizija, Automatizovana analiza šteta, Analitika osiguravajućih podataka, Upravljanje rizicima, Prevencija prevara

* Arti Analytics doo, Sarajevo, migdat.hodzic@artianalytics.com
International University of Sarajevo, mhodzic@ius.edu.ba

** Suada Alić-Mešanović, mr. aktuarstva i risk menadžmenta, direktor Sektora aktuarstva i upravljanja rizicima Asa Central osiguranje, suadaalic@yahoo.com

Abstract

Fraud in motor third-party liability insurance represents a significant financial and operational challenge for insurance companies, particularly due to its increasing frequency and growing complexity. Traditional fraud detection methods, largely based on manual claim processing and subjective assessment by employees, are often slow, costly, and insufficient for identifying sophisticated and organized fraudulent activities. The development of digital technologies and the growing availability of data further emphasize the need for more advanced approaches.

This study examines the application of artificial intelligence (AI) in detecting fraud in motor insurance, focusing on machine learning, natural language processing, and computer vision. The paper discusses the challenges present before the implementation of AI systems, as well as emerging fraud methods that utilize digital tools and AI to generate false evidence. Special attention is given to the importance of data quality and the integration of multiple data sources in the training process of AI models.

The practical part of the study presents a project involving the development of a classification-based AI model for early detection of suspicious motor insurance claims. The model was trained on historical insurance data and achieved a macro accuracy of 0.9596, demonstrating its high precision. The results indicate that the application of AI can significantly improve the efficiency of fraud detection, while maintaining the crucial role of expert teams in making final decisions.

Keywords: Motor insurance, Fraud detection, Artificial intelligence, Machine learning, Natural language processing (NLP), Computer vision, Automated claim analysis, Insurance data analytics, Risk management, Fraud prevention

Uvod

Prevare – značajan problem u segmentu autoodgovornosti

Autoodgovornost je obavezno osiguranje vlasnika odnosno korisnika motornog vozila od odgovornosti za štete trećim licima. Vlasnik vozila dužan je zaključiti ugovor o osiguranju od autoodgovornosti za štetu koju upotrebom vozila prouzrokuje trećim licima zbog smrti, tjelesne povrede, narušavanja zdravlja, uništenja ili oštećenja stvari. Dakle, ukoliko lice zaključi policu od automobilske odgovornosti u osiguravajućem društvu, društvo će platiti štetu koju pretrpe treća lica ako je do saobraćajne nezgode došlo krivicom tog lica, njegovog osiguranika. Treća lica su sva ona lica koja nemaju nikakve veze sa zaključenim ugovorom o osiguranju od odgovornosti za štete pričinjene trećim

licima upotrebom vozila i stoje izvan konkretnog obligaciono-pravnog odnosa. A šta je prevara, i to u osiguranju? To je radnja kojom jedan od sudionika iz zaključenog ugovora u osiguranju postigne nepravedno ili nezakonito dobitvanje novca ili dobra od druge strane iz ugovora. U nekim slučajevima sudionici mogu djelovati u dogovoru da bi prevarili treću stranu. Mnogi slučajevi prevare zabilježeni su kod osiguranja automobilske odgovornosti. U praksi se pokazuje da ovakve prevare nerijetko uključuju dogovor više aktera – kako prijavljenih oštećenika, tako i navodnih štetnika, a u određenim slučajevima i zaposlenika osiguravajućih društava te lažnih svjedoka. Ovakvi koordinirani pokušaji prevare predstavljaju značajan izazov za osiguravajuća društva, jer komplikuju otkrivanje nepravilnosti i zahtijevaju napredne mehanizme detekcije i kontrole, i na kraju koštaju osiguravajuće društvo finansijski.

Zbog sve teže ekonomske situacije, broj prevara u oblasti osiguranja raste, pri čemu su najčešće lažno prijavljene saobraćajne nezgode, krađe vozila i preuveličane povrede, dok su prevare u osiguranju imovine i putnom zdravstvenom osiguranju rjeđe, ali prisutne. Zanimljivo je da su prevare velikih šteta sve više zamijenjene prevarama sa manjim iznosima šteta, koje je lakše prikriti i koje često prolaze neopaženo. Ovaj trend predstavlja dodatni izazov za osiguravajuća društva jer teret dokazivanja fingirane štete ostaje na njima, a specifičan model u kojem društvo oštećenika obrađuje štetu, dok društvo štetnika isplaćuje naknadu, stvara prostor za dodatne zloupotrebe i otežava detekciju prevara.

Umjetna Inteligencija (UI) je dobar alat za borbu protiv prevara

S obzirom na složenost i sofisticiranost prevara koje se javljaju u osiguranju od autoodgovornosti, tradicionalni pristupi detekciji često nisu dovoljni da se uhvate svi pokušaji manipulacije. U ovom kontekstu, umjetna inteligencija (UI) nudi moćne alate koji omogućavaju prepoznavanje i sprječavanje prevara na mnogo učinkovitiji način.

Primjena UI tehnologija, kao što su mašinsko učenje, obrada prirodnog jezika (NLP i LLM) i računarska vizija, omogućava osiguravajućim društvima da prepoznaju sumnjive obrasce u velikim količinama podataka, često i prije nego što postanu očigledni ljudskim očima. Na primjer, algoritmi za mašinsko učenje mogu analizirati prijave šteta, izvještaje i druge dokumente kako bi uočili neskladnosti ili neuobičajene sekvence, dok računarska vizija može analizirati fotografije oštećenja vozila i identificirati lažne ili preuveličane štete.¹

Međutim, iako UI omogućava bržu i precizniju detekciju, ključnu ulogu u uspjehu ovih sistema igraju stručnjaci u odjelima za obradu šteta. UI je samo alat – njegova efikasnost ovisi o njegovoj integraciji u svakodnevne procese osiguravajućih društava i o sposobnosti uposlenika da interpretiraju i donose

¹ Solix Technologies: „AI in Insurance“, <https://www.solix.com/bs/products/answers/ai-in-insurance/>

odluke na temelju rezultata koje UI generira. Bez stručnog tima koji pravilno interpretira podatke i primjenjuje UI u kontekstu specifičnih slučajeva, cijeli sistem može izgubiti svoju efikasnost.

Korištenje UI također poboljšava transparentnost i efikasnost procesa, jer automatizacijom mnogih koraka u poslovnom procesu smanjuje operativne troškove i ubrzava donošenje odluka. U konačnici, UI pomaže osiguravajućim društvima da bolje prepoznaju i reagiraju na prijetnje, smanjujući financijske gubitke i povećavajući sigurnost cijelog sistema osiguranja.

1. Izazovi prije primjene UI

1.1. Tradicionalne „ručne“ metode

Tradicionalne metode otkrivanja prevara u osiguranju oslanjaju se na ručnu provjeru prijava šteta, jednostavna pravila i analizu dostavljene dokumentacije. Ovaj pristup je, u osnovi, zasnovan na iskustvu i intuiciji zaposlenika u odjelima za obradu šteta, koji pregledaju svaku sumnjivu prijavu pojedinačno. Glavni fokus je na:

- **Ručnoj provjeri prijava:** Zaposleni detaljno analiziraju sve informacije koje su dostavljene, uključujući prijave šteta, svjedočanstva i fotografije oštećenja, tražeći očite neskladnosti ili znakove potencijalnih prevara.
- **Primjena osnovnih pravila:** U mnogim slučajevima, osiguravajuća društva primjenjuju osnovna pravila koja se baziraju na prethodnim iskustvima i obrascima, kao što su geografske lokacije nezgoda, vrste šteta i druge demografske informacije. Ukoliko ovi podaci odgovaraju određenim šablonima, prijava bude odobrena bez daljnjeg istraživanja.
- **Analiza dokumentacije:** Analiziranje dokumenata kao što su izvještaji o šteti, medicinske potvrde ili prijave s osiguranja su standardna praksa. Cilj je utvrditi postoji li nesklad između različitih izvora podataka ili nepravilnosti u prikupljenim informacijama.

Međutim, unatoč tome što su ove metode temeljne, njihov opseg i efikasnost su ograničeni. Sljedeći izazovi nastali su uslijed ovih metoda, zbog čega su postale nedovoljne za rješavanje složenijih slučajeva prevara.

1.2. Problemi

Sporost procesa

Ručna provjera prijava šteta, iako temeljita, je izrazito spora. Zaposleni moraju pregledati velike količine podataka i dokumenata, što dovodi do značajnog vremenskog zastoja u procesu obrade šteta. Svaka prijava zahtijeva puno vremena, a zbog toga klijenti čekaju duže, što smanjuje zadovoljstvo i efikasnost cijelog sistema.

Visoki troškovi

Zbog velikog broja zaposlenih koji moraju analizirati svaku prijavu, proces postaje vrlo skup. Osiguravajuća društva su primorana ulagati značajna sredstva u ljudske resurse i vrijeme, što predstavlja dodatni finansijski teret.

Propuštene prevare

Jedan od glavnih problema je da tradicionalne metode nisu u mogućnosti prepoznati sve prevarante, posebno kada su u pitanju sofisticirane ili koordinirane prevare. Zbog velike količine podataka i ograničenih ljudskih kapaciteta, nemoguće je obraditi sve prijave s dovoljno detalja. Rezultat je da su mnoge prevare prošle neopaženo.

Greške u procjeni

Subjektivna procjena zaposlenika, premda temeljena na iskustvu, nije uvijek pouzdana. Različiti zaposlenici mogu imati različite standarde ili intuicije, što može dovesti do nesuglasica u odlukama. U slučaju složenih prijava, ove greške u procjeni mogu rezultirati odobrenjem sumnjivih šteta ili, obratno, odbijanjem opravdanih zahtjeva.

1.3. Nove metode prevare

Pored tradicionalnih oblika prevara, u posljednjih nekoliko godina bilježi se pojava nove generacije sofisticiranih prevara koje dodatno opterećuju sisteme autoosiguranja i razotkrivaju slabosti klasičnih metoda provjere.

Jedan od najznačajnijih izazova predstavlja upotreba umjetne inteligencije i digitalnih alata za generisanje lažnih dokaza. Prevaranti sve češće koriste AI za izradu realističnih fotografija oštećenih vozila, manipuliranih snimaka nesreća ili falsifikovanih dokumenata. Ovakvi materijali vizuelno djeluju uvjerljivo i teško ih je razlikovati od stvarnih dokaza prilikom ručne provjere.²

Dodatni problem predstavlja synthetic identity fraud, odnosno stvaranje lažnih identiteta kombinovanjem stvarnih i izmišljenih ličnih podataka. Ovi identiteti se koriste za sklapanje polisa i kasnije podnošenje lažnih zahtjeva za naknadu štete, pri čemu klasične provjere identiteta često ne otkrivaju nepravilnosti.

Također, zabilježen je porast lažnih digitalnih kanala i „spoof“ stranica, koje se predstavljaju kao legitimne osiguravajuće kuće ili servisi za prijavu šteta. Klijenti nesvjesno dostavljaju svoje podatke ili dokumentaciju prevarantima, što dodatno komplikuje proces obrade i povećava rizik od zloupotreba.

Na kraju, sve češće se javljaju organizirane kriminalne mreže koje koordinirano izvode veći broj povezanih prijava šteta. Ove grupe koriste obrasce

² Amir Havel i sur „A new wave of vehicle insurance fraud fueled by generative AI“, <https://arxiv.org/abs/2510.19957>

ponašanja koji su pojedinačno teško uočljivi, ali u zbiru uzrokuju velike finansijske gubitke. Tradicionalni, izolovani pristup obradi prijava nije prilagođen otkrivanju ovakvih kompleksnih i umreženih prevara.

Zbog navedenih novih metoda, postaje jasno da se problemi sporosti, visokih troškova, propuštenih prevara i grešaka u procjeni dodatno produbljuju, što ukazuje na potrebu za naprednijim, automatizovanim i analitički snažnijim rješenjima.

2. UI rješenja koja se koriste

U ovom dijelu opisat ćemo glavne tehnologije UI koje se koriste u borbi protiv prevara u osiguranju, posebno u segmentu autoodgovornosti, kao i na izvore podataka koji omogućavaju učinkovitu detekciju sumnjivih obrazaca i manipulacija.

2.1. Primjena UI tehnologija

UI rješenja koja se primjenjuju u detekciji prevara u osiguranju koriste nekoliko ključnih tehnologija, od kojih svaka igra specifičnu ulogu u poboljšanju efikasnosti procesa:

Obrada podataka

Ovo je ključni korak i od njega zavisi tačnost algoritama detekcije prevara, Sa lošim podacima gotovo je nemoguće napraviti dobar model detekcije prevara.

Mašinsko učenje (ML)

Mašinsko učenje je ključna tehnologija koja omogućava prepoznavanje neobičnih obrazaca u podacima.³ Algoritmi mašinskog učenja analiziraju velike količine podataka iz prijava šteta i izvještaja kako bi identificirali neuobičajene sekvence događaja koje mogu ukazivati na prevanu. Ovi algoritmi se stalno usavršavaju jer „uče“ iz novih podataka, čime povećavaju preciznost detekcije.

Obrada prirodnog jezika (NLP)

Obrada prirodnog jezika koristi se za analizu izvještaja, dokumenata i komunikacija između klijenata i osiguravajućih društava. NLP omogućava prepoznavanje ključnih informacija, analiziranje tekstualnih obrazaca te detekciju neslaganja između različitih izvora podataka. Ova tehnologija pomaže u otkrivanju lažnih izjava ili sumnjivih tvrdnji koje se mogu pojaviti u prijavama šteta.

3 Faheem Aslam i sur., „Insurance fraud detection: Evidence from artificial intelligence and machine learning“, <https://www.sciencedirect.com>

Računarska vizija (Computer Vision)

Računarska vizija omogućava analizu fotografija oštećenja vozila i drugih dokaza u štetnim prijavama. Algoritmi računarske vizije mogu prepoznati manipulacije fotografijama, razlike u vrsti i opsegu oštećenja u odnosu na prijavljenu štetu, te uočiti specifične karakteristike lokacija na kojima se štete često manipuliraju. Na primjer, algoritmi mogu prepoznati sumnjive obrasce u okolini nesreće, poput mračnih i zabačenih lokacija koje su česte u prijavama šteta, ili ponavljajuće prijave sličnih oštećenja na istim lokacijama. Ova tehnologija omogućava bržu i precizniju verifikaciju vizualnih dokaza, smanjujući mogućnost prevara.

Ove tehnologije omogućavaju osiguravajućim društvima da značajno poboljšaju svoje procese detekcije prevara, istovremeno smanjujući ljudske pogreške i ubrzavajući cijeli proces obrade šteta.

2.2. Izvori podataka

U procesu primjene UI rješenja u osiguranju, ključni izvori podataka igraju presudnu ulogu u treniranju modela i donošenju preciznih odluka. Podaci koji se koriste mogu biti vrlo različiti, a svaki izvor doprinosi stvaranju detaljne slike o prijavljenim štetama i ponašanju osiguranika.

Prijave šteta

Prvi i najvažniji izvor podataka su prijave šteta, koje uključuju sve informacije koje osiguranje dobije od klijenata prilikom prijave nezgode. To mogu biti tekstualni opisi događaja, svjedočanstva, fotografije oštećenja, medicinske potvrde i drugi dokumenti.

Baze podataka o vozilima

Podaci o vozilu, uključujući tehničke karakteristike, vlasničke informacije, istoriju nesreća i servisne informacije, pomažu u analizi vjerodostojnosti prijave. Ovi podaci omogućavaju prepoznavanje obrazaca u vezi s tipičnim oštećenjima koja se prijavljuju za određene modele vozila.

Istorija klijenata

Istorija osiguranja klijenta, uključujući prethodne prijave šteta, usmjerava sistem na moguću povratnu povezanost između pojedinih korisnika i njihovih obrazaca prijave šteta. Analizom tih podataka može se otkriti sumnjivo ponašanje koje može upućivati na ponavljane pokušaje prevara.

Vremenski podaci

Vremenski uslovi u trenutku nezgode mogu biti vrlo korisni u analizi štete. Algoritmi mogu analizirati vremenske uslove u trenutku kada je nezgoda prijavljena, upoređujući ih s informacijama u prijavi i analizirajući moguće neskladnosti.

Društvene mreže

Podaci s društvenih mreža i online platformi mogu osiguravajućim društvima pružiti dodatne uvide u ponašanje svojih klijenata. Analizom javnih objava, slika i komunikacija na mrežama, UI sistemi mogu prepoznati sumnjive aktivnosti koje nisu zabilježene u službenim prijavama šteta.

Na ovaj način je jasno da osiguravajuća društva koriste podatke o ponašanju svojih klijenata (osiguravača), a UI analizira te informacije za prepoznavanje potencijalnih nepravilnosti.⁴

Za uspješnu primjenu UI tehnologija, bitno je da se svi ovi podaci pravilno prikupe, analiziraju i koriste uz poštovanje zakonskih regulativa i zaštite privatnosti. Važno je napomenuti da se sistemi treniraju na historijskim podacima, pri čemu se moraju poštovati stroge kontrole zaštite privatnosti kako bi se osigurala fer upotreba podataka i sprečile zloupotrebe.

Bez ulaska u tehničke ili vlasničke detalje, generalno se može reći da se u borbi protiv prevara koristi napredna analitika ponašanja osiguranika i drugih učesnika u štetnim događajima. Primjenjuju se sofisticirani algoritmi koji prepoznaju neuobičajene obrasce i sekvence događaja koje mogu ukazivati na pokušaje prevare. Analiziraju se različiti izvori podataka, uključujući tekstualne zapise iz izjava i dokumenata, kao i vizualni materijal poput fotografija oštećenja. Ova kombinacija omogućava precizniju i bržu identifikaciju sumnjivih slučajeva. Sistem kontinuirano uči iz novih podataka, čime se njegova efikasnost vremenom dodatno povećava.⁵

3. Primjena UI u praksi – konkretan primjer/projekt

U okviru konkretnog projekta realizovanog sa jednim društvom za osiguranje, cilj je bio razvoj automatizovanog sistema zasnovanog na umjetnoj inteligenciji, koji omogućava rano prepoznavanje potencijalno sumnjivih zahtjeva za naknadu štete iz autoodgovornosti. Sistem je razvijen kao alat za podršku postojećim timovima za borbu protiv prevara, a njegova integracija u poslovne procese planirana je s ciljem efikasnijeg i preciznijeg prepoznavanja sumnjivih obrazaca ponašanja.

U prvoj fazi projekta, društvo je dostavilo strukturirane podatke koji uključuju ključne varijable relevantne za procjenu sumnje na prevaru – poput

4 International Journal of Artificial Intelligence, Data Science, and Machine Learning, „Improving Policy Integrity with AI“, <https://ijaidssl.org/index.php/ijaidssl/article/view/267>

5 Croatia osiguranje prvo u Europi uvodi automatiziranu procjenu šteta temeljenu na umjetnoj inteligenciji: procjena štete na vozilima sada je moguća u manje od tri minute, <https://kompanija.crosig.hr/hr/novosti/>

mjesta nastanka štete, uzroka, tipa povrede, iznosa materijalne štete, kao i informacija o osiguraniku, oštećeniku i karakteristikama vozila. Na osnovu tih podataka, izvršena je obrada i priprema ulaznih skupova za treniranje modela.

Model umjetne inteligencije treniran je na klasifikacijski zadatak – da za svaki novi slučaj štete procijeni vjerovatnoću postojanja prevare. Korišten je binarni pristup sa dvije izlazne klase: (1) bez osnova za sumnju na prevaru i (2) prisutna vjerovatnoća prevare. Tok rada obuhvatio je čišćenje i uvezivanje podataka, treniranje modela, evaluaciju njegove tačnosti te izradu preporuka za implementaciju u poslovne tokove. Postignuta makro tačnost od 0,9596 ukazuje na visoku preciznost modela pri razlikovanju između sumnjivih i regularnih zahtjeva, bez obzira na neravnotežu u klasama.

Model je testiran na konkretnim historijskim slučajevima iz poslovanja društva i pokazao je sposobnost pravilne klasifikacije uzoraka na osnovu dostupnih podataka. Kao naredni korak predviđena je izrada korisničkog interfejsa koji omogućava unos novih šteta pojedinačno ili u grupi, sa automatskim prikazom rezultata modela. Takođe, razmatra se razvoj složenijeg UI sistema koji bi uključivao i obradu nestrukturiranih podataka poput slika i tekstualnih izvještaja, čime bi se dodatno povećala preciznost detekcije.

Ova faza projekta jasno je demonstrirala potencijal AI tehnologija za jačanje kapaciteta osiguravajućih društava u prevenciji i ranom prepoznavanju prevara, uz očuvanje načela transparentnosti, provjerljivosti i poslovne etike.

4. Rezultati i upotrebljivost

4.1. Kvantitativni podaci

Primjena razvijenog UI modela donijela je značajne kvantitativne rezultate koji potvrđuju njegovu učinkovitost u svakodnevnom poslovanju. Na temelju testiranja i simulacija s historijskim podacima, model je značajno unaprijedio sposobnost prepoznavanja sumnjivih zahtjeva, čime je povećana stopa detekcije prevara. Pored toga, vrijeme potrebno za preliminarne procjene štetnih zahtjeva smanjeno je, što omogućava bržu reakciju timova za suzbijanje prevara. Automatizacija početne analize rezultirala je i uštedama operativnih troškova, osobito smanjenjem potrebe za ručnom obradom i selekcijom zahtjeva.

Kao ključni indikator uspješnosti modela, postignuta je makro tačnost od 0,9596, što znači da model s visokom preciznošću klasificira uzorke u dvije osnovne kategorije: „vjerovatnoća da nema prevare“ i „sumnja na prevaru“. Ovaj rezultat pokazuje da model uspješno prepoznaje i manje zastupljene slučajeve, uključujući prevaru, minimizirajući tako lažno pozitivne rezultate. Takva visoka tačnost ukazuje na sposobnost modela da precizno razlikuje sumnjive štete, povećavajući time učinkovitost i pouzdanost procesa detekcije prevara.

4.2. Kvalitativne koristi

Osim mjerljivih rezultata, zabilježeni su i značajna kvalitativna unaprijeđenja. UI sistem je omogućio veću preciznost u procjeni, jer koristi kompleksne obrasce i povezanosti između podataka koje tradicionalni alati ne mogu lako uočiti. Takođe, uvedena je veća transparentnost u proces detekcije prevara – rezultati modela su interpretabilni i mogu biti pregledani od strane stručnjaka, čime se osigurava kontrola i razumijevanje UI preporuka. Time je poboljšano i povjerenje u donošenje odluka zasnovanih na analizi podataka.

4.3. Eventualni izazovi tokom implementacije i kako su prevaziđeni

Tokom razvoja i integracije sistema, identifikovano je nekoliko izazova.

Prvi izazov odnosio se na dostupnost i kvalitet podataka – pojedine varijable su bile nepotpune ili nedovoljno standardizovane. Taj problem riješen je kroz proces dodatne obrade i uvezivanja podataka iz više izvora.

Drugi izazov bio je prilagođavanje poslovnih procesa – uvođenje UI zahtijevalo je redefinisanje uloga u timovima koji se bave obradom šteta, što je riješeno internim obukama i faznom implementacijom sistema. Takođe, vođena je pažljiva komunikacija s ciljem ublažavanja potencijalnog otpora zaposlenih prema novim tehnologijama. Integracija sa postojećim IT sistemima zahtijevala je tehnička prilagođavanja, ali su ona uspješno provedena uz saradnju internog IT sektora i eksternih partnera.

Uprkos izazovima, implementacija je pokazala da je moguće uvesti napredna UI rješenja na način koji ne narušava postojeće tokove rada, već ih nadograđuje i čini efikasnijim.

5. Zaključak i preporuke

5.1. Zaključak

Primjena umjetne inteligencije u detekciji prevara u osiguranju autoodgovornosti pokazala se izuzetno uspješnom, s obzirom na značajna poboljšanja u preciznosti, brzini obrade i smanjenju operativnih troškova. Ključni rezultat razvoja UI modela bio je postizanje makro tačnosti od 0,9596, što ukazuje na visoku preciznost modela u razlikovanju između sumnjivih i regularnih zahtjeva. Ova visoka tačnost omogućava sistemu da uspješno prepozna čak i manje zastupljene slučajeve prevare, minimizirajući lažno pozitivne rezultate i značajno povećavajući efikasnost u prepoznavanju štetnih prijava.

Uvođenjem UI tehnologija poput mašinskog učenja, obrade prirodnog jezika (NLP) i računarske vizije, osiguravajuća društva sada imaju mogućnost prepoznavanja sumnjivih obrazaca ponašanja u podacima, što omogućava bržu

i precizniju detekciju prevara. Osim toga, automatizacija početne analize šteta omogućava uštede u operativnim troškovima i smanjuje potrebu za ručnom obradom prijava, što dovodi do bržih odgovora timova za suzbijanje prevara.

Nadalje, integracija UI sistema u poslovne procese nije narušila postojeće tokove rada, već ih je unaprijedila. Prilagodba poslovnih procesa i obuka zaposlenih bila je ključna za uspješnu implementaciju, a svi izazovi, poput problema s kvalitetom podataka i integracijom u postojeće IT sisteme, uspješno su prevaziđeni.

5.2. Preporuke

Daljnje usavršavanje modela

Iako je postignut vrlo dobar rezultat u prepoznavanju prevara, uvijek postoji prostor za poboljšanje. Preporučuje se kontinuirano treniranje i usavršavanje modela, uključujući uvođenje novih podataka, kao i optimizaciju postojećih algoritama. Na taj način će model moći još preciznije razlikovati sumnjive prijave, osobito u slučajevima koji uključuju sofisticirane ili koordinirane prevare.

Širenje primjene UI na nestrukturirane podatke

Kako bi se dodatno povećala tačnost detekcije, preporučuje se proširenje obuhvata AI sistema na nestrukturirane podatke, poput fotografija oštećenja vozila i tekstualnih izvještaja. Razvijanje računarske vizije i NLP tehnologija koje analiziraju ove podatke omogućit će još precizniju procjenu i verifikaciju prijavljenih šteta.

Integracija s većim brojem izvora podataka

Dalje usavršavanje u analizi podataka može se postići integracijom dodatnih izvora podataka, poput društvenih mreža i drugih online platformi, čime bi UI sistem mogao prepoznati sumnjive aktivnosti koje nisu nužno dokumentirane u službenim prijavama šteta. To bi omogućilo brže i preciznije prepoznavanje manipulacija.

Obuka zaposlenih i upravljanje promjenama

Uspješna primjena UI tehnologija zahtijeva stalnu edukaciju i obuku zaposlenih koji će interpretirati rezultate modela. Preporučuje se redovna obuka i razvoj vještina kako bi zaposleni bili u potpunosti sposobni koristiti i razumjeti UI preporuke. Također, kako bi se smanjio otpor prema novim tehnologijama, važno je nastaviti s aktivnim upravljanjem promjenama kroz transparentnu komunikaciju i podršku timovima za obradu šteta.

Praćenje etičkih i zakonskih okvira

Preporučuje se provođenje dodatnih testiranja modela u stvarnim poslovnim uslovima kako bi se identificirali eventualni problemi ili nedostaci koje UI sistem još nije prepoznao. Testiranje na stvarnim podacima i u različitim okruženjima pomoći će u daljnjoj optimizaciji i prilagodbi sistema specifičnostima poslovanja.

Daljnje testiranje u stvarnom okruženju

Preporučuje se provođenje dodatnih testiranja modela u stvarnim poslovnim uvjetima kako bi se identificirali eventualni problemi ili nedostaci koje UI sustav još nije prepoznao. Testiranje na stvarnim podacima i u različitim okruženjima pomoći će u daljnjoj optimizaciji i prilagodbi sustava specifičnostima poslovanja.

Širenje upotrebe UI drugim segmentima

UI tehnologije u osiguranju ne trebaju se koristiti samo za detekciju prevara, već se mogu proširiti i na druge segmente poslovanja. Preporučuje se širenje upotrebe UI na procese upravljanja rizicima, *underwritinga* (procjene rizika pri izdavanju polica osiguranja), te procjene šteta. Integracija UI u ove procese može unaprijediti učinkovitost i preciznost odluka, te smanjiti ljudske pogreške u svim fazama osiguravajućeg procesa.