

Mesterséges intelligencia alapú döntéstámogató rendszer fejlesztése gépjármű biztosítási csalások feltárásához

Készítette: Berzicai Kevin
Matyasovszki Márton Gábor
Varga Viktória Annamária

Konzulensek: Dr. Lukács Judit
Váradi Péter

TARTALOM

Tartalmi kivonat.....	4
Abstract.....	5
1. Bevezetés.....	6
1.1. Motiváció	6
1.2. Téma létjogosultsága.....	7
2. Biztosítási csalások gyakorisága és az általuk okozott pénzügyi kár.....	9
2.1. Mesterséges intelligencia és a csalásfelderítés.....	9
2.2. Kárbejelentés menete Magyarországon	9
2.3. Kárbejelentés csatornái Magyarországon	11
2.4. Nemzetközi kitekintés a gépjármű biztosítási csalások esetén	12
3. Kutatás bemutatása.....	14
3.1. Felhasznált adatbázis.....	14
3.2. Alkalmazott módszer	14
4. Adaptálás	18
4.1. Fa Struktúra felépítése.....	18
4.2. Bemeneti paraméterek meghatározása	19
4.3. Szabálybázis létrehozása.....	20
4.4. Defuzzifikációs eljárás alkalmazása	21
5. A rendszer Részletes működése.....	22
5.1. Okozói kockázat vizsgálata.....	22
5.1.1. Jármű kockázata	22
5.1.2. Személy kockázata	25
5.1.3. Okozói kockázat	26
5.2. Károsult oldali kockázat.....	27

5.3. Teljes kockázati szint meghatározása	28
6. Eredmények	29
6.1. Előzetes vizsgálatok	29
6.2. Hierarchikus modell kiértékelése	33
6.3. Néhány érdekes eset	35
6.4. Összegzés	37
7. Összefoglalás	38
8. Felhasznált irodalom	39

TARTALMI KIVONAT

A biztosítási csalások (valótlan vagy akár eltúlzott kártérítési igény) világszerte ismert gazdasági bűncselekménynek számítanak. Súlyos károkat okoznak, valamint a biztosító társaságok és ügyfelek közötti bizalmat is rombolják. Így a csalárd esetek felismerése nagyon fontos folyamat. Jelen dolgozat keretein belül egy olyan döntéstámogató rendszert mutatunk be, mely alkalmas lehet a gyanús esetek kiválogatására a kötelező gépjármű felelősségbiztosítási piacon már a kivizsgálás igen korai szakaszában. Ennek megvalósítására valós kártérítési esetek adatait alkalmaztuk, az alábbi feltételek mentén: az igény alapjául szolgáló balesetben két érintett személygépjármű volt, ezek mindegyike magánszemély tulajdonában állt, illetve személyi sérülés nem történt. A fentiek figyelembevételével létrehoztunk egy hierarchikus fuzzy struktúrát, melyben az okozó és a károsult oldalán egyaránt meghatároztuk a csalás kockázati szintjét, majd ezeket összevonva számítottuk ki az eset teljes kockázatát. Megállapítottuk, hogy a küszöbérték felett részletesebb vizsgálat szükséges képzett kárszakértő részéről. Összességében elmondható, hogy az általunk létrehozott rendszer alkalmas lehet az esetek kiválogatására, a szakértelem fókuszálásával pedig a csalásgyanús esetek alaposabb áttekintése által hatékonyabbá tehető a kártérítési folyamat.

ABSTRACT

Insurance fraud (false or even exaggerated claims) is a well-known economic crime worldwide. These cases cause serious damage and destroy trust between insurance companies and their customers. Detecting fraudulent cases is, therefore, a very important process. In this paper, we present a decision support system that can be used to screen out suspicious cases in the compulsory motor liability insurance market at a very early stage of the investigation. To achieve this, data from real claims cases were used under the following conditions: the underlying accident involved two passenger cars, both owned by individuals, and no personal injury. Taking the above into account, a hierarchical fuzzy structure was created, in which the risk of fraud was defined on both the causer and the injured party sides, and then these were combined to calculate the total risk of the case. It was found that above the threshold, a more detailed investigation by a qualified loss adjuster is required. Overall, the system introduced in this work can be used to screen out cases, and by focusing expertise, a more thorough review of suspected fraud cases can make the claims process more efficient.

1. BEVEZETÉS

A dolgozat témája a biztosítási csalások felismerése és detektálása mesterséges intelligencia alkalmazásával. A biztosítási csalások korunkban egyre jelentősebb kihívást jelentenek a biztosítók és a társadalom számára egyaránt, mivel nemcsak pénzügyi károkat okoznak, hanem rontják a társadalmi bizalmat is. A csalások következményei mind gazdasági, mind társadalmi szinten érezhetőek, így elengedhetetlen olyan hatékony módszerek kidolgozása és alkalmazása, amelyek képesek ezek megelőzésére és gyors felderítésére. A mesterséges intelligencia nyújtotta technológiák ígéretes és innovatív megoldásokat kínálnak ezen a téren, jelentősen növelve a felderítési folyamat gyorsaságát és pontosságát, mindezt a biztosítók számára költséghatékony módon.

A dolgozat célja, hogy bemutassa a biztosítók előtt álló kihívásokat, különösen a biztosítási csalások detektálásában, és megvizsgálja, milyen szerepet tölthet be a mesterséges intelligencia a megoldásukban. A kutatás célja továbbá, hogy részletesen elemezze a biztosítási csalások gazdasági és társadalmi hatásait, bemutassa a kárbejelentési rendszerek hazai és nemzetközi működését, valamint áttekintse a hagyományos és modern csalásfelderítési módszerek fejlődését, különös tekintettel a mesterséges intelligencia alapú megoldások előnyeire, működésükre és potenciális alkalmazásukra


1.1. Motiváció

A biztosítási csalások magas előfordulása és az általuk okozott pénzügyi károk komoly problémát jelentenek a biztosítótársaságok és ügyfeleik számára. Ez a probléma nemcsak a biztosítók nyereségességét veszélyeztetheti, hanem a társadalom egészét is, hiszen a csalások más tényezők mellett közvetlen hatással vannak a biztosítási díjak alakulására, és bizalmatlanságot kelthetnek az ügyfelek körében. A mesterséges intelligencia gyors fejlődése lehetőséget biztosít a biztosítóknak arra, hogy hatékonyabb módszerekkel lépjenek fel a csalások ellen. A kutatás motivációja az, hogy bemutassuk, hogyan alkalmazhatóak a mesterséges intelligencia nyújtotta technológiák ezen a területen, ezzel segítve a biztosítási rendszer gördülékeny működését.

1.2. Téma létjogosultsága

A KSH adatai szerint Magyarországon évente 15-18 ezer közúti baleset történik, amelyek közül feltehetően 14%-a azaz nagyjából 2100-2500 olyan biztosítási csalás történik évente, amiket a biztosító társaságok nem küszöböltek ki. A biztosítási csalások felderítése és megelőzése kulcsfontosságú a biztosítási rendszerek hosszú távú fenntarthatósága szempontjából. Az e-kárbejelentő rendszerek megjelenésével a kárbejelentési folyamatok egyszerűsödtek és felgyorsultak, azonban a digitális csatornák új lehetőségeket is nyitnak a csalók számára [1][2].

A mesterséges intelligencia alapú detektálás automatizálhatja és javíthatja a kockázatértékelési folyamatokat (lásd 1. ábra), csökkentve az emberi erőforrás szükségességét az egyértelmű káresemények esetében, ezáltal növelve a pontosságot és a hatékonyságot a kevésbé egyértelmű csalás gyanús eseteknél.



1. ábra Hatékony biztosítási ügyintézés ciklusa

A folyamat felgyorsulása azt is jelenti, hogy a kifizetésre jogosultak hamarabb jutnak az őket illető összeghez úgy, hogy a biztosítási díjak kisebb mértékben emelkednek a biztosítók csökkent kiadásainak hatására.

Összegezve a téma napjainkban egyre fontosabb, mivel a biztosítási csalások elleni küzdelem nemcsak a biztosítók, hanem az ügyfelek és a társadalom közös érdeke is.

2. BIZTOSÍTÁSI CSALÁSOK GYAKORISÁGA ÉS AZ ÁLTALUK OKOZOTT FINANCIÁLIS KÁR

A biztosítási csalások száma világszerte növekvő tendenciát mutat, és súlyos gazdasági károkat okoz a biztosítóknak. Az ilyen esetek következményei nemcsak a biztosítótársaságok pénzügyi helyzetét rontják, hanem lassítják az ügymenetet és rossz fényt vethetnek a társaságokra. A mesterséges intelligencia által nyújtott egyik legnagyobb előny, hogy képes gyorsan és pontosan felismerni azokat a mintákat, amelyek csalásra utalhatnak, jelentősen csökkentve ezáltal a biztosítók pénzügyi veszteségeit. Ezeket a témákat részletesen kifejtve, a dolgozat célja, hogy átfogó képet adjon a biztosítási csalások elleni küzdelem jelenlegi állapotáról és a mesterséges intelligencia alkalmazásának lehetőségeiről.

2.1. Mesterséges intelligencia és a csalásfelderítés

A biztosítók egyre gyakrabban mesterséges intelligencia alapú megoldásokat alkalmaznak a kárbejelentési csalások kiszűrésére. Ezek a rendszerek képesek felismerni a gyanús mintázatokat, és előrejelzéseket készíteni a bejelentések alapján. Az adatelemzés és a gépi tanulás révén a mesterséges intelligencia alapú rendszerek hozzájárulnak a hatékonyabb és gyorsabb csalásfelderítéshez, csökkentve ezzel a biztosítók pénzügyi veszteségeit és gyorsítva az ügymenetet [3].

2.2. Kárbejelentés menete Magyarországon


A KGFB (Kötelező Gépjármű-felelősségbiztosítás) kárbejelentése és elbírálása egy több lépésből álló folyamat, amely a baleset bekövetkezésétől kezdve a kár rendezéséig tart. Ha baleset történik, az érintetteknek elsőként a helyszínen kell rögzíteniük az esemény részleteit a baleseti bejelentő segítségével, amely az esemény körülményeit, a résztvevőket, a gépjárműveket és a tanúk adatait is tartalmazza. Személyi sérülés esetén rendőrt is kell hívni a helyszínre, aki hivatalos jegyzőkönyvet vesz fel a történetekről.

A baleset bejelentése a biztosító felé történik, amelyre általában 5 munkanap áll rendelkezésre. A károsultaknak meg kell adniuk a baleset időpontját, helyszínét, a résztvevők adatait, valamint a baleseti bejelentő másolatát.

A kárbejelentés után a biztosító kijelöl egy kárszakértőt, aki felméri a baleset során keletkezett károkat. Ez lehet személyes felmérés, de egyre több biztosító biztosít online kárbejelentést is, ahol fényképekkel dokumentálják a sérüléseket. A kárszakértő megállapítja a javítás várható költségeit, illetve, hogy totálkár esetén milyen értékű a károsult gépjármű.

Az adatok és szakértői vélemények alapján a biztosító döntést hoz a kártérítésről. Amennyiben a károkozó fél felelőssége egyértelmű, a biztosító kifizeti a kár rendezéséhez szükséges összeget a károsultnak, vagy megszervezi a gépjármű javítását. Vitás esetekben rendőrségi jegyzőkönyv vagy további bizonyítékok beszerzése is szükségessé válhat. A kifizetés a biztosító döntését követően történik.

A kárrendezési folyamat lépései a 2. ábra szerint kapcsolódnak. Ezt a biztosítók igyekeznek a lehető legrövidebb időn belül lezárni, általában 15 napon belül. Ha azonban további vizsgálatok szükségesek, ez az időszak meghosszabbodhat, de a biztosítónak erről tájékoztatnia kell az érintetteket [4].



2. ábra Káriigyintézés folyamata

2.3. Kárbejelentés csatornái Magyarországon

Magyarországon a kötelező gépjármű biztosítással rendelkező ügyfeleknek több lehetőségük is van a káresemény bejelentésére:

1. E-kárbejelentő rendszer: Az online kárbejelentő platformok lehetővé teszik, hogy az ügyfelek gyorsan és egyszerűen jelenthessék be a biztosítási eseményeket mobilkészülékeikről. Az egyik legismertebb alkalmazás az "E-kárbejelentő" applikáció, amely közvetlenül kapcsolódik a biztosítókhoz így a bejelentés szinte azonnal megérkezik az érintett biztosítókhoz. Ezen rendszerek előnye a gyors feldolgozás, és az automatikus adatátvitel, amely jelentősen felgyorsítja a kárügyintézés első lépéseit.

2. Postai úton történő kárbejelentés: Hagyományos formája a kárbejelentésnek, amelynél a szükséges dokumentumokat (kárbejelentő lap, igazolások, fotók) postai úton kell elküldeni a biztosítóknak. Bár időigényesebb és kevésbé megbízható, még mindig sokan alkalmazzák, különösen az idősebb ügyfelek, illetve olyanok, akik nem rendelkeznek digitális hozzáféréssel.

3. E-mailes kárbejelentés: Egyes biztosítók lehetőséget biztosítanak arra, hogy az ügyfelek elektronikus úton, e-mailben küldjék el a kárigényt. Ez gyorsabb a postai útnál, de nem automatizált, mint az e-kárbejelentő.

4. Személyes bejelentés: Egyes biztosítók ügyfélszolgálati irodáiban is lehetőség van kárbejelentésre. Itt az ügyintéző segít a dokumentáció kitöltésében, és ellenőrzi az iratokat. Ez a módszer azoknak lehet hasznos, akik nem szívesen intézik online az ügyeiket.


Ezek a módszerek mind lehetőséget adnak arra, hogy az ügyfelek kényelmesen és gyorsan intézzék kárügyeiket, ugyanakkor a digitális térben történő bejelentések egyre nagyobb figyelmet követelnek a biztosítók részéről, különösen a csalások kiszűrése érdekében [4]. Gyorsabb ügyintézés, az online bejelentés a legtöbb biztosító esetében jelentősen felgyorsítja a folyamatot, mert az adatokat automatikusan továbbítják a rendszerbe, minimalizálva az emberi hiba lehetőségét.

A digitális csatornák használatával azonban új biztonsági kérdések is felmerülnek, például az adatvédelem és a digitális csalások elleni védelem szükségessége. Az e-kárbejelentő rendszerek adatainak helytelen kezelése vagy hamis bejelentések könnyen

vezethetnek csalási esetekhez, ezért a biztosítók egyre több erőforrást fordítanak a mesterséges intelligencia alapú csalásfelderítési módszerek fejlesztésére.

2.4. Nemzetközi kitekintés a gépjármű biztosítási csalások esetén

A környező országok kárbejelentési rendszerei hasonlóan működnek a magyarországiakhoz, azonban országonként eltérhetnek a digitalizáció mértékében, a kárbejelentési folyamat automatizáltságában, a biztosítási rendszer berendezkedésében és a csalások kiszűrésének módszereiben. A felmerülő, szerteágazó nehézségeket a 3. ábra szemlélteti.



3. ábra Csalásfelderítés nehézségei

A biztosítási csalás detektálása bináris osztályozási vagy többszörös osztályozási problémaként is kezelhető. Számos kutató alkalmazott gépi tanulási modelleket az autós biztosítási csalások detektálására, és hasznos eredményeket értek el. Viaene és társai [5], Kašćelan és társai [6], valamint Li és társai [7] a Bayes-i modellezés, klaszterelemzés, adatbányászat és véletlen erdő teljesítményét vizsgálták a gépjármű biztosítási csalás detektálásában. David és társai [8] a biztosított életkor változásának elemzésével a csalárd viselkedés magas kockázatú populációjának jellemzőit és tulajdonságait tárta fel. He és társai [9], Guo és társai [10] és Wang és társai [11] tovább kutatták a mélytanulási modellek potenciálját a csalás detektálásában. Subudhi és társai [12] és Majhi és társai

[13] hibrid modelleket építettek, amelyek hatékonyan képesek detektálni a gépjármű biztosítási csalásokat. Tuo és társai [14] és Liu és társai [15] először a biztosítási csalás játékelméletét vizsgálták Kínában. Gui és társai [16] áttekintette és osztályozta a gépjármű biztosítással kapcsolatos morális kockázatok irodalmát. Zhao és társai [17], Tang és társai [18] és Wang és társai [19] szintén gépi tanulási módszereket alkalmaztak a biztosítási csalás gyanús viselkedés modellezésére a kínai gépjármű biztosítási piac adatai alapján. Csak nemrégiben kezdtek el Yan és társai [20][21], Yu és társai [22] és Xu és társai mélytanulási modellek és kevert modellek alkalmazásával biztosítási csalási problémákat elemezni, és előrehaladást értek el az autós biztosítási csalás detektálása terén.

Megállapítható továbbá, hogy a csalásfelderítő rendszerek esetén nem elég a teljesítmény vizsgálta, hanem szükséges a költséghatékonyság elemzése is a hosszútávú fenntarthatóság érdekében. Ez a megközelítés számos egyéb tudományterületen is kiemelt kutatási terület, különösen az egészségügyben [24][25]. Ezen felül Benedek és Nagy [26] egy költségalapú összehasonlítást mutat be, arra a következtetésre jutva, hogy a vizsgált hagyományos és Mesterséges intelligencia alapú rendszerek között nem mutatható ki egyértelműen az MI jobb teljesítménye.

Sajnos azonban Magyarországon nincs hatékony, mesterséges intelligencián alapuló „jó módszer” a biztosítási csalások kiszűrésére [26]. Kijelenthető, hogy a fuzzy alapú döntéstámogató rendszerek a csalásdetektálás területén biztató eredményeket nyújthatnak. Ennek a módszertannak a vizsgálatát mutatja be Váradi és társai [27][28], ahol már egy elméleti döntéstámogató rendszer megalkotása is megjelenik [29].

3. KUTATÁS BEMUTATÁSA

A TDK dolgozat keretein belül elsődleges célunk egy olyan rendszer megalkotása volt, amely könnyen meghatározható tényezők alapján hatékony segítséget nyújthat a család esetek kiszűrésére. Ezt a szakértői tudás megfelelő csoportosításával kívánjuk elérni.

3.1. Felhasznált adatbázis

A kutatásunk alapját egy biztosító társaság által rendelkezésünkre bocsátott adatbázis képezte. Az adatbázist meghatározott szempontok alapján leszűrtük, végül azokat az eseteket vizsgáltuk, amelyekben

- két személygépjármű volt érintett,
- ezek tulajdonosai természetes személyek,
- illetve nem történt személyi sérülés.

A vizsgálatokat az így kapott közel 4000 eset figyelembevételével hajtottuk végre, melyek az elmúlt 10 évben következtek be.


3.2. Alkalmazott módszer

A mesterséges intelligencia szerteágazó módszerek gyűjteménye. Ennek részterületeit szemlélteti a 4. ábra.



4. ábra Mesterséges intelligencia alrendszerei [5]

Ennek fontos részét képezik a tudás alapú rendszerek. A fuzzy következtetés kifejezetten alkalmas az emberi gondolkodásmód jellemzésére, ugyanis a fekete-fehér/igen-nem/igaz-hamis kétértékű logika helyett a megfelelőség mértékét figyeli. Így nem az a kérdés, jó-e egy adott megoldás, hanem az, hogy mennyire. Ennek megvalósítására jelenik meg benne a tagsági függvény, amely a jóság jellemzésére alkalmas egy 0 (teljesen rossz) és 1 (tökéletesen jó) közötti skálán. Így válik lehetővé a részleges igazság figyelembevétele, illetve a nyelvi jellegű változók használata (pl.: „kicsi”, „közepes”, „nagy” stb.).




5. ábra Fuzzy következtető rendszer felépítése [6]alapján

Maga a fuzzy következtető rendszer négy alapvető elemből épül fel (lásd 5. ábra):

1. az illeszkedés mértékét befolyásoló egységben határozzuk meg a tagsági függvényeket (a fuzzy halmazokat),
2. a szabálybázis tartalmazza az eddigi szakértői tudást, HA... AKKOR... (IF...THEN...) formában,
3. a következtető motor hajtja végre az éppen aktív, tüzelő szabályok összevonását, az első két modullal összeköttetésben áll,
4. végül a defuzzifikáció segítségével kapunk az eredményhalmazból (fuzzy halmaz) egy konkrét, crisp értéket [6][7][8].

A következtető motor a központi része a rendszernek. A Mamdani-típusú következtetés az alábbi módon történik:

Az alapgondolata, hogy minél nagyobb egy feltételnek a tagsági értéke a bemeneti oldalon (minél „igazabb”), annál jelentősebben figyelembe kell venni az eredmény oldalon a kimenetben. Ha például veszünk egy egyszerű, két bemenettel és egy kimenettel rendelkező rendszert, ahol a bemenetek 3, míg a kimenet 4 lehetséges szinttel rendelkezik, akkor a rendszer alaphalmazainak egy lehetséges felosztása lehet az alábbi:




6. ábra Példa rendszer felosztása

Egy tetszőleges, méréssel meghatározott értékpár esetén, melyek x_{1M} és x_{2M} , két szabály aktiválódik, ugyanis ezek az értékek több részhalmazba is tartozhatnak, különböző mértékben:


$$R_1: \text{IF } x_1 \in A_2 \text{ AND } x_2 = B_3 \text{ THEN } y = C_3$$

$$R_2: \text{IF } x_1 \in A_3 \text{ AND } x_2 = B_3 \text{ THEN } y = C_2$$

Itt külön-külön megnézzük a szabályok erősségét:




7. ábra R1 szabály működése



8. ábra R2 szabály működése


A két szabály együttesen aktiválódik, így a részeredményeket össze kell vonni. Így kapjuk meg az összesített eredményhalmazt (lásd 9. ábra).




9. ábra Összevont fuzzy kimenet

Ez azonban egy látszólag nehezen kezelhető eredmény, így szükség van a defuzzifikációra, hogy egy egyértelmű, konkrét helyettesítő értéket kaphassunk. A defuzzifikáció többféle módszerek történhet:

- centroid módszer/COG: a súlypontba határozza meg a kimenetet (lásd 10. ábra a. rész)
- biszektor/COA: a görbe alatti terület felezővonalát adja eredményként,
- maxima módszerek: a legmagasabb tagsági értékű szakaszt vizsgálják (lásd 10. ábra b. része)
 - SOM: legkisebb – Smallest of Maxima
 - MOM: középső – Middle of Maxima
 - LOM: legnagyobb maximum érték – Last of Maxima.



a.



b.

10. ábra Defuzzifikációs módszerek

Általánosan jól működő módszer nincs, a megfelelő eljárás kiválasztása mindig az adott probléma figyelembevételével lehetséges.


4. ADAPTÁLÁS

A rendelkezésre álló adatsor alapján számos problémába ütköztünk: nagyon sok tényező szerepelt az adatbázisban, ezek befolyását külön-külön egyértelműen nem tudtuk kimutatni.

Mindezek alapján arra a következtetésre jutottunk, hogy csupán nagyon összetett, sok bemenettel rendelkező rendszer lenne alkalmas a jellemzésre. Ez azonban igen jelentős számítási igény növekedést eredményezne és bonyolult rendszert eredményezni. Így pont a rugalmasságot veszítenénk el.

4.1. Fa Struktúra felépítése

Ehelyett arra jutottunk, hogy inkább egy hierarchikus struktúrát hozunk létre, mely több, egyszerűbb fuzzy következtetést tartalmaz és kapcsol össze. Így lesz lehetőség a szabályok számának csökkentésére is.



11. ábra A modell struktúrája

A modell hierarchikus struktúrában épül fel, ahol az első szinten alapadatok találhatók, a további szinteken pedig az adatok részletesebb csoportosítása és az ezekhez kapcsolódó kockázati szintek megállapítása és összegzése történik. Az első szinten a káreset résztvevőinek adatait, a gépjárművek korát és értékét vettük figyelembe, amely adatok bizonyítottan kapcsolódnak a csalásgyanús kárigények gyakoriságához.

A Matlab környezetben létrehozott összevont rendszermodellt szemlélteti a 11. ábra, ahol minden doboz egy-egy fuzzy következtetési rendszert jelent.

4.2. Bemeneti paraméterek meghatározása

A rendszer bemeneteit két fő csoportra osztottuk: személyi kockázati tényezők és tárgyi (gépjármű) kockázati tényezők. A személyi kockázati tényezők tartalmazzák a bejelentést tevő fél demográfiai adatait (például életkor, lakhely lélekszáma), míg a tárgyi tényezők magukba foglalják a gépjármű értékét, életkorát, illetve okozói oldalon a biztosítás díjfizetési ciklusát, míg károsulti oldalon a totálkár bekövetkezését. Ezen utolsó kettő minőségi, míg a többi mennyiségi változókként jelenik meg a rendszerünkben.

Ezek szintjeit az alábbi táblázatok tartalmazzák.

Jármű életkora (év)	Kategória	Születési év	Kategória
0-2	új	-1964	Baby Boomer
3-7	fiatal	1965-1980	X generáció
8-14	közepesen idős	1981-1995	Y generáció
15+	régi	1996-	Z generáció
Jármű értéke (Ft)	Kategória	Népesség (fő)	Kategória
1-400 000	nagyon alacsony	1-5 000	község-falu
400 001-1 000 000	alacsony	5 001-20 000	kisváros
1 000 001-2 500 000	közepes	20 001-100 000	középváros
2 500 001-4 000 000	magas	100 001-1 000 000	nagyváros
3 000 000+	nagyon magas	1 000 000+	metropolisz

1. táblázat Bemeneti paraméterek tartományait meghatározó értékek

Ezeket az adatokat az adatbázisban található korábbi biztosítási csalások mintázatai alapján válogattuk ki, hogy releváns alapot képezzenek a fuzzy logikai modell számára.


4.3. Szabálybázis létrehozása

A fuzzy logikai rendszer alapját a szabálybázis adja, amely a kockázatok különböző szintekre történő besorolásáért felel. Az első szinten adatbázis-alapú, objektív szabályok kerültek be, amelyeket statisztikai vizsgálatok támasztanak alá. A további szinteken szakértői vélemények alapján, heurizmusokon nyugvó szabályokat adtunk hozzá. Ezen szabályok képesek a kockázati tényezők interakcióinak értékelésére, például figyelembe veszik, hogy a kisértékű öreg gépjárművek és nagyságrendekkel nagyobb értékű újabb gépjárművek káresetei esetében, nagyobb a csalás valószínűsége. Tehát összességében megállapítható, hogy

- Első szint: ezen a szinten határozzuk meg a káreset részvevőinek kockázati szintjét. A fentebb látható táblázatok segítségével létrehozott szabálybázisok beültetésre kerülnek az egyes fuzzy blokkokba.
- Második szint: a második szint két összegző részből adódik össze, amelyek meghatározott szabályok alapján összegzik az első szintről érkező különböző kockázati szinteket.

A második szinten a kockázati szintek összevonása az 4. táblázatban látható módon történt. Így került meghatározásra a vizsgált eset teljes kockázata.

A hozzájuk kapcsolódó tagsági függvényei az alábbi ábrán láthatók:



4.4. Defuzzifikációs eljárás alkalmazása

A fuzzy logikai rendszerek esetében a defuzzifikáció egy kritikus lépés, amely során a fuzzy eredményeket éles, konkrét értékekké alakítjuk. Ennek célja, hogy a rendszer által számított kockázati szint egyszerűen értelmezhető legyen. Mi két defuzzifikációs módszert, a LOM (Last of Maxima) és a centroid (Center of Gravity) módszereket teszteltük.

Az adaptálás során egy olyan szabály-alapú döntési modellt építettünk, amely képes a biztosítási csalások azonosítására és a különböző kockázati tényezők elemzésére. A modell kockázati besorolások alapján előrejelzést nyújt a csalásgyanús kárigényekkel kapcsolatban. Az adaptáció lépései a bemeneti paraméterek definiálásával, a fuzzy fa kialakításával és a szabálybázis felépítésével kezdődnek, végül pedig a modell kiértékelése zárja le a folyamatot.

5. A RENDSZER RÉSZLETES MŰKÖDÉSE

Fontos megjegyezni, hogy a modell megalkotása során azokat a bejelentett kárigényeket vettük figyelembe, amelyek esetében

1. gépjárművek tulajdonosai természetes személyek,
2. a káreset során nem történt személyi sérülés,
3. továbbá két személygépjármű részvételével következett be a baleset.

A vizsgálat során a modell a következő tényezőket és kapcsolatukat figyelembe véve határozza meg az érintett személyek és a járművek adatai, illetve a statisztikai számítások alapján a biztosítási csalás kockázatának valószínűségét külön az okozói és a károsult fél oldalán.

A számításokhoz olyan kulcsfontosságú adatokat kellett választanunk, amelyek minden káreset esetében rendelkezésre állnak, illetve a káreset résztvevői szempontjából a lehető legtöbb információval rendelkeznek. Ilyen adatok mind az okozó mind a károsult fél esetében a személy életkora és a lakóhelye, járműveik esetében pedig, az okozó jármű értéke, kora és a biztosítási díjfizetési időszak, a károsult jármű esetében pedig az értéke, kora, illetve a gazdasági totálkár bekövetkezése.

Ezen adatok könnyen beszerezhetők, elemezhető az összefüggésük a biztosítási csalások előfordulásának gyakoriságával.

Már a fuzzy fa első szintjén elkülönülnek az okozói és károsulti oldalak, valamint a személyi és tárgyi kockázati tényezők.

5.1. Okozói kockázat vizsgálata


Az okozó fél kockázati szintje két részből adódik össze: meg kell állapítani külön-külön a személyi és a jármű által jelentett tárgyi kockázatot.

5.1.1. Jármű kockázata


Az okozói oldalon szereplő jármű által okozott kockázat súlyosságát az adatbázis vizsgálata alapján határoztuk meg: az adott feltételrendszer esetén milyen arányban tárt fel a biztosító csalást.

Ehhez három bemenő változót vettünk figyelembe: a jármű értékét és korát, valamint a biztosítás díjfizetési időszakát. Ezek partíciói az alábbiak szerint alakult:


a.



b.



c.




13. ábra A jármű kockázat független bemenő változói

A 13. ábra szemlélteti az 1. táblázatban szereplő paraméterek közül az okozói járműhöz tartozó tényezőket és felosztásukat: az a. rész a jármű értékének forintban, a b. rész a kor években történő meghatározását szemlélteti mennyiségi változókként, míg a c. rész pedig a díjfizetési időszakra utal. Ez utóbbi minőségi változóként értelmezhető, három lehetőség közül lehet választani a biztosítás megkötésekor: negyedéves, féléves, illetve éves fizetési gyakoriság közül.

Ennek a blokknak a kimeneti oldalán az adatbázisban szereplő esetek alapján meghatároztuk az összes lehetséges szint kombinációja esetén a csalás valószínűségét. Ehhez rendeltük hozzá a fuzzy halmazokat (lásd 2. táblázat és 14. ábra).

Kockázati szint nyelvi leírása	csalás %-os előfordulása	
	-tól	-ig
elhanyagolható	0	1,25
alacsony	1,26	2,5
közepes	2,51	4,5
feltételezhető	4,51	7,5
valós	7,51	10,50
erős gyanú	10,51	100

2. táblázat Kimeneti változók felosztása a modell első szintjén




14. ábra Kimeneti változók fuzzy halmazai a modell első szintjén

A következtetés leírására lefedő szabálybázist alkalmaztunk, mely összesen 60 szabályt tartalmazott.

5.1.2. Személy kockázata

Az okozói oldalon a személyi kockázat meghatározása szintén az adatbázisban való előfordulás szerint került meghatározásra. Itt két bemenő paramétert használtunk: az ügyfél lakóhelyét a település lélekszáma szerint, valamint az életkorát a születési évszám alapján. A független változók nyelvi szintjei az 1. táblázatban találhatóak, míg a partíciói a 15. ábrán láthatók (a. rész a lakóhely – a szemléltetés miatt két részletben – a b. rész pedig a korosztály felosztását szemlélteti).




15. ábra Okozó személyi kockázat független változói

A következtetés kimenete a jármű kockázatához hasonlóan az adatbázisból származó csalási valószínűségek a 3. táblázatban és a 14. ábrán szereplő felosztásban. Itt is lefedő szabálybázissal dolgoztunk, összesen 20 szabályt hoztunk létre.


5.1.3. Okozói kockázat

Az okozói kockázat meghatározásakor a 16. ábrán látható módon dolgoztunk: a jármű és személy jellemzőiből adódó csalási valószínűségek alapján határoztuk meg az okozói kockázati szintet.



16. ábra Okozó kockázatának értelmezése

Ebben a lépésben a jármű és a személy kockázata kerül összevonásra, melyek egyben a következtetés bemenetei is. Kimenatként az okozói kockázat jelenik meg, melyet egy 6 fokozatú skálán értelmeztünk a 17. ábra szerint.



17. ábra Okozó kockázat szintjeinek meghatározása


A bemeneti és a kimeneti oldal összekapcsolása az alábbi szabálybázis szerint történt, mely a korábbiakhoz hasonlóan lefedő volt.

Teljes kockázat		Tárgyi kockázat					
		elhanyagolható	alacsony	közepes	feltételezhető	valós	erős gyanú
Személyi kockázat	elhanyagolható						
	alacsony						
	közepes						
	feltételezhető						
	valós						
	erős gyanú						

3. táblázat Szabálybázis az okozói kockázat meghatározásához

5.2. Károsult oldali kockázat

A károsult oldali kockázati szint meghatározása hasonlóan történik, azzal a különbséggel, hogy ott a biztosítási díjfizetési időszak helyett a gazdasági totálkár bekövetkezésének tényét vizsgáljuk. Ez szintén minőségi változóként jelenik meg, 2 szinten változtatjuk, „igen” és „nem” nyelvi változókkal leírva; a jármű kockázatot befolyásolja. A tagsági függvények az alábbi ábra szerint alakulnak.



18. ábra Gazdasági totálkár jellemzése

Szintén meghatározzuk, a jármű, illetve a személy kockázatát, illetve ezek összevonásával adjuk meg a károsult oldali kockázatot, szintén 0...5 skálán.


5.3. Teljes kockázati szint meghatározása

A rendszer utolsó eleme az adott esethez tartozó teljes kockázati szint kiszámítása. Itt az előzőekben bemutatott módon meghatározott okozói és károsult oldali kockázati szintek összevonása történik. Ehhez ismételtlen egy lefedő szabálybázist használtunk, amely kombinációi az 4. táblázatban láthatók.

Teljes kockázat		Károsult kockázata					
		elhanyagolható	alacsony	közepes	feltételezhető	valós	erős gyanú
Okozó kockázata	elhanyagolható						
	alacsony						
	közepes						
	feltételezhető						
	valós						
	erős gyanú						

4. táblázat Teljes kockázati szint szabálybázisa

Az 4. táblázatban szereplő nyelvi változókat szintén egy 0...5 közötti skálán értelmeztük. Ezt a partíciót szemlélteti a 19. ábra.




19. ábra Teljes kockázati szint felosztása

6. EREDMÉNYEK

6.1. Előzetes vizsgálatok

Az előzetes vizsgálatok végrehajtásához az Excelbe beépített kiértékelési módszereket alkalmaztuk.


Az adatainkat két nagy csoportra osztottuk: okozói és károsult jellemzői. Ezeken belül megkülönböztettünk személlyel és személygépjárművel kapcsolatos tényezőket (lásd 20. ábra).



20. ábra A figyelembe vett tényezők csoportosítása


Mivel számos összefüggés áll fenn a különböző paraméterek között, ezeket összevonva keresztkiértékeléseket hajtottunk végre.

Vizsgálható a detektált biztosítási csalások száma a járművek életkora, a jármű értékének nagysága, valamint az érintett személyek életkora függvényében. Ez látható a 21. ábrán okozói oldalról, míg a 22. ábrán a károsult esetén.



21. ábra Csalárd káresetek eloszlása az okozó gépjármű kora alapján

Okozói oldalon a közepesen idős és a régi személygépjárművek esetében volt számottevő bizonyítottan csalással végződő esemény. A fiatal és új járművek esetén nem történt csalás. A fenti diagramon látható, hogy alacsony értékű járművek esetén követtek el főként csalást, ezen belül is kiugró értéket találunk a régi járművet vezető X és Y generációhoz tartozó személyeknél.




22. ábra Csalárd káresetek eloszlása a károsult gépjármű kora alapján

Károsult oldalon is hasonló területen látható kiemelkedő érték, azonban itt nagyjából megegyezik a közepesen idős és régi járművek esetében történt csalások száma. Az előző diagrammal ellentétben itt a fiatal járműveknél is történt kevesebb ugyan, de már

figyelmet igénylő visszaélés. Megfigyeltük, hogy a rendelkezésre álló adatbázis alapján új járművel nem követtek el biztosítási csalást sem okozói, sem károsult oldalon.


Szintén vizsgálható a kárigények bejelentésének módja és a csalárd esetek száma közötti összefüggés. Ezt szemlélteti a 23. ábra.




23. ábra Csalárd káresetek eloszlása a bejelentés módja alapján

A csalással végződő kárigények több, mint felét e-mailben jelentették be, de az internetes kárbejelentések száma is kimagasló ebben az esetben. Mind a négy bejelentési módozat esetén az alacsony értékű járművek adták a csalárd esetek legjelentősebb részét.

A feltárt biztosítási csalások eloszlása település típusok szerint is elemezhető. Okozói (lásd 25. ábra) és károsult oldalon (24. ábra) is megfigyelhető, hogy a legtöbb csalást alacsony értékű járművek esetében és kisvárosokban követték el. A többi településtípus esetében a csalások száma nagyjából megegyező.




24. ábra Csalárd káresetek eloszlása a károsult ügyfél lakóhelye alapján



25. ábra Csalárd káresetek eloszlása az okozó ügyfél lakóhelye alapján

Ezen felül létrehoztunk térkép alapú kimutatásokat is, melyen vizuálisan is megjeleníthetők a bizonyítottan csalással végződő esetek területi megoszlásai. A 26. ábrán a megyék szerinti felosztásra fektettük a hangsúlyt és látható, hogy mely megyékben hány darab csalás történt. Itt a sötétebb árnyalat több csalási esetet jelent.



26. ábra Csalárd káresetek eloszlása Magyarország területén

A földrajzi eloszlás alapján megállapítható, hogy a csalásgyanús esetek legnagyobb mennyiségben Pest vármegyében fordultak elő, illetve szintén magas volt az észak-keleti országrész esetszáma.

6.2. Hierarchikus modell kiértékelése


Matematikai modellünk validációját a létrehozásához használt adatbázison végeztük el. Minden egyes adatsort lefuttatva jelentős különbségeket tapasztaltunk az eredményekben, amelyeket nagymértékben befolyásolt az alkalmazott defuzzifikációs eljárás típusa. A vizsgálatok alapján a LOM és a centroid módszerek bizonyultak a legjobbnak, ezek szolgáltatták a legmegbízhatóbb eredményeket.

A centroid defuzzifikációs módszer a fuzzy logikai rendszerekben alkalmazott defuzzifikációs eljárások egyike, súlyponti elven alapul. Célja, hogy egy adott fuzzy halmazt éles, konkrét értékre alakítson át, amely a döntéshozatali folyamatok alapját képezi.

A "Last of Maxima" (LOM) defuzzifikációs módszer a fuzzy halmazban lévő maximális tagsági érték legnagyobb xxx-koordinátáját választja ki. Ez az eljárás különösen hasznos olyan alkalmazásokban, ahol a legnagyobb végpontot kell kiválasztani a fuzzy halmaz

csúcsszintjén. A gyakorlatban ez azt jelenti, hogy először meghatározzuk a kimeneti fuzzy halmaz maximális tagsági szintjét, majd azt az értéket keressük meg, amelyiknél ez a maximális tagsági érték még érvényes [10].

Az eredmények alapján a centroid módszer eredményei bizonyultak a leginkább összehangoltnak a biztosító döntéseivel, így ezek elemzését mélyebben vizsgáltuk. A fuzzy modell által generált kockázati szinteket az egyes kárbejelentésekre vonatkozó döntésekkel vetettük össze, figyelembe véve, hogy a biztosító milyen álláspontra helyezkedett, az ügyfél indított-e jogi eljárást, valamint az eljárás kimenetelét. Ezen elemzések alapján a modell 72%-os egyezést mutatott a biztosító által hozott döntésekkel. A fuzzy rendszer végső kimenete 0 és 5 közötti kockázati szintet rendel az egyes kárigényekhez, amely segít annak eldöntésében, szükséges-e az adott eset alaposabb vizsgálata. Ha a kockázati szint $z \leq 2,00$ akkor a káreset további vizsgálata nem indokolt, és az erőforrások átcsoportosíthatók azokhoz az esetekhez, ahol $z > 2,00$. Az összesített eredmények szerint a 4000 káreset 73,3%-a 2,00 alatti kockázati szinttel rendelkezett, jelezve, hogy ezek az esetek kevesebb szakértői figyelmet igényelnek, mivel kicsi a csalás valószínűsége. A fennmaradó 26,7% kárigény esetében azonban megalapozottan merül fel a csalás gyanúja, így az erőforrások átcsoportosításával ezek az ügyek gyorsabban lezárhatók.



27. ábra Teljes kockázati szint az okozó- és a károsult oldali kockázati szint függvényében

6.3. Néhány érdekes eset

Jelen szakaszban néhány különleges esetet szeretnénk bemutatni, ahol

- a. a biztosító döntése és a modell által meghatározott kockázati szint egyezést mutat
- b. illetve néhány eltérést is szeretnénk kiemelni.

A 5. táblázat erre mutat néhány példát.

Okozó jármű értéke (Ft)	2 400 000	2 800 000	1 800 000	2 800 000
Okozó jármű kora (év)	13	12	14	7
Okozó díjfizetési időszaka	Negyedéves	Éves	Éves	Éves
Okozó lakóhelyének lélekszáma (fő)	8066	1723836	448	1723836
Okozó születési éve	1990	1974	1991	1979
Károsult jármű értéke (Ft)	1 200 000	800 000	5 600 000	3 480 000
Károsult jármű kora év	11	22	12	2
Gazdasági totálkár?	Nem	Nem	Nem	Nem
Károsult lakóhelyének lélekszáma (fő)	2787	1723836	1338	23119
Károsult születési éve	1979	1927	1997	1981
Teljes kockázati szint	4	1	4	0,7
Biztosító döntése	Csalás	Nem csalás	Nem csalás	Csalás
Volt kifizetés?	Nem	Igen	Igen	Igen
Peres eljárás?	Nem	Nem	Nem	Igen

5. táblázat A modell eredményeinek összehasonlítása valós biztosítási kárigényekkel

A biztosító első esetben csalásként minősítette a kárigényt, amely így kifizetés nélkül zárult. A modell előrejelzése szerint az adott eset kockázatos, 4-es szintű valós csalási gyanú feltételezhető, tehát mindenképpen átfogó elemzés szükséges szakértő részéről.

A második és harmadik esetben a biztosító nem minősítette csalásnak a kárigényeket, és megtörtént a kártérítési összeg kifizetése. Mindazonáltal, a modell előrejelzése alapján a második eset „biztonságosnak” tekinthető, a harmadik azonban csalás gyanús lehet, ami

arra utal, hogy a biztosító részéről részletesebb vizsgálat szükséges. Ez valószínűleg meg is történt.

Azonban felmerült néhány speciális eset is. A biztosító döntését a kárigénylő ügyfélnek nem mindenáron kell elfogadnia. Amennyiben a biztosító csalásnak minősít egy esetet, a kártérítés kifizetését megtagadja. Amennyiben az érintett ügyfél ezt nem fogadja el, jogi úton érvényesítheti érdekeit bírósági peres eljárásban. Itt újabb felülvizsgálat történik. Eerre látható egy példa a 6. táblázat utolsó oszlopában. Ezt az esetet a biztosító csalásnak titulálta a kárigényt. Ezzel szemben a modell nem találta gyanúsának az esetet. A bíróság az eljárás során a károsult javára döntött, tehát végeredményként nem csalásként, kárkifizetéssel zárult az ügy. A második és harmadik esetről a biztosító szerint nem csalárd a kárigény viszont az ügyfél magasabb kártérítésért indított pert.

Hasonló helyzet alakulhat ki akkor is, ha az ügyfél a biztosító által meghatározott kártérítési összeget nem tartja elegendőnek, szintén bírósághoz fordulhat felülvizsgálatra. Tehát a biztosító döntése esetenként nem a végleges lezárása az ügyeknek.

Ezekre mutat néhány példát a 6. táblázat, amikor a károsult ügyfél pert indított vagy nagyobb kárkifizetésért, vagy mert nem értett egyet a biztosító döntésével.

Okozó jármű értéke (Ft)	200 000	600 000
Okozó jármű kora (év)	22	21
Okozó díjfizetési időszaka	Éves	Éves
Okozó lakóhelyének lélekszáma (fő)	158942	158942
Okozó születési éve	1999	1944
Károsult jármű értéke (Ft)	2 000 000	1 600 000
Károsult jármű kora év	12	13
Gazdasági totálkár?	Nem	Nem
Károsult lakóhelyének lélekszáma (fő)	158942	1004
Károsult születési éve	1985	1958
Teljes kockázati szint	1,0	3,0
Biztosító döntése	Nem csalás	Nem csalás
Peres?	Igen	Igen
Volt kifizetés?	Igen	Igen

6. táblázat A modell eredményeinek összehasonlítása valós biztosítási kárigényekkel peres esetekben


Ilyenkor a csalás gyanújának fennállása esetén a biztosító részéről stratégia is lehet az alacsonyabb mértékű kártérítési összeg megadása

6.4. Összegzés

Az eredmények alapján a modell 2900 esetben sikeresen azonosította a kis kockázatú biztosítási csalásokat, így lehetővé tette, hogy az erőforrások inkább a 1100 magasabb kockázatú eset vizsgálatára összpontosuljanak. A modell összesített pontossága 72%-os volt, ami megegyezett a biztosító értékeléseivel.

Érdemes kiemelni, hogy a modell a biztosító ítéleteivel ellenkezőleg többször is nem gyanúsként azonosította az ügyeket olyan esetekben, amikor a biztosító csalásnak minősítette a kárigényt, de végül pert vesztett a károsulttal szemben. Mindezek figyelembevételével a modell pontossága tovább javul, ugyanis megfelelően határozta meg a kockázati szintet számos későbbi peres eljárás esetén is. Így az összesített pontosság 75%-ra emelkedett a bírósági eljárások figyelembevételével.

Mindezek alapján megállapítható, hogy a dolgozatban bemutatott modell hatékony segítség lehet a gépjármű biztosítási piacon a kártérítési igények vizsgálata során.



28. ábra Döntéstámogató rendszer működése

7. ÖSSZEFOGLALÁS

A kutatás során a biztosítási csalások feltárásához egy mesterséges intelligencia alapú döntéstámogató rendszert dolgoztunk ki, amely a fuzzy logikát alkalmazza a kockázatos kárbejelentések azonosítására. A fuzzy logika olyan technológiai megközelítést kínál, amely lehetővé teszi a kockázatok fokozatos, nem pedig bináris besorolását. Azaz csalás vagy nem csalás formájában értékeli a kárigényeket, hanem egy folyamatos kockázati skálán osztályozza azokat, amely jelentősen megnöveli a gyanús esetek felismerésének pontosságát. A fuzzy logikai megközelítés további előnye, hogy lehetőséget biztosít az ügyintézés gyorsítására és a vizsgálati folyamat rugalmasabbá tételére.

A meghatározott szintek alapján a rendszer képes hatékonyabban elkülöníteni a magasabb kockázatú eseteket az alacsonyabb kockázatúaktól, ezzel elkerülve a túlzottan szigorú vagy éppen túl engedékeny hozzáállást. Ezzel együtt a későbbiekben finomabban szabályozhatjuk a kárigények elbírálását, amivel csökkenthetjük akár az operatív költségeket és az erőforrások felhasználását.

Összességében a fuzzy logika alapú döntéstámogató rendszerek jelentős előnyökkel járnak a biztosítási csalások elleni küzdelemben, mivel a kockázatok fokozatos besorolása és az összetett szabályrendszerek alkalmazása lehetővé teszi a kárigények pontosabb, rugalmasabb és hatékonyabb kezelését.

8. FELHASZNÁLT IRODALOM

- [1] https://www.ksh.hu/docs/hun/xstadat/xstadat_evkozi/e_feb002.html (Megtekintve: 2024. október 12.)
- [2] <https://www.autoklub.hu/klub/hirek/baleseti-statisztikak/> (Megtekintve: 2024. október 12.)
- [3] <https://www.insurancefraud.org> (Megtekintve: 2024. október 14.)
- [4] Magyar Nemzeti Bank, KGFB kárbejelentési útmutatók, 2024.
- [5] Viaene, S., Dedene, G., Derrig, R.A.: Auto claim fraud detection using Bayesian learning neural networks. *Expert Systems with Applications* 29(3), 653-666 (2005)
- [6] Kaščelan, L., Kaščelan, V., Novović-Burić, M.: A Data Mining Approach for Risk Assessment in Car Insurance: Evidence from Montenegro. *International Journal of Business Intelligence Research (IJBIR)* 5(3), 11-28 (2014)
- [7] Li, Y., Yan, C., Liu, W., Li, M.: A principle component analysis-based random forest with the potential nearest neighbor method for automobile insurance fraud identification. *Applied Soft Computing* 70, 1000-1009 (2018)
- [8] David, M., Jemna, D.V.: Modeling the frequency of autoinsurance claims by means of poisson and negative binomial models. *Analele stiintifice ale Universitatii "Al. I. Cuza" din Iasi. Stiinte economice/Scientific Annals of the "Al. I. Cuza"* (2015)
- [9] He, X., Chua, T.S.: Neural factorization machines for sparse predictive analytics. In *Proceedings of the 40th International ACM SIGIR conference on Research and Development in Information Retrieval*, pp. 355-364 (2017, August)
- [10] Guo, J., Liu, G., Zuo, Y., Wu, J.: Learning sequential behavior representations for fraud detection. In *2018 IEEE international conference on data mining (ICDM)*, pp. 127-136 (2018, November)

- [11] Wang, Y., Xu, W.: Leveraging deep learning with LDA-based text analytics to detect automobile insurance fraud. *Decision Support Systems* 105, 87-95 (2018)
- [12] Subudhi, S., Panigrahi, S.: Use of optimized Fuzzy C- Means clustering and supervised classifiers for automobile insurance fraud detection. *Journal of King Saud University-Computer and Information Sciences* 32(5), 568-575 (2020)
- [13] Majhi, S.K.: Fuzzy clustering algorithm based on modified whale optimization algorithm for automobile insurance fraud detection. *Evolutionary intelligence* 14(1), 35-46 (2021)
- [14] Tuo, G., Duan, J.: Game Theory Analysis of Insurance Fraud. *Journal of Capital University of Economics and Business* (3), 51-54 (1999)
- [15] Liu, X., Jin, J.: The Insurance Fraud Game and Insurance Contract Based on Optimal Game Strategies. *Systems Engineering-Theory & Practice* 24(2), 19-24 (2004)
- [16] Gui, P., Hu, Q.: A Literature Review of Auto Insurance Moral Hazard at Home and Abroad. *Insurance Studies* (6), 121–127 (2011)
- [17] Zhao, G., Wu, H.: Is There Moral Hazard in Chinese Automobile Insurance Market?-Evidence from Dynamic Renewal Policies. *Journal of Financial Research* (6), 175- 188 (2010)
- [18] Tang, J., Mo, Y.: Construction of Auto Insurance Anti- fraud System Based on Data Mining Technology. *Journal of the Postgraduate of Zhongnan University of Economics and Law* (5), 80-87 (2013)
- [19] Wang, H.: A Research on Chinese Insurers' Moral Hazard Screening in Operation: From the Big Data Hadoop Clustering Analysis Technology Perspective. *Insurance Studies* (2), 59-67 (2016)
- [20] Yan, C., Li, Y., Sun, H.: A Research on Automobile Insurance Fraud Identification Based on Random Forest Model and Ant Colony Optimization Algorithm. *Insurance Studies* (6), 114-127 (2017)
- [21] Yan, C., Li, M., Zhou, X.: Improved genetic algorithm for vehicle insurance fraud identification model based on BP neural network. *Journal of*

Shandong University of Science and Technology (Natural Science) 38(5), 72-80 (2019)

[22] Yu, W., Feng, G., Zhang, W.: A Research on Fraud Detection System and Gang Identification of Vehicle Insurance. *Insurance Studies* (2), 63-73 (2017)

[23] Jiaxi Yang, Kui Chen, Kai Ding, Chongning Na & Meng Wang (2022): Auto Insurance Fraud Detection with Multimodal Learning

[24] Lee, A., Taylor, P., Kalpathy-Cramer, J., & Tufail, A. (2017). Machine learning has arrived!. *Ophthalmology*, 124(12), 1726-1728.

[25] Hill, N. R., Sandler, B., Mokgokong, R., Lister, S., Ward, T., Boyce, R., ... & Gordon, J. (2020). Cost-effectiveness of targeted screening for the identification of patients with atrial fibrillation: evaluation of a machine learning risk prediction algorithm. *Journal of medical economics*, 23(4), 386-393.

[26] Benedek, B., Nagy, B. Hagymányos versus MI-alapú csalásfelderítés: Költséghatékonyság a gépjármű-biztosítások területén. *HITELINTÉZETI SZEMLE*, 77.

[27] Váradi, P., Lukács, J., & Horváth, R. (2023, May). Examination of vehicle fraud detection possibilities with the help of Fuzzy inference system. In 2023 IEEE 17th International Symposium on Applied Computational Intelligence and Informatics (SACI) (pp. 000353-000358). IEEE.

[28] Váradi, P., Lukács, J., & Horváth, R. (2024, April). Response Surface Methodology to Characterize the Indicators for the Early Detection of Fraudulent Cases in the Motor Insurance Market. In 2024 IEEE 11th International Conference on Computational Cybernetics and Cyber-Medical Systems (ICCC) (pp. 000201-000204). IEEE.

[29] Váradi, P., Lukács, J., & Horváth, R. (2024). Elméleti fuzzy következtetési rendszer a csalásgyanús esetek korai felismerésére a gépjármű-biztosítási ágazatban. *Közlekedéstudományi Szemle*, 74(5), 31-43.

[30] Sciberras, M., Dingli, A. (2023). AI and Its Wider Impact. In: Investigating AI Readiness in the Maltese Public Administration. Lecture Notes

in Networks and Systems, vol 568. Springer, Cham.
https://doi.org/10.1007/978-3-031-19900-4_2

[31] Kóczy, L. T., & Tikk, D. (2000). Fuzzy rendszerek. TypoTEX, Budapest.

[32] Brassai, S. T. (2019). Neurális hálózatok és fuzzy logika. Scientia Kiadó.

[33] WANG, P. P. (2000). Computing with words—made easy. In Intelligent Techniques And Soft Computing In Nuclear Science And Engineering (pp. 16-26).

[34] Mamdani. (1977). Application of fuzzy logic to approximate reasoning using linguistic synthesis. IEEE transactions on computers, 100(12), 1182-1191.

[35] Ross, T. J. (2005). Fuzzy logic with engineering applications. John Wiley & Sons.