

Elméleti fuzzy következtetési rendszer a csalásgyanús esetek korai felismerésére a gépjármű-biztosítási ágazatban

Biztosítási csalásról akkor beszélhetünk, amikor az igénylő alaptalan, indokolatlan kártérítési igény benyújtásával igyekszik anyagi előnyre szert tenni. Ezek az esetek súlyos gazdasági károkat okozhatnak. Ennek következtében a csalárd esetek felderítése napjainkban kulcskérdés, különösen a gépjármű-felelősségbiztosítási piac esetében.

Kulcsszavak: biztosítási csalás felderítése, Mamdani-típusú fuzzy következtetési rendszer, gazdasági kockázat, gépjármű-biztosítás

DOI: <https://doi.org/10.24228/KTSZ.2024.5.3>

Váradi Péter¹ – Lukács Judit² – Horváth Richárd³

¹ Óbudai Egyetem, Biztonságtudományi Doktori Iskola

² Óbudai Egyetem, Bánki Donát Gépész és Biztonságtechnikai Mérnöki Kar

³ Óbudai Egyetem, Bánki Donát Gépész és Biztonságtechnikai Mérnöki Kar

e-mail: varadi.peter@phd.uni-obuda.hu, lukacs.judit@bgk.uni-obuda.hu, horvath.richard@bgk.uni-obuda.hu

1. BEVEZETÉS

A biztosítási csalás jelentős gazdasági károkat eredményez. Ezért az ilyen esetek felderítése napjainkban kulcsfontosságú társadalmi kérdés. A biztosítási csalás olyan helyzetként határozható meg, amikor egy személy vagy szervezet hamis, valótlan állításokat nyújt be annak érdekében, hogy olyan pénzügyi kártérítéshez vagy valamilyen juttatáshoz jusson, amelyre nem jogosult. A felderítésre több különböző technika is alkalmazható.

Az elmúlt néhány évben számos kutatás foglalkozott a biztosítási csalás modellezésének lehetőségeivel. Még az ezredforduló környékén Bordoni és Facchinetti [1] egy fuzzy rendszert javasoltak a biztosítási csalások felderítésére az

olasz biztosítási csalások piacán. Spanyolországban Artis és tsi. [2] egy spanyol biztosítási piaci adatbázist használtak, amely valós és csalárd kárigényeket tartalmazott. Létrehoztak egy logisztikus regressziós modellt, amely képes volt megbecsülni a fel nem fedezett csalárd esetek valószínűségét. Morley és tsi. [3] etnográfiai vizsgálatot terveztek. Az elemzést a gépjármű-biztosítási csalások jellegére és felderítési gyakorlatuk lehetőségeire alapozott két piacvezető biztosítótársaságnál végezték.

Napjainkban az adatbányászati technikák segítséget nyújthatnak a biztosított ügyfelek viselkedésének feltérképezésében. Goleji és tsi. [4] három különböző adatbányászati módszert vizsgáltak a gépjármű-biztosítások csalásának meghatározására. Nian és tsi. [5]

egy új, felügyelet nélküli spektrális rangsorolási módszert (SRA, Spectral Ranking for Abnormality) mutattak be az anomáliák felderítésére. Roy és George [6] arról számoltak be, hogy a biztosítási csalások összköltsége 2017-ben több mint negyvenmilliárd dollár volt. Tanulmányukban a gépi tanulási technikák segítségével történő járműcsalások felderítésére összpontosítottak. Ezenkívül az adatbányászati technikák is szóba kerültek, mint a biztosítási ágazat irányítására szolgáló, hatalmas adatokban rejlő rejtett tudás és minták kinyerésére szolgáló hatékony megközelítés.

A gépi tanulás is egyre fontosabb szerepet játszik ezen a területen is. Bécsi és tsi. [7] munkájukban ismertették a közlekedés és a gépi tanulás kapcsolatát, valamint a járműipar várható átalakulását. Ghorbani és Farzai [8] adatbányászatot alkalmaztak a gépjármű-biztosítási csalások esetén különféle minták fel-tárására.

Megállapítást nyert, hogy a biztosított személyek viselkedése szintén fontos tényező ezekben az esetekben [9][10]. A biztosított ügyfelek viselkedésével kapcsolatban Gomes és tsi. [11] egy újszerű mélytanulási módszert javasoltak annak megértésére, hogyan lehet minimális erőfeszítéssel betekintést nyerni egy biztosított személy csalárd viselkedésébe.

A prediktív modelleket széles körben alkalmazzák a biztosítási gyakorlatban a csalárd esetek felderítésére. A lágyszámítási és a gépi tanulási eljárások alkalmazásáról szóló tanulmányokban többnyire a releváns adatok tekintetében az információhiánnyal kell szembenézni. Hanafy és Ming [12] 13 gépi tanulási algoritmust vizsgáltak valós adatok felhasználásával. A tanulmány célja az volt, hogy bizonyítsák a kiegyensúlyozatlan adatok problémáinak hatását. Emellett meghatározták az optimális újramintázási technikát több véletlenszerű mintavételezési eljárás elemzésével (Random Over Sampler – ROS, Random Under Sampler – RUS). Egyedi megközelítésként a SMOTE (Synthetic Minority Oversampling Technique) mintavételezési módszer alkalmazhatóságát, valamint egy további, hibrid újramintázási módszert is vizsgáltak.

A járműjavító műhelyek szintén jelentős szerepet játszanak a biztosítási csalások tekintetében. Ezért Macedo és tsi. [13] azt vizsgálta, hogy a javítóműhelyek hogyan járulhatnak hozzá az ilyen típusú bűncselekmények számának csökkentéséhez, rossz esetben növeléséhez.

Aslam és tsi. [14] három prediktív modellt mutatott be (logisztikus regresszió, tartó vektor gép (Support Vector Machine, SVM) és naiv Bayes-modell), amelyeket egy csalásdetektáló rendszer kifejlesztésére alkalmaztak. Megállapították, hogy a pontosság tekintetében a tartó vektor gép jobban teljesített. Azonban a logisztikus regresszió érte el a legmagasabb értéket. A biztosítási csalások felderítésének módszereiről Bolton és Hand [15], valamint Hassan és Abraham [16] átfogó áttekintést készítettek. A fentiek alapján megállapítható, hogy többféle prediktív módszer merült fel a csalásnyűs esetek felismerésére és feltárására. Ezen megközelítések számos tényezővel, körülménnyel operálnak, céljuk a biztosítási csalásokból eredő gazdasági és társadalmi kockázat csökkentése.

Ebben a tanulmányban egy Mamdani-típusú, több bemenetű, egy kimenetű (Multi-Input-Single-Output, MISO) fuzzy következtetési rendszer kerül bemutatásra a gépjármű-biztosítási csalás valószínűségének becslésére. Három független bemeneti változót választottunk a kezdeti stádiumban a gyanú felkeltésére. Ezek az alábbiak: *biztosítási kárkifizetés*, Ft; a *vétlen résztvevő jármű életkora*, év; a kárt okozó fél biztosítási szerződésének *fizetési időszaka*. Egyetlen kimenetként a biztosítási csalás hipotetikus, *feltételezett valószínűségét*, %, határoztuk meg. A bemutatott modell a kártérítési ügyek előzetes vizsgálata során ígéretes eredményeket hozhat.

2. MÓDSZEREK

A halmaz matematikai értelemben a matematikai ismeretek alapfogalmaként adható meg. Maga a halmaz meghatározott tulajdonsággal bíró, homogén objektumok gyűjteménye. A rendező alapelv a halmazhoz tartozás mértéke. Crisp halmazelmélet esetében egy halmaz ele-

mei egyértelműen meghatározzák a halmazt. Ennek eredményeképpen az alaphalmaz minden egyes elemét a karakterisztikus függvény írja le;

$$\kappa_A(x) = \begin{cases} 1, & \text{if } x \in A \\ 0, & \text{if } x \notin A \end{cases} \quad (1)$$

ahol $A \in X$ maga a vizsgált halmaz, x egy elem, X pedig az alaphalmaz (univerzum).

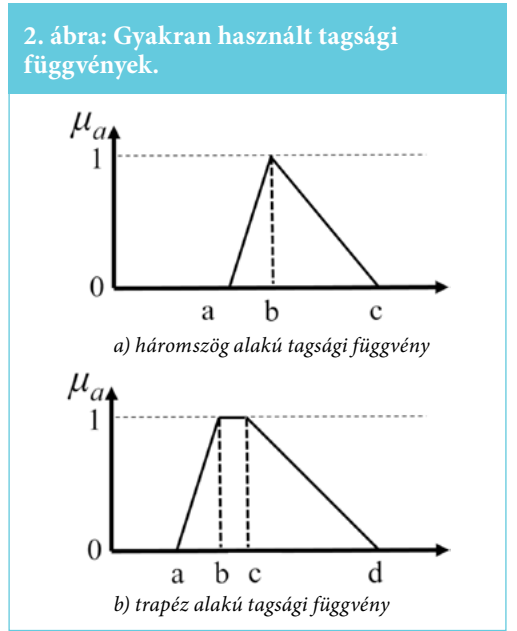
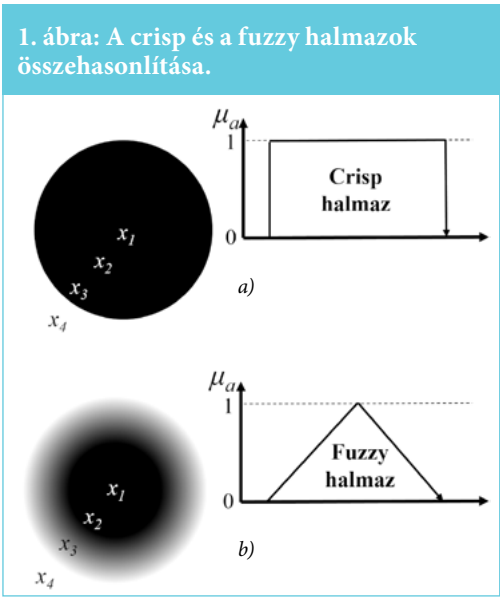
Ebben az esetben egy tetszőlegesen kiválasztott elemet egyértelműen a vizsgált halmazhoz tartozónak, vagy azon kívüli objektumnak lehet azonosítani (1. ábra felső része).

Ez a koncepció azonban nem teljesen alkalmas a szubjektív, személyes vonatkozású, valamint kategorizálási problémák kezelésére. Ezért a kétértékű "halmaz" fogalom bővítésére fogalmazódik meg igény. Az emberi viselkedés (gondolkodásmód, döntéshozatal, stb.) modellezése esetén ez kifejezetten indokolt lehet.

A fuzzy halmazelméletet L. A. Zadeh [17] vezette be 1965-ben. A fő gondolat az volt, hogy a részleges igazság fogalmát matematikai szempontból is értelmezni tudjuk (1. b) ábra). Ebben az esetben a halmazok szigorú határai el-

mosódnak, és átmeneti tartományok jelennek meg. A karakterisztikus függvényt az úgynevezett tagsági függvény váltja fel, amely a $[0, 1]$ intervallumon a megfelelést, halmazhoz tartozás mértékét írja le, vagyis azt, hogy egy adott elem mennyire tartozik egy vizsgált halmazhoz. E megközelítés szerint az 1-es tagsági érték teljes mértékű tagságot (megfelelést) jelent, míg a 0 pedig a halmazhoz egyáltalán nem tartozást.

Különböző típusú tagsági függvények alkalmazhatóak a halmazhoz tartozás jellemzésére. A háromszög (2. a) ábra és a (2) egyenlet), valamint a trapéz alakú (2. b) ábra és a (3) egyenlet) változatok általában megfelelő hatékonysággal használhatók [18][19][20].




A 2. ábrán látható fuzzy halmazokhoz tartozó tagsági függvények matematikai formulaként az alábbiak szerint írhatók le:

$$\mu_A(x) = \max \left\{ \min \left(\frac{x-a}{b-a}, \frac{c-x}{c-b} \right), 0 \right\} \quad (2)$$

$$\mu_A(x) = \max \left\{ \min \left(\frac{x-a}{b-a}, 1, \frac{d-x}{d-c} \right), 0 \right\} \quad (3)$$

3. ábra: A fuzzy következtetési rendszerek felépítése



ahol a , b , c és d konstans értékek, a tagsági függvények paraméterei [21].

A többváltozós logika a klasszikus halmazelmélet kiterjesztésének segítségével vezethető be. Az egzakt, éles értékek helyett ebben az esetben intervallumok használhatók.

Az előrejelzési modellekhez a fuzzy következtető rendszerek (Fuzzy Inference Systems, FIS) használhatók. Ezen eljárás legfőbb előnye, hogy a bizonytalanságot, a pontatlanságot és az információhiányt rendkívül nagy hatékonysággal tudja kezelni. A megközelítést széles körben alkalmazzák számos tudomány területen [22][23]. A FIS felépítése a 3. ábrán látható.

A FIS négy alapelemből áll: a fuzzifikációs modult az adatok átalakítására használjuk, a változók tagsági függvényeinek meghatározásához. A következtető, szabálybázisnak nevezett részben a szakértői tudás kerül meghatározásra. A rendelkezésre álló ismeretanyag betáplálására *HA ...antecedens(ek)... AK-KOR...következmény(ek)* ... alakban felírt szabályokat használunk a rendelkezésre álló tudásbázis leírására.

A FIS központi egysége a következtető motor, amely meghatározza a rendszer viselkedését. Különböző típu-


sok léteznek. Ebben az esetben egy Mamdani-típusú FIS-t használunk, amelynek bevezetése Mamdani nevéhez fűződik (1974) [24]. Ebben a szakaszban a szabályok aktiválása megtörténik, a tüzelési szintek kerülnek meghatározásra, és létrejön az adott szabályhoz tartozó kimeneti fuzzy halmaz.

Mivel a fuzzy halmazok nehezen értelmezhetőek közvetlenül a rendszer jellemzésére, a FIS utolsó lépése a defuzzifikáció, amely egyfajta fordítás jellegű műveletnek tekinthető. A kimeneti tagsági függvényből helyettesítő crisp értéket hozunk létre.


3. BEVEZETETT ELŐREJELZÉSI MODELL

Ebben a tanulmányban a több résztvevő járművel érintett balesetek eseteit vizsgáltuk. A biztosítási család feltételezett valószínűségének becsléséhez egy Mamdani-típusú fuzzy modellt hoztunk létre (4. ábra).

4. ábra: Mamdani-típusú FIS a feltételezett valószínűség előrejelzésére



5. ábra: A biztosítási kifizetés felosztása, Ft



A modellalkotáshoz három független bemeneti változót választottunk: a *biztosítási kifizetést*, Ft; a *vétlen résztvevő jármű életkorát*, év; és a *biztosítási szerződés díj fizetési időszakát*. Ezek közül az első két paraméter mennyiségi, míg a harmadik minőségi változóként jelenik meg a rendszerben. A kimeneti oldalon a *becsült feltételezett valószínűség*et határoztuk meg a biztosítási kártérítési esetekre, %-ban kifejezve.

A. Bevett kárszakértői gyakorlat, hogy a magasabb értékű kárkifizetéseket részletesebb szakértői vizsgálat előzi meg, így ezek kiemelt figyelmet kapnak. Az átfogó áttekintés azonban nem (vagy csak ritka esetekben) érvényesül az alacsonyabb összegű kifizetéseknél. Mindezek alapján a modell alkalmazhatósági területé elsősorban a rela-


tíve alacsonyabb összegű káresetek elemzése.

A modell létrehozásának első lépése a fuzziifikáció, ami a tagsági függvények, partíciók és szintek meghatározását jelenti.


Az első bemeneti paraméter a *biztosítási kifizetés*, Ft, ahol a vizsgált intervallumban (0... 3 000 000 Ft) három különböző szintet hoztunk létre: alacsony, közepes és magas szintet. Ehhez, trapéz alakú tagsági függvényeket használtunk (5. ábra).

Kijelenthető, hogy minél magasabb a kártérítés, annál nagyobb valószínűséggel feltételezhető biztosítási család. Emellett elmondható, hogy a 3 000 000 Ft-nál magasabb számított kártérítés esetén egyébként is kiemelt figyelmet kell fordítani a kárbejelentési ügyre.

6. ábra: A vétlen résztvevő jármű életkorának felosztása, év



7. ábra: A fizetési időszak felosztása



nagyon alacsony (NA), alacsony (A), közepesen alacsony (KA), közepes (K), közepesen magas (KM), magas (M), nagyon magas (NM).

B. Szabálybázis

A független változók meghatározott szintjeit tekintve 36 lehetséges kombináció létezik. Ezen lehetséges esetek jellemzésére 36 szabályt határoztunk meg a bemeneti és a kimeneti változók összekapcsolására, így egy lefedő szabálybázist tudunk megalkotni. Az összefüggéseket az 1. táblázat tartalmazza,

A vizsgált végtelen résztvevő jármű években kifejezett *életkorát* tekintve négy különböző szintet határoztunk meg; a nagyon fiatal, fiatal, öreg és nagyon öreg járművek halmazát, melyeket szintén trapéz alakú tagsági függvényekkel írtunk le (lásd a 6. ábrát).

amelyek megalkotása szakértő bevonásával történt.


C. Defuzzifikáció

Az említett következtetési motor kimenete az

A biztosítási szerződés *fizetési időszakát* illetően három szintet definiáltunk az alábbiak szerint: negyedéves, féléves és éves. A 7. ábrán háromszög alakú tagsági függvényekkel történő leírása látható. Ebben az esetben az alacsonyabb értékek a biztosítási család magasabb szintjének gyanúját vetik fel.

Végül a biztosítási család becslött, feltételezett valószínűségét osztályoztuk. Hét tagsági függvényt határoztunk meg (8. ábra), úgy, mint:


8. ábra: A feltételezett valószínűség felosztása, %



1. táblázat: A szabálybázis összefüggései

Szabály	Kárkifizetés, Ft	Vétlen jármű kora, év	Díjfizetési periódus	Csalás feltételezett valószínűsége, %
1.	Alacsony	Nagyon fiatal	Negyedéves	Közepes
2.	Alacsony	Nagyon fiatal	Féléves	Közepes
3.	Alacsony	Nagyon fiatal	Éves	Közepesen alacsony
4.	Alacsony	Fiatal	Negyedéves	Közepes
5.	Alacsony	Fiatal	Féléves	Közepesen alacsony
6.	Alacsony	Fiatal	Éves	Alacsony
7.	Alacsony	Idős	Negyedéves	Közepesen alacsony
8.	Alacsony	Idős	Féléves	Alacsony
9.	Alacsony	Idős	Éves	Nagyon alacsony
10.	Alacsony	Nagyon idős	Negyedéves	Alacsony
11.	Alacsony	Nagyon idős	Féléves	Nagyon alacsony
12.	Alacsony	Nagyon idős	Éves	Nagyon alacsony
13.	Közepes	Nagyon fiatal	Negyedéves	Közepesen magas
14.	Közepes	Nagyon fiatal	Féléves	Közepes
15.	Közepes	Nagyon fiatal	Éves	Közepesen alacsony
16.	Közepes	Fiatal	Negyedéves	Közepes
17.	Közepes	Fiatal	Féléves	Közepesen alacsony
18.	Közepes	Fiatal	Éves	Alacsony
19.	Közepes	Idős	Negyedéves	Közepesen alacsony
20.	Közepes	Idős	Féléves	Alacsony
21.	Közepes	Idős	Éves	Nagyon alacsony
22.	Közepes	Nagyon idős	Negyedéves	Közepesen alacsony
23.	Közepes	Nagyon idős	Féléves	Alacsony
24.	Közepes	Nagyon idős	Éves	Nagyon alacsony
25.	Magas	Nagyon fiatal	Negyedéves	Nagyon magas
26.	Magas	Nagyon fiatal	Féléves	Nagyon magas
27.	Magas	Nagyon fiatal	Éves	Magas
28.	Magas	Fiatal	Negyedéves	Magas
29.	Magas	Fiatal	Féléves	Közepesen magas
30.	Magas	Fiatal	Éves	Közepes
31.	Magas	Idős	Negyedéves	Nagyon magas
32.	Magas	Idős	Féléves	Magas
33.	Magas	Idős	Éves	Közepesen magas
34.	Magas	Nagyon idős	Negyedéves	Nagyon magas
35.	Magas	Nagyon idős	Féléves	Magas
36.	Magas	Nagyon idős	Éves	Magas

9. ábra: Defuzzifikáció a centroid módszerrel



aktivált szabályok által generált fuzzy halmaz. Ez nem használható közvetlenül a becült érték jellemzésére. Emiatt defuzzifikációra van szükség, amely az eredmény konkrét, crisp értékké alakítását jelenti.

Számos különböző technika létezik az átalakítás megvalósítására. Jelen tanulmányban a centroid módszert (Centre of Gravity, COG) alkalmaztuk, amelynek a grafikus magyarázata a 9. ábrán látható.

Matematikai értelemben a defuzzifikált kimenet kiszámítható a (4) egyenlet segítségével diszkrét, és az (5) egyenlet segítségével folytonos tagsági függvény esetén:

$$y_{cog}^* = \frac{\sum_{i=1}^n y_i \cdot \mu(y_i) dy}{\sum_{i=1}^n \mu(y_i) dy} \quad (4)$$

$$y_{cog}^* = \frac{\int y \cdot \mu(y) dy}{\int \mu(y) dy} \quad (5)$$


ahol y^* a defuzzifikált érték, y_i az adott elem, $\mu(y_i)$ a tagsági függvény, és n az elemek száma [25].

4. EREDMÉNYEK

A három bemeneti változóval rendelkező prediktív modell kimeneti eredményeit 3D-s grafikus ábrázolással csak úgy tehetjük meg, ha az egyik bemeneti változót állandó értéken tartjuk. Az alacsonyabb valószínűséget kékkel, a magasabbat pedig sárgával jelöltük.

A 10. és a 11. ábra a feltételezett valószínűséget mutatja a *vétlen résztvevő jármű életkorának* és a *fizetési időszaknak* a függvényében. Ebben az esetben a *biztosítási kifizetést*


10. ábra: 3D felület: 150 000 Ft kifizetése



két esetben vizsgáltuk: 150 000 Ft (10. ábra) és 500 000 Ft összegű (11. ábra) kártérítés esetén.

Megállapítható, hogy az alacsonyabb kifizetés (150 000 Ft) esetén a becült valószínűség legfeljebb ~50%. Az életkor növekedése azonban a valószínűség emelkedésével jár. Emellett a legmeredekebben csökkenő tendencia 10...15 éves életkor esetén határozható meg, ugyanis ekkor jelenik meg a karbantartási költségek jelentős növekedése egy átlagos jármű esetében. Továbbá a fizetési időszak hatását is vizs-

11. ábra: 3D felület: 500 000 Ft kifizetése



gálhatjuk. Éves díjfizetés esetén alacsonyabb, negyedéves díjfizetés esetén pedig magasabb csalási valószínűséget tapasztalhatunk.

Hasonló körülményeket elemeztünk 500 000 Ft-os kifizetés esetén is. A 11. ábra alapján a legmagasabb csalási valószínűség kb. 60%-

ra emelkedik. Továbbá az életkor növekedése a *feltételezett valószínűség* kissé egyenletesebb növekedését eredményezi. Emellett elmondható, hogy a 0...2 éves korú járművek esetében a kifizetési időszak hatása szinte elhanyagolható. Az életkor növekedésével azonban ennek a változónak a hatása egyre jelentősebbé válik, szintén összefüggésbe hozható a csalás valószínűségének alakulásával.


Szintén vizsgáltuk a *biztosítási kifizetés és a díjfizetési időszak* hatásait is (a 15 éves gépjármű életkort választva).

A 12. ábra alapján megállapítható, hogy a meg-növekedett kártérítés erősen befolyásolja a család feltételezett valószínűségét. Emellett a *díjfizetési időszak* csökkenésével a gyanú mértéke


ugyancsak emelkedik. Az összefüggés csupán a magas kifizetések esetében elhanyagolható: körülbelül 2 000 000 Ft kártérítés felett a *díjfizetési időszak* hatása jelentősen csökken.

Végül a *biztosítási kifizetés és a vétlen résztvevő jármű korának* hatásait három, a *kifizetési időszak* szintjei által meghatározott esetben elemeztük. A 13. ábra a *feltételezett valószínűség* alakulását mutatja éves, a 14. ábra féléves, a 15. ábra pedig negyedéves *fizetési időszak* esetén.

12. ábra: 3D felület: 15 éves járművek




13. ábra: 3D felület: éves fizetési időszak



A hasonlóságok ellenére azonban számos különbség is felfedezhető. A *feltételezett valószínűség* elméletileg 0...100% skálán számítható. Így a 13-15. ábrán látható esetekben a kimeneti tartományok eltéréseket mutatnak. Az éves és féléves esetekben a legkisebb kimeneti érték 7%. Másrészt a negyedéves fizetési időszak esetében a minimális feltételezett valószínűség 20%-os volt. Emellett a minimális kimeneti érték (sötétkékkel jelölve) területe a kifizetés csökkentésével csökken.

14. ábra: 3D felület: féléves fizetési időszak




Továbbá a maximális régió is elemezhető. Megállapítható, hogy a magasabb életkor és a megnövekedett kártérítés a biztosítási családok emelkedett szintjét jelenti. Emellett a középső terület is felfelé tolódik az éves kifizetésekről a negyedéves kifizetésekre. Megállapítható, hogy ezek a tendenciák megfelelően leírják a valós eseteket.

Mindazonáltal meg kell jegyezni, hogy ezt a paramétert az ügyfél nagyon könnyen manipulálhatja. Ennek

Elmondható, hogy mindhárom eset grafikus megjelenése hasonló jeleget mutat: az életkor és a fizetési időszak alacsonyabb tartományai kisebb valószínűséget eredményeznek (kék tartomány), a magasabb értékek pedig erősebb gyanút keltenek (sárga tartomány).

eredményeképpen a későbbiekben néhány bővítést és további részleteket kell figyelembe venni egy megbízhatóbb előrejelző rendszer létrehozásához.

15. ábra: 3D felület: negyedéves fizetési időszak



- A bevezetett empirikus modell megfelelő hatékonysággal jellemzi a valós trendeket, tendenciákat.

- Megvizsgáltuk a független változók hatásait. Megállapítottuk, hogy a magasabb összegű kárkifizetés növeli a csalárd esetek valószínűségét. Fiatalabb járművek esetében a *kifizetési időszak* hatása kevésbé lényeges; az életkor előrehaladtával azonban a *kifizetési időszak* időtartamának csökkenése magasabb szintű gyanút eredményez.

5. KÖVETKEZTETÉS

Jelen tanulmány keretein belül egy elméleti fenomenológiai modellt vezettünk be a csalárd gépjármű-biztosítási esetek feltárását elősegítendő. Ehhez egy Mamdani-típusú MISO fuzzy következtetési rendszert hoztunk létre. A számításához három független bemeneti paramétert definiáltunk, úgy mint: a *biztosítási kifizetést*, Ft; a *vétlen résztvevő jármű életkorát*, év; és az esetért felelős ügyfél biztosítási szerződésének *fizetési időszakát*. A következtetési rendszer kimeneti változója a biztosítási csalás *feltételezett valószínűsége* volt, %-ban megadva.

A tanulmány célja a fuzzy rendszerek alkalmazhatóságának igazolása volt ezen a területen. A bemutatott modell alapján az alábbi következtetések vonhatók le:

- Kimutattuk, hogy a bemeneti változók (a *biztosítási kifizetés*, a *vétlen résztvevő jármű életkora* és a *kifizetési időszak*) és a kimeneti paraméterként *feltételezett valószínűség* közötti kapcsolat leírható egy Mamdani-típusú fuzzy következtetési rendszerrel, mint előrejelzési modellel.

Összességében elmondható, hogy az említett FIS hatékonyan alkalmazható az elsődleges gyanú felderítésére azokban az esetekben, amikor további vizsgálatok javasoltak.

A bemutatott elméleti modell alátámasztotta a fuzzy logika alkalmazhatóságát a csalások felderítésében. Néhány további parameter bevonása azonban szükséges lehet. Ebből a célból a jövőben a tanulmányban ismertetett modellt felhasználva fejlettebb modelleket lehet létrehozni, amelyek még kifinomultabb módon jellemezhetik az ügyfelek valós viselkedését.

KÖSZÖNETNYILVÁNÍTÁS

Támogatta a Kulturális és Innovációs Minisztérium ÚNKP-23-3 és ÚNKP-23-4 Új Nemzeti Kiválósági Programja.

FELHASZNÁLT IRODALOM

- [1] Stefano, B., & Gisella, F. (2001, December). Insurance fraud evaluation: a fuzzy expert system. In 10th IEEE International Conference on Fuzzy Systems.(Cat. No. 01CH37297) (Vol. 3, pp. 1491-1494). IEEE. DOI: <https://doi.org/fw6zmq>

- [2] Artís, M., Ayuso, M., & Guillén, M. (2002). Detection of automobile insurance fraud with discrete choice models and misclassified claims. *Journal of Risk and Insurance*, 69(3), 325-340. DOI: <https://doi.org/cxgk34>
- [3] Morley, N. J., Ball, L. J., & Ormerod, T. C. (2006). How the detection of insurance fraud succeeds and fails. *Psychology, Crime & Law*, 12(2), 163-180. DOI: <https://doi.org/cfwtfp>
- [4] Goleiji, L., & Tarokh, M. J. (2016) Fraud detection in the insurance using decision tree, naïve Bayesian and support vector machine data mining algorithms (Case study-automobile's body insurance). *Majlesi Journal of Multimedia Processing*, 5(1), 29-33.
- [5] Nian, K., Zhang, H., Tayal, A., Coleman, T., & Li, Y. (2016). Auto insurance fraud detection using unsupervised spectral ranking for anomaly. *The Journal of Financand Data Science*, 2(1), 58-75. DOI: <https://doi.org/nfrz>
- [6] Roy, R., & George, K. T. (2017, April). Detecting insurance claims fraud using machine learning techniques. In 2017 international conference on circuit, power and computing technologies (ICCPCT) (pp. 1-6). IEEE. DOI: <https://doi.org/gnrfd8>
- [7] Bécsi, T., Aradi, S., & Fehér, A. (2020). A gépi tanulás szerepe és hatásai a közlekedésben. *KÖZLEKEDÉSTUDOMÁNYI SZEMLE*, 70(1), 54-65. DOI: <https://doi.org/nfr2>
- [8] Ghorbani, A., & Farzai, S. (2018). Fraud detection in automobile insurance using a data mining based approach. *International Journal of Mechatronics, Electrical and Computer Technology (IJMEC)*, 8(27), 3764-3771.
- [9] Kovács, G., Hőgye-Nagy, Á., & Kurucz, G. (2021). Human Factor Aspects of Situation Awareness in Autonomous Cars—An Overview of Psychological Approaches. *Acta Polytechnica Hungarica*, 18(7), 7-24. DOI: <https://doi.org/gqv7xs>
- [10] Horváth, Z. C., Buics, L., Földesi, P., & Ballassa, B. E. (2022). The Role of Hungarian Traffic Rules Education and Examination System—a Quality Function Deployment Approach. *Acta Polytechnica Hungarica*, 19(7). DOI: <https://doi.org/nfr3>
- [11] Gomes, C., Jin, Z., & Yang, H. (2021). Insurance fraud detection with unsupervised deep learning. *Journal of Risk and Insurance*, 88(3), 591-624. DOI: <https://doi.org/nfr4>
- [12] Hanafy, M. O. H. A. M. E. D., & Ming, R. (2021). Using machine learning models to compare various resampling methods in predicting insurance fraud. *J. Theor. Appl. Inf. Technol*, 99(12), 2819-2833.
- [13] Macedo, A. M., Cardoso, C. V., & Neto, J. S. M. (2021). Car insurance fraud: the role of vehicle repair workshops. *International Journal of Law, Crime and Justice*, 65, 100456. DOI: <https://doi.org/gshcbr>
- [14] Aslam, F., Hunjra, A. I., Ftiti, Z., Louhichi, W., & Shams, T. (2022). Insurance fraud detection: Evidence from artificial intelligence and machine learning. *Research in International Business and Finance*, 62, 101744. DOI: <https://doi.org/nfr5>
- [15] Bolton, R. J., & Hand, D. J. (2002). Statistical fraud detection: A review. *Statistical science*, 17(3), 235-255. DOI: <https://doi.org/cbqv2n>
- [16] Hassan, A. K. I., & Abraham, A. (2013). Computational intelligence models for insurance fraud detection: a review of a decade of research. *Journal of Network and Innovative Computing*, 1(2013), 341-347
- [17] Zadeh, L. A. (1965). Fuzzy set theory. *Information and control*, 8(3), 338-353.
- [18] Pedrycz, W. (1994). Why triangular membership functions?. *Fuzzy sets and Systems*, 64(1), 21-30.
- [19] Barua, A., Mudunuri, L. S., & Kosheleva, O. (2013). Why trapezoidal and triangular membership functions work so well: Towards a theoretical explanation.
- [20] Kreinovich, V., Kosheleva, O., & Shahbazova, S. N. (2020). Why triangular and trapezoid membership functions: A simple explanation. *Recent Developments in Fuzzy Logic and Fuzzy Sets: Dedicated to Lotfi A. Zadeh*, 25-31. DOI: <https://doi.org/nfr6>
- [21] Zhao, J., & Bose, B. K. (2002, November). Evaluation of membership functions for fuzzy logic controlled induction motor drive. In *IEEE 2002 28th Annual*

Conference of the Industrial Electronics Society. IECON 02 (Vol. 1, pp. 229-234). IEEE. DOI: <https://doi.org/b3xq2d>

- [22] Ozguney, O. C., & Burkan, R. (2021). Fuzzy-terminal sliding mode control of a flexible link manipulator. *Acta Polytechnica Hungarica*, 18(3), 179-195. DOI: <https://doi.org/nfr7>
- [23] Borisov, V., Chernovalova, M., Dulyasova, M., Morozov, D., & Vasiliev, A. (2022). Fuzzy Methods for Comparing Project Situations and Selecting Precedent

Decisions. *Acta Polytechnica Hungarica*, 19(10). DOI: <https://doi.org/nfr8>

- [24] Mamdani, E. H. (1974, December). Application of fuzzy algorithms for control of simple dynamic plant. In *Proceedings of the institution of electrical engineers* (Vol. 121, No. 12, pp. 1585-1588). IET Digital Library.
- [25] Saade, J. J., & Diab, H. B. (2004). Defuzzification methods and new techniques for fuzzy controllers.



Investigation of the possibilities for detecting motor insurance fraud using fuzzy inference

Keywords: detection of insurance fraud, Mamdani fuzzy inference system, economic risk, motor insurance

Insurance fraud occurs when a claimant tries to gain financial benefits by making an unfounded, unjustified claim. These cases can cause serious economic damage. Consequently, fraud detection is a key issue at present, especially in the motor insurance market. Soft computing techniques have emerged in recent decades to model and support problem detection. In the framework of this paper, a theoretical Mamdani-type fuzzy inference system is presented for predicting the assumed probability of insurance fraud using easily determinable parameters: the *insurance payout*, in Ft; the *age* of the not faulty participant vehicle, in years; and the *payment period* of the insurance contract.



Untersuchung der Aufklärungsmöglichkeiten von Kfz-Versicherungsbetrügereien mittels Fuzzy-Inferenz

Schlüsselwörter: Aufklärung von Versicherungsbetrug, Mamdani Fuzzy Inferenz System, wirtschaftliches Risiko, Kfz-Versicherung

Ein Versicherungsbetrug liegt vor, wenn ein Antragsteller versucht, sich durch unbegründete und ungerechtfertigte Anträge einen finanziellen Vorteil zu verschaffen. Diese Fälle können einen erheblichen wirtschaftlichen Schaden verursachen. Daher ist die Aufdeckung von Betrügern heute ein zentrales Thema, insbesondere auf dem Kfz-Versicherungsmarkt. In den letzten Jahrzehnten sind Soft-Computing-Techniken zur Modellierung und Unterstützung der Problemerkennung entstanden. Im Rahmen dieses Beitrags wird ein theoretisches Mamdani Fuzzy-Inferenzsystem vorgestellt, mit dem die angenommene Wahrscheinlichkeit eines Versicherungsbetrugs anhand von leicht bestimmbareren Parametern, wie *die Summe* der Versicherungsauszahlung (in Ft), *Alter* des unverschuldeten Teilnehmerfahrzeugs (Jahre) und die *Auszahlungsdauer* der Versicherungsvertrags vorhergesagt werden kann.