


Szénmonoxid szivárgással járó események előrejelzése

Karsa Róbert

Nemzeti Köszolgálati Egyetem Katonai Műszaki Doktori Iskola
doktorandusz

Pécsi Tudományegyetem, TTK MII tanársegéd

Email: karsar@gamma.ttk.pte.hu

ORCID: 0000-0003-0502-1508 

Absztrakt:

Ebben a kutatásban a szénmonoxid mérgezéssel járó káresemények előre jelezhetőségét vizsgáljuk. A tüzeléstechnikai berendezések hibáiból fakadó szénmonoxid szivárgások fizikai okait feltárva feltételezéseket állítottunk fel, amit későbbiekben adat alapú elemzésekkel bizonyítunk. A kutatás során valós szénmonoxid szivárgással kapcsolatos adatokat használtunk fel és azt találtuk, hogy az adatokból gépi tanulási módszerek segítségével, az adatok belső összefüggései is megismerhetők.

A szivárgásos jelenségek a helyi meteorológiai előrejelzések figyelembevételével előre jelezhetőek. Az eredmények segítségével korai figyelmeztető rendszer kiépítését javasoljuk, amely terület specifikusan képes egy térképen érthető formában felhívni a figyelmet a kockázatokra.

Kulcsszavak szénmonoxid mérgezés, gépi tanulás, előrejelzés, mesterséges intelligencia

Abstract:

In this research, we investigate the predictability of carbon monoxide poisoning incidents. By exploring the physical causes of carbon monoxide leaks due to faults in combustion equipment, hypotheses are made and subsequently proven through data-based analyses. We have utilized data from real carbon monoxide leaks and found that machine learning methods can be employed to identify internal correlations within the data.

Leakage events can be predicted by considering local meteorological forecasts. Using these results, we propose the deployment of an early warning system that can provide area-specific risk awareness in a map format that can be understood.

Keywords: carbon monoxide poisoning, machine learning, forecast, artificial intelligence

1. BEVEZETÉS

Szén-monoxid (CO) mérgezés miatt évente több mint 1000-szer riasztják a katasztrófavédelem tűzoltó egységeit. A káresek nagyjából felében történik mérgezés és az esetek kapcsán évente átlagosan 11 eseménynél 14 haláleset történik. [1] Az Amerikai Egyesült Államokban évente körülbelül 50 000 CO mérgezéses esetet regisztrálnak, ami 16,0 esetet jelent 100 000 lakosra vetítve. A halálos kimenetelű esetek száma az USA-ban csökkenő tendenciát mutat, 2014-ben 1319 halálesetet regisztráltak [2]. Ezek a számok lakosságárányosan magasabbak a magyarországi esetszámoknál. A CO színtelen, szagtalan, íztelen, a levegőnél könnyebb mérgező gáz. Belélegezve gátolja a vér oxigénszállító képességét, a mérgezés tünetei, a szédülés, rosszullet, fejfájás, hányinger, fáradtság hasonlóak más betegségekhez, ezért nehéz a felismerése [2]. A CO keletkezése, illetve feldúsulása három fő okra vezethető vissza: ezek a nyílt lánggal égő berendezés nem megfelelő műszaki kialakítása, a nyílt lánggal égő berendezés nem megfelelő légutánpótlása és a berendezések elmaradt karbantartása, tisztítása. A CO okozta balesetek nagyrészt elkerülhetőek lennének, amennyiben minden kockázati helyre CO érzékelő kerülne.

Az elmúlt években a katasztrófavédelem kiemelt hangsúlyt fektetett a CO mérgezések megelőzése érdekében a CO érzékelők elterjedésének támogatására. A CO érzékelők beszerzésével és megfelelő telepítésével megelőzhetőek a halálesetek is. [3]

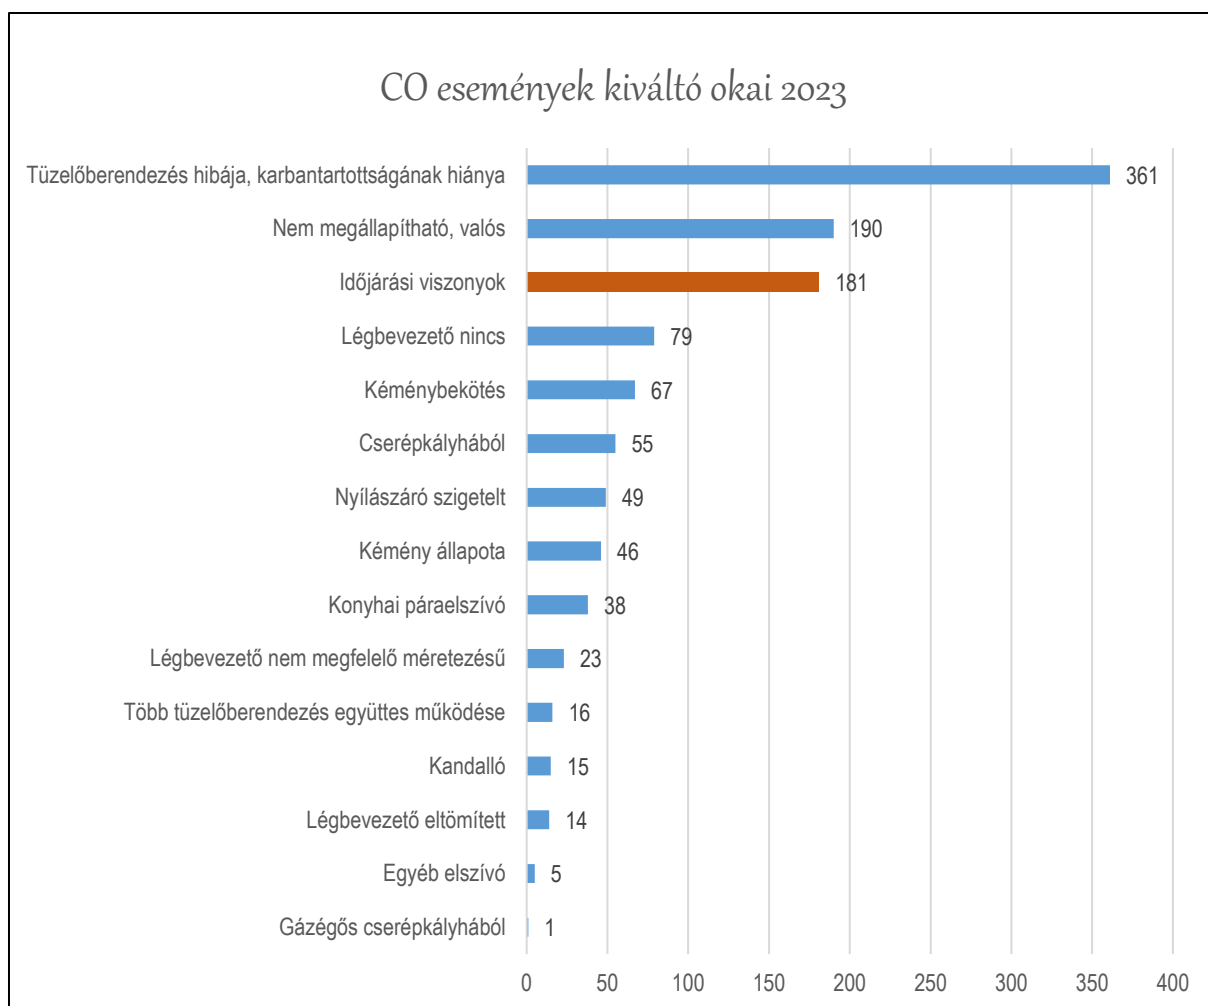
A CO káresemények nem csak a fűtési időszakban fordulnak elő, hanem a teljes évben jellemzőek. Publikációmban arra keresem a választ, hogy ezek a káresek mennyire jelezhetőek előre. A motivációt a kutatásra egy olyan nap jelentette, amikor több CO-s káresemény történt egy megyében és felmerült bennem a kérdés, hogy van-e valami közös jellemzőjük az ilyen típusú eseményeknek. Egy közelmúltbeli tanulmány kimutatta, hogy meteorológiai tényezők figyelembevételével lehetséges előrejelző modellt készíteni a CO-mérgezések kockázatára vonatkozóan. A modell olyan tényezőket vesz figyelembe, mint a hőmérséklet, szélsőségek, napi hőmérséklet-változás és a levegő CO-koncentrációja [4].

2. A SZÉNMONOXIDOS ESEMÉNYEK HÁTTERE

1. A rendelkezésre álló adatok vizsgálata

A 2023-as évet vizsgálva a katasztrófavédelem KAP Online¹ adatbázisából megállapítható, hogy 1137 olyan esemény történt az országban, amely kapcsán CO-s adatlap került kitöltésre, azaz ténylegesen CO szivárgás történt. Ezekben az esetekben a helyszínen tartózkodó tűzoltó feladata a CO szivárgást kiváltó elsődleges és másodlagos okok azonosítása, később rögzítése a KAP Online adatbázisban.

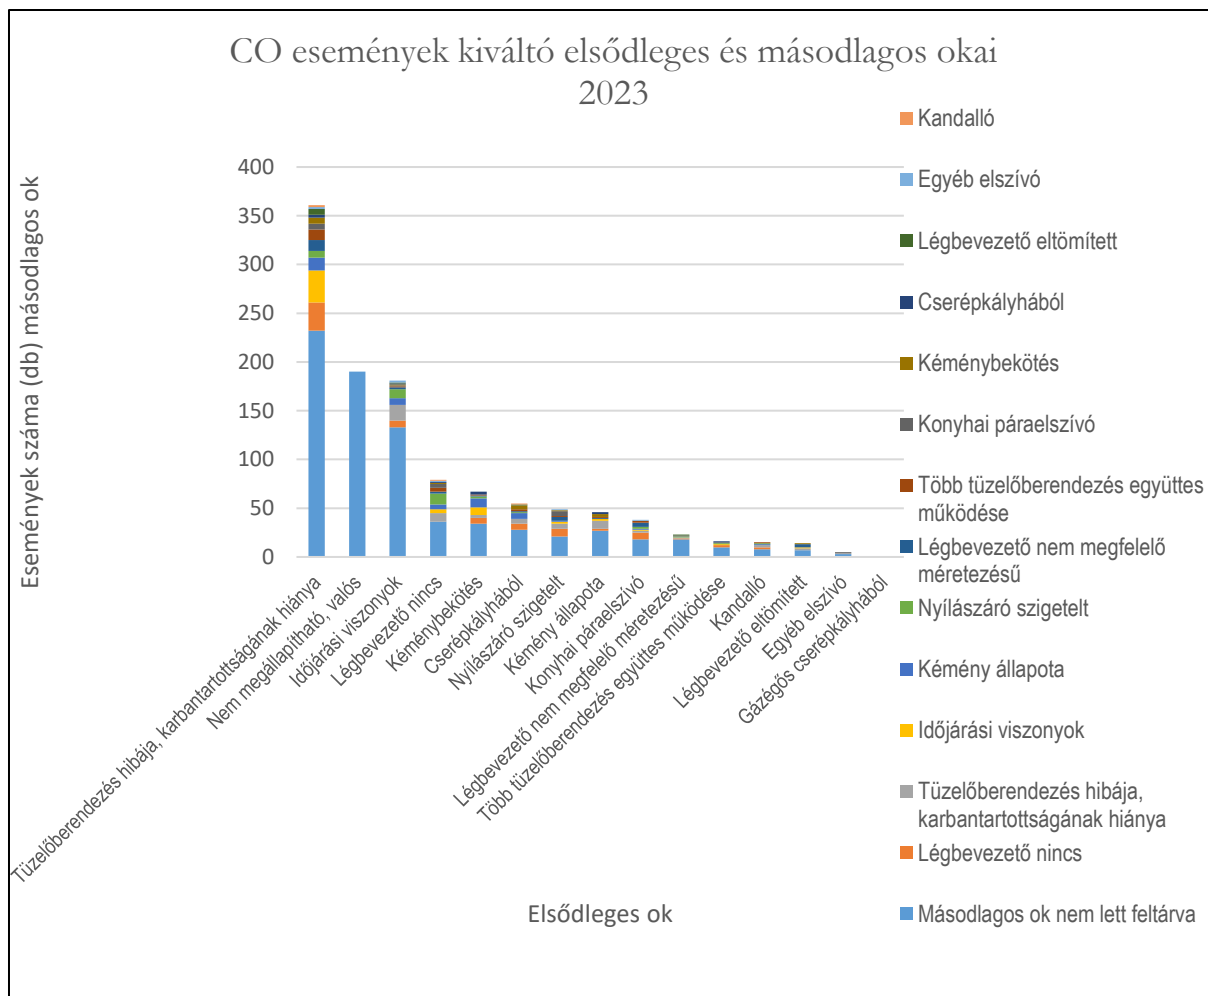
¹ Katasztrófavédelmi Adatszolgáltató Program



1. ábra, a CO események kiváltó elsődleges okainak bemutatása 2023-ban Magyarország területén (készítette a szerző) [1]

Amint az 1. ábrából is látszik, az esetek nagy részében a helyszínen nem lehetett megállapítani a kiváltó okot. Az események nagy részében a szivárgás visszavezethető a tüzelőberendezés hibájára, karbantartásának elmulasztására. Jelentős még az időjárási viszonyok miatt kialakult szivárgások száma is. A helyszínen nem megállapítható, de valós keletkezési okot csak akkor választja a tűzoltásvezető, ha a helyszínen a szakmai tudása, tapasztalata alapján nem lát, nem érzel olyan körülményt, ami a szén-monoxid keletkezéséhez vezethetett, és a bevont, a helyszínen esetlegesen megjelenő kéményseprő, gázszolgáltató sem tudnak nyilatkozni a szén-monoxid keletkezési okáról, viszont a szén-monoxid koncentráció egyértelműen mérhető volt.

A helyszínen nem megállapítható, de valós események nagy száma utalhat arra, hogy lehetnek olyan körülmények, amelyek a helyszíni vizsgálatok, az esemény rekonstrukciója során nem észlelhetőek, ezért más irányú megközelítést kell alkalmazni ezek vizsgálatakor. Az időjárási viszonyok kategória magas száma és a kategória megítélésének nehézsége okán felmerülhet a kérdés: mennyire játszik szerepet az időjárás egy CO-s esemény bekövetkezésékor.



2. ábra, a CO eseményeket kiváltó elsődleges és másodlagos okok bemutatása 2023-ban Magyarország területén (készítette a szerző) [1]

Általánosságban elmondható, hogy a szén-monoxid szivárgás nem egy okra vezethető vissza, hanem kettő, vagy akár több oknak az együttes bekövetkezése okozza a problémát. A helyszíni adatgyűjtés során a kárhelyparancsnok megjelölhet másodlagos okokat is a CO szivárgást kiváltó események kapcsán. A 2. ábrán látható, hogy a másodlagos okokat figyelembe véve, az időjárási viszonyok miatt bekövetkezett CO szivárgások száma magas, és vannak olyan események ahol másodlagos okot nem tártak fel. A KAP Online programból megállapítható, hogy 2023-ban 115 esetben kizárólag szilárd tüzelésű berendezés, 533 esetben kizárólag gázüzemű berendezés működött, a többi esetben pedig párhuzamosan működött szilárdtüzelésű és gázüzemű berendezés is a CO-s káresemények kapcsán. Az adatokból látszik, hogy a gáztüzelésű berendezések esetén sokkal gyakoribbak a CO-hoz köthető káresemények. Az időjárási viszonyok CO szivárgásra gyakorolt hatását több tanulmány is vizsgálta. Egy kutatás kimutatta, hogy az alacsony hőmérséklet, az alacsony szélsebesség és a magas napi hőmérséklet-ingadozás növeli a CO mérgezések kockázatát [4]. Ez részben magyarázatot adhat arra, hogy miért olyan jelentős az időjárási tényezők szerepe a bemutatott adatokban. Egy másik tanulmány specifikusan a hideg időjárási frontok hatását vizsgálta, és megállapította, hogy a hirtelen lehűlések növelik a CO mérgezések előfordulását [5]. Ez összhangban van azzal a megfigyeléssel, hogy az időjárási viszonyok gyakran másodlagos okként jelennek meg a CO események kapcsán.

2. Szénmonoxid visszaáramlás kialakulása

A CO szivárgás a nyílt égésterű tüzelőberendezések esetén gyakoribb, mint a zárt égéster esetén. A nyílt égéster azt jelenti, hogy a tüzet tápláló égési levegő abból a helyiségből származik, ahol a berendezés működik, ez lehet például akár egy fürdőszoba is. A CO szivárgás egyik fő közvetlen oka az égéstermék elvezetőn kialakuló elégtelen huzat. Egy üzemelő tüzeléstechnikai berendezés esetén a csatlakoztatott kéményben lévő füstgázok melegebbek, mint a külső levegő. A melegebb levegő könnyebb, mint a hidegebb ezért magasabbra törekszik, azaz felfelé mozog, az így kialakuló áramlás hozza létre a huzatot. Ahhoz, hogy a CO szivárgást jobban megértsük, meg kell vizsgálni a tüzeléstechnikai berendezésekhez kapcsolódó fontosabb jogszabályokat és vizsgálatokat. Törvényi szinten a 2015. évi CCXI. törvény a kéményseprő-ipari tevékenységről határozza meg a kéményseprők tevékenységi körét. A törvényhez kapcsolódik a 99/2016. (V. 13.) Korm. rendelet a kéményseprő-ipari tevékenységről szóló törvény végrehajtásáról és a 21/2016. (VI. 9.) BM rendelet a kéményseprő-ipari tevékenység ellátásának szakmai szabályairól, amely többek között előírja az égéstermék tartós visszaáramlásának ellenőrzését is, mint vizsgálatot. Ezt a vizsgálatot a tüzeléstechnikai szakirodalom is tárgyalja. Biztonsági elvárás, hogy deflektoros (huzatmegszakító) gázkészülékeknél a működő rendszer a deflektoron az égéstermék tömegáram legalább 30%-ának megfelelő levegő mennyiséget szívjon be. Ezt a legalacsonyabb huzat, felhajtóerő esetén is teljesítenie kell, például egy átfolyós gáz-vízmelegítőnek a nyári kánikulai hőségben. Ennek ellenőrzésére kidolgozásra került egy módszertan, amely során a külső, belső levegő és füstgáz hőmérsékleti adatok segítségével ellenőrizhető az égéstermék visszaáramlása. Ezt a kémények ellenőrzésénél a kéményseprő szakemberek időszakosan vizsgálják. A külső hőmérsékleti változások hatása miatt egy tüzelőberendezés és égéstermék elvezető együttes működése során a téli alacsony külső levegő hőmérséklet esetén történő ellenőrzésénél lényegesen nagyobb felhajtóerő alakul ki, mint ugyan annál a rendszerrel nyári kánikulai hőségben. Ezért a télen megfelelően működő rendszer nyári körülmények között esetleg nem fog megfelelően működni és ez eredményezhet égéstermék visszaáramlást a készülék felállítási helyiségébe, CO szivárgást okozhat. [6] A tüzelőberendezések esetében a rendszeres karbantartás kulcsfontosságú a biztonságos működés és a tüzelőanyag nem megfelelő égéséből származó CO szivárgások elkerülése érdekében [7].

3. Az időjárás hatása a kéményben kialakuló huzatra

A kéményekben természetesen kialakuló áramlási viszonyokat modellezte Andrzejczyk Rafal [8], amely során több matematikai modellt is készített a kéményben kialakuló áramlási viszonyok számításához. Minden modellt a kémény paraméterein túl számításba vette a külső és belső levegő sűrűségét, hőmérsékletét, a napsugárzást és a szél áramlási sebességét. A kutatás ugyan a passzív szellőztető rendszerekre fókuszál, de a matematikai modell hasonlóan a Leikauf Tibor [6] által kidolgozott visszaáramlás mérési számításához hasonló bemeneti adatkörrel dolgozik. A hazánkban alkalmazott visszaáramlási módszer tartalmaz egyszerűsítéseket, így csak hőmérsékleti adatokat használ fel a visszaáramlás számításához, amely a kéményseprő gyakorlatban jól alkalmazható.

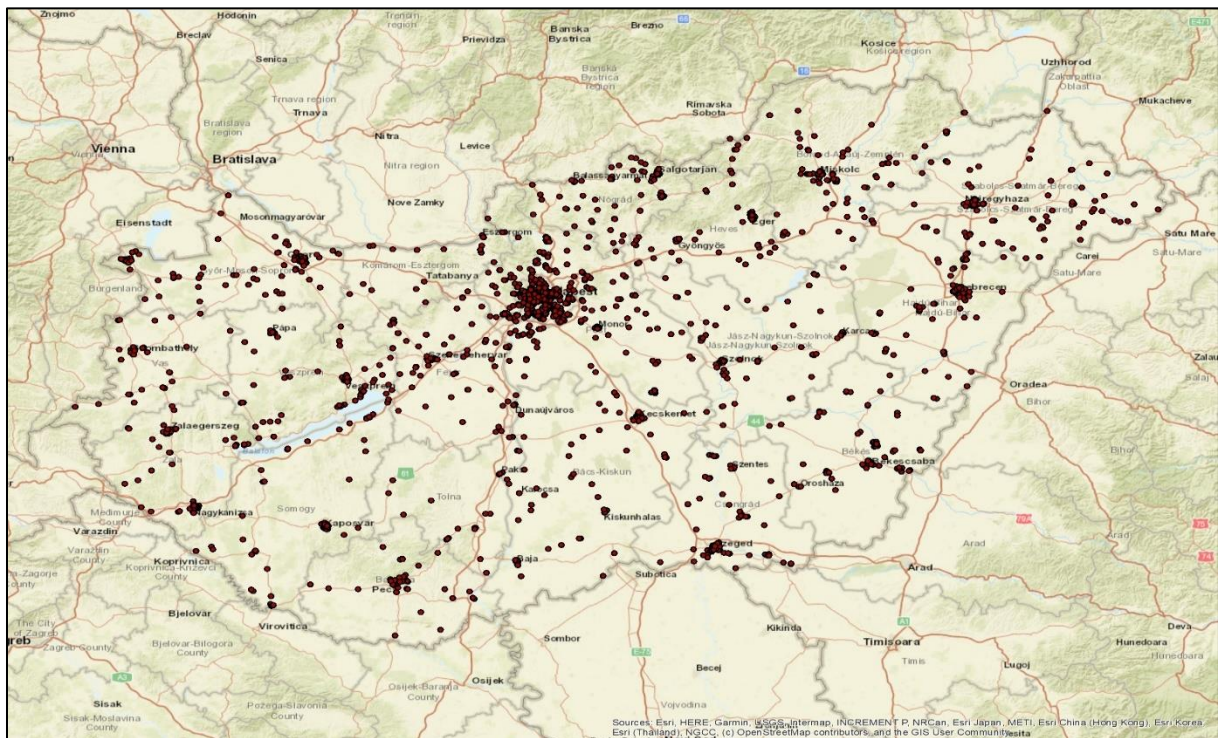
Ezekből már levonható az a következtetés, hogy a tüzelő berendezések és a kémények együttes működésére kihatással van az időjárás, ezért a CO szivárgási esetekre is kihatással lehet az időjárás. Ezen a ponton érdemes elgondolkodni, hogy vajon milyen kapcsolat van az időjárás adatok és a CO szivárgás között. Vannak ismert kapcsolatok, jelenségek, mint az inverzió, amikor a légköri áramlási viszonyok megváltoznak a különböző magassági rétegekben kialakuló hőmérsékleti viszonyok kapcsán és ez a kémények áramlási viszonyait is befolyásolja [9]. Egy másik releváns tanulmány egy egyszerűsített matematikai modellt dolgozott ki az épületben kialakuló nyomáeloszlás és légáramlási sebesség kiszámítására, amely figyelembe veszi a kazán, a kémény és az épület közötti kölcsönhatást. A tanulmány foglalkozik a kéményben kialakuló áramlási sebesség időjárás paraméterektől való függésével is [10].

Felmerülhet a kérdés, hogy a CO megjelenése, szivárgása és az időjárás között milyen kapcsolat van? Ennek a kapcsolatnak a keresésére adatalapú géptanulási módszerek segítségével keressük a választ.

3. ELŐREJELZŐ RENDSZER ÉPÍTÉSE

4. Vizsgált adatok köre:

Annak érdekében, hogy a CO szivárgás és az időjárás adatok között összefüggéseket találjunk, nézzük meg a rendelkezésre álló adatkört. Az első és kulcsfontosságú adat maga a CO szivárgással kapcsolatos adathalmaz. A katasztrófavédelemi szerveknél 2011-óta működik az egységes KAP Online rendszer, amely tartalmaz CO szivárgással kapcsolatos káreseményeket is. 2012-től ezek az adatok geokódoltak, azaz a káresemény pontos helyszíne nem csak postai címmezővel van ellátva, hanem EOV² koordinátákkal is, amely nagyban segíti az adatok gyors térképi feldolgozását. Az adattartalom itt mindössze arra korlátozódik egy káresemény kapcsán, hogy a helyszínen történt-e CO szivárgás. Ennek a megállapítását a tűzoltófecskendőkre málházott gázérzékelőkkel végezték. 2016-tól megjelentek a CO-s adatlapok, amelyek egy CO szivárgással kapcsolatos eseménynél jóval több adatot gyűjtenek. Ilyenek például a keletkezési helyiség, mért értékek, tüzelőberendezés típusa, kéménybekötés, légbevezető állapota, CO érzékelő jelenléte, típusa és a keletkezési ok. Tehát rendelkezésünkre állnak több évre visszamenőleg azok a helyszínek, ahol CO szivárgás történt valamilyen tüzelőberendezés működése kapcsán.



3. ábra, a CO események 2023-ban Magyarország területén (készítette a szerző, adatok forrása: KAP Online)

A 3. ábrán a 2023. évi beavatkozást igénylő CO-s káresemények térképi ábrázolása látható, minden egyes pont egy CO-s eseményt reprezentál. Megállapítható hogy az események jelentős része városokhoz, nagyobb településekhez köthető.

² Egységes Országos Vetületi Rendszer

A második adatkör azokat a meteorológiai adatokat jelenti amelyek a CO-szivárgás időpontjához köthetők. Hosszas keresés után találtam rá az OpenWeather³ szolgáltatásaira, amely képes lokációhoz kötött múltbeli meteorológiai adatokat megadni automatizált módon egy API⁴-n keresztül. Tudomásom szerint jelenleg ilyen ingyenes API-t a magyar meteorológiai szolgáltatással foglalkozó szervezetek nem biztosítanak. Ez azt jelenti, hogy a korábbiakban vázolt CO-s káresemények pontos helyéhez a legközelebbi meteorológiai mérőállomás adatait kaphatjuk vissza óránkénti felbontásban. A KAP Online rendszerből származó TMMJ⁵ adatlapokban az események EOY koordinátái és azoknak a jelzésének időpontja óra, perc pontossággal szerepel, ezért ehhez könnyen lehet a környezetre akkor jellemző időjárási adatokat társítani. Ezt kihasználva minden egyes káreseményhez letöltöttem az aktuális hőmérséklet, hőmérséklet érzet, légnyomás, páratartalom, napi maximum és minimum hőmérsékletek, szélesség, szélirány, szélhőmérséklet, felhőborítottság adatokat. Korlátot jelentett, hogy az API-n keresztül ingyenesen csak 1 évre visszamenőlegesen lehetett adatokat letölteni, ezért két időben eltöltöttem letöltéssel jelenleg 1,5 évnél régebbi CO-s eseményhez köthető meteorológiai adattal rendelkezem.

5. Adatok előkészítése

Vajon milyen összefüggések vannak az időjárási adatok és a CO-s szivárgások között tehetjük fel a kérdést. Ennek megválaszolásához a gépi tanulást hívtam segítségül, amely egyfajta függvényközelítést végez a bemeneti és a kimeneti adatok között. Esetünkben a bemeneti adatok az időjárási adatok, a kimeneti adat pedig a CO-s esemény bekövetkezése. A feladat pedig összefüggések keresése a bemeneti és kimeneti adatok között. Ez egy klasszikus bináris osztályozási feladatként is felfogható ahol egy esemény bekövetkezését kell megjósolni. A gépi tanulási algoritmusok közül többet is kipróbáltam a feladat megoldásához, de mielőtt erre rátérnénk, látnunk kell, hogy a bináris osztályozáshoz szükség van olyan bemeneti adatokra is, amikor a kimenet 0, azaz keresni kell olyan meteorológiai környezetet, amikor nem volt CO-s káresemény. Ezeket az adatokat már önkényesen választottam, azaz véletlenszerűen kerestem az évben olyan napokat, amikor nem volt az országban CO-s esemény, illetve támaszkodva a 3. ábrára, nagyvárosokat jelöltem meg helyszíneként és ezekhez az időpontokhoz és helyszínekhez szintén letöltöttem a vonatkozó meteorológiai adatokat. Azért hogy a két osztály, az 1-el jelölt CO-s szivárgási eseményt, illetve a 0-val jelölt, nincs esemény, kiegyensúlyozott legyen, az 1-es eseményhez hasonló számú 0-s eseményt generáltam.

Az időjárási tényezők és a CO-s esemény bekövetkezése közötti kapcsolatot első körben a point-biserial korrelációval [11] végeztem, hiszen ez alkalmas folytonos és dichotóm (CO-s káresemény) változók kezelésére. [12] Azt találtam, hogy az időjárási adatok és a CO-s káresemények között nincs vagy nagyon gyenge a korreláció. A legnagyobb korrelációt a szélhőmérséklet paraméternél⁶ számoltam, ami mindössze 0,2 volt $p=0$ érték mellett. A p -érték azt a valószínűséget jelenti, hogy a két változó közötti korreláció a véletlennek köszönhető. Általában a 0,05-nél kisebb p -értéket tekintik statisztikailag szignifikánsnak. Ez gyenge korreláció azonban statisztikailag szignifikáns, azaz valódi kapcsolatot jelent. Tehát az egyes meteorológiai adatok és a CO-s események bekövetkezése között csak gyenge kapcsolatot tudunk kimutatni, azonban a feltételezésem szerint van kapcsolat a kettő között. A korreláció külön-külön azaz páronként vizsgálja a változók közötti kapcsolatokat, de a valóságban ennél sokkal bonyolultabb és összetettebb kapcsolatokat feltételezek. A bonyolultabb kapcsolatok feltárására és modellezésére gépi tanulási eszközöket mutatok be a következőkben.

³ <https://openweathermap.org/>

⁴ Application Programming Interface

⁵ Tűzoltási és Műszaki Mentési Jelentés

⁶ az adathalmazban az angol terminológia szerint gust

6. Vizsgált algoritmusok, használt keretrendszerek

Annak megértése, hogy mi vezethet CO-s eseményhez az adatokon keresztül lehetséges. A nagyszámú adat segítségével gépi tanulási modelleket készítettem, hogy az időjárás körülmények és a CO-s események között összefüggést találjak. Mivel a rendelkezésre álló adatok táblázatos adatok, ezért a klasszikus gépi tanulási algoritmusokat használtam a modell készítésére. Az első és egyik legrobosztusabb megoldás a Random Forest [13] modell volt, ami döntési fákon alapszik. A modell képzése során döntési fák sokaságát hozza létre az algoritmus és az osztályozási feladatoknál a modell kimenete a legtöbb döntési fa által kiválasztott osztály lesz. Több döntési fa alapú modellt vizsgáltam. Ilyen volt a Gradient Boosting algoritmus [14], amely a képzés során folyamatosan új döntési fákat ad a meglévőkhöz. Minden új döntési fa arra összpontosít, hogy kijavítsa az előző fák által elkövetett hibákat, így a modellek fokozatosan egyre pontosabbá válnak. Vizsgáltam még a XGBoosting [15] algoritmust is, amely szintén döntési fa alapú módszer, ami jól skálázható és a működése hasonló a Gradient Boosting algoritmuséhoz. A döntési fák mellett hagyományos teljesen összekapcsolt neurális hálózatokkal [16] is végeztem kísérleteket. A modelleket Google Colab⁷ futtató környezetben készítettem Python nyelven a Scikit Learn⁸ és Tensorflow⁹ keretrendszerek használatával. Ezek az eszközrendszerek a mai modern géptanulási, mesterséges intelligencia alkalmazások létrehozásához szükséges építőelemek. A tanítási folyamat lényege, hogy nagyszámú tanítóadat segítségével olyan modelleket hozzunk létre, amelyek képesek általánosítani, azaz olyan adatokra is képesek jó előrejelzéseket adni, amelyek nem voltak benne a tanítóhalmaz adataiban.

7. Mintázatok megjelenése, modellek belső összefüggései

A létrehozott modellek előrejelzéseket adnak eddig még nem látott bemeneti adatokra, tehát időjárás adatokra. A modell kimenete egy valószínűség, amely a CO-s esemény bekövetkezésére utal. A modellek előrejelzéseinek értelmezéséhez rendelkezésre áll néhány eszköz, hogy milyen okok vezettek egy adott előrejelzéshez vagy éppen általánosan a modell melyik bemeneti adatot mennyire találja fontosnak az előrejelzés meghozatala során. Megvizsgáltam az egyik legkorszerűbb algoritmust az XGBoost-ot és annak belső döntéseit a SHAP (SHapley Additive exPlanations) [17] segítségével. A gépi tanulásban a SHAP a modellek működésének magyarázatára alkalmazott módszer, ahol az egyes bemeneti jellemzőknek a predikcióhoz való hozzájárulásának megértése a cél. A SHAP a gépi tanulási modellek népszerű magyarázati módszere, amely betekintést nyújt az egyes bemeneti tényezők adott előrejelzéshez való hozzájárulásába. SHAP értékek használata már a tűzvédelem területén is megjelent, hiszen egy 2024-es tanulmányban használtak a mesterséges intelligencia döntéseinek mélyebb értelmezésére erdőtüz kockázati térképek készítéséhez [18]. A SHAP analízis segített feltárni az egyes tényezők hozzájárulását a tűzvesélyességi kockázatokhoz. A SHAP értékek az egyes bemeneti adatszoportok átlagos hozzájárulását fejezik ki a modell által készített előrejelzéshez. A 4. ábrán láthatjuk a bemeneti adatokhoz tartozó SHAP értékeket. A diagram függőleges tengelyén a különböző változók (bemeneti adatok) jelennek meg (pl. temp_max¹⁰, gust, pressure¹¹). Ezek azok a tényezők, amelyek alapján a modell előrejelzéseket készít. A diagramban a vizsgált jellemzők fontossági sorrendben láthatóak, tehát a legfontosabb tényező a napi maximális hőmérséklet. A vízszintes tengelyen a bemeneti adatokhoz tartozó SHAP értékek láthatóak, amelyek azt jelzik, hogy az adott jellemző milyen mértékben és irányban befolyásolta a modell kimenetét. Ezt színes pontokkal ábrázoltam, ahol minden egyes adatpont egy színes pontnak felel meg egy adott bemeneti adathoz kapcsolódóan. Amikor a SHAP érték pozitív, akkor az adott jellemző növelte az előre jelzett osztály (CO-s esemény bekövetkezése) valószínűségét, míg ha negatív, akkor csökkentette azt. A színskála mutatja az adott bemeneti adat

⁷ colab.research.google.com


⁸ scikit-learn.org

⁹ tensorflow.org

¹⁰ napi maximális hőmérséklet

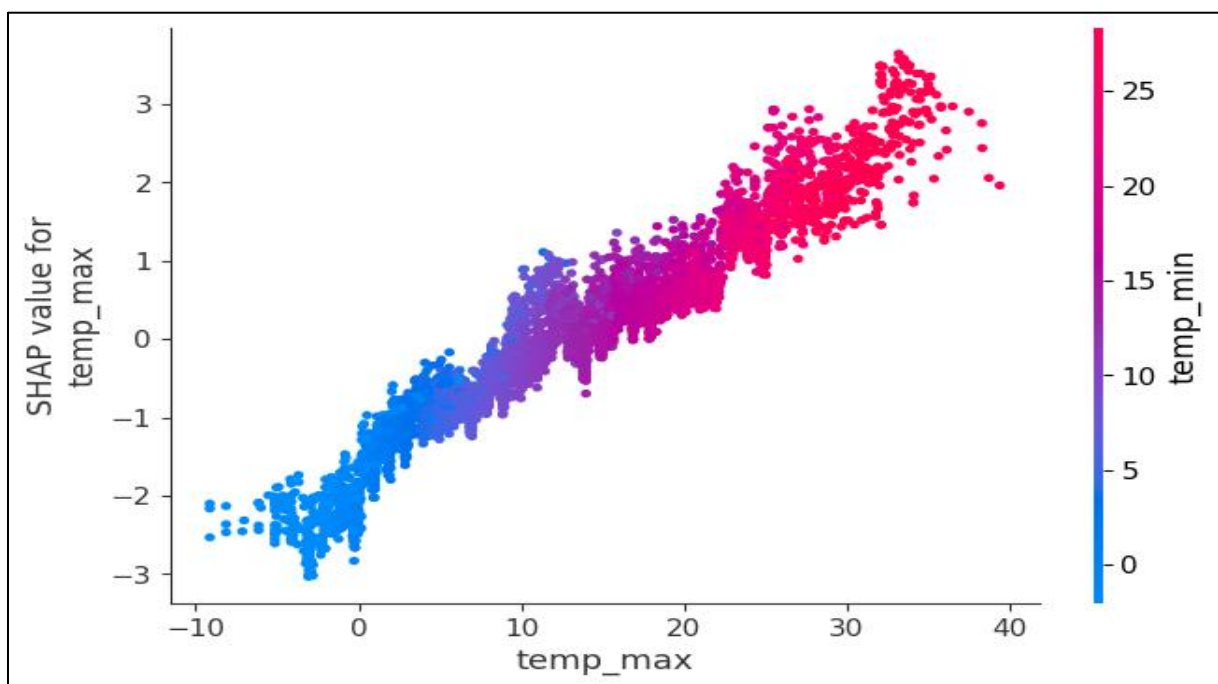
¹¹ légnyomás

értékeit (kék az alacsony, piros a magas értékeket jelöli). Ez segít megérteni, hogy az egyes bemeneti adatok magas vagy alacsony értékei hogyan befolyásolják a modell előrejelzését.



4. ábra, az egyes bemeneti adatokhoz tartozó SHAP értékek (készítette a szerző)

A modell azt találta, hogy például a temp_max, azaz a napi maximális hőmérséklet úgy befolyásolja a CO-s eseményeket, hogy azokon a napokon, amikor magas volt a temp_max értéke, azok pozitívan befolyásolták (elősegítették) a CO-s esemény bekövetkezését. A temp_min, azaz a napi hőmérsékleti minimum értékei alapján, amikor az érték magas, tehát magas a napi minimum hőmérséklet, akkor a CO-s eseményeknek kisebb a valószínűsége. A nagy szélökés (gust) értékek szintén növelik a CO-s esemény bekövetkezésének valószínűségét. A modell azonban ennél sokkal bonyolultabb belső összefüggéseket is megtalál és felhasznál az előrejelzés készítése során.



5. ábra, a napi maximum és minimum hőmérséklet együtthatása (készítette a szerző)

Az 5. ábrán a napi maximum és minimum hőmérsékletek együttes hatása látható a SHAP értékekre. Magas napi maximum és minimum hőmérsékletek (nyári időjárás) esetén a modell inkább a CO-s esemény bekövetkezésének irányába dönt. A temp-max-hoz tartozó SHAP értékek kb. 10 C-fok felett pozitívak, miközben a temp_min értékek is viszonylag magasak (5 C-fok felett). Azonban nagyon alacsony napi maximum és minimum értékek esetén (erős fagyok) a modell kisebb SHAP értékeket mutat, azaz csökken a CO-s esemény bekövetkezésének valószínűsége pusztán a hőmérséklet értékét figyelembe véve. Ez összhangban van azzal, hogy a téli időjárás esetén jóval nagyobb felhajtóerő alakul ki a kéményben, ami csökkenti a CO-s esemény bekövetkezési valószínűségét [6]. Amikor egy modell jól működik, akkor tulajdonképpen megtanulja a nagyszámú tanító adatokból azokat a fizikai törvényszerűségeket, amelyek a világunkban jelen vannak. Az előbbieken csak a temp_min-t vizsgálva megállapítottuk, hogy magasabb értékek inkább csökkentik a CO-s esemény bekövetkezési valószínűségét, együtt vizsgálva a temp_max-al már árnyaltabb a kép, hiszen az egyedi hatások és az együttes hatások különböznek. A SHAP értékek nem lineárisan viselkednek, hiszen a létrehozott modell maga sem lineáris, hanem sokkal bonyolultabb összetett rendszer.

8. Modell eredmények vizsgálata

A modellek képzése során az adatokat felosztottam tréning és validációs részekre 80%-20% arányban. A validációs halmaz adatait a modellek nem láthatták a képzésük során, kizárólag a modellek értékelésére használtam azokat. Az 1. táblázat tartalmazza a modellek által elért eredményeket.

Ssz.	Modell	pontosság	precizitás (0)	fedés (0)	precizitás (1)	fedés (1)
1.	gradient boosting (n_estimators=100)	0.77	0.79	0.88	0.69	0.55
2.	random forest (oversampling)	0.77	0.82	0.83	0.66	0.64
3.	neurális hálózat	0.72	0.82	0.62	0.50	0.74
4.	XGBoost	0.75	0.80	0.84	0.65	0.58
5.	XGBoost (custom threshold)	0.69	0.90	0.60	0.53	0.87
6.	random forest	0.79	0.81	0.88	0.74	0.63
7.	neurális hálózat	0.74	0.83	0.75	0.62	0.72

1. táblázat, a betanított modellek teljesítményéről (készítette a szerző)

Az 1. táblázatban lévő modellek értékelését a pontosság, precizitás, fedés metrikák alapján végeztem. A modellek pontossága 70% feletti, azonban sokkal érdekesebb mérőszám a precizitás és fedés vagy felidőzésnek is nevezett metrika. A precizitás jelentése: a CO-s eseménynek jelzett események közül mennyi a tényleges CO-s esemény. A fedés jelentése: az összes CO-s esemény hány százalékát találja meg a modell.

$$\text{pontosság} = \frac{TP+TN}{TP+TN+FP+FN}$$

$$\text{precizitás} = \frac{TP}{TP+FP}$$

$$\text{fedés} = \frac{TP}{TP+FN}$$

6. ábra a használt metrikák definíciója (készítette a szerző)

A 6. ábrán látható a felhasznált metrikák számítási módja, ahol a statisztikában használatos jelölések szerint TP: True Positive (valós pozitív), TN: True Negative (valós negatív), FP: False Positive (hamis pozitív), FN: False Negative (hamis negatív). A modellek precizitása a 0-ás osztály (nincs CO szivárgás) tekintetében általában 80% feletti, míg az 1-es osztály (CO szivárgás) tekintetében alacsonyabb, tehát a nem CO-s események előrejelzésében a modell jobb. A fedést vizsgálva szintén a 0-ás osztály eredményei jobbak. A döntési határt eltolva, mint az 1. táblázatban feltüntetett 5. modell esetében elérhető, hogy a modell a CO-s események 87%-át megtalálja, azonban ezt a precizitás kárára teszi, azaz sokkal több hamis pozitív előrejelzést generál, azaz a téves riasztások száma, amikor a modell tévesen CO-s eseményt jelez, is megemelkedik. Megállapítható, hogy a CO-s eseményeket nagy valószínűséggel előre tudjuk jelezni, azonban viszonylag magas a hamis pozitívok (jelzések) aránya. Ehhez a modell döntési határát, ami alapértelmezésként 0,5 lejjebb kellett állítani 0,3-as értékre, ahol a fenti eredmények adódtak. Itt a döntési határ a modell által előre jelzett CO-s esemény bekövetkezési valószínűségét jelenti. A modell kimenetén a döntési határszám megváltozása befolyásolja a precizitás és fedés metrikákat. A döntési határszám kiválasztásánál azt kell mérlegelni, hogy amennyiben a modell precizitása nagy, a fedése alacsonyabb lesz, vagyis az előre jelzett események nagyobb részt valós CO-s események lesznek, de az alacsony fedés miatt lesz sok olyan valós CO-s esemény, amit a modell nem jelez előre. A döntési határszám csökkentésével a precizitás nő a fedés csökken. A CO-s események előre jelzésénél azonban a fedés fontosabb metrika, hiszen a cél az összes CO-s esemény előrejelzése, de ilyenkor a precizitás viszont csökken, tehát a modell előre jelzi a tényleges CO-s eseményeket, de sok hibás előrejelzést is tesz.

9. További lehetőségek

A meteorológiai és egyéb riasztásokhoz, veszélyességi térképekhez hasonlóan, felmerülhet az igény egy CO szivárgás veszélyének előre jelzésére vonatkozó webalkalmazás, mobil applikáció kifejlesztésére. A nyílt égésterű tüzelőberendezések esetén előfordulhatnak olyan időjárási jelenségek, amelyek megnövelik a kockázatát a CO visszaáramlásának valamilyen meglévő műszaki hiba vagy probléma esetén. Ilyen esetekben a megfelelő biztonsági intézkedések alkalmazásával elkerülhető lehet a CO szivárgás, vagy annak hatása mérsékelhető lenne. A modell segítségével automatizáltan létre tudnánk hozni olyan webfelületet, amely meteorológiai előrejelzések és korábbi adatokból betanított modellt felhasználva veszélyességi térképeket jelenít meg. A térképi felület a változó meteorológiai előrejelzések alapján automatikusan frissíthetné a veszélyességi térképet, így tájékoztatást adhatna a lakosság részére. További meteorológiai állomások bevonásával a modell terepi felbontása tovább növelhető, amely pontosabb előrejelzéseket tenne lehetővé. A 1,5 évnyi tanítóadat kiterjesztésével szintén növelni lehetne a modell pontosságát, hiszen a modell a történelmi tényeket tanulja meg és a tanultak alapján általánosít egy jövőbeni helyzetre. A KAP Online adatbázisban gyűjtött helyszíni információkból gépi tanulási módszerek segítségével olyan modellt tudnánk létrehozni amely CO szivárgással kapcsolatos kockázati értéket számolna egy-egy ingatlanhoz. Az így kialakított modell segítségével egy internetes felületen pedig bárki a saját ingatlanjának adataival fel tudná mérni a kockázatokat.

4. KÖVETKEZTETÉS

A kutatás a CO mérgezéssel járó káresemények előre jelezhetőségét vizsgálja. A cél a CO-s események okainak azonosítása, az időjárás és más környezeti tényezők hatásának feltárása, valamint egy megelőző figyelmeztető rendszer kidolgozása gépi tanulás segítségével. Évente több mint 1000 CO-val kapcsolatos riasztás érkezik a katasztrófavédelemhez és ezzel összefüggésben átlagosan 11 eseménynél 14 haláleset történik. A CO szivárgás fő indokai: a tüzelő berendezés hibája, karbantartás elmaradása, elégtelen légutánpótlás, azonban a kutatás rávilágít arra, hogy az előzőeken túl kimutathatóan jelentőséggel bírnak az időjárási körülmények is. A kutatás során gépi tanulási algoritmusokat (pl. Random Forest, Gradient Boosting) használtam a CO-események előre jelzésére. A modelleket valós múltbeli CO érzékelők által jelzett CO-s eseményeken tanítottam.

Az eredmények igazolták azt a feltevésemet, hogy a műszaki problémák az időjárással együtt komplex módon befolyásolják a CO-s események létrejöttét és megfelelő módszerek kiválasztásával azok előre jelezhetőek. Az előrejelzést komplex módon kell értelmezni, azaz ha van valamilyen műszaki meghibásodás vagy probléma, az adott időjárási helyzettel együtt milyen CO szivárgási kockázatot jelent. Az előrejelzések pontossága 70% feletti volt. Ezeket az eredményeket felhasználva javaslatot tettem egy veszélyességi térkép kialakítására annak érdekében, hogy a lakosság számára ezek a veszélyek megismerhetőek legyenek. A legnagyobb biztonságot továbbra is a CO érzékelők jelentik, hiszen ezek objektív méréseken alapuló riasztást generálnak.

5. RÖVIDÍTÉSEK ÉS IDEGEN KIFEJEZÉSEK JEGYZÉKE

1. **Accuracy / Pontosság** – Az összes és a helyesen előre jelzett események aránya.
2. **API** – *Application Programming Interface*: Alkalmazásprogramozási felület, szoftverek közötti adatkapcsolatot biztosít.
3. **Binary classification / Bináris osztályozás** – Gépi tanulási feladat, amely két kimeneti osztály (pl. esemény / nem esemény) közötti döntést hoz.
4. **Colab** – *Google Colaboratory*: Ingyenes online környezet Python futtatására.
5. **EOV** – *Egységes Országos Vetületi rendszer*: Magyarországon használt térképészeti koordinátarendszer.
6. **FN** – *False Negative*: Hamis negatív – elmaradt riasztás.
7. **FP** – *False Positive*: Hamis pozitív – téves riasztás.
8. **Gradient Boosting**: Gépi tanulási technika, amely fokozatosan tanul a korábban elkövetett hibákból.
9. **KAP** – *Katasztrófavédelmi Adatszolgáltató Program*: A katasztrófavédelem belső adatgyűjtő rendszere.
10. **Neural Network**: – *Neurális hálózat*: Gépi tanulási modell, amely az emberi agy működését utánozza.
11. **Point-biserial correlation** – Kétféle változós korrelációtípus, amelyet folytonos és bináris változók kapcsolatának vizsgálatára használnak.
12. **Precision / Precizitás** – Az előrejelzett pozitív találatok közül mennyi a valódi pozitív.
13. **Random Forest**: Gépi tanulási algoritmus, amely döntési fák együttese.
14. **Recall / Fedés** – Az összes valódi pozitív közül mennyit talált meg a modell.
15. **Scikit Learn**: – Python nyelvhez tartozó nyílt forráskódú gépi tanulási könyvtár.
16. **SHAP** – *SHapley Additive exPlanations*: A gépi tanulási modellek döntéseinek értelmezésére szolgáló módszer.
17. **TensorFlow**: – Nyílt forráskódú szoftverkönyvtár mesterséges intelligencia modellek építésére.
18. **Threshold / Döntési küszöb** – Az a határérték, amely felett egy osztályozó modell pozitívként jelzi az eseményt.
19. **TMMJ** – *Tűzeseti Műszaki Mentési Jelentés*: A katasztrófavédelem által készített tűzeseti vagy műszaki mentési adatlap.
20. **TN** – *True Negative*: Valós negatív találat.
21. **TP** – *True Positive*: Valós pozitív találat egy előrejelzési modellben.
22. **Training set / Tanítóhalmaz** – Az a része az adatoknak, amelyet a modell tanulásra használ.
23. **Validation set / Validációs halmaz** – Az adatok azon része, amellyel a modell teljesítményét ellenőrzik.
24. **XGBoost**: Gépi tanulási technika, amely fokozatosan tanul a korábban elkövetett hibákból.

6. IRODALOMJEGYZÉK

- [1] KAP, „Katasztrófavédelmi Adatszolgáltató Program,” Belügyminisztérium Országos Katasztrófavédelmi Főigazgatóság, 2024.
- [2] J. J. Rose, L. Wang, Q. Xu, F. C. McTiernan, S. Shiva, J. Tejero, T. M. Gladwin, „Carbon Monoxide Poisoning: Pathogenesis, Management, and Future Directions of Therapy,” *American journal of respiratory and critical care medicine*, pp. 596–606, 2017. [Online]. Elérhetőség: <https://pubmed.ncbi.nlm.nih.gov/27753502/> (2025.03.16.)
- [3] BM OKF, „A szén-monoxid-mérgezés megelőzhető!” 2024. [Online]. Elérhetőség: <https://katasztrofavedelem.hu/329/a-szen-monoxid-mergezes-megelőzhető> (2025.03.16.)
- [4] H. L. Ruan, W-S. Deng, Y. Wang, J-B. Chen, W-L. Hong, S-S. Ye, Z-J. Hu „Carbon monoxide poisoning: a prediction model using meteorological factors and air pollutant,” *BMC proceedings*, 15(Suppl 1), 2021. [Online]. Elérhetőség: <https://bmcproc.biomedcentral.com/articles/10.1186/s12919-021-00206-7> (2025.03.16.)
- [5] C-H. Wang, S-C. Shao, K-C. Chang, M-J. Hung, C-C. Yang, S-C. Liao „Quantifying the Effects of Climate Factors on Carbon Monoxide Poisoning: A Retrospective Study in Taiwan,” *Frontiers in Public Health*, 2021. [Online]. Elérhetőség: <https://pubmed.ncbi.nlm.nih.gov/34722435/> (2025.03.16.)
- [6] Leikauf P., *Tűzvédelmi elméleti ismeretek gyakorlati alkalmazása a kéményseprő-ipari tevékenységekben.*, 2021.
- [7] S. Sridharan, S. Mangalam „Carbon monoxide risks and implications on maintenance-intensive fuel-burning appliances — A regulatory perspective,” *Annual Reliability and Maintainability Symposium*, 2017. [Online]. Elérhetőség: <https://ieeexplore.ieee.org/document/7889726> (2025.03.16.)
- [8] R. Andrzejczyk, „Analysis of the Year-Round Operation of Enhanced Natural Ventilation Systems under Transient Weather Conditions in Europe,” *Energies*, 2024. [Online]. Elérhetőség: <https://www.mdpi.com/1996-1073/17/15/3795> (2025.03.16.)
- [9] Farkas J., Huszár T., Kocsis K., Leikauf T., Kéményseprő-ipari szakmai ismeret tansegédlet, Budapest: Katasztrófavédelmi Oktatási Központ, 2018. [Online]. Elérhetőség: https://bmkszf.hu/dokumentum/2543/KEMENYSEPROIPARI_SZAKMAI_ISMERET_TANSEGEDLETi.pdf (2025.03.18.)
- [10] G. V. Fracastoro & M. Masoero, „Air Infiltration induced by Heating Appliances.” 1988. [Online]. Elérhetőség: https://www.aivc.org/sites/default/files/AIVC_1988_CP09_Vol1.pdf (2025.03.18.)
- [11] V. Leblanc & M. A. A. Cox, „Interpretation of the point-biserial correlation coefficient in the context of a school examination,” *The Quantitative Methods for Psychology*. 13., pp. 46-56., 2017. [Online]. Elérhetőség: <https://www.tqmp.org/RegularArticles/vol13-1/p046/p046.pdf> (2025.03.18.)
- [12] M. A. Nikitina. & I. M. Chernuka, „Nonparametric statistics. Part 3. Correlation coefficients,” *Theory and practice of meat processing*, 2023. [Online]. Elérhetőség: <https://www.meatjournal.ru/jour/article/view/286> (2025.03.18.)
- [13] L. Breiman, „Random Forests,” *Machine Learning* 45 „, p. 5–32, 2001. [Online]. Elérhetőség: https://www.researchgate.net/publication/275342330_Random_Forests (2025.03.18.)

- [14] Z. He, D. Lin, T. Lau, M. Wu, „Gradient Boosting Machine: A Survey,” 2019. [Online]. Elérhetőség: <https://arxiv.org/abs/1908.06951> (2025.03.18.)
- [15] T. Chen, C. Guestin, „XGBoost: A Scalable Tree Boosting System.,” *In Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, p. pp. 785–794, 2016. ” [Online]. Elérhetőség: <https://arxiv.org/abs/1603.02754> (2025.03.18.)
- [16] J. Schmidhuber, „Deep learning in neural networks: An overview.,” *Neural Networks*, 61, p. pp. 85–117., 2015. [Online]. Elérhetőség: <https://www.sciencedirect.com/science/article/abs/pii/S0893608014002135> (2025.03.18.)
- [17] S. Lundberg, S-I. Lee, „A Unified Approach to Interpreting Model Predictions.,” *Advances in Neural Information Processing Systems* 30, pp. pp. 4765--4774, 2017. [Online]. Elérhetőség: <https://arxiv.org/abs/1705.07874> (2025.03.18.)
- [18] M. C. Iban, O. Aksu, „SHAP-Driven Explainable Artificial Intelligence Framework for Wildfire Susceptibility Mapping Using MODIS Active Fire Pixels: An In-Depth Interpretation of Contributing Factors in Izmir,” *Türkiye. Remote. Sens.*, 16, 2842., 2024. [Online]. Elérhetőség: <https://www.mdpi.com/2072-4292/16/15/2842> (2025.03.18.)
- [19] Szinell Cs., Merza Á., „Meteorológiai alapismeretek,” 1999. [Online]. Available: [Online]. Elérhetőség: <https://www.muszeroldal.hu/measurenotes/meteor.pdf> (2025.03.20)