

36. Országos Tudományos Diákköri Konferencia
Had- és Rendészettudományi Szekció
Budapest, 2023. április 18-20.
Nemzeti Közszolgálati Egyetem
Rendészettudományi Kar

Mesterséges intelligencia alkalmazási lehetőségei a tűzszerész feladatok technikai támogatásában

Jelige: *Robbanótestek*

Pályamunka lezárásának időpontja: 2022. június

2023.

AZ INNOVÁCIÓS ÉS TECHNOLÓGIAI MINISZTERIUM ÚNKP-21-1-I-NKE-93
KÓDSZÁMÚ ÚJ NEMZETI KIVÁLÓSÁG PROGRAMJÁNAK SZAKMAI
TÁMOGATÁSÁVAL KÉSZÜLT.



TARTALOM

BEVEZETÉS.....	4
1. TŰZSZERÉSZ FELADATOK VÉGREHAJTÁSÁNAK KERETEI	7
1.1. Az ezred felépítése	7
1.2. Jogszabályban rögzített közszolgálati feladatok.....	8
1.3. Robbanótestek Magyarországon	10
2. A MESTERSÉGES INTELLIGENCIA ALKALMAZÁSÁNAK LEHETŐSÉGEI	14
2.1. Mesterséges intelligencia fogalma	14
2.2. Funkcionalitás szerinti csoportosítás	16
2.3. Gépi tanulás.....	17
2.3.1. Felügyelt tanulás.....	17
2.3.2. Nem felügyelt tanulás.....	19
2.3.3. Megerősítéssel tanulás	19
2.4. Mesterséges neurális hálózat	21
2.5. Konvolúciós neurális hálózat	23
3. MESTERSÉGES INTELLIGENCIA ALAPÚ TŰZSZERÉSZ TÁMOGATÓ INFORMÁCIÓS RENDSZER	24
3.1. Objektumfelismerés vagy képelemzés	24
3.2. Képelemzés elvi működése	26
3.3. Szoftveres háttér	31
3.4. Képi adatbázis	34
3.5. Neurális háló és komponenseinek jellemzése, a meghatározás pontosságának mérése	38
4. FEJLESZTÉSI LEHETŐSÉGEK	43
ÖSSZEGZÉS.....	45
IRODALOMJEGYZÉK.....	47

BEVEZETÉS

Magyarország területén az elmúlt évszázadok során számos olyan fegyveres konfliktus zajlott, amelyben a robbanóanyagok egyik típusát, a tolóhatású robbanóanyagot, vagyis a lőport használták. Már a török hódoltság területén vívott harcokban is használtak puskaporral töltött ágyúkból kilőtt repeszbombákat. Bár az 1848/49-es forradalom és szabadságharc időszakában is számos hasonló elven működő eszköz került bevetésre, a robbanóeszközök alkalmazása az ország területén az I. és II. világháború alatt vált igazán tömegessé, így nem véletlen, hogy napjainkban is ezek okozzák a legnagyobb fejtörést a szakembereknek. A II. világháború maradványaiból például átlagosan évi több mint 30.000 db kerül elő, míg a szakemberek becslése alapján a földben nyugvó eszközök száma milliós nagyságrendű. A leginkább érintett megyék közé tartozik Fejér és Pest megye. Azt is érdemes megjegyezni, hogy bár a bejelentések túlnyomó többsége valóban veszélyes eszközről érkezik, a kiszállások 10%-ában megvizsgált test valójában nem robbanótest¹. Az ilyen értelemben tévesnek tekinthető riasztások jelentős erőforrásokat köthetnek le humán és anyagi értelemben egyaránt, így a ténylegesen veszélyes robbanótestek mentesítése késedelmet szenvedhet, ami növelheti például egy esetleges baleset kockázatát is. [1]

A felsőoktatásban folytatott tanulmányaim során több II. világháborús fémkereső műszeres kutatást is végeztem, amelyek során számos alkalommal találtam az I. és II. világháborúból visszamaradt elműködött vagy éles robbanótesteket is. Ezáltal megismerkedtem azzal a hatósági folyamattal, amely a robbanótesteket előtalálásuktól egészen a megsemmisítésükig, vagy központi gyűjtőbe szállításukig kíséri. Felismertem, hogy – a későbbiekben részletesen bemutatásra kerülő – eljárásrendben dolgozó Rendőrség és a MH 1. Honvéd Tűzszerész és Hadihajós Ezred (a továbbiakban: MH 1. HTHE) munkatársainak közös munkáját nagyban elősegítené egy olyan mesterséges intelligencia (MI)² alapú szoftver, ami képes hatékonyan felismerni és beazonosítani (nem feltétlenül 100% pontossággal) az egyes előtalált robbanótesteket akár már néhány fénykép alapján.

Mivel az általam végzett kutatások több tudományterülethez is kapcsolódnak, az interdiszciplináris jelleg miatt számos új területen kellett további ismereteket szereznem az eredményes lebonyolítás érdekében. Témám egyrészt a társadalomtudományok, azon belül pedig a hadtudomány területén helyezkedik el. A hadtudomány tudományágon belül a

¹ Ennek egy része bár robbanótestnek néz ki, vagy korábban az volt, de napjainkra valamilyen okból már nincs benne robbanóanyag vagy pirotechnikai anyag, mint pl. egy üres aknagránát vagy ürméret alatti páncéltörő lövedék.

² Mesterséges Intelligencia (MI) – Artificial intelligence (AI)

haditechnika tudományterületén kutattam a II. világháborús robbanótestek felépítését és alakját. Másrészt a műszaki tudományok területén az informatika tudományágának eredményeit használtam fel a mesterséges intelligencia kutatása és programozása során. [2]

A hadtudomány jelen kiemelt kutatási területei közé tartozik az országvédelem és az állampolgárok védelme, így közvetetten az ország területének robbanótestektől való mentesítése, de fontos részét képezik a védelmi célú robotika területének fejlesztései is. [3] Így akár az általam készített robbanótest azonosító rendszer további fejlesztésével és egy tűzszerész robotra történő integrációjával, akár egy autonóm harcanyag felismerő és hatástalanító, semlegesítő eszközt is létre lehetne hozni a jövőben.

Kutatási módszerként alkalmaztam a forráskutatást, az internetes és nyomtatott folyóiratokban, könyvekben fellelhető információk rendszerezését, értékelését egyrészt az MI alkalmazásának és programozásának lehetőségeiről, másrészt a tűzszerész feladatokról és a különböző szabványok alapján gyártott (az azonos eszközök egymással pontosan megegyezők), egykor hadrendben lévő robbanótestekről. Konzultációt folytattam a MI programozásban jártas szakemberekkel, illetve egy I. osztályú tűzszerésszel az azonosítás lehetséges lépéseiről.

Empirikus tapasztalatokat is szereztem mind a szükséges képi adatbázis létrehozásával, mind pedig az MI programozásával kapcsolatosan. Nagyon sok tesztelésre volt szükség a megfelelő felépítésű és összetételű, MI tanítására alkalmas képi adatbázis létrehozásához. Több változó (háttér, fényképezés szöge, képek mennyisége, fő és alcsoportok száma) együttes figyelembevételével, azok súlyozásának helyes megválasztásával válhatott csak sikeressé a tevékenység. Az MI programozása során a változók (rétegek, újratanulások száma) optimális értékének meghatározása is egy komoly visszaellenőrzési folyamat eredménye, ugyanis nincsen pontos definíció azok kiválasztására, és nem tudhatjuk előre, hogy milyen változók alkalmazásával válik a rendszer a leghatékonyabbá. Ennek egyik fő oka, hogy nincs két egyforma képi adatbázis és nincs két azonos neurális háló sem.

A kutatás kezdetén megfogalmaztam hipotéziseket és kitűztem az általam elvárando eredményeket is, amelyek a következők:

- Létrehozható egy olyan MI szoftver, amely képes reguláris robbanótestek besorolására előre meghatározott csoportokba;
- Egy MI szoftver képes a reguláris robbanótestek legalább 70% pontossággal történő azonosítására;
- Kialakítható egy olyan képi adatbázis a reguláris robbanótestekről, amely segítségével hatásos képelemző MI tanítható;

- Egy programozási előismeretekkel nem rendelkező egyén is képes adott felhasználási célra előállított MI programozására.

A kutatás célja: a Magyarországon legnagyobb számban fellelhető robbanóeszközökről rendelkezésre álló információk, műszaki paraméterek vizsgálata és rendszerezése a fejlesztésre tervezett szoftver tanításának támogatása érdekében. Egy MI alapú robbanótest azonosító szoftver elméleti alapjainak és lehetőség szerint prototípusának kidolgozása, amely tovább fejlesztve alkalmassá tehető az MH 1. HTHE, valamint a Rendőrség kapcsolódó szakfeladatainak hatékony támogatására.

1. TŰZSZERÉSZ FELADATOK VÉGREHAJTÁSÁNAK KERETEI

A fejezetben bemutatásra kerül a MH 1. HTHE felépítése és katonai, illetve közszolgálati feladatai közül azok, amelyek meghatározzák azt a keretet, amiben a tűzszerező katonák nap, mint nap tevékenykednek. Ezek megismerésével egyértelművé válik, hogy mi a célja a Mesterséges Intelligencia Alapú Tűzszerező Támogató Információs Rendszernek, és ez mennyiben tudja majd segíteni jövőben a szakállomány napi tevékenységét. Továbbá megvizsgálom a Magyarországra jellemző robbanótest statisztikát is, annak érdekében hogy szemléltessem a probléma jellegét és nagyságrendjét, valamint behatóan a kutatásom szempontjából legfontosabb eszközök körét.

1.1. Az ezred felépítése

A Magyar Honvédség (MH) és jogelődj szervezetének egyik legrégibb alakulata a MH 1. Honvéd Tűzszerező és Hadihajós Ezred. A II. világháború magyarországi szakaszának befejezését követően a fontosabb területek szervezett akna és robbanótest mentesítésére már 1947-ben létrehozták az 1. Honvéd Aknakutató Zászlóaljat, amellyel az ország területének mentesítése szakszerűbbé és hatékonyabbá vált. 1975-ben már önálló egység lett az alakulatból 1. Tűzszerező és Aknakutató Zászlóalj néven. A fejlődés továbbra is töretlen maradt, így egy hadihajós alosztállyal kiegészülve 2001. július 1-jével létrejött a napjainkban is hadrendi elemet képező MH 1. Honvéd Tűzszerező és Hadihajós Ezred. Az ezred kibővített feladatrendszerrel a MH Összhaderőnemi Parancsnokság közvetlen alárendeltségében tevékenykedik 2007 márciusától folyamatosan.³ [4]

Az ezred fő feladatai és tevékenységei a következők:

- *Katonai objektumok tűzszerezési átvizsgálása, mentesítése;*
- *Kezelésre veszélyes robbanószerkezetek és pirotechnikai anyagok megsemmisítése;*
- *A Magyar Honvédség tűzszerező beosztású katonáinak kiképzése;*
- *A külszolgálatra távozó katonák tűzszerezési felkészítése;*
- *Tűzszerező-bemutatók szervezése a polgári lakosság tájékoztatása érdekében;*
- *Rendezvények hadihajós biztosítása. [4]*

³ 2007. március 01. és 2010. június 15. között az alakulat zászlóalj kötelékben, majd ezt követően újra ezred kötelékben hajtja végre feladatait.



1. ábra: MH 1. HTHE címere⁴

Az alakulat szervezete négy fő részre tagolható. A vezető szervekre, a végrehajtó alegységekre, amelyek közé tartozik az 1. tüzszerész század, a Speciális tüzszerész század, a Hadihajós alosztály és a Robbanóanyag-kereső kutyás műveleti század. A logisztikai alegységek közé tartoznak a raktárak és a logisztikai század, de az alakulat rendelkezik egészségügyi központtal is. [4]

Mivel Magyarország területén, annak történelme során többször is heves harcok dúltak, így jelentős mennyiségű fel nem robbant robbanótest maradt vissza leginkább a II. világháborúból. Mivel az ország területén többször is húzódtak frontvonalak, ezért európai viszonylatban is kiemelkedő a visszamaradt eszközök száma. Ez a tény, illetve az ebből eredő feladatok indokolják egy önálló katonai szervezet fenntartását. Bár a Hadihajós alosztály alapvetően nem csak a tüzszerész feladatokat támogatja, feladatainak egy részét mégis a folyókban és állóvizekben talált robbanótestek ártalmatlanítása során a tüzszerész bűvárok tevékenységének biztosítása képezi.

1.2. Jogszabályban rögzített közszolgálati feladatok

A MH 1. HTHE közszolgálati feladatait a tüzszerészeti mentesítési feladatok ellátásáról szóló 142/1999. (IX. 8.) Kormányrendelet szabályozza. A rendelet hatálya alá esnek azok a katonai tüzszerészek, közreműködő személyek és szervezetek, amelyek katonai felhasználásra

⁴ <https://honvedelem.hu/alakulat/mh-1-honved-tuzszeresz-es-hadihajos-ezred.html>
(Letöltve: 2022.01.24.)

készített és rendszeresített robbanóanyagot tartalmazó elhagyott robbanótestek mentesítését, hatástalanítását végzik. [5]

Az a személy, aki elhagyott robbanótestet vagy annak látszó tárgyat talál, illetve ilyenről tudomása van, köteles azt a helyi illetékes rendőri szervnek azonnal bejelenteni. Ahol erre nincs lehetőség, ott a település jegyzőjét kell értesíteni, aki megteszi a rendőri szervek kiértékelését. Ezt követően a település jegyzője vagy a rendőri szerv tagja ellenőrzi a bejelentés valódiságát, majd megjelöli az esetleges robbanótest helyét és elhelyezi a robbanásveszélyre utaló jelzést. A továbbiakban az intézkedő felveszi a kapcsolatot az MH Tűzserész Ügylettel, ahol bejelentést tesz a robbanótestről, illetve az általa korábban végzett intézkedésekről, valamint javaslatokat tehet további korlátozó intézkedésekről a robbanótest környezetének biztosítása és az állampolgárok védelme érdekében. [5]

A beérkezett bejelentést a MH Tűzserész Ügylet nyilvántartásba veszi és jelenti a tűzserész szervezet parancsnokának (vagy ügyeletes parancsnokának), aki a MH Tűzserész Ügyleten keresztül tájékoztatja a bejelentőt a további tevékenységekről, a robbanótest hatástalanításának módjáról és rendjéről. A parancsnok a szükséges tűzserész erőt soron kívül köteles kirendelni a helyszínre, ha a robbanótest lakóépületben, oktatási, nevelési, szociális vagy egészségügyi intézményben, vízi vagy szárazföldi útvonalon, közterületen vagy vízszolgáltatást biztosító létesítményben, esetleg vízszolgáltatást biztosító helyen található. Ezen esetek kivételével a mentesítést 30 napon belül, a szervezet akadályoztatása esetén meghosszabbított határidővel kell elvégezni. [5]

Az előtalált robbanótest hatástalanítását vagy elszállítását és megsemmisítését egy tűzserész járőr vagy alegység hajtja végre. Ezért a megtalált eszközt más személynek tilos megfognia vagy elmozdítania. Továbbá a megtalálás helyszínének (ingatlan, építmény, földterület stb.) tulajdonosától elvárható, hogy a közveszély elhárítása érdekében mindennemű ésszerű segítséget megadjon a tűzserész járőrnek. A mentesítés végrehajtása érdekében fogantatott további intézkedéseket a tűzserész járőr, a rendőri szerv és a település önkormányzatának jegyzője közreműködésével, bevonásával végzi. Továbbá a tűzserész járőrparancsnok igényeinek megfelelően a település önkormányzata a veszély elhárítása érdekében személyi állományt, eszközöket, anyagokat és gépeket térítésmentesen köteles biztosítani. Amennyiben a robbanótest elszállítása nem lehetséges és azt a helyszínen kell megsemmisíteni, a települési jegyző feladta a megsemmisítési terepszakasz kijelölése természetesen a járőrparancsnok szakmai útmutatásának figyelembe vételével. [5]

Mivel a tűzserész feladatok célja az állampolgárok testi épségének szavatolása, ezért közvetlen életveszély esetén a rendőrség tűzserész szervezete is jogosult ilyen esetekben a szükséges intézkedések megtételére. [5]

A tűzserész szervezet térítés ellenében is végezhet mentesítési munkákat,⁵ viszont ezek nem akadályozhatják és hátráltathatják a térítésmentesen végzendő feladatokat. Megrendelésre olyan területeket és objektumokat, illetve anyaghalmazokat (pl. fémhulladék) vizsgálhatnak át, amelyen a megrendelő szerint robbanótestek találhatók. Továbbá a nagyobb mennyiségű robbanóanyag (pl. pirotechnikai eszközök) hatástalanítását, tűzserész feladatok támogatására történő felkészítést és szakértői feladatok ellátását is végezhetik térítés ellenében. Ezt a tűzserész tevékenységet a szervezet szolgálati előjárója engedélyezheti, de annak idejéről és a végrehajtásáról a szervezet parancsnoka határoz. [5]

A tűzserész feladatok végrehajtásának törvényi kereteiből kiderül, hogy az ezred katonáinak milyen szerteágazó közszolgálati feladatai vannak a katonai hivatásból származó feladatok mellett. Erre a szigorú törvényi háttérre azért van szükség, mert Magyarország területén napjainkban is millió számra nyugszanak föld alatt megbúvó éles robbanótestek, aminek köszönhetően évente több tízezer bejelentés érkezik, amelyek ellenőrzése, és az eszközök hatástalanítása az ezred feladata.

1.3. Robbanótestek Magyarországon

A napjainkra visszamaradt legnagyobb robbanótest szennyezés a II. világháború következménye. A főváros ostroma például 102 napig tartott, amit a Budapest visszaszerzésére irányuló Konrád német műveletek követtek. Ehhez jön még az ország számos területén kialakított megerősített vonalak, mint pl. a Gizella-, Attila-, vagy Karola-vonalak, ahol a védők hosszabb-rövidebb időre feltartóztatták a szovjet csapatok előrenyomulását. Ezzel elhúzódó harcokat vállaltak, amely jelentősen növelte a bevetett haditechnikai eszközök és felhasznált anyagok mennyiségét.

Arra a kérdésre, hogy ezek az eszközök még a háború után több mint 70 évvel is veszélyesek-e, a válasz igen. Sőt, az idő múlásával a bennük lévő robbanóanyag a külső környezeti tényezők hatására vagy veszít érzékenységéből vagy pont fordítva, kikristályosodik, és fokozottan érzékennyé válik. Éppen ezért fontos ezeknek az eszközöknek a szakemberek által történő hatástalanítása. [1]

⁵ A szolgáltatás díjáról a szerződő felek nonprofit módon megállapodnak, így az nem lehet kevesebb a feladat önköltségénél, amely nagyrészt a személyi állomány járandóságaiából és a technikai eszközök üzemeltetésének költségéből áll össze.

A legfrissebb részletes statisztikai adatok a 2019-es évről lettek publikálva. Ebben az évben a tűzszerészek 34.768 eszközt hatástalanítottak. Ennek legnagyobb része 27.931 eszköz gyalogsági lőszer volt, viszont a gyakorlat azt bizonyítja, hogy nem ezek a legveszélyesebbek, hanem a tűzéségi gránátok és a légibombák, amelyek az esetek 8%-át tették ki. Érdekesség, hogy mindössze 16 db aknát kellett hatástalanítani az évben, és ez az alacsony szám a II világháborút követő sikeres aknamentesítő folyamatok eredménye. Viszont az esetek 10%-a, azaz 3476 tárgy nem volt tényleges robbanóeszköz, ezek általában konzervdobozok vagy nagyobb henger alakú tárgyak voltak. [1]

Az elmúlt évek tapasztalatai alapján évente átlagosan 2400 bejelentés érkezik a MH Tűzszerész Ügyeletre, amely átlagban napi 6-7 esetet jelent, ugyanakkor a bejelentések tényleges eloszlása évszakonként jelentősen változik. Márciusban és áprilisban a tavaszi munkák kezdetén érkezik az éves esetszám 20%-a. A nyáron is magas a riasztások aránya, amely az őszi munkák befejezésével folyamatosan csökken, és értelemszerűen télen van legkevesebbszer szükség a tűzszerészek beavatkozására. [6]

A bejelentések számát nemcsak idő, hanem területi eloszlás alapján is lehet vizsgálni. A legkevesebb robbanótest Békés, Zala, Nógrád és Tolna megyékben kerül elő, mivel e megyék területén kevesebb ideig és kisebb hevességgel dúltak a harcok. A legszennyezettebb megye Pest megyét is megelőzve Fejér megye, ahonnan a bejelentések 15–20%-a is érkezik. Budapesten belül a XII. és XIV. kerületekben kerül elő a legtöbb robbanótest, ugyanis ezeken a területeken zajlottak a leghosszabb ideig hevesebb harcok. [1]

A számos bejelentés kezelésében a tűzszerész műveleti irányítás nagy segítségére lenne egy olyan mesterséges intelligencia alapú felismerő szoftver, amely képes lenne beazonosítani és kategorizálni a robbanótestek típusát ezzel megkönnyítve a besorolás folyamatát. Napjainkban ez a legmodernebb szoftveres támogatás, amely jelen körülmények között segíteni tudná az ország területének további mentesítését, illetve a feladatok elvégzésének hatásfokát, illetve biztonságosságát is növelné.

A gyalogsági löszerek sok esetben egy bejelentett helyszínen nagyobb mennyiségben kerülnek elő, mivel méretük kicsi és ezres számban alkalmazták azokat egyszerre. Viszont van egy robbanótest típus, amely tömeges alkalmazása miatt minden napos feladatot ad ma is a tűzszerészeknek. Ez az aknagránátok csoportja, amely több különböző űrméretben fellelhető az egykori csaták helyszínein.

Az aknavető egy meredek röppályájú fegyver, amelynek rendeltetése a röppálya alakjából kifolyólag a fedezékekben, illetve a terephullámok mögött elhelyezkedő élőerő és technikai eszközök pusztítása, valamint harcképtelenné tétele. Kisebb űrméretű változatait (8 cm-es

kategóriáig) a különböző nemzetek haderőiben általában a gyalogság használta (2. ábra), míg nagyobb űrméretű változatait a tüzérség alkalmazta. [7]

Az első típusait még kézi szekéren húzták az alkalmazás helyszínére, ahol a kezelők szerelték azt össze. Majd kialakultak összecusukható változataik, illetve a nagyobb űrméretű eszközöket már saját gumikerekekkel látták el, így tehergépjárművel is vontathatóvá váltak. A MH-ban első modernnek mondható aknavetőt 1936 M aknavető néven rendszeresítették (3. ábra). Ez egy 81 mm-es űrméretű, simacsövű, elöltöltő fegyver volt, amelynek krómnikkel-acél csövét menetes csatlakozással lehetett a csőfarhoz kapcsolni. Ez a talplemezhez kapcsolódott, amely négyszögletű bádoglemezből készült, ennek feladata a lövésből származó hátrarúgást okozó energiák közvetítése volt a talajra, ezzel stabilan és elmozdulásmentesen tartva a fegyvert. A lövegcső magasságát egy villás lábú állvánnyal lehetett szabályozni, a célzás helyét pedig ennek állításával lehetett változtatni. [7] Ez a felépítés a napjainkban használt aknavetők legnagyobb részénél hasonlóan megtalálható.



2. ábra: Granatwerfer 34 8 cm-es német aknavető⁶

Az aknagránátok tetején található a gyújtószerkezet, alatta a fejrész, a hengeres rész és a farok rész. Az aknagránát legvégén található a stabilizátorszárny, amely egyrészt a gránát kilövése során azt a csőben a megfelelő pozícióban tartja, másrészt a röppályán forgással

⁶ <https://www.dday-overlord.com/en/material/artillery/8-cm-granatwerfer-34> (Letöltve: 2022.03.24.)

stabilizálja az eszközt. Kezdetben a stabilizátor szárnylapok közé helyezték el a kiegészítő lőporos zacskókat, amely felrobbanása a megfelelő kezdő impulzust adta a gránátnak. De a nagyobb elhelyezhető mennyiség miatt a későbbiekben inkább megnövelték a stabilizátor nyeles részének hosszát, amelyen így körbe-körbe nagyobb mennyiségű lőport lehet elhelyezni. Az aknavető hatótávolságát a nyeles részre helyezett lőportasakok számával lehet módosítani. [8] A II. világháborúban alkalmazott aknavetők maximális lőtávolsága típustól függően 2–6 km [9] volt, ez napjainkra 10–20 km-re [10] növekedett.

Mivel mindennapos eseménynek számít az aknagránátok előtalálása, így a kutatás során ennek a robbanótest csoportnak az egyes típusait vizsgáltam, azokról készítettem fényképes adatbázist és a mesterséges intelligenciát is ezen eszközök felismerésére programoztam, az összes létező ilyen eszköz felismerésének igénye nélkül.



3. ábra: 1936 M 8 cm-es aknavető tüzelőállásban leálcázva⁷

⁷ Kovács Vilmos: *A Magyar Királyi Honvédség fegyverzete a 2. hadsereg frontra küldésének időszakában és a doni hadműveletben 1942–43.* Rubicon 30. évf. 1. szám, 2019. 31. o.

2. A MESTERSÉGES INTELLIGENCIA ALKALMAZÁSÁNAK LEHETŐSÉGEI

Jelen fejezetben bemutatásra kerülnek a mesterséges intelligenciával kapcsolatos alapfogalmak, továbbá magának a kutatási területnek a szerepe és jelentősége napjainkban. A fejezetből megismerhetők a mesterséges intelligencia alaptípusai, azok főbb jellemzői, amely megismerése szükséges a tűzszerész támogató információs rendszer alapjainak megértéséhez.

2.1. Mesterséges intelligencia fogalma

Az elmúlt évek egyik leggyorsabban fejlődő ipari, gazdasági és társadalom befolyásoló informatikai alapú megoldása a mesterséges intelligencia, amely már napjainkban is az élet számos területén megtalálható elektronikai eszközök funkcióiba integrálva, vagy a különböző szoftverek részeként. Az MI fejlődésére és terjedésére napjainkban jellemző tendencia a következő években és évtizedekben nagy valószínűséggel egyre dinamikusabbá válik majd. Ennek, és az alkalmazási területek sokszínűségének is köszönhető, hogy a kutatók mindeddig hiába próbálták ezt a technológiát sokféleképpen, de egyetlen fogalommal megmagyarázni, a mai napig egyetlenesen érvényes és elfogadott fogalommeghatározás nem ismert.

A mesterséges intelligencia szókapcsolat nyelvtani elemzéséből kiindulva megállapíthatjuk, hogy míg a mesterséges⁸ szó egyértelműen valamilyen emberi beavatkozás vagy tevékenység eredményeként létrejött készítményt takar, az intelligencia szó jelentése már nehezebben behatárolható. A magyar nyelv értelmező szótára alapján jelentése⁹ fejlett értelmi, megértő ítélőképesség. Arisztotelész ókorból származó meghatározása alapján [11]: „Az intelligencia az igazságot megragadó megállapítás, beleértve a következtetést, amely ahhoz a tevékenységhez kapcsolódik, amely jó, vagy rossz egy ember számára. ...és ez megfelelőnek tűnik azután egy intelligens személy számára arra, hogy képes legyen finoman megítélni, mi a jó és előnyös számára; nem néhány korlátozott területre vonatkozóan (pl. ami jó az egészség, vagy az erő számára), hanem amely általában támogatja a jólétet.”¹⁰ Jól nyomon követhető ezen fogalom fejlődése és átalakulása az idő múlásával. Erre jó példa Marvin Minsky informatikus XXI. századi intelligencia meghatározása: „Az intelligencia egy gyakran használt

⁸ A magyar nyelv értelmező szótára: *mesterséges*. <https://www.arcanum.com/hu/online-kiadvanyok/Lexikonok-a-magyar-nyelv-ertelmezo-szotara-1BE8B/m-3C77D/mesterseges-3F751/?list=eyJmaWx0ZXJzIjogeyJNVSI6IFsiTkZPX0xFWF9MZxhpa29ub2tfMUJFOEliXX0sICJxdWVyeSI6ICJtZXN0ZXJzXHUwMGU5Z2VzIn0> (Letöltve: 2022.01.14.)

⁹ A magyar nyelv értelmező szótára: *intelligencia*. <https://www.arcanum.com/hu/online-kiadvanyok/Lexikonok-a-magyar-nyelv-ertelmezo-szotara-1BE8B/i-i-31843/intelligencia-32449/?list=eyJmaWx0ZXJzIjogeyJNVSI6IFsiTkZPX0xFWF9MZxhpa29ub2tfMUJFOEliXX0sICJxdWVyeSI6ICJpbmRibGxpZ2VzIn0> (Letöltve: 2021.09.28.)

¹⁰ Dr. Négyesi Imre: *A mesterséges intelligencia és a hadsereg I. rész*. HADTUDOMÁNYI SZEMLE X. évf. 2. szám, 2017. 25. o.

*fogalom annak a rejtélynek a kifejezésére, hogy néhány önálló elem, vagy elemek felelősek a személy következtetési képességéért. Én jobban szeretem úgy elképzelni ezt, mint amely nemcsak valami különös erőt, vagy tüneményt reprezentál, hanem egyszerűen az összes mentális képességet, amelyet mi minden pillanatban megcsodálhatunk, de még nem értettünk meg.*¹¹ Christopher F. Chabris meghatározásában már az MI-re is elfogadható meghatározást kapunk [12]: *„Mondhatnánk azt: Nem tudom megmondani, mi az intelligencia, de megismerem, ha találkozok vele. Az intelligencia olyan fogalom, amely jelentését a kontextusból, alkalmazási környezetéből nyeri, nem pedig egy felállított modellből, vagy kritériumrendszerből.*¹²

A szókapcsolat nyelvtani értelmezését követően térjünk át az MI konkrét fogalom meghatározásához, amely rendkívül sok párhuzammal kapcsolódik az előzőekben bemutatott intelligencia fogalom meghatározásokhoz. Az MI fogalma Cihan H. Dagli szerint: *„A gépi intelligencia emulálja, vagy lemásolja az emberi ingerfeldolgozást (érzéket-feldolgozást) és a döntéshozó képességet számítógépekkel. Az intelligens rendszereknek autonóm tanulási képességekkel kell bírniuk és alkalmazkodniuk kell tudni bizonytalan, vagy részlegesen ismert környezetekhez.*¹³ Ennél talán kézzelfoghatóbb és közérthetőbb a következő megfogalmazás [13]: *„Olyan hardver és szoftvertchnológiák összessége, amely képes önálló döntések meghozatalára tudományos érvek, vagy akár emberi gondolatok, reakciók, érzelmek figyelembevételével.*¹⁴

A mesterséges intelligencia tehát olyan számítógépeken futó programok összessége, amelyek célja az emberi gondolkodásmód és annak absztrakt, kreatív és deduktív alapokon nyugvó döntéseinek lemodellezése. [14] Ennek modellezése kétféleképpen történhet meg. Az emberi gondolkodású MI akkor jön létre, amikor az emberi elme és gondolkodás működése kerül modellezésre egy rendszeren belül. Ekkor a döntéshozatal az emberi gondolatok és érzelmek lemásolásával történik. A racionális gondolkodáson alapuló MI egzaktabb, konkrét adatokra támaszkodik. Ilyen akkor jön létre, amikor a cél nem az emberi viselkedés lehető legpontosabb utánzása, hanem a tudományos érvek alapján történő döntéshozatal. Ebben az esetben a döntés az adatok és tudományos érvek alapján, azok igazolásával születik meg. [15]

¹¹ Dr. Négyesi Imre: *A mesterséges intelligencia és a hadsereg I. rész.* HADTUDOMÁNYI SZEMLE X. évf. 2. szám, 2017. 25. o.

¹² Kovács György: *Gyártásautomatizálás és Robotika.* Pécsi Tudományegyetem, Műszaki és Informatikai Kar, Pécs, 2015. 24. o.

¹³ Dr. Négyesi Imre: *A mesterséges intelligencia és a hadsereg I. rész.* HADTUDOMÁNYI SZEMLE X. évf. 2. szám, 2017. 26. o.

¹⁴ Németh András, Virágh Krisztián: *Mesterséges intelligencia és haderő – A mesterséges intelligencia fejlődéstörténete I. rész.* HADITECHNIKA LVI. évf. 1. szám, 2022. 19. o.

Napjainkban a különböző tudományterületek és MI-t alkalmazó szakterületek általában a racionális gondolkodású változatot alkalmazzák, ugyanis elégséges a szoftvereknek egy adott szakterületen egy vagy néhány adott kérdésben döntést hozni. Éppen ezért ez a terület napjainkban sokkal előbbre is jár a fejlődésben, viszont az igazi, teljes értékű gondolkodást és problémamegoldást csak az emberi gondolkodású MI rendszerek létrehozásával lehet elérni. A jövő MI kutatásainak tehát középpontjában az emberi gondolkodás lemodellezése fog szerepelni. Ennek létrejötte viszont gyökeresen fogja megváltoztatni a mai ismert világunkat és technikai eszközeinket.

2.2. Funkcionalitás szerinti csoportosítás

A mesterséges intelligenciák mérhető tulajdonságaik alapján, mint a tudatosság és döntéshozatali képesség, 3 nagy csoportba sorolhatók [16]:

- Gyenge (keskeny) mesterséges intelligencia¹⁵;
- Erős (általános) mesterséges intelligencia¹⁶;
- Szuper (tudatos) mesterséges intelligencia¹⁷.

A gyenge vagy keskeny MI lényege, hogy előre meghatározott cselekvéssorozatok (algoritmusok) segítségével képes egy adott feladat önálló elvégzésére. Viszont ezen MI-nek nincsen öntudata, fejlődni és saját magát újfajta feladatok végrehajtására képezni még nem tudja. Ezért ezek az élet egy-egy speciális területén alkalmazhatók. Napjainkban a legtöbb MI-t alkalmazó területen ilyen gyenge szoftvereket használnak. Ezek gyakorlati megvalósítására szemléletes példát jelentenek az arc- vagy hangfelismerő, orvosi diagnosztikai, személyi asszisztens, internetes keresőmotor, fordító és email fiókok spamszűrését végző programok. [17]

Az erős vagy általános MI esetében a rendszer képes saját maga fejlesztésére, így újabb és egymástól független feladatokat lesz képes elvégezni az idő előre haladtával. Ezek a szoftverek már képesek az emberi értelemben vett intelligencia jellegzetességeit is megvalósító funkciók biztosítására, viszont nem rendelkeznek az emberre jellemző öntudattal. Napjainkban az MI-k ilyen szintű fejlettsége még nem elérhető. A Ray Kurzweil által fémjelzett legoptimistább becslés alapján is csak 2029-től lesz elérhető az erős MI, de a kutatók többsége csak 2060 körüli időszakra prognosztizálja a technológia megjelenését. Ennek további fejlődése valószínűleg már csak a kvantumszámítógépek elterjedésével válik elképzelhetővé. [15] [17]

¹⁵ Nemzetközileg használt megnevezése: Artificial Narrow Intelligence

¹⁶ Nemzetközileg használt megnevezése: Artificial General Intelligence

¹⁷ Nemzetközileg használt megnevezése: Artificial Super Intelligence

A szuper vagy tudatos MI megalkotásával már egy öntudattal rendelkező gondolkodni, érzelmeket kifejezni és problémákat elemezni, valamint megoldani képes szoftvert kapunk, amely kognitív képességei már túlmutatnak az emberi intelligencia hasonló képességein. Az MI ilyen szintre való fejlődése már az embernél komplexebb gondolkodás létrejöttét eredményezi, amelyet az emberiség joggal saját fennmaradása szempontjából veszélyként értelmezhet. Ezt az emberi fenyegetést érzékelve a tudatos MI is veszélyeztetve érezheti saját fennmaradását, ezzel mint egy végtelen körforgását megteremtve a kognitív gondolkodás trónjának elfoglalására irányuló ember és MI közötti hatalmi harcnak. A küzdelem reális kimenetele az emberi faj létének gyökeres megváltozása lehet. [15]

2.3. Gépi tanulás


A gépi tanulás az MI egy olyan részterülete, ahol matematikai adatmodellek (algoritmusok) segítségével történik az adatok elemzése és az erre épülő döntéshozatal. A gépi tanulás során az MI algoritmusok segítségével definiál különböző mintázatokat az adathalmazban (a tanulóhalmaz segítségével), amelyből adatmodelleket generál és így lesz képes abból előrejelzéseket (eredményeket) készíteni. Ennek következtében a meglévő adatok és az azokkal kapcsolatos tapasztalatok száma az idő előre haladtával (a gépi tanulása révén) folyamatosan növekszik, ezáltal sokkal pontosabbá válik az adatmodell és a feladatok végrehajtásának precizitása is. Ezt leginkább azzal lehet szemléltetni, hogy az ember egy adott tevékenység gyakorlása során a feladatot idővel sokkal eredményesebben képes végrehajtani. Az adathalmazra épülő mintázatok minél eredményesebb létrejöttéhez megfelelő mennyiségű és minőségű forrásra van szükség az alaphalmazban. Ezzel a folyamattal a gépi tanulás algoritmusai a meghatározott példák elemzésével létrejött modell segítségével ismeretlen adatokat tartalmazó elemek feldolgozására is képessé válik. A gépi tanulási technikák három különböző csoportba sorolhatók [18] [19]:

- felügyelt tanulás;
- nem felügyelt tanulás;
- megerősítéses tanulás.

2.3.1. Felügyelt tanulás

Felügyelt tanulás alkalmával (4. ábra) a tanulóhalmazban példapárok találhatók, amelyek adott bemeneti információk és azokhoz rendelt kimeneti változók kapcsolataiból állnak. Ez utóbbiakat címkének nevezik. A szoftver ezeknek a példapároknak a vizsgálatával állítja elő az adatmodelleket, amelyek a későbbi kimeneti változókat határozzák meg az adatfeldolgozás

után. Az algoritmus kívánt pontosságú működésének elérésével fejeződik be a gépi tanulás folyamata. Ezen pontosság vizsgálata két lépcsőben történhet. Első lépcsőben meg kell vizsgálni, hogy adott bemeneti értékekre tényleg helyes kimeneti értékeket ad-e az algoritmus. Második lépcsőben a példahalmazt kell kicserélni egy másik új adathalmazra, amin az algoritmus használatával kapott kimeneti értékek helyességét kell vizsgálni. Amennyiben mindkét lépcsőben helyes kimeneti változókat határoz meg az algoritmus, azt megfelelő tanítási szinttel rendelkezőnek lehet tekinteni. [15] [20]



4. ábra: Felügyelt tanulás elve¹⁸


A felügyelt tanulás módszerének segítségével kétféle típusú feladatot lehet hatékonyan megoldani. Ennek egyike az osztályozási feladat, amely során az adott értékeket különböző tulajdonságaik alapján definiált osztályokba helyezi, így kialakítva kettő (kétf csoportos osztályozás) vagy több csoportot (többcsoportos osztályozás). Ezt a folyamatot egyszerűen bemutató példa az email fiókok spam szűrője is, amely két csoportot képez a levelek között, fontos (not spam) és minden más (spam) kategória. A vizsgált tényező valamely osztályhoz tartozásának erőssége az osztályozási pontossággal jellemezhető, amely egy százalékos érték, így 0 és 100 közé eshet. A magasabb százaléktértek az erősebb adatartozást jelenti. [21] A másik feladattípus a regressziós problémákat képes megoldani. Ekkor a bemeneti adatok segítségével előre jósolhatóvá válik a kimenet, vagyis az előre következtethető eredmény. Ezek a kimeneti

¹⁸ Németh András, Virágh Krisztián: Mesterséges intelligencia és haderő – A mesterséges intelligencia területei III. rész. HADITECHNIKA LVI. évf. 3. szám, 2022. 3. o.

eredmények általában egy számszerű értékben, vagy mértékegységben jelennek meg. Nagyon jó példa erre egy autó piaci értékét meghatározó kalkulátor. A kalkulátor az autómárka, típus, évjárat, futott kilométer, felszereltség, szervizeltetés rendszeressége és hasonló kategóriájú gépjárművek alapján képes annak értékét egy konkrét összegben meghatározni. [15]

2.3.2. Nem felügyelt tanulás

Nem felügyelt tanulás esetén (5. ábra) a bemeneti változók között nincsen külsőleg meghatározott csoportosítás (címkézés), ennek eredményeként az algoritmus a bemeneti változókban keres mintaszerűséget és ez alapján hoz létre csoportokat és csoportosítja a beérkező információkat. A nem felügyelt tanulási folyamatokat ezért legeredményesebben társításos, vagyis asszociációs, illetve klaszterezési feladatok megoldására alkalmazhatjuk. Klaszterezés segítségével nagy adattömböket lehet homogén csoportba sorolni, ezzel csökkentve az adatok mennyiségét. [22]



5. ábra: Nem felügyelt tanulás elve¹⁹


2.3.3. Megerősítéssel tanulás

A megerősítéssel tanulás elvének (6. ábra) megértéséhez először meg kell határozni az ágens fogalmát. Az ágens egy szoftveralapú számítógépes rendszer, amely:

- önálló, tehát képes emberi felügyelet nélkül cselekedni és szabályozni saját reakcióit és állapotát;

¹⁹ Németh András, Virágh Krisztián: Mesterséges intelligencia és haderő – A mesterséges intelligencia területei III. rész. HADITECHNIKA LVI. évf. 3. szám, 2022. 4. o.

- személyisége van, tehát hiteles és valós emberszerű személyiségjegyekkel rendelkezik, amely lehetővé teszi az emberekkel történő kommunikációt;
- képes kommunikálni, tehát kapcsolatba tud lépni más ágensekkel, vagy emberi személyekkel információ szerzés érdekében;
- alkalmazkodóképes, tehát képes igazodni a használója vagy a külső környezetben történő változásokhoz, korábbi tapasztalatai alapján;
- mobilitással rendelkezik, tehát képes a számítógépek között saját maga átvitelére, függetlenül a rendszerarchitektúrától. [23]




6. ábra: Megerősítéses tanulás elve²⁰

A megerősítéses tanuláshoz a gép számára meg kell határozni különböző paramétereket, amelyek alapján a jövőben végre fogja hajtani cselekedeteit. Meg kell meghatározni azt a fizikai környezetet, ahol az ágens működik; minden olyan cselekvést, amit az ágens megtehet; a szituációs környezetet, amelyben az ágens dolgozik; azt a jutalmat, amit az utolsó cselekvés után a környezettől visszajelzésként kap; definiálni kell az ágens következő lépését adott helyzetben és meg kell határozni azt a hosszútávú jutalmat, amit meghatározott esemény során a helyes cselekvéssor a végrehajtására kap. [15]

A megerősítéses tanulás során az algoritmus a lehetséges kimeneteket próbálja végig, amelyekből a jutalmak, vagyis jó döntések és a büntetések, vagyis rossz döntések alapján

²⁰ Németh András, Virágh Krisztián: Mesterséges intelligencia és haderő – A mesterséges intelligencia területei III. rész. HADITECHNIKA LVI. évf. 3. szám, 2022. 4. o.

választja ki az ideális lehetőségeket. Ebben a tanulási folyamatban nincsen szükség tanulóhalmazokra vagy példapárookra, itt az algoritmus a környezetéből érkező külső ingereket használja fel a tanulás folyamatához. Ezt úgy is lehet értelmezni, mint egy sakkjátszmát, amelyben ha az MI veszít, azt büntetésként éli meg, ezért a következő játékra képes lesz fejlődni tanulva hibáiból. Ezzel a módszerrel idővel egy legyőzhetetlen sakkozó MI fejleszthető. [15]




7. ábra: Mesterséges neuron felépítése²¹

2.4. Mesterséges neurális hálózat

Az emberi agy és az idegsejtek szerves kapcsolódásainak komplex biológiai hálózatát a mesterséges neurális hálózat képes lemodellezni a szellemi térben. Az emberi agy egy neuronja több idegpályával is kapcsolódhat a többi neuronhoz, így kialakítva a neuronok több tíz milliárdos hálózatát, amelyek közül több millió is áthaladhat egy-egy adat, amire az agy információ feldolgozó részéhez érkezik. A mesterséges neurális hálózatok ezt a neuronhalmazt és a hozzá kapcsolódó idegpálya útvonalakat hivatottak lemodellezni. Ezek a mesterséges neuronok (7. ábra) az agy szerkezetét modellezzik le. A beérkező adatokat összegezik és előállítanak belőle egy kimenetet, amelyet aztán továbbítani tudnak a többi neuronnak. A mesterséges neuron tehát egy olyan nemlineáris, paraméterekhez kapcsolt összegző függvény, aminek változóit és értékeit a neuron bemeneteinek és kimeneteinek nevezik. [15]

²¹ Németh András, Virágh Krisztián: Mesterséges intelligencia és haderő – A mesterséges intelligencia területei III. rész. HADITECHNIKA LVI. évf. 3. szám, 2022. 5. o.

Egy-egy neuron több másik neuronhoz kapcsolódik, amely kapcsolódási vonalakon az információ csak egy irányban halad. Ezek a neuronok különböző rétegekben helyezkednek el (8. ábra) az információ terjedése szempontjából, így megkülönböztethető bemeneti, kimeneti és rejtett réteg. A bemeneti rétegben elhelyezkedő bemeneti neuronok feladata a jel továbbítása a hálózat irányába. A rejtett rétegben elhelyezkedő rejtett neuronok a bemeneti rétegen keresztül kapják meg a jelet, amelyen a tényleges adatfeldolgozást végzik. Innen kerül tovább a jel (információ) a kimeneti réteg kimeneti neuronjaihoz, amelyek azt a külvilág felé közvetítik. A rejtett neuronok a beérkező jeleket súlyozzák, vagyis súlytényezővel látják el, összegezik és nemlineáris függvényekkel egészítik ki, így jönnek létre a transzfer függvények. Gyakran használt transzfer függvények a lépcső-, a logisztikus és a tangens hiperbolikus függvények. Ennek a folyamatnak a végére a neuron létrehozza a saját információját, amelyet aztán továbbíthat a vele kapcsolódó neuronoknak, amik ugyan ezt a folyamatot végzik el rajta. Az információ így folyamatosan rétegről rétegre halad, ahol az egyes neuronok elvégzik a saját matematikai transzformációs feladataikat. A folyamat végére a kimeneti neuronokhoz ér a kész információ. Gyakori, hogy egy-egy rejtett réteg neuronjainak kimenetei az összes következő réteg neuronjainak bemeneteivel összeköttetésben vannak, ezért ezt a folyamatot mátrixok segítségével lehet a legkönnyebben leírni. [24]



8. ábra: Neurális hálózat rétegei kapcsolatának vázlata²²

²² What Is Deep Learning? 3 things you need to know. (é. n.). Internetes elérhetőség: <https://www.mathworks.com/discovery/deep-learning.html> (Letöltve: 2022.02.02.) alapján fordította a szerző.

A mélytanulás²³ jelenségét is fontos megismerni, mint a mesterséges neurális hálózatok²⁴ egyik fontos ágát. A mélytanulással képzett neurális hálózat főbb tulajdonsága, hogy kettő vagy több rejtett rétege van. Ezzel a tanulási folyamat végére létrejövő neurális háló rétegei és így az adatok elemzése sokkal mélyebb lesz. A mesterséges neurális hálózatok kutatásának nagy eredménye volt a mélytanulás kifejlesztése, ugyanis ezzel sokszorosára növelték a mesterséges intelligenciák pontosságát, hatásosságát és teljesítményét. [25]

A neurális hálónak több fajtája ismert, ezek közül a konvolúciós neurális hálózatokról²⁵ érdemes több szót ejteni a kutatás tárgya szempontjából.

2.5. Konvolúciós neurális hálózat

A mély neurális hálózatok egyik leggyakrabban használt típusa a konvolúciós neurális hálózat. Elsősorban kép, másodsorban video vagy hang feldolgozására lehet használni. Képpel történő alkalmazás során a kép adatait (pixeleit) veti össze a háló a meglévő mintákkal. A konvolúciós hálózatok szükségtelessé teszik a képek egyedi jellemzői közötti különbségek ember által történő meghatározását, így a készítőnek nem kell azonosítania a képek osztályozásához használt eltérő jellemzőket. A háló működése során közvetlenül a képek pixeleinek csoportjából vonja ki az információkat, ezáltal nincs szükség a háló előképzésére, az megtanulja és kialakítja a saját vizsgálati szempontrendszerét, miközben a betáplált képi adatbázison fejlődik. Ez az automatizált, kezelőtől független szempontmeghatározás teszi rendkívül pontossá a mélytanulási modelleket a gépi látási feladatokhoz, mint például az objektumok és tárgyak felismerése. [25] A képelemzés elvi működésének bemutatására a következő fejezetben kerül sor.

²³ Nemzetközileg használt megnevezése: Deep Learning

²⁴ Másnéven mély neurális hálózatokat.

²⁵ Nemzetközileg használt megnevezése: Convolutional Neural Network (CNN)

3. MESTERSÉGES INTELLIGENCIA ALAPÚ TŰZSZERÉSZ TÁMOGATÓ INFORMÁCIÓS RENDSZER

Mesterséges Intelligencia Alapú Tűzserész Támogató Információs Rendszer célja, hogy a tudomány jelen állása szerinti legkorszerűbb feltételeket nyújtsa a tűzserész műveletek irányításának és szervezésének támogatására. Ezt a vezetési támogatást a mesterséges intelligencia alapú képelemző szoftver biztosítja, amely valós idejű és szűrt, tehát megfelelően hitelesített adatokat biztosít a parancsnok részére a minél pontosabb és körültekintőbb döntéshozatalhoz. A rendszer gyakorlati felhasználására két területen, egyrészt a rendőr járőr, másrészt a tűzserész járőr tevékenysége során kerülhet sor.

A mesterséges intelligencia alapú szoftvert a lakossági bejelentést követően a kiérkező rendőr járőr tudná első lépésben felhasználni, aki ennek segítségével meghatározhatja a robbanótest kategóriáját (nyolc alapvető kategóriát különböztettem meg), illetve a tűzserész műveleti vezetés kérésére további csoport és alcsoport, tehát konkrét eszköz meghatározás is történhetne. Ennek, és az eszköz helyzetének ismeretében sokkal egyszerűbbé válna a robbanótest mentesítés prioritásának (sürgősségének) meghatározása, valamint következtetni lehetne a mentesítéshez szükséges alapvető felszereléseken (pl. robbanóanyag) túl az esetleges speciális eszközigényére (pl. csörlő, emelődaru, vegyvédelmi biztosítás) is. A fejlesztés egy későbbi szakaszát követően a tűzserész járőr feladatvégrehajtását is támogathatja a rendszer, amennyiben a hosszú tanítási folyamat eredményeként a tévesztés kockázata már minimálisra redukálódott. Ebben az esetben a felismerő szoftver önállóan képes lenne azonosítani a robbanótestet és egy tűzserész mentesítő robot vezérlésbe integrálva az képes lehet a hatástalanítás egyes meghatározott folyamatait autonóm módon végrehajtani.


A támogatás lényege, hogy a MH Tűzserész Ügyletre beérkező első információk az előtalált robbanótestről minél pontosabban behatárolják az előtalált eszköz kategóriáját és pontos típusát. Az így megszerzett információk alapján az eszköz veszélyességi foka sokkal pontosabban behatárolható. Illetve a feladatra küldhető, átirányítható járőrök felszerelésének, fogyóanyagjainak és robbanószer mennyiségének függvényében azok sokkal nagyobb precizitással, hatékonysággal irányíthatók át egyik feladatról a másikra. Ezek olyan képességek, amelyek akár már néhány éven belül is az MH 1. HTHE parancsnoki állománya számára átfogó és hiteles döntéstámogatást nyújthatnak.

3.1. Objektumfelismerés vagy képelemzés

Napjaink mesterséges intelligencia kutatásai legnagyobb számban az objektum felismerés vagy képelemzés témájában zajlanak. Az objektum felismerés kifejezést gyakran

szinonimaként használják a képelemzés és képfeldolgozás szavakra, de a két fogalom között van lényeges eltérés is. [26]

Az objektum felismerés fogalmát leggyakrabban azokra a szoftverekre kell érteni, amelyek élő képen, de inkább videó anyagon képesek kategorizálni és felismerni az előre betáplált alakzatokat. Ezek egymástól gyökeresen eltérő méretű, formájú, színű és egyéb tulajdonságú tárgyak, eszközök. Éppen ezért a program célja csupán a tárgyak egymástól történő megkülönböztetése (9. ábra) és nem az azonos tárgyak közötti különbségek vizsgálata. [27]



9. ábra: Objektum felismerés a valóságban²⁶

Ezzel szemben a képelemzés²⁷ lényege, hogy az egymással megegyező tárgyak, tárgykategóriák között az adatbázis felhasználásával a tanulási folyamat eredményeként a létrejövő neurális háló képes legyen minimális, apró színbeli, formabéli vagy más eltéréseket azonosítani, majd betanulni és így valamekkora bizonytalansággal a későbbiekben a felhasználás során meg is különböztetni azokat. Tehát a képelemzés már egy sokkal precízebb és pontosabb beazonosítást eredményez,²⁸ mint az objektum felismerés, de amennyiben a nagy

²⁶ Objektum felismerő (képfelismerő) AI megoldásunk, 2019. Internetes elérhetőség: <https://www.regens.com/hu/-/objektum-felismeres-kepfelismeres-mesterseges-intelligenciaval-bemutato-video> (Letöltve: 2022.02.23.)

²⁷ Nemzetközileg használt megnevezése: Image Processing


²⁸ A képelemzés két fajtáját különböztetik meg, az analóg és digitális felismerést. Analóg felismerés esetén egy elkészült kép egyes pontjaihoz, pixelihez rendelnek szín értéket, így a kép egy számokkal leírható adathalmazzá válik, ami utána már változtatható. Ezt a technológiát használják a régi képek vagy videók digitális újra színezéséhez. A digitális képek esetében pedig a képek pixelihez már alapvetően hozzá van rendelve egy adat (x, y koordináta és szín), így az átalakítás nem szükséges. [28]

eltérésekkel rendelkező objektumok valós idejű felismerése a cél, abban az esetben az objektumfelismerés eszközeinek alkalmazása a leghatékonyabb megoldás. [29]

3.2. Képelemzés elvi működése

A konvolúciós neurális hálóról (CNN) korábban már esett szó, ezúttal pedig célszerű azok működési elvét is megvizsgálni (10. ábra), hogy megértsük szerepüket a képelemzés területén. A konvolúciós hálózatok jelentősen eltérnek a többi neurális háló típustoktól. Ez leginkább azzal magyarázható, hogy ezeket a hálókat kifejezetten képi felismerésre fejlesztették ki. [30]

Fő előnye elődeihez képest, hogy emberi felügyelet nélkül, automatikusan is képes felismerni a fontosabb eltéréseket. Például macskákról és kutyákról készült képek alapján képes megtanulni az egyes csoportok jellegzetes vonásait, így azokat meg tudja különböztetni egymástól. Minden CNN modell hasonló architektúrát követ, amint az az alábbi ábrán látható. [25]



10. ábra: Konvolúciós folyamatok²⁹

Az elemzésre váró kép a rendszer bemeneti információja, ez az input. A háló a kép egyes kijelölt részeiről egy számot generál a konvolúció matematikai formuláival. A konvolúciós műveletek összekapcsolódásával, azok sorozataként jön létre a neurális háló, amelyet számos teljesen összekapcsolt réteg alkot. A folyamat végén, az osztályozás (többosztályos) során létrejön a kimenet, a softmax. A CNN fő eleme a konvolúciós réteg. A konvolúció egy matematikai művelet két információhalmaz összevonására. Esetünkben a konvolúciót a bemeneti adatokra alkalmazzuk egy konvolúciós szűrő segítségével, így létrejön a jellemzőtérkép. [31]

²⁹ Arden Dertat: *Applied Deep Learning - Part 4: Convolutional Neural Networks*, 2017. Internetes elérhetőség: <https://towardsdatascience.com/applied-deep-learning-part-4-convolutional-neural-networks-584bc134c1e2> (Letöltve: 2022.03.02.) alapján fordította a szerző.

1	1	1	0	0
0	1	1	1	0
0	0	1	1	1
0	0	1	1	0
0	1	1	0	0

11. ábra: Konvolúció bemenete³⁰

1	0	1
0	1	0
1	0	1

12. ábra: Kernel³¹

A példa kedvéért a 11. ábrán látható konvolúciós réteg a bemeneti kép, míg a 12. ábrán a konvolúciós szűrő, az úgynevezett kernel. A szűrő alakja miatt a példában bemutatott folyamatot 3×3 -as konvolúciónak nevezik. A konvolúciós műveletet úgy hajtjuk végre, hogy ezt a szűrőt a bemenetre helyezzük. Minden helyen elemenkénti mátrixszorzást végzünk a kernelben és a bemenetben található értékekre, majd az eredményt összegezzük. Ez az összeg kerül be a jellemzőtérképbe. Azt a zöldterületet, ahol a konvolúciós művelet végbemegy, receptív mezőnek nevezzük. A szűrő méretéből adódóan a receptív mező is 3×3 -as méretű. A 13. ábrán látható, ahogy a szűrő a bal felső sarokban van, a mátrixműveletek elvégzése után pedig a konvolúciós művelet kimeneteként a jellemzőtérképen megjelenik a „4” kapott érték (14. ábra). Ezután jobbra kell csúsztatni a kernelt, és végre kell hajtani ugyanazt a műveletet, hozzáadva az eredményt a jellemzőtérkéhez. Ezt a metódust folytatva elkészül a teljes térkép (15. ábra). [31] [32]

³⁰ <https://towardsdatascience.com/applied-deep-learning-part-4-convolutional-neural-networks-584bc134c1e2>
(Letöltve: 2022.03.02.) alapján a szerző saját szerkesztése

³¹ <https://towardsdatascience.com/applied-deep-learning-part-4-convolutional-neural-networks-584bc134c1e2>
(Letöltve: 2022.03.02.) alapján a szerző saját szerkesztése

1×1	1×0	1×1	0	0
0×0	1×1	1×0	1	0
0×1	0×0	1×1	1	1
0	0	1	1	0
0	1	1	0	0

13. ábra: Bemenet és a kernel³²

4		

14. ábra: Jellemzőtérkép részlet³³

4	3	4
2	4	3
2	3	4


15. ábra: Teljes jellemzőtérkép³⁴

A példa szerinti konvolúciós művelet két dimenzióban (2D) került bemutatásra, 3×3-as szűrő használatával, de a tényleges felhasználás során ezeket a konvolúciókat három dimenzióban (3D) hajtják végre. A valóságban egy kép 3D-s mátrixként jelenik meg magassággal (y koordináta), szélességgel (x koordináta) és mélységgel, ahol a mélység a színcsatornáknak (RGB) felel meg. A konvolúciós szűrőnek meghatározott magassága és szélessége van, például 3×3 vagy 5×5, és kialakításánál fogva lefedi a bemenet teljes mélységét, ezért is kell 3D-snek lennie. Az eredményes vizsgálathoz több konvolúciót kell végrehajtani egy bemeneten, mindegyik esetben más-más szűrőt használva, amely így eltérő jellemzőtérképet eredményez. Ezt követően egyesíteni kell ezeket a jellemzőtérképeket, és ez lesz a konvolúciós réteg végső kimenete. A következő ábrákon egyetlen szűrő alkalmazásával készült folyamatra láthatunk példát. [31]

³² <https://towardsdatascience.com/applied-deep-learning-part-4-convolutional-neural-networks-584bc134c1e2> (Letöltve: 2022.03.02.) alapján a szerző saját szerkesztése

³³ <https://towardsdatascience.com/applied-deep-learning-part-4-convolutional-neural-networks-584bc134c1e2> (Letöltve: 2022.03.02.) alapján a szerző saját szerkesztése


³⁴ <https://towardsdatascience.com/applied-deep-learning-part-4-convolutional-neural-networks-584bc134c1e2> (Letöltve: 2022.03.02.) alapján a szerző saját szerkesztése



16. ábra: 3D konvolúció³⁵

Tegyük fel, hogy van egy $32 \times 32 \times 3$ -as képünk, és egy $5 \times 5 \times 3$ -as kernelt használunk, azaz a konvolúciós szűrő mélysége megegyezik a kép mélységével. A szűrő egy adott helyen lefedi a bemenet egy kis részét, itt végrehajtja a fent leírt konvolúciós műveletet. Az egyetlen különbség az, hogy ezúttal a mátrixszorzás összegét 3D-ben végezi és nem 2D-bent, de az eredmény továbbra is műveletenként egy-egy skalár. A bemeneten a szűrő áthelyezésével (a fenti módon) minden helyen megtörténik a konvolúció, amely eredményét a jellemzőtérkép összesíti. Ez a jellemzőtérkép $32 \times 32 \times 1$ méretű, a 16. ábra jobb oldalán piros szeletként látható. Ha 10 különböző szűrőt használnak, akkor 10 db $32 \times 32 \times 1$ méretű tereptérképet kapnánk, és ezeket a mélységi dimenzió mentén egymásra rakva megkapnánk a konvolúciós réteg végső kimenetét: egy $32 \times 32 \times 10$ méretű 3D mátrixot, amely a 16. ábra jobb oldalán nagy kék dobozként látható. A tereptérkép magassága és szélessége változatlan, azaz továbbra is 32, ami a kitöltésnek köszönhető. A 17. ábrán az látható, hogyan készül két jellemzőtérképe a mélységdimenzióban eltolva egymástól. Az egyes szűrők konvolúciós műveleteit egymástól függetlenül hajtják végre, és az eredményül kapott jellemzőtérképek diszjunktak, vagyis nincs közös részük. [31]

³⁵ Arden Dertat: *Applied Deep Learning - Part 4: Convolutional Neural Networks*, 2017. Internetes elérhetőség: <https://towardsdatascience.com/applied-deep-learning-part-4-convolutional-neural-networks-584bc134c1e2> (Letöltve: 2022.03.02.)




17. ábra: 3D konvolúció mélységi eltolással³⁶

A konvolúció után általában pooling (összehúzás) művelet történik a magasság és a szélesség csökkentése érdekében. Ez lehetővé teszi a paraméterek számának csökkentését, ami egyrészt lerövidíti a tanulási folyamat idejét, másrészt pedig a túltanulás kockázatát csökkenti. Az egyesített rétegek külön-külön leképezik az egyes tereptárgyak jellemtérképét, csökkentve a magasságot és a szélességet, a mélységen viszont nem változtatnak. A leggyakrabban használt összehúzó eljárás a max pooling, amely azt jelenti, hogy a pooling ablakban található maximális értéket veszi fel az adott terület értékének. A konvolúciós művelettel ellentétben a poolingnak nincsenek paraméterei. Egy ablakot csúsztat a bemenete fölé, és egyszerűen felveszi az ablakban található értékek közül a maximális értéket. A konvolúcióhoz hasonlóan meg kell határozni az ablak méretét és lépésszámát. Példaként egy 2×2 -es ablak és 2-es lépésszámú³⁷ összevonás eredménye látható a 18. ábrán. Minden szín más ablakot jelöl. Mivel mind az ablak mérete, mind a lépésszám 2, az ablakok nem fedik egymást. Ennek a folyamatnak a célja, hogy csökkenjen a jellemtérkép szélessége és magassága. Összehasonlítva a jellemtérkép méreteit az összevonás előtt és után azt kapjuk, hogy ha a gyűjtőréteg bemenetének mérete pl. $32 \times 32 \times 10$ volt, akkor a pooling paraméterek használatával az eredmény egy $16 \times 16 \times 10$ -es jellemzőtérkép lesz. A térkép magassága és szélessége is a felére csökken, de a mélység nem változik, mert a pooling egymástól függetlenül működik a bemenet minden egyes mélységi szeletén. A bemeneti kép 2D koordinátái (súlyok) száma negyedére csökkent. Figyelembe véve, hogy a konvolúciós hálók általában több millió súllyal dolgoznak, nagyon fontos az adattömeg

³⁶ Arden Dertat: *Applied Deep Learning - Part 4: Convolutional Neural Networks*, 2017. Internetes elérhetőség: <https://towardsdatascience.com/applied-deep-learning-part-4-convolutional-neural-networks-584bc134c1e2> (Letöltve: 2022.03.02.)

³⁷ Az ablak kettő egységet mozog oldalra. Ezt az értéket konvolúció során érdemes 1-nek hagyni, pooling során pedig többnek is lehet, amennyiben megegyezik az ablak méretével nem lesz átfedés az ablakok között.

csökkentése. A CNN architektúrákban a pooling rendszerint 2×2 ablakkal és 2 lépéssel, míg a konvolúció 3×3 -as ablakkal, 1 lépéssel történik. [31] [32] [33]



18. ábra: Max pooling³⁸

A teljes felismerési folyamat nagyrészt ezekből az alapfolyamatokból áll, kiegészülve még olyan tevékenységekkel, amelyekről terjedelmi megfontolás miatt a dolgozatban ezúttal nem esik szó, de alapvetően ezeknek az értékeknek az összehasonlításán alapszik a képi felismerés elve. Tehát a mintahalmaz ilyen módon létrejövő értékei kerülnek összehasonlításra a bemeneti kép értékével, ami alapján a mesterséges intelligencia meghatározza, hogy a kép melyik csoportba tartozik.

3.3. Szoftveres háttér


Mivel műszaki hallgatóként programozási ismereteket nem tanulunk, ezért nagyon fontos volt egy olyan szoftver keresése, amely megfelelő hatásfokkal és pontossággal dolgozik, mégis kevés programozási ismeretre van szükség használatához. Az MI Koalíció Bevezetés a Mesterséges Intelligencia világába című kurzusát hallgatva ismertem meg a „Teachable Machine” alkalmazást, amit a kutatás során is használtam.

A Teachable Machine egy webalapú eszköz a Google fejlesztése, amely gyors és egyszerű használatot biztosít, így mindenki számára elérhetővé teszi a gépi tanulási modellek létrehozását akár kép, zene vagy testhelyzetek felismerésére van szükség. A webes alkalmazás első verzióját 2017-ben ismerhették meg a felhasználók. Azóta számos fejlesztés és javítás történt nemcsak a grafikus kezelőfelületen, hanem a neurális hálókészítés beállításainak lehetőségeiben, valamint a hálóképzés sebességében és pontosságában is. Segítségével képfelismerő algoritmus készíthető a készülék kamerája, vagy a meglévő fényképek

³⁸ Arden Dertat: *Applied Deep Learning - Part 4: Convolutional Neural Networks*, 2017. Internetes elérhetőség: <https://towardsdatascience.com/applied-deep-learning-part-4-convolutional-neural-networks-584bc134c1e2> (Letöltve: 2022.03.02.)

használatával. Képes hangok és dallamok felismerésére is, mikrofon vagy hangfájlok alkalmazásával, továbbá képessé tehető az emberi mozdulatok és testtartások felismerésére valós időben webkamera segítségével. [34]

A neurális háló képzése három egyszerű lépésben történik, amelyek a következők: adatgyűjtés és osztályozás, modellképzés és az elkészült modell exportálása, felhasználása. Adatgyűjtés során egy megfelelő mennyiségű és minőségű adattal feltöltött halmazt kell létrehozni (ezek a kívánt tevékenység alapján állhatnak kép, hang vagy videófájlokból). A feltöltött elemeket csoportosítani szükséges, ami a példák osztályokba vagy kategóriákba rendezést jelenti, ezeket kell majd a neurális hálónak megtanulnia. Az adatbázis feltöltése történhet a webkamerával valós időben készített képekből, a Google Driveről,³⁹ illetve adattáróló eszközökről 'png', 'jpeg', vagy 'bmp' kiterjesztéssel (19. ábra). A képeket a program automatikusan négyzet alakúra vágja ki. Kétféle feltöltési lehetőség közül lehet választani, 240 × 240 pixel méretű színes képek vagy 96 × 96 pixel méretű fekete-fehér képek. Természetesen a jobb képminőség és színes adathalmaz jobb felismerhetőséget is eredményez, így ajánlott ezzel a módszerrel használni az alkalmazást. [34]




19. ábra: Adatok osztályokba rendezése⁴⁰

³⁹ A Google Drive egy fájlok tárolását, szinkronizálását és szerkesztését lehetővé tevő szolgáltatás, amelyhez minden Google fiókkal rendelkező felhasználó számára 15 GB felhőalapú tárhelyet biztosít a cég.

⁴⁰ Teachable Machine, (é. n.). Internetes elérhetőség: <https://teachablemachine.withgoogle.com/> (Letöltve: 2022.02.21.)

Modellképzés során (20. ábra) a tanítás gombra kattintva, megkezdődik a tanulási folyamat, amelyhez a rendszer nem a saját számítógép erőforrásait használja fel, hanem a Google szervereit, így minimalizálva a felhasználó hardverigényét és maximalizálva a feladat elvégzésének sebességét. A tanítás során két változó értékét lehet állítani, az epoch⁴¹ és batch size⁴² változókat. A rövid időn belül elkészülő modell azonnal tesztelhetővé válik, így hamar megállapítható, hogy a modell képes-e megfelelően besorolni az új teszt példákat. A pontosság vizsgálathoz próbafájlokat lehet készíteni a webkamera segítségével vagy azok fel is tölthetők adattárolókról. Az alkalmazás a tesztfájltra vetítve meghatározza, hogy az egyes csoportokkal, osztályokkal milyen százalékos arányban egyezik meg a tartalom. A modell exportálása, felhasználása során az elkészült neurális háló különböző formátumokban (Tensorflow.js, Tensorflow [Keras] és Tensorflow Lite) kimenthető az alkalmazásból (21. ábra), hogy azt a különböző projektekben lehessen alkalmazni. Egy ilyen plusz felhasználási lehetőséget biztosít a Google is, így az Android operációs rendszerekkel rendelkező telefonokra alkalmazást lehet programozni a kapott mesterséges intelligencia használatára. [34]




20. ábra: Modellképzés⁴³

⁴¹ Egy epoch a mintahalmaz egyszeri végigfuttatása a neurális hálón. Ha például ez az érték 50, akkor 50 esetben fut végig a minta feldolgozása és a súlyozás. A kis epoch szám alul tanított, a nagy epoch szám túltanított neurális hálót eredményez. De alapvetés, hogy minél nagyobb az epoch szám, várhatóan annál jobb modellt kapunk.

⁴² A batch size lényege, hogy egy tanulási ciklusban meghatározott számú képet tanítunk be a neurális hálónak. Ha a tanulóhalmaz 80 képet tartalmaz és a batch size 16, akkor $80 \div 16 = 5$ batch-be lesz szétosztva a 80 kép. Ha mind az 5 batch átment a tanulás folyamatán, akkor kész egy epoch. Ha az 5 batch kétszer is átmegy a tanulási folyamaton, akkor kész kettő epochs és így tovább.

⁴³ Teachable Machine, (é. n.). Internetes elérhetőség: <https://teachablemachine.withgoogle.com/> (Letöltve: 2022.02.21.)



21. ábra: Modell exportálása és letöltése⁴⁴

A Teachable Machine használatával készült például egy apró tárgyak osztályozására képes robotmechanizmus a Tiny Sorter,⁴⁵ az Euphonia projekt keretében az atipikus beszéddel küzdők segítségét szolgáló MI,⁴⁶ vagy a Teachable Snake játékban, ahol egy papírlap lesz a játékos irányító eszköze.⁴⁷

A program megfelelő működéséhez és használatához szükség van a már sokszor említett nagyméretű képi adatbázishoz, aminek kialakításához a MH 1. HTHE laktanyájában, a „barakk” nevű kiképzőteremben készítettünk fényképeket. A továbbiakban az általam használt adatbázisról lesz szó.

3.4. Képi adatbázis

A képfelismerő vagy konvolúciós neurális hálózatok tanulási folyamatának elengedhetetlen részét, kiindulási alapját jelenti egy megfelelő minőségű, részletességű, pontos és hiteles forrásból származó képi adatbázis. Az adatbázissal szemben támasztott követelmény továbbá, hogy minden eszközről (felismerendő tárgyról) közel azonos számú képet tartalmazzon. Ezzel elkerülhető a túltanítás jelensége, ami akkor jön létre, ha egy adott tárgyról


⁴⁴ Teachable Machine, (é. n.). Internetes elérhetőség: <https://teachablemachine.withgoogle.com/> (Letöltve: 2022.02.21.)

⁴⁵ <https://learn.adafruit.com/machine-learning-with-marshmallows-and-tiny-sorter> (Letöltve: 2022.02.21.)

⁴⁶ <https://www.laptopmag.com/features/project-euphonia-help-people-with-atypical-speech> (Letöltve: 2022.02.21.)

⁴⁷ <https://teachable-snake.netlify.app/> (Letöltve: 2022.02.21.)

arányaiban nagyon sok, egy másik tárgyról arányaiban kevés kép kerül az adatbázisba. Így a kiépült neurális hálózat arányai eltolódnak és az mindenben azt a tárgyat fogja felismerni, amelyikről a jelentősen több kép készült.



22. ábra: Aknagránát szerkezete⁴⁸

Ezt elkerülendő minden eszközről azonos számú és háttérrel rendelkező fotó került felhasználásra. Alapelveként szolgált a minél nagyobb adatbázis létrehozása, amely szűrése irodai körülmények között sokkal kedvezőbb, mint több fényképezés leszervezése. Az aknagránátok kategóriájába tartozó eszközökről kép készült: oldalról, előlről, hátulról, felülről és ezeket kiegészítve eltérő, ferde szögekből, összesen 7 állásból. Háttérként is kétféle textúra jelent meg a képeken, egy teljesen fehér „műteremi” és egy természetesebb füves növényzettel

⁴⁸ Lődi Antal: *Katonai robbanótestek alapismerete, szerkezete*. Jegyzet. Budapest, 2010. 59. o.

borított talaj. Az adatbázis és a későbbi tanítási folyamat során kétféle formában kerültek a képek feltöltésre. Eredeti fotóként, amelyen a céltárgy kb. 20%-át foglalta csak el a teljes képfelületnek, illetve egy kivágott formátumban, amelyen a céltárgy kitöltési arány már 70–80% volt.

1 Aknagránátok	1.1 Kis űrméretű (5-6 cm)	
	1.2 Kis űrméretű (8 cm)	
	1.3 Közepes űrméretű (12 cm)	
2 Tüzérségi gránátok	2.1 Páncéltörő gránátok	2.1.1 Kis űrméretű (-75 mm)
		2.1.2 Közepes űrméretű (75-155 mm)
		2.1.3 Nagy űrméretű (155- mm)
	2.2 Repesz gránátok	2.2.1 Kis űrméretű (-75 mm)
		2.2.2 Közepes űrméretű (75-155 mm)
		2.2.3 Nagy űrméretű (155- mm)
	2.3 Romboló gránátok	2.3.1 Kis űrméretű (-75 mm)
		2.3.2 Közepes űrméretű (75-155 mm)
		2.3.3 Nagy űrméretű (155- mm)
	2.4 Repesz-romboló gránátok	2.4.1 Kis űrméretű (-75 mm)
		2.4.2 Közepes űrméretű (75-155 mm)
		2.4.3 Nagy űrméretű (155- mm)
3 Kézi tüzérség eszközei	3.1 Aktív hajtómóvel	
	3.2 Hajtómó nélkül	
4 Puskagránátok és gránátvetők	4.1 Puskagránátok	
	4.2 Gránátvetők	
5 Kézigránátok	5.1 Gömbölyded	
	5.2 Hengeres	
	5.3 Nyéllel ellátott	
6 Bombák	6.1 Szabadeséső bombák	
	6.2 Fékezett bombák	
	6.3 Laser-vezérléső bombák	
7 Aknák	7.1 Gyalogsági aknák	7.1.1 Földfelszín alá helyezett aknák
		7.1.2 Irányított hatású repesztöltetek
	7.2 Harckocsi aknák	
	7.3 Vízi aknák	
8 Rakéták	8.1 Föld-föld	
	8.2 Föld-levegő	
	8.3 Levegő-föld	
	8.4 Levegő-levegő	

23. ábra: Képi adatbázis felépítése

Az adatbázis hitelességéhez kétség sem férhet, ugyanis minden fotó az MH 1. HTHE laktanyájának tüzserész kiképző termében készült, ahol több ezer hatástalanított, mára kiképzési anyag, makett szerepet betöltő hatástalanított robbanótest található. A tudományos diákköri kutatás keretében ezeknek egy szűkebb csoportja az aknagránátok részletesen, de nem a teljesség igényével kerültek befotózásra (22. ábra). Bár ezek az eszközök oktatási célokat

szolgálnak egykor élesek voltak, így a hatástalanítási eljárás következményeként csak annyival térnek el a máig földben szunnyadó társaiktól, hogy nincs bennük robbanóanyag, illetve pirotechnikai anyag. A hiteles képi adatbázis létrejöttének támogatásához ezúton is szeretnék köszönetet mondani a MH 1. HTHE vezetésének.

A Mesterséges Intelligencia Alapú Tűzszerész Támogató Információs Rendszer alapját a már sokszor tárgyalt képi adatbázis jelenti. Ahhoz, hogy megfelelő hatásfokkal működjön a rendszer, az eszközök fotóinak logikus és egyértelmű csoportosítására van szükség az adatbázisban. Ennek érdekében készítettem egy olyan mappaszerkezetet, amelyben a tűzszerész szakmában is bevált osztályozási rendszer egyes elemeit használtam fel. Így minden robbanótestet 8 db kategóriába soroltam. Az egyes kategóriákba tartozó eszközök között rendeltetés, forma, méret és felépítésbeli különbségek vannak, amelyek alapján nagyon pontosan elhatárolhatók egymástól. A kategóriákat 1-től 8-ig számoztam a 23. ábra alapján. A kategóriákon belül csoportokat különböztettem meg, amelyek az űrméretre vagy a kialakítás sajátosságára utalnak elsősorban. Ezek viselik a kategória és a saját, kategórián belüli számukat is. A további alcsoportokra történő bontás már nem történt meg mindegyik csoportban, ahol mégis van ilyen, annak a száma viseli a kategória, a csoport és a saját, csoporton belüli számukat is.

Az alcsoporton belül helyezkednek el a konkrét robbanótestek, amelyek az előző rendszer alapján újabb számot kapnak a kategória, csoport és esetleges alcsoport számok mellé. Ezt az elvet folytatva minden egyes robbanótestről készült kép is kaphat egy hivatkozási számot, így azoknak felső határa nincsen. A tanulóhalmazba készített és a tesztképek között az a különbség, hogy a tesztképek száma elé egy T betű kerül, ezzel ezeknek a fotóknak a száma is korlátlanul növelhető.

Az aknagránátokról készült képek 3 fő csoportba kerültek besorolásra az űrméretük alapján. Ezek a csoportok az 5–6 cm-es, a 8 cm-es és a 12 cm-es. A fő csoporton belül található az alcsoportok, amelyek már az aknagránátok pontos, rendszeresített nevét jelentik. Tehát az aknagránátok képi adatbázisa kétszintes felépítéssel rendelkezik (24. ábra).

Az 5–6 cm-es eszközökből négy különböző nemzet robbanóteste került bele a képzési adathalmazba. Minden egyes eszközről 28 db fénykép került be az adatbázisba. Ennek közel a fele egységes fehér háttér előtt, másik fele természetes környezetben talaj háttérrel készült. Alapvetően az eszközök tetejéről (gyújtóról), oldaláról és a végéről (stabilizátorszárnyról) készültek a képek merőleges vagy közel 45°-os szögben. A gyakorló adathalmazban a teljes alakú képek mellett részletképek is találhatóak az egyes jobban azonosítható és felismerhető részletekről, mint a fej- és hengeres részek, illetve a stabilizátor részről.

1.1 Kis űrméretű (5-6 cm)	1.1.1 Wgr. 36 (német)
	1.1.2 39M (magyar)
	1.1.3 Md. 35 (román)
	1.1.4 O-822 (szovjet)
1.2 Kis űrméretű (8 cm)	1.2.1 Wgr. 34 (német)
	1.2.2 36M (magyar)
	1.2.3 57-V-003 (magyar)
	1.2.4 Md. 35 (román)
	1.2.5 O-832 (szovjet)
	1.2.6 O-832D (szovjet)
	1.2.7 O-832DU (szovjet)
	1.2.8 Sz-832 (szovjet)
1.3 Közepes űrméretű (12 cm)	1.3.1 Wgr. 42 (német)
	1.3.2 43M (magyar)
	1.3.3 Román repesz-romboló (román)
	1.3.4 OF-843 (szovjet)

24. ábra: Aknagránátok csoportosítása

A 8 cm-es csoportban hasonlóan négy különböző nemzet aknagránátjai találhatók, de azokból több rendeltetésű is bekerült az adatbázisba. Ebben a csoportban 32 db kép került bele a tanulóhalmazba minden eszközről. Itt is hasonló elvek alapján körülbelül azonos szögekből készültek a fotók. Illetve egy fekvő 45°-os oldalsó szögből is készült fénykép, ennek az adathalmaz bővítése volt a célja, ugyanis ebben a csoportban nyolc, tehát kétszer annyi eszközt kell tudnia megkülönböztetni a neurális hálónak a másik két csoporthoz képest.

A 12 cm-es aknagránátoknál négy eszköz került kiválogatásra négy különböző nemzet egykori hadrendjéből. Itt minden eszközről 30 db kép került kiválogatásra, hasonló elvek mentén, ahogy az az előzőknél történt. Viszont az eszközök fizikai méretei, illetve tömege jelentősen megnehezítette a munkát a képi adatbázis készítése során. A nagyságrendileg 80 cm hosszú eszközök mozgatása és pozícionálása nehézkes volt, illetve kiemelt figyelmet követelt, hogy az egységes fehér háttérből se lógjon ki az eszköz a fényképezés során.

3.5. Neurális háló és komponenseinek jellemzése, a meghatározás pontosságának mérése

A kutatás fő eredményeként létrehoztam három olyan neurális hálót a képi adatbázis felhasználásával, amelyek az aknagránátok kategória csoportjában (5–6 cm, 8 cm, 12 cm) képesek különböző pontossággal felismerni az abban található eszközöket. Mindegyik kategória neurális hálóját többször, eltérő epochs és batch size paraméterekkel tanítottam, így

a tesztképek segítségével meg tudtam határozni a vizsgált párosítások közül a kategóriához legjobban illő arányokat. Epochs számban 100, 200, 500, 1000, 2000, 5000 és 10000 értékekkel dolgoztam, alapvetően 16-os batch size-al. Három esetben, 200, 1000 és 5000 értékeknél 32-es batch size-al is betanítottam a neurális hálót. A háló teszteléséhez különböző számú képet használtam fel, amelyek a két fényképezés során készültek. Ezek között volt olyan, amelyik a padlón vagy tanteremi asztalon ferdeszögből készült, illetve kültéri helyszínen, falevelekkel és növényzettel néhol fedett, eltérő szögekből készített fotók is a tesztalmaz részét képezték.

	Wgr. 36	39M	Md. 35	O-822	Összesen
Tesztképek száma	6	6	5	7	24
Epochs 100					
Helyes/helytelen	3/3	5/1	5/0	6/1	19/24
Helyesség aránya	83.3%	83.3%	100%	85.7%	79.2%
Epochs 200					
Helyes/helytelen	5/1	1/5	5/0	6/1	17/24
Helyesség aránya	83.3%	16.6%	100%	85.7%	70.8%
Epochs 200 Batch size 32					
Helyes/helytelen	5/1	3/3	5/0	6/1	19/24
Helyesség aránya	83.3%	50%	100%	85.7%	79.2%
Epochs 500					
Helyes/helytelen	5/1	2/4	5/0	6/1	18/24
Helyesség aránya	83.3%	33.3%	100%	85.7%	75%
Epochs 1000					
Helyes/helytelen	5/1	4/2	5/0	6/1	20/24
Helyesség aránya	83.3%	66.7%	100%	85.7%	83.3%
Epochs 1000 Batch size 32					
Helyes/helytelen	5/1	2/4	5/0	6/1	18/24
Helyesség aránya	83.3%	33.3%	100%	85.7%	75%
Epochs 2000					
Helyes/helytelen	5/1	4/2	5/0	6/1	20/24
Helyesség aránya	83.3%	66.7%	100%	85.7%	83.3%
Epochs 5000					
Helyes/helytelen	5/1	1/5	5/0	6/1	17/24
Helyesség aránya	83.3%	16.6%	100%	85.7%	70.8%
Epochs 5000 Batch size 32					
Helyes/helytelen	5/1	4/2	5/0	5/2	19/24
Helyesség aránya	83.3%	66.7%	100%	71.4%	79.2%
Epochs 10000					
Helyes/helytelen	5/1	2/4	5/0	5/2	17/24
Helyesség aránya	83.3%	33.3%	100%	71.4%	70.8%

25. ábra: Mérési eredmények 5–6 cm-es aknagránátok esetén

A 6 cm-es csoportban 4 db eszköz⁴⁹ megkülönböztetése volt a cél. Ahogy az az eredményekből is szemléletesen látszik, viszonylag kis szórása lett a különböző epochs és batch size értékek párosításának. Ez a szórás számszerűen 12,5%. A legsikeresebb 83,3%-os 20/24-es eredményt⁵⁰ két hálóval is sikerült elérni, továbbá csupán eggyel kevesebb helyes megoldás is három esetben született. Ezzel stabilan elérve a kitűzött minimum 70%-os célt (25. ábra). Mivel a két legsikeresebb háló közül ki kell választani egyet, így az 1000 epochs és 16-os batch size kombinációt használok a továbbiakban, mivel ez gyorsabban tanítható.

	Wgr. 34	36M	57-V-003	Md. 35	O-832	O-832D	O-832DU	Sz-832	Összesen
Tesztképek száma	5	5	5	5	5	3	5	5	38
Epochs 100									
Helyes/helytelen	2/3	3/2	3/2	3/2	3/2	0/3	2/3	2/3	18/38
Helyesség aránya	40%	60%	60%	60%	60%	0%	40%	40%	47.4%
Epochs 200									
Helyes/helytelen	1/4	4/1	3/2	3/2	3/2	0/3	4/1	2/3	20/38
Helyesség aránya	20%	80%	60%	60%	60%	0%	80%	40%	52.6%
Epochs 200 Batch size 32									
Helyes/helytelen	3/2	3/2	3/2	2/3	3/2	0/3	3/2	1/4	18/38
Helyesség aránya	60%	60%	60%	40%	60%	0%	60%	20%	47.4%
Epochs 500									
Helyes/helytelen	1/4	3/2	3/2	3/2	3/2	1/3	4/1	1/4	19/38
Helyesség aránya	20%	60%	60%	60%	60%	33.3%	80%	20%	50%
Epochs 1000									
Helyes/helytelen	3/2	3/2	3/2	2/3	3/2	0/3	3/2	2/3	19/38
Helyesség aránya	60%	60%	60%	40%	60%	0%	60%	40%	50%
Epochs 1000 Batch size 32									
Helyes/helytelen	1/4	3/2	3/2	3/2	3/2	0/3	3/2	2/3	18/38
Helyesség aránya	20%	60%	60%	60%	60%	0%	60%	40%	47.4%
Epochs 2000									
Helyes/helytelen	1/4	3/2	3/2	3/2	3/2	0/3	4/1	2/3	19/38
Helyesség aránya	20%	60%	60%	60%	60%	0%	80%	40%	50%
Epochs 5000									
Helyes/helytelen	2/3	3/2	3/2	2/3	3/2	0/3	3/2	2/3	18/38
Helyesség aránya	40%	60%	60%	40%	60%	0%	60%	40%	47.4%
Epochs 5000 Batch size 32									
Helyes/helytelen	2/3	3/2	3/2	3/2	3/2	0/3	4/1	3/2	21/38
Helyesség aránya	40%	60%	60%	60%	60%	0%	80%	60%	55.2%
Epochs 10000									
Helyes/helytelen	1/4	3/2	3/2	2/3	3/2	0/3	4/1	2/3	18/38
Helyesség aránya	20%	60%	60%	40%	60%	0%	80%	40%	47.4%
Epochs 5000 Batch size 32 (vágott képek)									
Helyes/helytelen	5/0	5/0	3/2	4/1	3/2	3/0	4/1	4/1	31/38
Helyesség aránya	100%	100%	60%	80%	60%	100%	80%	80%	81.6%

26. ábra: Mérési eredmények 8 cm-es aknagránátok esetén

A 8 cm-es aknagránátok közül 8 db eltérő típus képei kerültek bele a neurális háló tanulóhalmazába.⁵¹ Mivel itt kétszer annyi eszközt kellett beazonosítani a mesterséges intelligenciának, így a mérési eredmények is jelentősen alacsonyabb pontosságról adnak számot. Az alap képekkel 55,2%-os 21/38-as arányt ért el az 5000 epochs és 16-os batch size

⁴⁹ Ezek a korábbiakban pontosan meghatározásra kerültek.

⁵⁰ A legmagasabb sikeres arányt zöld színnel, a második legmagasabb arányt sárga színnel jelöltem az ábrákon.

⁵¹ Ezek a korábbiakban pontosan meghatározásra kerültek.

párosítású háló. Bár jelentősen több kép alkotta a tesztalmazt, a legpontosabb és a legkevésbé pontos háló között csupán 7,8%-os az eltérés. Mivel a kapott legjobb arány messze alul marad a kitűzött 70%-os céltól el kellett gondolkodni azon, hogyan lehetne fejleszteni és pontosabbá tenni a hálót. Mivel a tanulóhalmaz képein nem kívántam változtatni, így a tesztalmaz képeit vettem görcső alá. Mivel a felismerés és összehasonlítás során a tesztképből is a beolvasás során négyzet alakú kép keletkezik, ezért a tesztalmaz képeit is kivágtam négyzet alakúra, továbbá ezzel együtt levágtam a felesleges háttérelemeket. Ezzel a folyamattal elértem, hogy az azonosítani kívánt eszköz alkotja a tesztképek legnagyobb felületét.

	Wgr. 42	43M	ROM 12	OF-843	Összesen
Tesztképek száma	5	6	5	5	21
Epochs 100					
Helyes/helytelen	4/1	5/1	5/0	4/1	18/21
Helyesség aránya	80%	83.3%	100%	80%	85.7%
Epochs 200					
Helyes/helytelen	4/1	4/2	5/0	3/2	16/21
Helyesség aránya	80%	66.7%	100%	60%	76.1%
Epochs 200 Batch size 32					
Helyes/helytelen	5/0	4/2	5/0	4/1	18/21
Helyesség aránya	100%	66.7%	100%	80%	85.7%
Epochs 500					
Helyes/helytelen	4/1	5/1	5/0	3/2	17/21
Helyesség aránya	80%	83.3%	100%	60%	81%
Epochs 1000					
Helyes/helytelen	5/0	5/1	5/0	2/3	17/21
Helyesség aránya	100%	83.3%	100%	40%	81%
Epochs 1000 Batch size 32					
Helyes/helytelen	5/0	5/1	5/0	4/1	19/21
Helyesség aránya	100%	83.3%	100%	80%	90.5%
Epochs 2000					
Helyes/helytelen	5/0	5/1	5/0	3/2	18/21
Helyesség aránya	100%	83.3%	100%	60%	85.7%
Epochs 5000					
Helyes/helytelen	4/1	5/1	5/0	4/1	18/21
Helyesség aránya	80%	83.3%	100%	80%	85.7%
Epochs 5000 Batch size 32					
Helyes/helytelen	5/0	5/1	5/0	4/1	19/21
Helyesség aránya	100%	83.3%	100%	80%	90.5%
Epochs 10000					
Helyes/helytelen	4/1	4/2	5/0	4/1	17/21
Helyesség aránya	80%	66.7%	100%	80%	81%

27. ábra: Mérési eredmények 12 cm-es aknagránátok esetén

A módosítások alkalmazásával sikerült elérni a mesterséges intelligencia 81,6%-os pontosságát (26. ábra legalsó sorai), amely jelentős, 26,4%-os növekedést jelentett. A képek kivágásával és az eszközök kinagyításával tehát a pontosság jelentős emelkedését lehet elérni, amit nem csak ennél a csoportnál vagy kategóriánál lehet alkalmazni, hanem az minden robbanótest felismerésénél általános érvényű szabállyá válik.

A 12 cm-es csoportban 4 db eszköz⁵² pontos azonosítása volt a cél. Az eredményekből látszik, hogy a legnagyobb pontosságot az 1000 epochs és 32-es batch size, továbbá az 5000 epochs és 32-es batch size kombináció alkalmazásával értem el. A minimális és maximális 90,5%-os mérési eredmények között a legnagyobb az eltérés a csoportok között, amely 14,4%-ot jelent. Mivel itt is két esetben is 19/21-es helyességi arányt sikerült elérnem választanom kellett a hálók között (27. ábra). Újra a sebesség kritériumát választva a végleges háló 1000 epochs és 32 batch size értékekkel készült.

A készített neurális hálók tehát elérik a kívánt 70%-os pontossági határt. De ahol a tesztalmaz első képeivel nem is, a nagyított képek segítségével már bőven a határ fölé emelhető az azonosítás pontossága. Mivel a neurális hálózat tanulóhalmazába több kép is van a robbanótestek egyes részleteiről, így a felhasználás során érdemes az eszköz egésze mellett az egyes részletekről, mint a fejrész vagy a stabilizátorszárny is képet készíteni. A nagyobb pontosság elérése céljából az eszközről felismerendő fotót készíteni a hossz tengelyére merőleges irányból érdemes. Ez igaz a részletek fényképezésére is. Valamint javasolt a robbanótest környezetének lehető leghomogénebbé tétele. Vagyis, ha talajban található az eszköz, akkor a nem talaj részecskéket, növényi részeket, eszközöket célszerű eltenni a fényképező látószögéből.

A kutatás során szerzett tapasztalataim alapján a felhasználás során javaslom, hogy minden eszköztől 3 különböző kép készüljön, és amennyiben mindegyik esetében a felismerés azonos robbanótestet jelöl meg, akkor az elég nagy valószínűséggel tényleg a jelzett robbanótest lesz. Amennyiben ez nem lehetséges (például, ha csak adott része látszik ki a talajból), akkor is érdemes több képet készíteni különböző szögekből.

⁵² Ezek a korábbiakban pontosan meghatározásra kerültek.

4. FEJLESZTÉSI LEHETŐSÉGEK

A fejlesztés és továbblépés lehetőségei több csoportra oszthatók, azok megvalósításához szükséges idő tekintetében. Így beszélhetünk rövid-, közepes- és hosszútávú fejlesztési lehetőségekről. Ezen feladatok elvégzéséhez részben már adottak a feltételek.

Rövidtávú fejlesztési lehetőségként kínálkozik az aknagránátok kategóriára egy komplex neurális háló tanítása, amely a különböző vizsgált űrméretek eszközei között lenne képes különbséget tenni. Ezzel egy robbanótest típusának pontos beazonosítása többszintű neurális hálókkal lenne lehetséges. Rövidtávú fejlesztésekre már lehetne alkalmazni a MATLAB⁵³ programozási nyelvet, amely segítségével grafikusán, programozási ismeretek széles tárháza nélkül is képes valaki megbízható neurális hálót készíteni. Illetve a MATLAB Image Processing Toolbox segítségével a hálókészítésen kívül a képek előfeldolgozása is sokkal egyszerűbbé válhat. A képek előfeldolgozása alatt olyan változtatások értendők, mint a képek szíkontrasztja, a tárgyak éleinek erősebb kontúrúvá tétele vagy a fehérités eljárások, amelyek egyértelműen és bizonyítottan javítják a neurális hálók felismerési pontosságának eredményeit a tanulóhalmaz képein keresztül. Továbbá a meglévő képek gépi „torzításával” és forgatásával újabb képhalmazok állíthatók elő a programban. [35] A neurális hálók felhasználásához létre lehet hozni egy Android operációs rendszerhez készített alkalmazást is, amely a program használatát felhasználóbaráttá teszi.

Középtávú cél lehet az egyes kategóriák eszközeiről történő képi adatbázisok létrehozása és az azokhoz tartozó MI-k programozása. A folyamatosan bővülő adatbázis segítségével korrigálhatni lehet a robbanótest felismeréséhez alkotott neuron háló modellek tulajdonságait, hogy azok megbízhatóbban és pontosabban működjenek. Középtávú célként már megjelenhet a transfer learning beépítése is a folyamatokba, amelynek célja, hogy a rendszer az egyik felismerési probléma megoldása során megszerzett ismereteket tárolja és egy másik, de kapcsolódó felismerési probléma megoldása során azokat előhívja, megbízhatóbbá téve ezzel a felismerést. Érdemes lenne egy önálló mesterséges intelligencia szerver kialakítása, amin a programozásokat, valamint a képek felismerését lehetne végezni. Ez a számítógép vezeték nélküli hálózaton kapcsolódna a telefonon futó Androidos alkalmazáshoz, aminek köszönhetően a telefon erőforrásait nem használná a felismerő rendszer, az csak adatrögzítő és grafikus megjelenítő szerepet töltené be. Az alkalmazás szempontjából elengedhetetlen egy külső erőforrás használata, ugyanis az egyre növekvő neuronhálók és azok tárhelyigénye már

⁵³ A MATLAB egy programozási és numerikus számítási platform, amelyet mérnökök és kutatók milliói használnak adatok elemzésére, algoritmusok fejlesztésére és modellek létrehozására.

lényegesen meghaladná a telefonok hardvereinek képességét. A megerősítéses tanuláson alapuló háló nem lehet cél, mivel az nem a képfelismerés bevett módszere, illetve a leggyakrabban előtalált robbanótestekről egy idő után többszörös mennyiségű kép keletkezne, amely eltolná a tanulóhalmaz arányait és ezzel akár egyre nagyobb pontatlanságot is eredményezhetne a felismerésben.

Egy további középtávú cél lehet, a fémszemét és a robbanótestek megkülönböztetésének képessége. Ezzel a neurális háló képes lenne a valódi robbanótesteket megkülönböztetni az egyébként veszélytelen fémhulladéktól, mint pl. a gránátokat és a konzervdobozokat, vagy a több száz kilós légi bombákat és az illegális szemétlerakásokból származó bojlereket.

Hosszútávú célként fogalmazható meg, hogy a létrehozott kategóriák, csoportok és alcsoportok mindegyike feltöltésre kerüljön az összesen akár több ezer különféle eszköz adataival. Ezen esetben a már korábban leírt többszintű azonosítást kellene alkalmazni, amely használata több szempontból is előnyös. Egyrészt a neurális hálók rendszerének egyes hálói sokkal egyszerűbben ki lehet cserélni, ha új eszköz vagy új képek kerülnek a tanulóhalmazba, ezzel az újra programozás idejét is leredukálva. Másrészt pontosabb azonosítást tesz lehetővé, mivel ha az összes eszköz egy hálón keresztül lenne betanítva, akkor az valószínűleg csak a kategóriák között tudna különbséget tenni, ugyanis a csoportok és alcsoportok eltérései, különbségei már eltörpülnének a kategóriák közöttiekhez képest. Harmadrészt a MI-k rendszerét szintenként is lehetne használni. Tehát ha a tűzszerész műveletet irányító parancsnok információ igényét kielégíti a csoport vagy alcsoport meghatározása is, akkor a hálók rendszere ezt nagyobb pontossággal meg fogja tudni határozni, mint az eszköz pontos típusát. Leghosszabb távú cél lehet, hogy az elkészült programot integráljuk egy tűzszerész robotra, hogy az önállóan is képes legyen egy robbanótest azonosítására és esetleg hatástalanítására az előre beprogramozott cselekvéssor végrehajtásával.

ÖSSZEGZÉS

Dolgozatomban bemutattam a MH 1. HTHE felépítését, feladatrendszerét és feltártam azokat a vezetéstámogatási területeket, amelyekben a mesterséges intelligencia alkalmazásával előrelépés érhető el a tűzszerészek biztonsága, illetve a műveletvezetés támogatása érdekében. Vizsgáltam továbbá a mesterséges intelligencia egyes alapelemeit, amelynek megértése elengedhetetlen a komplex rendszer kialakításához.

Fő eredménynek tartom, hogy sikerült kidolgoznom egy olyan tűzszerész műveleteket támogató képelemzésen alapuló szoftvert, valamint a mögötte lévő rendszerelvet, amely képes beazonosítani és megnevezni az aknagránátok egyes típusait. A három ürmérethez tartozó három neurális háló mérési eredményeit figyelembe véve azok jelentősen nagyobb felismerési pontosságot értek el, mint a célul kitűzött 70%-os pontosság. A teljes rendszer felismerési spektrumának a három neurális háló csak egy része, de annak eredményei nagyon biztatók a jövőbeni fejlesztésekre és a bővítés lehetőségére vonatkozóan. Kidolgoztam a neurális hálók és a képi adatbázisok egymásra épülő rendszerének elméleti hátterét, így a további fejlesztésekhez már „csak” több tízezer fényképpel kell feltölteni a képi adatbázis vonatkozó részeit.

Az elkészült program egy olyan prototípus, amely felhőalapú számítási kapacitás felhasználásával került fejlesztésre és tanításra. Ugyanakkor katonai célú rendszerek gyakorlatban történő megvalósítása és alkalmazhatósága szempontjából már a neurális hálók készítéséhez is célszerű lenne a felhő alapú felhasználói felületet egy platformfüggetlen megoldásra cserélni. A piacon több ilyen szoftver is elérhető, de a felhasználói szempontokat figyelembe véve a MATLAB és annak a kifejezetten az MI fejlesztésekre optimalizált moduljai (toolboxok) kínálják a leghatékonyabb megoldást. Ezzel már a neurális háló alapmodellt is lehet módosítani, így a „Teachable Machine” általános hálója helyett egy direkt robbanótestekre készített hálót lehetne programozni. A megbízható és biztonságos működéshez, a valós műveleti alkalmazásokhoz egy további fontos szempont a képi adatbázisok védelmének biztosítása, amely a fenti szoftverplatform, és privát hálózati infrastruktúra segítségével szintén biztosítható.

A fentiek alapján a jövőben mindenképpen folytatni szeretném kutatásaimat. Tervezem újabb eszközcsoportokról, és konkrét eszközökről további képeket feltölteni a felismerő rendszerbe, ezáltal megvalósítva a tanulóhalmaz bővítését, majd megvizsgálva annak felismerési pontosságra gyakorolt hatását. A képi előfeldolgozás eszköztárának felhasználása segítségével szeretnék további javulást elérni a szoftver hatékonyságában.

Ezúton is szeretném megköszönni az MH 1. HTHE vezetőinek, kiképzőinek és állományának, hogy lehetőséget és támogatást kaptam a képi adatbázis elkészítéséhez, amely nélkül a kutatás nem jöhetett volna létre.

IRODALOMJEGYZÉK

- [1] Ember István: *A lőszermentesítés szerepe az építőiparban*. Építőanyag, 72. évf. 2. szám, pp. 59–63., 2020.
- [2] Magyar Tudományos Akadémia: *Tudományági nómenklátúra*, 2017. Internetes elérhetőség: <https://mta.hu/doktori-tanacs/tudomanyagi-nomenklatura-106809> (Letöltve: 2021.11.10.)
- [3] Boda József, Boldizsár Gábor, Kovács László, Orosz Zoltán, Padányi József, Resperger István, Szenes Zoltán: *Fókusz és együttműködés. A hadtudomány kutatási feladatai*. Honvédségi Szemle, 144. évf. 3. szám, pp. 3–19., 2016.
- [4] *MH 1. Honvéd Tűzszerész és Hadihajós Ezred*, 2020. Internetes elérhetőség: <https://honvedelem.hu/alakulat/mh-1-honved-tuzszeresz-es-hadihajos-ezred.html> (Letöltve: 2021.09.28.)
- [5] *142/1999. (IX. 8.) Kormányrendelet a tűzszerészeti mentesítési feladatok ellátásáról* Internetes elérhetőség: <https://net.jogtar.hu/jogszabaly?docid=99900142.kor> (Letöltve: 2021.12.10.)
- [6] Ember István: *A robbanótestek, mint a talajban rejlő potenciális veszélyforrások*. Geotechnika 2020, pp. 25–32., 2020.
- [7] Sipos Péter, Ravasz István (szerk.): *Magyarország a második világháborúban*. Lexikon A–Zs. 2. kiad. Budapest, 1997.
- [8] Lódi Antal: *Katonai robbanótestek alapismerete, szerkezete*. Jegyzet. Budapest, 2010.
- [9] *WWII Mortars of USSR* (é. n.) Internetes elérhetősége: <http://wio.ru/galgrnd/mortar.html> (Letöltve: 2022.03.30.)
- [10] *Hirtemberger Defence System: 120 MM SYSTEM* 2018. Internetes elérhetősége: <https://hds.hirtenberger.com/120mm-system/> (Letöltve: 2022.03.30.)
- [11] Dr. Négyesi Imre: *A mesterséges intelligencia és a hadsereg I. rész*. HADTUDOMÁNYI SZEMLE X. évf. 2. szám, pp. 23–34., 2017.
- [12] Kovács György: *Gyártásautomatizálás és Robotika*. Pécsi Tudományegyetem, Műszaki és Informatikai Kar, Pécs, 2015.
- [13] Németh András, Virágh Krisztián: *Mesterséges intelligencia és haderő – A mesterséges intelligencia fejlődéstörténete I. rész*. HADITECHNIKA LVI. évf. 1. szám, pp. 10–14., 2022.
- [14] Rajczy István: *Mesterséges intelligencia*. Képviselői Információs Szolgálat, 2019/11. szám, 2019.
- [15] Németh András, Virágh Krisztián: *Mesterséges intelligencia és haderő – A mesterséges intelligencia területei III. rész*. HADITECHNIKA LVI. évf. 3. szám, pp. 2–7., 2022.

- [16] Tannya D. Jajal: *Distinguishing between Narrow AI, General AI and Super AI*, Medium, 2018. Internetes elérhetőség: <https://medium.com/@tjajal/distinguishing-between-narrow-ai-general-ai-and-super-ai-a4bc44172e22> (Letöltve: 2022.01.20.)
- [17] Stuart Russell, Peter Norvig: *Artificial Intelligence: A Modern Approach (3rd Edition)*, Prentice Hall, 2010.
- [18] *Mi a gépi tanulás?* Microsoft Azure, (é. n.). Internetes elérhetőség: <https://azure.microsoft.com/hu-hu/overview/what-is-machine-learning-platform/#benefits> (Letöltve: 2022.02.01.)
- [19] Expert System team: *What is Machine Learning? A definition*, Expert System, 2017. Internetes elérhetőség: <https://expertsystem.com/machine-learning-definition/> (Letöltve: 2022.02.01.)
- [20] M. Tim Jones: *Models for machine learning*, IBM, 2017. Internetes elérhetőség: <https://developer.ibm.com/articles/cc-models-machine-learning/> (Letöltve: 2022.02.01.)
- [21] Jason Brownlee: *Machine Learning Mastery*, 2017. Internetes elérhetőség: <https://machinelearningmastery.com/classification-versus-regression-in-machine-learning/> (Letöltve: 2022.02.02.)
- [22] Vinod Sharma: *Machine Learning – Introduction to Unsupervised Learning*, 2018. Internetes elérhetőség: <https://vinodsblog.com/2018/11/01/machine-learning-introduction-to-unsupervised-learning/> (Letöltve: 2022.02.02.)
- [23] Mészáros Tamás: *Ágensék*, (é. n.). Internetes elérhetőség: <http://home.mit.bme.hu/~meszaros/edu/onallo/it/guth.97/> (Letöltve: 2022.02.02.)
- [24] Federico Marini, Remo Bucci, Antonio L. Magri: *Multilayer feed-forward artificial neural networks for class modeling*, Chemometrics and Intelligent Laboratory Systems, Vol. 88. No. 1., pp. 118–124., 2007.
- [25] *What Is Deep Learning? 3 things you need to know*, (é. n.). Internetes elérhetőség: <https://www.mathworks.com/discovery/deep-learning.html> (Letöltve: 2022.02.02.)
- [26] *Objektum felismerő (képfelismerő) AI megoldásunk*, 2019. Internetes elérhetőség: <https://www.regens.com/hu/-/objektum-felismeres-kepfelismeres-mesterseges-intelligencia-aval-bemutato-video> (Letöltve: 2022.02.23.)
- [27] Joos Korstanje: *What is the difference between Object Detection and Image Segmentation?*, 2020. Internetes elérhetőség: <https://towardsdatascience.com/what-is-the-difference-between-object-detection-and-image-segmentation-ee746a935cc1> (Letöltve: 2022.02.23.)
- [28] *Analog Image Processing vs. Digital Image Processing* (é. n.). Internetes elérhetőség: <https://www.javatpoint.com/analog-image-processing-vs-digital-image-processing> (Letöltve: 2022.02.23.)
- [29] *Image Processing Definition, Examples and Application*, (é. n.). Internetes elérhetőség: <https://www.zr-tech.co.uk/Image-Processing-/> (Letöltve: 2022.02.23.)

- [30] Kovács Róbert: *Neurális hálózatok elrendezési és funkcionális típusai*, 2019. <https://mesterin.hu/neuralis-halozatok-elrendezesi-es-funkcionalis-tipusai/> (Letöltve: 2022.02.21.)
- [31] Arden Dertat: *Applied Deep Learning - Part 4: Convolutional Neural Networks*, 2017. Internetes elérhetőség: <https://towardsdatascience.com/applied-deep-learning-part-4-convolutional-neural-networks-584bc134c1e2> (Letöltve: 2022.03.02.)
- [32] Jason Brownlee: *How Do Convolutional Layers Work in Deep Learning Neural Networks?*, 2020. Internetes elérhetőség: <https://machinelearningmastery.com/convolutional-layers-for-deep-learning-neural-networks/> (Letöltve: 2022.03.02.)
- [33] *Max Pooling*, (é. n.). Internetes elérhetőség: <https://paperswithcode.com/method/max-pooling> (Letöltve: 2022.03.02.)
- [34] *Teachable Machine*, (é. n.). Internetes elérhetőség: <https://teachablemachine.withgoogle.com/> (Letöltve: 2022.02.21.)
- [35] *Deep Learning*, (é. n.). Internetes elérhetőség: <https://www.mathworks.com/solutions/deep-learning/deep-learning-computer-vision.html> (Letöltve: 2022.03.24.)