

Hammas Attila,¹ Négyesi Imre²

A mesterséges intelligencia felhasználási lehetőségei képi felderítési műveletek támogatására

Technológiai áttekintés

Potential Uses of Artificial Intelligence to Support Image Reconnaissance Operations

A Technology Overview

Absztrakt

Az információs korban, amelyet gyakran a digitális forradalom korszakaként is emlegetnek, az adatok gyűjtése és hatékony feldolgozása elengedhetetlen képesség mind polgári, mind katonai környezetben. A technológia rohamos fejlődésének köszönhetően a gépi tanulás és a távérzékelés összefonódása rengeteg lehetőséget biztosít a kutatók számára, különösen az információgyűjtés, -feldolgozás és -értelmezés területén. Az információk hatékony kezelésének és felhasználásának fontossága megkérdőjelezhetetlen, az információk a stratégiai döntések alapkövei számos területen. Jelen tanulmány a technológia által nyújtott lehetőségeket és a felhasználás főbb területeit vizsgálja.

Kulcsszavak: felderítés, IMINT, mesterséges intelligencia, gépi tanulás

¹ Doktori hallgató, Nemzeti Közsolgálati Egyetem Katonai Műszaki Doktori Iskola, e-mail: hammas.attila@stud.uni-nke.hu

² Egyetemi docens, Nemzeti Közsolgálati Egyetem Hadtudomány és Honvédtisztoképző Kar, e-mail: negyesi.imre@uni-nke.hu

Abstract

In the information age, often referred to as the era of the digital revolution, the collection and the processing of data is an essential capability in both civilian and military environments. Thanks to the rapid development of technology, the intertwining of machine learning and remote sensing provides us with many opportunities, especially in the areas of information collection, processing and interpretation. The importance of effective management and use of information is unquestionable—information is the cornerstone of strategic decisions in many areas. The article will examine the opportunities provided by technology.

Keywords: reconnaissance, IMINT, artificial intelligence, machine learning

Bevezetés

Az információs korban, amelyre gyakran a digitális forradalom korszakaként is hivatkoznak, az adatok gyűjtése és feldolgozása központi szerepet játszik az információs társadalom működésében. Az adatok ma már mindenütt jelen vannak, és az élet szinte minden területén alapvető fontosságúak. A technológiai fejlődés, különösen az internet és a mobileszközök elterjedése, forradalmasította az adatgyűjtés és -feldolgozás módjait, mondhatni, az elmúlt évtizedekben keletkező adat mennyisége ennek is köszönhetően exponenciálisan növekedett. A különféle szenzorokkal és eszközökkel gyűjtött adatok lehetővé teszik a valós idejű megfigyelést, elemzést és döntéshozatalt, ami elősegíti a hatékonyság növelését és a kapcsolódó innovációkat. Az adatok feldolgozása és elemzése révén a szervezetek és az egyének jobban megérthetik a komplex rendszerek működését, és ezáltal megalapozottabb döntéseket hozhatnak. Az információs társadalomban az adatok tehát nem csupán nyers információk, hanem értékes erőforrások, amelyeknek a megfelelő kezelése és felhasználása nélkülözhetetlen a gazdasági és társadalmi fejlődéshez.

Katonai szempontból az információs műveletek olyan tervezett tevékenységeket foglalnak magukban, amelyek elsődleges célja az ellenség információs rendszereinek megtévesztése, megzavarása és manipulálása, valamint a saját műveletek támogatásához szükséges információ megszerzése és védelme. Ezek a tevékenységek kiterjednek az információ gyűjtésére, feldolgozására, elemzésére, tárolására, szétosztására, illetve a szemben álló fél megtévesztése érdekében téves és álinformációk terjesztésére, valamint az ellenfél információs rendszereinek a támadására, hogy befolyásolják annak döntéshozó képességét. Az információs műveletekhez tartozó tevékenységekről beszélhetünk a fizikai dimenzióban, a kibertérben, illetve a kognitív dimenzióban is.

Ugyanakkor azt is figyelembe kell vennünk, hogy az elmúlt évszázadban egyre nagyobb hangsúly került a hibrid konfliktusokra, illetve a proxyháború az egyik legelterjedtebb háborútípus.³ Clausewitz híres megfogalmazása szerint „a háború a politika más eszközökkel való folytatása”⁴. Ez azt jelenti, hogy a háborút nem öncélú

³ BODA 2023: 27.

⁴ CLAUSEWITZ 2013: 54.

erőszakként kell értelmezni, hanem a politikai célok elérésének egy extrém eszközeként, amikor más módszerek már nem hoznak eredményt.⁵ Ha egy állam politikai akaratának a befolyásolása a cél, akkor nincs szükség fegyveres erőszak alkalmazására, sok esetben az adott állam politikailag nem akarja nyíltan félvállalni az agresszor szerepét.⁶ A második világháború után a nemzetközi viszonyok több átalakuláson estek át: a hidegháború idején a két szemben álló nagyhatalom (az Amerikai Egyesült Államok és a Szovjetunió) által képviselt ideológia bipoláris világrendet hozott létre, ahol a nagyhatalmak elsősorban különböző proxyháborúkkal próbáltak egymáson felülkerekedni. A Szovjetunió összeomlása után az Amerikai Egyesült Államok emelkedett ki mint egyedülálló nagyhatalom, és a „világ csendőreként” folytatott proxyháborút a résállamokban (a globalizációt elutasító államok) megjelenő terrorista szervezetek ellen. Azonban a 21. század elejétől új regionális hatalmak – mint például Kína, Oroszország, India és az Európai Unió – egyre nagyobb befolyást gyakoroltak a nemzetközi politikára, és a globális hatalmi egyensúly fokozatosan multipoláris és poliarchikus alakult.⁷ A proxyháborúk fejlődése és a hibrid konfliktusok jellemzői – különösen a nem állami szereplők térnyerése és az információs műveletek növekvő szerepe – szorosan kapcsolódnak a mesterséges intelligencia alkalmazási lehetőségeihez a képi felderítésben. A modern poliarchikus nemzetközi helyzetben az MI-alapú képelemzés és információs hadviselés lehetőséget biztosít a konfliktusok rejtett dimenzióinak feltárására, az ellenséges tevékenységek azonosítására, valamint a nem állami szereplők és támogatott milíciák mozgásának és logisztikájának pontosabb nyomon követésére. A történelem során a haditechnológia fejlődéséről az mondható el, hogy a pusztítási kapacitás rohamosan nőtt addig a szintig, hogy a nagyhatalmak képesek kölcsönösen egymást megsemmisíteni, ezzel veszélyeztetve az emberiség egészét.⁸ A mesterséges intelligencia, mint egy új fegyvertípus, azon feltörekvő technológiákhoz sorolható, amelyeknek elsődlegesen elemző és szimuláló szerepük van, és jelentősen csökkenthetik a konfliktus által okozta kockázatot a saját állományra nézve.⁹

A tanulmány során vizsgálni fogjuk a mesterséges intelligencia jelentőségét napjainkban, főként a képelemzési eljárásokat, amelyek alkalmazása támogatja és támogathatja a képi felderítést, azzal a céllal, hogy feltárjuk a gépi látás, a felderítés és a távérzékelés területek átfedéseit. Ugyanakkor a tanulmány arra is rávilágíthat, hogy a civil szférában alkalmazott gépi látási feladatokra elkészült megoldások milyen mértékben használhatók fel a védelmi szférában.

A gépi tanulás és a távérzékelés szerepe az információs műveletekben

A tanulmány az információs műveletek egy apró szeletét, az információgyűjtést és -feldolgozást vizsgálja. Mind katonai, mind polgári környezetben a műveletek hatékonysága nagymértékben függ a döntéshozók, illetve a beavatkozók számára

⁵ BODA 2024: 114.

⁶ A hibrid háború korszakába léptünk: de mit is jelent ez? 2022.

⁷ BODA 2023: 28–30.

⁸ KONRÁD 1963: 1, 7.

⁹ BODA 2024: 116.

elérhető megbízható információtól. A katonai műveletek során, harci körülmények között, ahol a kockázat akár rendkívül magas is lehet, az információs műveletek szerepe még fontosabbá válik, így az információ megfelelő gyűjtése, feldolgozása, ellenőrzése és kiaknázása biztosítja, hogy a műveletek egy reális helyzetkép alapján legyenek megtervezve, majd végrehajtva. A gépi tanulás (*machine learning*, ML) ezeket a képességeket növeli, lehetővé téve a hatalmas adathalmazok gyorsabb feldolgozását, az ember számára észlelhetetlen mintázatok azonosítását, valamint az ellenfél cselekedeteinek pontosabb előrejelzését. Manapság a begyűjtött adatok azonnali kiértékelésre szorulnak, hiszen sok esetben a helyzetkép kialakításához szükséges információ rövid idő alatt irrelevánssá válhat. Ugyanakkor az információ megbízhatóságának a növelése érdekében ezt érdemes több forrásból is begyűjteni, majd a feldolgozott összadatforrás alapján kialakítani az aktuális helyzetképet, ezzel részlegesen szűrni lehet a téves információkat. A technológia rohamos fejlődése során a gépi tanulás és a távérzékelés összefonódása hatalmas lehetőségeket rejt magában, különösen az információelemzés területén. Az információk hatékony kezelésének és felhasználásának fontossága megkérdőjelezhetetlen – az információk a stratégiai döntések alapkövei számos területen. Ez különösen igaz a védelem területén, ahol a felülmúlhatatlan információk, illetve ennek időszerűsége jelentős taktikai előnyöket biztosíthatnak.¹⁰


Annak alapján, hogy a felderítés során szerzett információ forrása, milyensége, illetve hogy az milyen céllal lesz felhasználható, a különböző felderítési eljárásokat csoportosítani lehet. A Magyar Honvédség Összhaderőnemi Doktrína által alkalmazott felderítési folyamatok és eljárások csoportosítása:¹¹

- emberi erővel folytatott felderítés (HUMINT – *human intelligence*);
- képfelderítés (IMINT – *imagery intelligence*);
- rádióelektronikai felderítés (SIGINT – *signal intelligence*);
- rádiófelderítés (COMINT – *communication intelligence*);
- rádiótechnikai felderítés (ELINT – *electronic intelligence*);
- hangfelderítés (ACINT – *acoustic intelligence*);
- kisugárzás és jelfelderítés (MASINT – *measurements intelligence*);
- radarfelderítés (RADINT – *radar intelligence*);
- technikai felderítés (TECHINT – *technical intelligence*);
- nyílt források által folytatott felderítés (OSINT – *open-source intelligence*);
- az ellenség felderítését elhárító tevékenység, saját csapatok védelme (CI/FP – *counterintelligence and force protection*).

A begyűjtött adatokból kinyert információ alapján a vezetők, a megfogalmazott cél elérése érdekében, kiválasztják a legmegfelelőbb beavatkozási eljárást. A kivitelezés után ez direkt vagy indirekt módon hatással van az aktuális állapotra, azaz egy visszacsatolásról, egy folytonos hurokról beszélhetünk, amint ezt az 1. ábra is szemlélteti.

¹⁰ HAIG-VÁRHEGYI 2005.

¹¹ HAIG et al. 2014: 95.



1. ábra: Az OODA-hurok és az adat, információ, felderítési adat viszonya

Forrás: HAIG et al. 2014; PLOUMIS 2022 alapján a szerzők szerkesztése

Különösen a katonai műveletek során, de nem csak ekkor, olyan környezetben kell információt gyűjtenünk, amelyhez nincs direkt hozzáférésünk, vagy az itt végzett tevékenység kockázattal jár a végrehajtó személyzetre nézve. A távérzékelés során úgy gyűjtünk információt a megfigyelendő objektumokról vagy jelenségekről, hogy a folyamat során nem érintkezünk fizikailag az adott környezettel.

A modern védelmi stratégiák egyre inkább támaszkodnak a távérzékelésre, hogy kritikus adatpontokat szolgáltatassanak a műveleti tervezéshez, valamint a fenyegetések feltárásához és kiértékeléséhez. A mesterséges intelligencia (*artificial intelligence*, AI) alkalmazása ebben a kontextusban fokozza a távérzékelési technológiák képességeit, lehetővé téve pontosabb, gyorsabb információ előállítását. Az óriási adatkészletek elemzésének automatizálásával a gépi tanulás lehetővé teszi a védelmi elemzők számára, hogy olyan mintázatokat és anomáliákat észleljenek, amelyek az emberi szem számára észrevehetetlenek lennének.¹² Például az előzetesen begyűjtött nagy mennyiségű adat, az ebből kinyert statisztikai mintázatok alapján a mesterségesintelligencia-alapú algoritmusok segíthetnek a megfelelő következtetések levonásában.

A gépi tanulás alkalmazásainak technológiai áttekintése a távérzékelésben nemcsak a jelenlegi képességeket mutatja be, hanem a jövőbeli előrelépések lehetőségét is megvilágíthatja. Ahogy a mesterségesintelligencia-alapú algoritmusok egyre

¹² BODA 2024: 9.

kifinomultabbá válnak, integrációjuk a távérzékelési technológiákkal még hatékonyabb eszközöket ígér az adatelemzéshez és -értelmezéshez. Ezek az előlepek javíthatják a helyzetfelismerést, a jobb erőforrás-gazdálkodást és a hatékonyabb védelmi stratégiák alkalmazását, amelyek mind létfontosságúak a nemzetbiztonság fenntartásában.

Képfeldolgozás, gépi látás és mesterséges intelligencia

A mesterséges intelligencia nem egyszerűen definiálható fogalom, hiszen több oldalról is megközelíthető; egy átfogó meghatározás a következő lehet: „Olyan hardver- és szoftvertechnológiák összessége, amely képes önálló döntések meghozatalára tudományos érvek, vagy akár emberi gondolatok, reakciók, érzelmek figyelembevételével.”¹³

A mesterséges intelligencia kezdetben jól lehatárolt és explicit szabályrendszerrel ellátott feladatokban ért el átütő sikereket, itt gondolunk például az IBM által fejlesztett Deep Blue mesterséges intelligencia által elért sikerekre az akkori sakkbajnok ellen, vagy a Google DeepMind által fejlesztett AlphaGo győzelmeire 2015–2016-ban gojátékosok ellen.¹⁴ Napjainkban azonban a mesterséges intelligenciával felvértezett rendszerek olyan környezetben is képesek helytállni, amelyben a szabályrendszereket sok zavaró tényező és bizonytalanság veszi körül, miközben a bemenet sem tekinthető strukturáltnak. Itt most gondolhatunk az önvezető autókra vagy a multimodális nagy nyelvi modellekre, amelyek szöveget, hangot és képeket is képesek feldolgozni. Egy példa erejéig lássuk egy önvezető autó összetett feladatát (2. ábra):

- észlelnie kell a körülötte elhelyezkedő akadályokat, amelyeket a pályatervező algoritmusnak ki kell kerülnie, legyen az egy másik gépjármű, gyalogos vagy akár betonfal;
- be kell tartania a forgalomra vonatkozó szabályokat (elsőbbségadás, haladási irány, sebesség és sok más korlátozás), ehhez azonosítania kell a táblákat, úttesteket, illetve ezeket kontextuálisan el kell helyeznie a térben;
- figyelnie kell a váratlan eseményekre, mint például takarásból kifutó kisgyerek vagy a semmiből megjelenő őzek.

Laikusként mondhatjuk azt, hogy a KRESZ (Közüti Rendelkezések Egységes Szabályozása) jól definiált szabályrendszerként megfogalmazza, hogyan kell a gépjárművezetőnek eljárnia különböző esetekben. Azonban nem hagyhatjuk figyelmen kívül, hogy a gyakorlatban sok zavaró tényező van jelen: optikai csalódás miatt az akadály beleolvad a környezetébe, a táblák takarásban vannak, a felfestések idővel lekopnak, a közforgalomban részt vevő szereplők szabályt szegnek, javítás miatt terelések és útszűkítések vannak, és még sorolhatnánk.

¹³ NÉMETH-VIRÁGH 2022a: 19.

¹⁴ NÉMETH-VIRÁGH 2022b.



2. ábra: A környezet egy Tesla önvezető autó szemszögéből

Forrás: Andrej Karpathy [é. n.]

Különböző gyártók annyira megbíznak a gépi látási algoritmusok képességeiben, hogy bizonyos szenzorokat kezdenek kiiktatni az arzenáljukból, ezáltal csökkentve az adatforrások számát, ami a megbízhatóság rovására mehet, a gyártási költségek csökkentése érdekében. Ilyen például a Tesla elektromosautó-gyártó 2022-ben hozott döntése, miszerint az ultrahangos távérzékelőket fokozatosan kihagyja az újabb gyártású gépjárműiből, és kizárólag a gépi látásra támaszkodva fejleszti tovább az önvezető autókban rejlő algoritmusokat.¹⁵ Ezáltal a rendszerek egyfajta redundanciájukat elveszítik, ami olykor hibás kimeneteket is eredményezhet: például történt olyan eset, amikor egy Tesla önvezető autó nekicsapódott egy elválasztó falnak.¹⁶ Ilyenkor felmerül a felelősség kérdése is, hiszen az előbbi példában az ütközéskor és az azt megelőző pillanatokban a jármű önvezető üzemmódban volt ugyan, de a felhasználói feltételekben megtalálható, hogy a járművezetőnek felügyelnie kell az önvezető autót, és hiba esetén be kell avatkoznia.¹⁷ Az ilyen esetek relatív számossága kisebb, mint a nem önvezető autók esetében, viszont az önvezető autók által okozott balesetek sokkal nagyobb figyelmet kapnak a médiában újszerűségüknek köszönhetően. Ugyanakkor az is probléma, hogy a mesterségesintelligencia-alapú rendszerek egyfajta feketedobozként foghatók fel, és nem lehet egyértelműen megállapítani, hogy miért is az adott eredmény született.¹⁸

A gépi látás nagymértékben mesterségesintelligencia-alapú algoritmusok ötvözése különböző képfeldolgozási eljárásokkal. A bemenetén kapott képi információkat feldolgozza és átalakítja olyan információvá, amelyet később más rendszerek felhasználhatnak. Ha az autópárból akarunk példát meríteni, akkor gondolhatunk az autonóm sávtartó vagy vészfékező rendszerekre. Például ha az autó haladási pályája keresztezni fogja egy gyalogos útvonalát, akkor a képfeldolgozó algoritmus eredménye alapján tud beavatkozási döntéseket hozni, mint például a haladási irány megváltoztatása vagy a fék alkalmazása.

¹⁵ Tesla Vision Update: Replacing Ultrasonic Sensors with Tesla Vision [é. n.].

16 THORBECKE 2020.

¹⁷ NÉGYESI 2023: 7, 13.

¹⁸ SZABADFÖLDI 2022: 360–361.

A gépi látás területén számtalan feladatról tudunk beszélni, azonban ezekből a fontosabbak lesznek részletesebben elemezve: képosztályozás vagy klaszterezés, objektum- vagy anomáliaérzékelés, illetve követés, szegmentáció.

Képosztályozás

A képosztályozás klasszikus képfeldolgozási feladat, amely egy teljes kép feldolgozását foglalja magában. A cél a kép osztályozása úgy, hogy azt egy adott címkéhez rendeli. Ezt a fajta feladatot a leggyakrabban konvolúciós neuronhálókkal (*convolutional neural network*, CNN) oldják meg, amelyeknek a bemenete maga a kép vagy annak a leskáladott változata, valamint a kimenete a különböző osztályokhoz rendelt konfidenciaszint.¹⁹ A képosztályozó konvolúciós neuronhálók két részből épülnek fel: az előfeldolgozás célját szolgáló konvolúciós és összevonó rétegek sorozatából (ezt sok helyen „gerincként” említik), valamint teljesen összezsúrolt osztályozó rétegek sorozatából („fej”). A konvolúciós rétegek hangolásával a neuronháló megtanulja kinyerni a legfontosabb jellemzőket, amelyek alapján majd az osztályozó rész könnyedén el tudja dönteni, hogy a bemenetet milyen osztályba kell sorolni.

Lévén, hogy a mélytanuló algoritmusok tanítása során rengeteg paraméter együttes hangolása szükséges, a túltanulás elkerülése végett elengedhetetlen a nagy mennyiségű változatos minta. A túltanulás az a jelenség, amikor az adott neuronháló paramétereinek hangolása során a modell túlzottan illeszkedik a tanítómintákban található mintázatokra, és amikor egy új, eddig még nem látott bemeneten értékeljük ki, rosszabb teljesítményt nyújt, mivel nem képes megfelelően általánosítani, az új minta pedig részleteiben eltér az eddig látottaktól. Így a kutatók rendelkezésére bocsátott nagy méretű adatbázisok katalizátorként hatottak a mesterséges intelligenciával kapcsolatos kutatások területén. Az egyik első ilyen rendelkezésre álló adatbázis az ImageNet, amely a közzétételének pillanatában 3,2 millió képet tartalmazott, mára pedig már több mint 15 millió képből tevődik össze. Az egyik fontos tulajdonsága ennek az adathalmaznak a méretén kívül, hogy egy hierarchikus osztályozási rendszert alkalmazott, azaz az osztályok lebonthatók voltok alosztályokra, lehetővé téve az adathalmaz széles körű felhasználását.²⁰ Az adathalmaz a következő években tovább bővült, illetve egy verseny is kihirdetett, amelynek címe: ImageNet Large Scale Visual Recognition Challenge (ILSVRC). A 2012-ben megszervezett ILSVRC-versenyt az AlexNet architektúra nyerte meg, megelőzve az addig alkalmazott LeNet architektúrát. Az AlexNet egy mélyebb konvolúciós háló volt, mint az addig alkalmazott struktúrák, valamint bevezetett új fogalmakat, mint a normalizáló rétegek és a *dropout* (az adott tanítási ciklusok során véletlenszerűen kiválasztott neuronok fagyasztva vannak és nincsenek hangolva a visszafejtett hiba alapján), aminek köszönhetően az algoritmus kevésbé volt kitéve a túltanulásnak. A 2014-ben megszervezett versenyen a GoogleNet nyert, amely az *inception* rétegekkel csökkentette a szükséges számítási kapacitást, azáltal, hogy ezek a rétegek különböző méretű konvolúciós kerneleket ötvöztek egy rétegben,

¹⁹ BRASSAI 2019.

²⁰ DENG et al. 2009.

így csökkenteni tudták a hálómélységet. A VGGNET modelles család bizonyította, hogy a konvolúciós hálók mélységének növelésével jobb eredmények érhetők el, viszont a mélyhálók hangolása nehézségekkel jár, erre nyújtott megoldást a ResNet (Residual Network) architektúrával bevezetett reziduális blokk, amely lehetővé tette a mélyebb architektúrák hatékony hangolását.²¹

A képosztályozó eljárások használata napjainkban szerteágazó, nagyon sok területen alkalmazzák őket, amint ezt az 1. táblázat is összefoglalja.

1. táblázat: Képosztályozó algoritmusok alkalmazási lehetőségei a különböző területeken

Terület	Alkalmazás
Egészségügy	<i>Leletek osztályozása:</i> különböző orvosi leletek osztályozása, ahol a cél az anomália jelenlétének a meghatározása.
Logisztika és kereskedelem	<i>Raktározás:</i> termékek automatikus osztályozása. <i>Keresés:</i> hasonló osztályba sorolható tárgyak keresése.
Szociális hálók, telekommunikáció	<i>Tartalomszűrés:</i> a képanyagok automatikus besorolása, valamint nem megengedett tartalmak (erőszak, meztelen képek stb.) kiszűrése. <i>Automatikus címkézés:</i> a képek különböző címkékkel való ellátása annak érdekében, hogy utólag gyorsabban lehessen őket keresni és klaszterezni.
Biztonság és területvédelem	<i>Anomália észlelése:</i> térfigyelő kamerák képeinek osztályozása szokatlan tevékenységek vagy tárgyak észlelése érdekében. <i>Hozzáférés-vezérlés:</i> arcfelismerés használata személyek osztályozására és ellenőrzésére a biztonságos hozzáférés érdekében.
Ipar	<i>Minőség ellenőrzése:</i> a termékek besorolása és gyártási hibás termékek megjelölése.
Védelmi szféra	<i>Fenyegetés észlelése:</i> képek osztályozása a lehetséges fenyegetések, például az ellenséges harcjárművek, tüzéség és repülőgépek azonosításához.

Forrás: a szerzők szerkesztése

Objektumészlelés

Manapság a kihívást nem a képek egy osztályba sorolása jelenti, hanem a kulcsfontosságú elemek, objektumok észlelése és azok lokalizációjának a meghatározása az adott bemeneti képen. Erre a problémára is vannak különféle adathalmazok, mint például az MS COCO²² (Microsoft Common Objects in Context, magyarul: mindennapi tárgyak a környezetünkben), a PASCAL VOC²³ (Pascal Visual Object Classes, magyarul: Pascal vizuális objektum osztályok), vagy a távérzékelést támogató rendszerek hangolására alkalmas adathalmazok: DOTA²⁴ (Dataset for Object deTection in Aerial Images, magyarul: adathalmaz légifelvételen való objektumészleléshez), UAVDT²⁵ (UAV Detection and Tracking, magyarul: objektumészlelés és követés pilóta nélküli járművekkel

²¹ ALOM et al. 2018: 12–13.

²² LIN et al. 2014.


²³ EVERINGHAM et al. 2010.

²⁴ XIA et al. 2018.

²⁵ DU et al. 2018.

készített felvételeken), DroneVis²⁶ (Drone Vision – Versatile Computer Vision Library for Drones, magyarul: gépi látási könyvtár drónoknak), LoveDA²⁷ (Land-Cover Dataset for Domain Adaptive Semantic Segmentation, magyarul: adathalmaz felszínborítási szemantikus szegmentáció feladathoz). Az objektumészlelés problémára kialakított konvolúciós neuronháló-architektúrák két osztályba sorolhatók:

- Kétlépcsős: itt a legfontosabb megemlíteni a régióalapú konvolúciós neuronháló (R-CNN) családot (R-CNN,²⁸ Fast R-CNN, Faster R-CNN). Ezek a neuronhálók két lépésben oldják meg az objektumészlelést: egy régiójavasoló modul (*region proposal network*, RPN) megjelöli azokat a potenciális képrészeket, ahol egy objektum helyezkedik el, majd egy osztályozó lépésben az algoritmus a megjelölt régiókról eldönti, hogy az háttér, vagy valamely előre definiált osztályhoz tartozik.²⁹ Ez a folyamat a 3. ábrán van szemléltetve.
- Egylépcsős: a legnagyobb népszerűséget élvező architektúra a YOLO³⁰ (You Only Look Once), ennek mára már számos verziója és variánsa elérhető. Ez a mélytanuló algoritmus egyetlen lépésben hajtja végre az objektumok detektálását, lokalizációját és osztályozását, így gyorsabb, viszont néha kevésbé pontos becslést ad, mint kétlépcsős társai.



3. ábra: R-CNN alapú algoritmus működési elve

Forrás: GIRSHICK et al. 2013: 1

Ezek az objektumészlelő mélytanuló algoritmusok a képosztályozók által alkalmazott konvolúciós szerkezetekre építkeznek. Sok esetben a képosztályozó konvolúciós neuronhálók jellemző kinyerő szerkezetek (konvolúciós és összevonó rétegek), fellelhetők az objektumészlelő modellekben. Például a ResNet-ben vagy a VGG-ben (az Oxford Egyetemen a Visual Geometry Group által fejlesztett VGG-Net) alkalmazott jellemzőkinyerő struktúrák vagy hangolási eljárások ugyanúgy használatban vannak az objektumészlelő modellek megvalósítása során. Sok esetben ezeket a jellemzőkinyerő struktúrákat (gerinc) előre hangolják egy hasonló jellegű képosztályozási adatbázison, majd az így betanított gerincet használják objektumészlelő modellben

²⁶ HEAKL et al. 2024.

²⁷ WANG et al. 2022.

²⁸ R-CNN – Regional Convolutional Neural Network.

²⁹ GIRSHICK et al. 2013.

³⁰ REDMON et al. 2015.

is. Így az adott modult kevesebbet kell hangolni az új feladatra. Ennek az eljárásnak a neve *transfer learning*.

Az objektumészlelő algoritmusok alkalmazási lehetőségeit a különböző területeken a 2. táblázat foglalja össze.

2. táblázat: Objektumészlelő algoritmusok alkalmazási lehetőségei a különböző területeken

Terület	Alkalmazás
Egészségügy	<i>Tumorfelismerés:</i> daganatok észlelése és lokalizálása orvosi képeken a pontos kezelés tervezése érdekében.
Autóipar	<i>Önvezető autók:</i> járművek, gyalogosok, útjelző táblák és akadályok észlelése és lokalizálása a biztonságos navigáció érdekében. <i>Forgalomfigyelés:</i> járművek észlelése és számlálása a forgalmi felvételeken a forgalom elemzéséhez és kezeléséhez.
Logisztika és kereskedelem	<i>Automatizált fizetés:</i> termékek észlelése és felismerése a pénztárnál az automatikus számlázás érdekében. <i>Polcfigyelés:</i> termékelhelyezés és készletszint észlelése az üzletek polcain a készletkezeléshez.
Biztonság és területvédelem	<i>Behatolásészlelés:</i> illetéktelen személyek vagy tárgyak észlelése és nyomon követése korlátozott területeken. <i>Közbiztonság:</i> tömegsűrűség és a közterületi viselkedés észlelése és elemzése a biztonság és a védelem irányítása érdekében.
Ipar	<i>Automatizált összeszerelősor:</i> alkatrészek meglétének észlelése és ellenőrzése az összeszerelés során. <i>Minőség-ellenőrzés:</i> termékek hibáinak észlelése és lokalizálása. <i>Robotika:</i> Lehetővé teszi a robotok számára, hogy észleljék az objektumokat, és interakcióba lépjenek velük. ³¹ <i>Drónnavigáció:</i> akadályok észlelése a navigáláshoz ütközés elkerülése érdekében. ³²
Védelmi szféra	<i>Felügyeleti rendszerek:</i> potenciális célpontok (például személyzet, járművek, fegyverek) valós idejű észlelése és lokalizálása. ³³ <i>Fegyverirányítás:</i> rakéta- és tűzérési rendszerek pontosságának növelése a célpontok valós idejű észlelésével és követésével. <i>Aknaérzékelés:</i> aknamezők azonosítása és feltérképezése tárgyfelismerő technikák segítségével speciális érzékelőkről gyűjtött képeken. ³⁴

Forrás: a szerző szerkesztése

Az objektumészlelő algoritmusok kiegészíthetők különböző eljárásokkal, aminek köszönhetően az egymást követő képeken azonosítani tudjuk a különböző objektumgyedeket, így a mozgóképeken követni lehet azok mozgását. Például célszerű, ha egy forgalommegfigyelő rendszer képes meghatározni, hogy két egymás után következő képen ugyanazt az objektumot észleltük (amely feltehetőleg elmozdult), vagy két egymástól független objektumot. Ez megvalósítható a két egymást követő képkockán észlelt határoló keretek koordinátáinak az elemzésével. Ugyanakkor ezek az algoritmusok felhasználhatják az észlelés során az objektumokról kinyert jellemzőtérképeket, ezzel

³¹ NÉMETH-VIRÁGH 2022c: 1.

³² NÉMETH-VIRÁGH 2022c: 5.

³³ ERDÉSZ 2023: 8.

³⁴ QIU et al. 2023.

növelve a követési pontosságot és csökkentve azokat az eseteket, ahol egy objektum egy képsorozat alatt két különböző objektumként van észlelve. Példa egy ilyen eljárásra a DeepSORT, amely a kinyert konvolúciós jellemzőket is figyelembe veszi, amikor két egymást követő képkockán társítja az észlelt objektumokat.³⁵ Ez például drónfelvételek elemzésénél lehet hasznos, amikor nemcsak az észlelt objektumok vannak mozgásban, hanem a drón (nézőpont) is elmozdul.

Szegmentáció

A szemantikus szegmentáció során a képet több részre vagy szegmensre osztják, ilyenkor sok esetben pixelenként határolják el az objektumokat. Ez a módszer lehetővé teszi, hogy a gépi látás rendszerei pontosabban észleljék és értelmezzék a képeken található objektumokat, hiszen a neuronháló kimenete nemcsak egy egyszerű téglalap alakú keret lesz, hanem az adott objektum vagy anomália pontos határait egy poligon vagy egy maszk határozza meg. A képosztályozási, az objektumészlelési és a szegmentációs feladatok közötti különbségeket a 4. ábra szemlélteti. Az ezt megvalósító algoritmusok alkalmazása széles körű, de talán a legelterjedtebben az orvosi képalkotásban használják diagnosztikai célokra,³⁶ vagy az autonóm járművek fejlesztése során³⁷ az út és a közlekedési táblák észlelésére. A szemantikus szegmentáció a távérzékelés területén is megállja a helyét, itt gondolhatunk a felszínborítottság becslésére is.³⁸ Ez az eljárás alkalmazható építkezés tervezésére, a mezőgazdaságban a termés minőségének becslésére vagy akár a védelmi szférában a műveletek megtervezésénél. A mindennapokból az egyik leglátványosabb példa talán a Teamsen, a Zoomon vagy más online, videó átvitelére alkalmas kommunikációs platformokon a háttérzsere-funkció: amikor az alkalmazás elkülöníti az alanyt a háttértől, majd az utóbbit elhomályosítja vagy teljes egészében lecseréli egy (álló vagy mozgó) képre.



4. ábra: Példák képosztályozási, objektumészlelési, szemantikus szegmentációs és egyedszegmentációs feladatokra³⁹

Forrás: LI-ADELI 2024: 14

³⁵ WOJKE-BEWLEY-PAULUS 2017.


³⁶ HUANG et al. 2020: 1.

³⁷ HUSSAIN-HAMZA-SAMAD 2022: 429.

³⁸ ULMAS-LIIV 2020: 10.

³⁹ LI-ADELI 2024: 14.

Erre a feladatra is nagy előszeretettel alkalmazzák a konvolúciós neuronhálókat. Egy úttörő architektúra volt az FCN (*fully convolutional network*),⁴⁰ amely kizárólag konvolúciós és összevonó rétegekből épül fel. Az FCN eredményét egy dekonvolúciós rétegen keresztül kapjuk, amelynek a feladata, hogy a sokdimenziós kis felbontású jellemzőtérképet visszaskálázza a bementi kép felbontására. Tekintettel arra, hogy kizárólag konvolúciós és összevonási műveleteket alkalmaz, a neuronháló hangolása után is minimális pontosságvesztéssel skálázható nagyobb vagy kisebb felbontású képek elemzésére egyaránt. Az orvosi diagnosztikában a legelterjedtebb architektúra az U-Net,⁴¹ amelynek – mint a neve is jelzi – egy U alakú szerkezete van, és egy szimmetrikusan felépített enkóderből és dekóderből áll (lásd 5. ábra). Ez lehetővé teszi, hogy a mélyebb szinteken az enkóder által előállított jellemzők alapján a dekóder egyre pontosabb maszkokat alkosson, felhasználva a mélyebb és többdimenziós jellemzőtérképeket, valamint az enkóder ugyanazon szintjén található kevésbé összetett, de nagyobb felbontású jellemzőtérképeket is.



5. ábra: Az U-Net architektúra felépítése

Forrás: RONNEBERGER–FISCHER–BROX 2015: 2 alapján a szerzők szerkesztése

Az U-Net architektúra nemcsak arra alkalmazható, hogy a képeket különböző előre definiált osztályokba soroljuk, hanem a képmélység térképének a megközelítő becslésére is.⁴²

⁴⁰ LONG–SHELHAMER–DARRELL 2015.

⁴¹ RONNEBERGER–FISCHER–BROX 2015.

⁴² ALHASHIM–WONKA 2019.

Az objektumészlelő algoritmusok és egy leegyszerűsített FCN ötvözéséből gyakorlatilag egyszegmentációra képes architektúrák kialakítása lehetséges. Például az előző részben tárgyalt Faster R-CNN háló minimális módosításával és egy új ág hozzáadásával egy pontos szegmentációra képes Mask R-CNN⁴³ architektúrát kapunk.⁴⁴ Természetesen az új YOLO architektúrák is rendelkeznek hasonló variánsokkal, amelyek a határoló keretek mellett képesek egyszegmentációt is elvégezni.⁴⁵ Ezekben az esetekben nem feltétlenül csak szemantikus szegmentációról beszélünk, hanem egyszegmentációkról, ugyanis ugyanabba az osztályba tartozó maszkok is el vannak különítve egymástól, amint ezt a 4. ábra is szemlélteti. Lévé, hogy ezek az objektumészlelő algoritmusokhoz képest többszámítást igényelhetnek, olyan esetekben, ahol egyáltalán nem előnyös az adott objektum pontos határainak a kijelölése, célszerű az egyszerűbb határolókeretes detektorok alkalmazása.

3. táblázat: Szegmentációs algoritmusok alkalmazási lehetőségei a különböző területeken

Terület	Alkalmazás
Egészségügy	<i>Képdiaosztikák kiértékelése:</i> különböző képeken (például CT) daganatok vagy más anomáliák észlelése és elhatárolása. ⁴⁶ <i>Műtétek tervezése:</i> különböző szövetek és szervek azonosítása és pontos elhatárolása. ⁴⁷
Autóipar	<i>Önvezető autók:</i> járművek, gyalogosok, illetve különböző felületek (út, járda, átjáró, sávok stb.) elhatárolása. ⁴⁸
Logisztika és kereskedelem	<i>Raktári automatizáció:</i> termékek automatikus szortírozása és nyomon követése, csomagok és címkék azonosítása. ⁴⁹
Szociális hálók, telekommunikáció	<i>Alany meghatározása:</i> fókuszban levő alany (személy vagy tárgy) elhatárolása például a háttér homályosítására vagy cseréjére.
Biztonság és területvédelem	<i>Behatolásészlelés:</i> illetéktelen személyek vagy tárgyak észlelése és nyomon követése korlátozott területeken.
Ipar	<i>Minőség-ellenőrzés:</i> termékek gyártási hibáinak észlelése és lokalizálása, mint például repedések vagy egyéb anyaghibák. <i>Robotika:</i> környezeti elemek szegmentálása a navigáció vagy mozgás precíz tervezéséhez, legyen az egyszerű szegmentáció vagy mélységbecslés. ⁵⁰
Védelmi szféra	<i>Célazonosítás:</i> földfelszín és katonai objektumok, járművek elhatárolása műholdas vagy légi felvételeken. ⁵¹ <i>Változáskövetés:</i> környezeti katasztrófák megfigyelése és területi változások monitorozása. ⁵²

Forrás: a szerzők szerkesztése

⁴³ HE et al. 2018.

⁴⁴ HE et al. 2018.

⁴⁵ Ultralytics Team 2022.

⁴⁶ MA et al. 2022: 4.

⁴⁷ MA et al. 2022: 2.

⁴⁸ NÉMETH-VIRÁGH 2022d: 1.

⁴⁹ NÉMETH-VIRÁGH 2023: 3.

⁵⁰ NÉMETH-VIRÁGH 2022c: 1.

⁵¹ ERDÉSZ 2023: 8.

⁵² ERDÉSZ 2023: 11.

Összegzés

A mesterséges intelligencia robbanásszerű fejlődésen esett át az elmúlt évtizedben, mind a polgári, mind a katonai szférában. Természetesen a fent összefoglalt, lassan klasszikusnak nevezhető gépi látással kapcsolatos feladatokon kívül rengeteg más célspecifikus feladatról lehet beszélni. A gépi látás technológiája egyértelműen kettős felhasználású, hiszen mind civil, mind katonai alkalmazásai felgyorsíthatják és automatizálhatják az információk feldolgozását és elemzését. A gyakorlati példákból kitűnik, hogy a mesterségesintelligencia-alapú látórendszerek számos ipari, biztonsági, közlekedési és egészségügyi területen nyújtanak megoldásokat, ugyanakkor a védelmi szférában is kulcsfontosságú szerepet töltenek be. Az autonóm járművek, orvosi diagnosztikai rendszerek és logisztikai alkalmazások mellett a felügyeleti rendszerek, behatolásérzékelők, célazonosító rendszerek és haditechnikai eszközök fejlesztése is ugyanazon gépi látási algoritmusokra építhető. A gépi látás alkalmazásai lehetővé teszik a valós idejű felderítést, a célazonosítást és a fenyegetések automatikus észlelését, amelyek egyaránt használhatók katonai és polgári biztonsági célokra. Az információk műveletek során az objektumkövető és anomáliaészlelő algoritmusok támogatják az adatvezérelt döntéshozatalt, ami a hadviselés és a kiberbiztonság terén is egyre meghatározóbb. Egy olyan világban, ahol az aszimmetrikus fenyegetések és az információk háborúk dominálnak, a gépi látás által nyújtott automatizált megfigyelési és elemzési képességek stratégiai előnyt, egyfajta információs vagy vezetési fölényt biztosítanak mind az államok, mind az ipari szereplők számára.

Ahhoz, hogy megfeleljük azt a kérdést, mekkora autonómiát adunk ezeknek a rendszereknek, természetesen mérlegelni kell, hogy ha az adott feladatot a gép hibásan hajtja végre, mekkora károk keletkezhetnek, illetve ki az a személy vagy szervezet, aki vagy amely felelős az okozott károkért. Fontos, hogy az ilyen rendszerek átláthatók legyenek, stabil teljesítményt nyújtsanak, minimálisra csökkentsék sebezhetőségüket. A gépi látás területén sok megoldatlan problémáról beszélhetünk, amely további kutatást igényel, mint például: hogyan állítsuk össze a hangolás során alkalmazott címkézett vagy akár címkézetlen adathalmazokat, mely architektúra nyújthatja a legjobb eredményt az adott célfeladatra, figyelembe véve az erőforrás-megszorításokat, vagy hogyan tudjuk teljes egészében kiküszöbölni a feketedoboz-problémát.

Felhasznált irodalom

- A hibrid háború korszakába léptünk: de mit is jelent ez? *B COOL Magazin*, 2022. április 22. Online: <https://bcoolmagazin.hu/a-hibrid-haboru-korszakaba-leptunk-de-mit-is-jelent-ez/>
- ALHASHIM, Ibraheem – WONKA, Peter (2019): High Quality Monocular Depth Estimation via Transfer Learning. *ArXiv*, 2019. március 10. Online: <https://doi.org/10.48550/arXiv.1812.11941>
- ALOM, Md Zahangir et al. (2018): The History Began from AlexNet: A Comprehensive Survey on Deep Learning Approaches. *ArXiv*, 2018. szeptember 13. Online: <https://doi.org/10.48550/ARXIV.1803.01164>

- Andrej Karpathy [é. n.]. Online: <https://karpathy.ai/>
- BODA Mihály (2023): A proxyháború filozófiai és etikai megközelítésben. *Honvédségi Szemle*, 151(6), 27–39. Online: <https://doi.org/10.35926/HSZ.2023.6.3>
- BODA Mihály (2024): A kockázatkerülő háború és a bátorság a 20–21. század fordulóján. *Honvédségi Szemle*, 152(3), 113–125. Online: <https://doi.org/10.35926/HSZ.2024.3.9>
- BRASSAI Sándor Tihamér (2019): *Neurális hálózatok és fuzzy logika*. Kolozsvár: Scientia Kiadó.
- DENG, Jia et al. (2009): ImageNet: A Large-Scale Hierarchical Image Database. In *2009 IEEE Conference on Computer Vision and Pattern Recognition*. 248–255. Online: <https://doi.org/10.1109/CVPR.2009.5206848>
- DU, Dawei et al. (2018): The Unmanned Aerial Vehicle Benchmark: Object Detection and Tracking. *ArXiv*, 2018. március 26. Online: <https://doi.org/10.48550/arXiv.1804.00518>
- ERDÉSZ Viktor (2023): Milyen lehetőségeket hoz az új technológiák elterjedése a felderítés számára? In KOVÁCS Zoltán (szerk.): *A mesterséges intelligencia és egyéb felforgató technológiák hatásainak átfogó vizsgálata*. Budapest: Katonai Nemzetbiztonsági Szolgálat, 440–465.
- EVERINGHAM, Mark et al. (2010): The Pascal Visual Object Classes (VOC) Challenge. *International Journal of Computer Vision*, 88, 303–338. Online: <https://doi.org/10.1007/s11263-009-0275-4>
- GIRSHICK, Ross et al. (2013): Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation. *ArXiv*, 2013. november 11. Online: <https://doi.org/10.48550/ARXIV.1311.2524>
- HAIG Zsolt et al. (2014): *Elektronikai hadviselés*. Budapest: Nemzeti Köszolgálati Egyetem.
- HAIG Zsolt – VÁRHEGYI István (2005): *Hadviselés az információs hadszíntéren*. Budapest: Zrínyi Kiadó.
- HE, Kaiming et al. (2018): Mask R-CNN. *ArXiv*, 2018. január 24. Online: <https://doi.org/10.48550/arXiv.1703.06870>
- HEAKL, Ahmed et al. (2024): DroneVis: Versatile Computer Vision Library for Drones. *ArXiv*, 2024. június 1. Online: <https://doi.org/10.48550/arXiv.2406.00447>
- HUANG, Huimin et al. (2020): UNet 3+: A Full-Scale Connected UNet for Medical Image Segmentation. *ArXiv*, 2020. április 19. Online: <https://doi.org/10.48550/arXiv.2004.08790>
- HUSSAIN, Syed Muhammad Fasih – HAMZA, Syed Muhammad – SAMAD, Abdul (2022): Image Segmentation for Autonomous Driving Using U-Net Inception. *2022 7th International Conference on Signal and Image Processing (ICSIP)*, 426–429. Online: <https://doi.org/10.1109/ICSIP55141.2022.9885809>
- KONRÁD György (1963): A korszerű háború korszerűtlensége I. *Valóság*, 6(6), 16–30.
- LI, Fei-Fei – ADELI, Ehsan (2024): *CS231n: Deep Learning for Computer Vision*. Online: https://cs231n.stanford.edu/slides/2024/lecture_1_part_2.pdf
- LIN, Tsung-Yi et al. (2014): Microsoft COCO: Common Objects in Context. In FLEET, David et al. (szerk.): *Computer Vision – ECCV 2014*. Cham: Springer, 740–455. Online: https://doi.org/10.1007/978-3-319-10602-1_48

- LONG, Jonathan – SHELHAMER, Evan – DARRELL, Trevor (2015): Fully Convolutional Networks for Semantic Segmentation. *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 3431–3440. Online: <https://doi.org/10.1109/CVPR.2015.7298965>
- MA, Jun et al. (2022): AbdomenCT-1K: Is Abdominal Organ Segmentation a Solved Problem? *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 44(10), 6695–6714. Online: <https://doi.org/10.1109/TPAMI.2021.3100536>
- NÉGYESI Imre (2023): A mesterséges intelligencia társadalmi és etikai kérdései. *Honvédségi Szemle*, 151(4), 6–18. Online: <https://doi.org/10.35926/HSZ.2023.4.1>
- NÉMETH András – VIRÁGH Krisztián (2022a): Mesterséges intelligencia és haderő – A mesterséges intelligencia fejlődéstörténete I. rész. *Haditechnika*, 56(1), 17–22. Online: <https://doi.org/10.23713/HT.56.1.03>
- NÉMETH András – VIRÁGH Krisztián (2022b): Mesterséges intelligencia és haderő – A mesterséges intelligencia fejlődéstörténete II. rész. *Haditechnika*, 56(2), 2–6. Online: <https://doi.org/10.23713/HT.56.2.01>
- NÉMETH András – VIRÁGH Krisztián (2022c): Mesterséges intelligencia és haderő – Polgári alkalmazási lehetőségek V. rész. *Haditechnika*, 56(5), 2–7. Online: <https://doi.org/10.23713/HT.56.5.01>
- NÉMETH András – VIRÁGH Krisztián (2022d): Mesterséges intelligencia és haderő VI. rész – További polgári alkalmazási lehetőségek. *Haditechnika*, 56(6), 2–7. Online: <https://doi.org/10.23713/HT.56.6.01>
- NÉMETH András – VIRÁGH Krisztián (2023): Mesterséges intelligencia és haderő VII. Rész – Katonai alkalmazási lehetőségek. *Haditechnika*, 57(1), 2–6. Online: <https://doi.org/10.23713/HT.57.1.01>
- PLOUMIS, Michail (2022): AI Weapon Systems in Future War Operations; Strategy, Operations and Tactics. *Comparative Strategy*, 41(1), 1–18. Online: <https://doi.org/10.1080/01495933.2021.2017739>
- QIU, Zhongze et al. (2023): Joint Fusion and Detection via Deep Learning in UAV-Borne Multispectral Sensing of Scatterable Landmine. *Sensors*, 23(12), 5693. Online: <https://doi.org/10.3390/s23125693>
- REDMON, Joseph et al. (2015): You Only Look Once: Unified, Real-Time Object Detection. *ArXiv*, 2015. június 8. Online: <https://doi.org/10.48550/ARXIV.1506.02640>
- RONNEBERGER, Olaf – FISCHER, Philipp – BROX, Thomas (2015): U-Net: Convolutional Networks for Biomedical Image Segmentation. *ArXiv*, 2015. május 18. Online: <https://doi.org/10.48550/arXiv.1505.04597>
- SZABADFÖLDI István (2022): A mesterséges intelligencia alkalmazási lehetőségei az elektronikai hadviselésben. In FÖLDI László (szerk.): *Szemelvények a katonai műszaki tudományok eredményeiből III.* Budapest: Ludovika Egyetemi Kiadó, 351–370.
- Tesla Vision Update: Replacing Ultrasonic Sensors with Tesla Vision* [é. n.]. Online: www.tesla.com/support/transitioning-tesla-vision
- THORBECKE, Catherine (2020): Tesla on Autopilot Had Steered Driver towards Same Barrier before Fatal Crash, NTSB Says. *ABC News*, 2020. február 12. Online: <https://abcnews.go.com/Business/tesla-autopilot-steered-driver-barrier-fatal-crash-ntsb/story?id=68936725>

- ULMAS, Priit – LIIV, Innar (2020): Segmentation of Satellite Imagery using U-Net Models for Land Cover Classification. *ArXiv*, 2020. március 5. Online: <https://doi.org/10.48550/arXiv.2003.02899>
- Ultralytics Team (2022): Introducing Instance Segmentation in Ultralytics YOLOv5 v7.0. *Ultralytics*, 2022. november 23. Online: www.ultralytics.com/blog/introducing-instance-segmentation-in-yolov5-v7-0
- WANG, Junjue et al. (2022): LoveDA: A Remote Sensing Land-Cover Dataset for Domain Adaptive Semantic Segmentation. *ArXiv*, 2022. október 17. Online: <https://doi.org/10.48550/arXiv.2110.08733>
- WOJKE, Nicolai – BEWLEY, Alex – PAULUS, Dietrich (2017): Simple Online and Realtime Tracking with a Deep Association Metric. *ArXiv*, 2017. március 21. Online: <https://doi.org/10.48550/ARXIV.1703.07402>
- XIA, Gui-Song et al. (2018): DOTA: A Large-Scale Dataset for Object Detection in Aerial Images. In *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 3974–3983. Online: <https://doi.org/10.1109/CVPR.2018.00418>