

**AMBRUS ÉVA<sup>18</sup>**

PÁNCÉLBA ZÁRT SZELLEM – A NYÍLT FORRÁSÚ FELDERÍTÉSI CIKLUS ÉS A MESTERSÉGES  
INTELLIGENCIA

**Absztrakt**

A mesterséges intelligencia jelenléte mindennapjainkban megkerülhetetlennek tűnik. A gépi tanulás képessége meghatározza az általa végezhető feladatok körét, ennek bemutatása célom a nyílt forrású felderítés értékelés-elemzésében. Az információ túl-telítődés kifejezetten káros azon szakemberek számára, akiknek mindennapi feladatuk szűrni, értékelni és elemezni azokat. Ebben nyújthat segítséget a mesterséges intelligencia, mindazonáltal nem szabad túlbecsülni a képességeit, a gépi tanulás jelenlegi állapotában nem vethető össze az összetett emberi gondolkodással, azonban kiegészítheti azt.

Kulcsszavak: mesterséges intelligencia, gépi tanulás, értékelés-elemzés

GHOST IN THE SHELL – ARTIFICIAL INTELLIGENCE AND OSINT INTELLIGENCE CYCLE

**Abstract**

The presence of artificial intelligence is a given in our daily lives. The ability of machine learning determines the scope of the tasks it can perform, and my aim is to present its capabilities in the data analysis of open source intelligence. Information overload is particularly harmful to professionals whose daily task is to screen, evaluate and analyze them. Artificial intelligence can help regarding information overload, but its capabilities should not overestimated as in its current state machine learning cannot be compared to the complexity of human thinking, but it can complement it.

Keywords: artificial intelligence, machine learning, analysis-evaluation

---

<sup>18</sup> Nemzeti Közszolgálati Egyetem, Katonai Műszaki Doktori Iskola, doktorandusz

### 1. Bevezetés

Korunk technológiai fejlődésének egyik központi kérdése lett a pedagógia-pszichológia egyik alapvetése: a tanulás tanulása. Összefüggése a tanulmány címével elsőre távolinak tűnhet, azonban a jelenlegi fejlettségi szintjén a mesterséges intelligenciának igen fontos elágazása az algoritmusok tanulási képessége. Jelen tanulmányban megvizsgálom a hírszerzési ciklus, kifejezetten a nyílt forrású hírszerzés és a mesterséges intelligencia közötti kapcsolatot. Az elmúlt évtized technológiai és infokommunikációs fejlődése több kihívást is eredményezett ezen a területen: egyfelől az adatmennyiség növekedését, ezzel egyidejűleg a szűrés fontossága megnövekedett, másfelől a mesterséges intelligencia újabb fejlődését, amely segítséget jelent az adatok és információk feldolgozásában. Jelen tanulmány fókuszja a mesterséges intelligencia megjelenése a nyílt forrású felderítés (OSINT) tükrében és a hírszerzési ciklus elemzés-értékelés fázisában. Az értékelő-elemzőnek három realitással kell szembenéznie: az összetettséggel (komplexitással), hiányos és többértelmű információkkal és az emberi elme korlátai. Ezek megjelennek a nyílt forrású adatok szűrésénél és értékelésénél, az előítéletekben, elfogultságban (cognitive bias) és a mentális modellekben (*US Government Tradecraft 2009*). A mesterséges intelligencia területén tett lépések képesek-e ezen hiányosságok pótlására?

### 2. OSINT és hírszerzési ciklus

Az OSINT (nyíltforrású hírszerzés - OSINT, open-source intelligence a hírszerzés egyik ága. Definíció között létezik eltérés, ahogyan Solti István tanulmányában (*Solti 2019: 5-7*) rámutat, az angolszász megfogalmazásban nyilvánosan elérhető forrásokról beszélünk (azaz bárki által fellelhető, megvásárolható), míg Lévay és Vida értelmezésében fontos, hogy nyílt is legyen a forrás (azaz nem minősített) (*Solti 2019: 6*). További megkülönböztetésre ad lehetőséget hogy klasszikus, vagy elektronikus forrásról van-e szó. Klasszikusnak (vagy első generációs) forrásnak tekinthető a könyvtár, irattár, sajtótermék, rádió és tv-adások, konferenciák, interjúk, folyóiratok, tudományos publikációk, míg elektronikus (vagy második generációs) forrásnak például az interneten fellelhető adatbázisokat, a közösségi médiát, keresőrendszereket (*Vadász 2015: 88*).

A hírszerzési ciklus a hírszerzés folyamatának sematikus leírása, amelynek általánosságban öt fázisát szokás megkülönböztetni: (1) az információigények fogadása, (2) az adatszerzésből, (3) az információk feldolgozásából és rendszerezéséből, (4) az információk elemzéséből-értékeléséből, valamint (5) a tájékoztatás (Vida 2018: 115). A ciklust összekapcsolva az OSINT-tal, Vida Csaba megfogalmazásában „a nyílt forrású adatszerzés speciális módszertan alapján, folyamatosan végzendő adatszerző tevékenység, amely elsődleges (nyers) és másodlagos (már feldolgozott vagy átvett) nyílt információk megszerzésére és feldolgozására irányul a felhasználók (kormányzat, haderő, rendőrség, cégek, vállalatok stb.) információigényeinek kielégítése érdekében” (Vida 2018: 134).

Az OSINT-nak - kiváltképp a második generációs nyílt forrású felderítésnek - számtalan előnye van: a gyorsasága (az információ terjedésének gyorsasága elsősorban), a mennyisége (sokkal több blogger, újságíró, riporter és kutató van, mint elemző-értékelő egy adott szervezetnél), minőség (megfelelő szűrés és ellenőrzés után), átláthatóság (forrás), tájékoztatás egyszerűsége (az információ továbbítása egyszerűbb, mint minősített adatok esetében) és költséghatékonyság (technikai, előfizetések) (Mercado 2007).

Az elmúlt két évtized adatrobbanása következtében korábban elképzelhetetlen mennyiségű és minőségű adat áll rendelkezésre. Ez egyfelől nagy lehetőség, másfelől kihívás, hiszen az adatok formája, minősége, mennyisége és sebessége igencsak változó. Ezek a változók angolul a „four Vs”-nek nevezik, azaz: volume (adatforrás mennyiség), variety (adatforrás formája), velocity (adatforrás sebessége) és veracity (minősége, megbízhatósága) (Atwood 2015).

Ennek a folyamatnak következménye az értékelő-elemzők információs túltelítődése. Az információs túltelítődés fogalmát Alvin Toffler népszerűsítette *Jövősokk* című könyvében, definíciója „az információ össz-tömegének disszonáns, egészségtelen növekedése. Mivel az információk áttekintésének, keresésének, kezelésének és felhasználásának módszerei lassabban fejlődnek, mint az elérhető információ mennyisége, a túlzott információtermelés okozta feldolgozási problémák alapvető rendszerfunkciókat veszélyeztetnek” (Informatorium 2016).

Ennek kezelésére az egyik segítség a mesterséges intelligencia a folyamatok automatizálásában, az elemző-értékelők képességeinek kiterjesztésében az adatok gyűjtésében, szűrésében, összekapcsolásában. Azonban – minden optimizmus ellenére – a mesterséges intelligencia jelen állapotában gyerekcipőben jár ezen a területen. Ennek oka újfent a hírszerzési ciklusban keresendő: az információigényben (az első fázisban): a legtöbb információigény három általános kategóriába eshet: rejtvény (puzzle) vagy rejtély (mystery), illetve komplex típusról (*Treverton 2008: 13*):

Probléma	Leírás	Hírszerzői termék
Rejtvény	Létezik válasz, de nem ismert	A válasz
Rejtély	Több lehetséges válasz, de több kulcsváltozó megadhatja a legvalószínűbbet	Legvalószínűbb előrejelzés, forgatókönyvek
Komplex probléma	Több szereplő reagál a változó körülményekre, nincs minta	Értelmezés.

1. ábra: rejtvény, rejtély, komplex probléma

Forrás: Treverton, G.F. (ed. 2008): *New Frontiers in Intelligence*, Notes from seminar in Stockholm, may 27-28, published by The Swedish National Defence College, p. 13.

A mesterséges intelligencia jelenlegi fejlettségi szinten képes segíteni a rejtvény és rejtély esetében, azonban minta hiányában a komplexebb kérdésekben nem. A mesterséges intelligencia használata az OSINT esetében több kihívást jelent: a releváns információk *mind* hihetetlenül sokrétűek, és erősen összefüggnek a kontextussal, a nagy mennyiségű adatelemzés képes trendeket kimutatni, azonban gyakran minden rendelkezésre álló, releváns adatra szükség van, és meg kell vizsgálni minden dokumentum hitelességét, megbízhatóságát, valamint a szerző motivációját (*Eldrige, Hobbs–Moran 2017: 3*). A következőkben bemutatom röviden a mesterséges intelligencia (MI) alakulását és a nagymennyiségű adatok (big data) megjelenését.

### 3. Big Data és Mesterséges Intelligencia

A mesterséges intelligenciának (MI) több definíciója megtalálható a szakirodalomban, Russel és Norvig szerint alapvetően aszerint változik a meghatározás, hogy mi az MI célja, és az erre adott válaszok alapján négy fő kategóriát állapítottak meg. Ezek (1) emberi módon cselekvő rendszerek, (2) emberi módon gondolkodó rendszerek, (3) racionális módon gondolkodó rendszerek és (4) racionális módon cselekvő rendszerek (*Russel–Norvig 2009: 2*).

1950-ben Alan Turing, angol matematikus, több publikációban foglalkozott a számítógépek és gondolkodás kapcsolatáról. Egyike ezeknek a *Computing machines and Intelligence* (*Turing 1950*) volt, ahol azt járta körbe, hogy tudnak-e gondolkodni a gépek? Vagyis van-e a gépnek képessége emberi jellegű képességek megjelenítésére, mint például az érvelés, a tanulás, tervezés és kreativitás. Tanulmányát a következő gondolattal nyitotta: “Azt javaslom, hogy gondolják át, gondolkodhatnak-e a gépek?” (*Turing 1950: 433*). Ezt a gondolatot tovább vitte az ún. Turing-tesztnél, amely arra hivatott, hogy egy gépről megállapítsa, képes-e olyan válaszokat adni feladatokra, mint egy ember. A Turing-tesztet több kritika érte az idők folyamán (*Oppy–Dowe 2019*), azonban cikke és munkássága vitathatatlanul fellendítette a mesterséges intelligencia iránti érdeklődést.

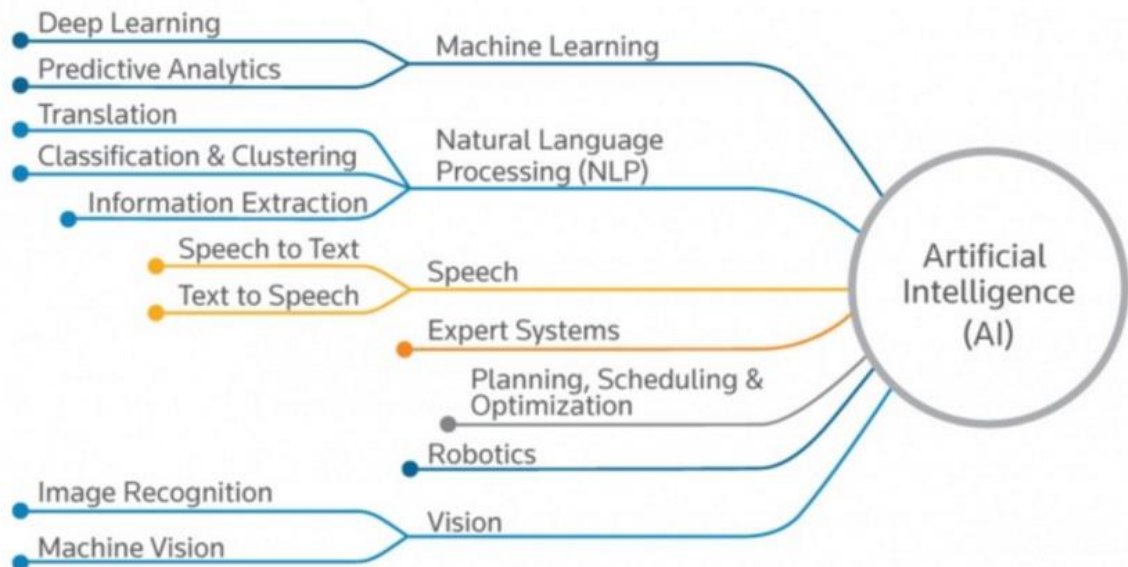
Jelen tanulmányban gondolkodás alatt a következő definíciót értem: „a gondolkodás a tudás szellemi reprezentációjának szisztematikus átalakítása a világ aktuális vagy lehetséges állapotának jellemzésére, gyakran bizonyos célok szolgálatában” (*Holyoak–Morrison 2012: 1*).

A mesterséges intelligenciáról való gondolkodás az 1960-as években aköré épült, hogy az intelligens emberi viselkedést logikai szabályok sorozataként lehet dekonstruálni. Ezeket algoritmusokba átírva a gépek lekövethetik az intelligens viselkedés megjelenítését. Ez volt a szimbólum-rendszer érvelés, melyet Newell és Simon képviselt (*Newell–Simon 1976*). Ennek egyszerű lényege, hogy a gépnek adott információkat olyan szimbólumokká (grafikonokká, logikai képletekké) kell átalakítani, amelyeket a számítógép egy szabálykészlet segítségével manipulálhat. Ez egy felülről lefelé (top-down) mutató megközelítés volt, amely egy adott viselkedést kisebb problémákra bont le.

Bármely reprezentációs rendszer minimálisan egy reprezentációs elem szókészletéből (például szimbólumok a szimbolikus modellben vagy csomópontok egy neurális modellben), és egy szabálykészletből áll, hogy az a meglévő utasításokból új állításokat vonjon le (*Doumas–Hummel 2012: 56*). Az e téren folytatott kutatás nagy része azt feltételezte, hogy az emberi tudás ábrázolása szimbolikus, és az érvelés, a nyelv, a tervezés és a látás megérthető a szimbolikus műveletek szempontjából. Könnyen elképzelhető milyen feladat elé állította a programozókat e szabálykészletek megalkotása, hiszen minden eshetőségre szükséges volt egy szabály megalkotása. “Ennek a modellnek két korlátja van, mégpedig hogy hogyan lehetséges (amennyiben akár lehetséges) megtanulni a szimbolikus ábrázolásokat (azaz a szókészletet), valamint, hogy az emberi mentális reprezentációk szemantikai tartalommal bírnak. Azaz a dolgokról szólnak, és valamilyen természetes módon megfogják, hogy ezek a dolgok hogyan hasonlítanak egymáshoz vagy különböznek egymástól” (*Doumas–Hummel 2012: 58*).

A 70-es – 80-as években lankadt a lelkesedés a terület iránt, a kutatások nem tudtak tovább lépni, egészen az IBM szuper-számítógépe, a Deep Blue győzelméig Kasparov ellen 1997-ben (*Chess.com*). Ez volt az első eset, hogy egy számítógép legyőzött egy embert (egy játékban). A Deep Blue egy olyan algoritmuson alapult, amely másodpercenként több millió lehetőséget elemzett, és kiválasztotta a legígéretesebb lépést. Ezt az emberfeletti számítási sebességek nevezik “brutális erő”-nek (*Press 2018*). E fellendülés együtt járt a neurális hálózatok rendszere, az adatbányászat és a bayes-hálók iránti érdeklődéssel.

A 2000-es évekre a technikai fejlődés két új eleme tovább lendíti az MI fejlődését: a tanuló algoritmusok (gépi tanulás) és a digitális világ fejlődésével előállított nagy mennyiségű adat (big data) elterjedése. Ennek egyik következménye lett, hogy nagyon specifikus területek alakultak ki az MI-n belül: számítógépes látás, beszéd felismerés, mélytanulás.



Source: Neota Logic

2. ábra: az MI alterületei, első elágazás felülről lefelé (tovább bontás): gépi tanulása (mélytanulás, prediktív elemzés), természetes nyelvfeldolgozás (fordítás, osztályozás és klaszterezés, információ kinyerés), beszéd (beszédet szöveggé, szöveget beszéddé), szakértői rendszerek, tervezés – ütemezés - optimalizálás, robotika, látás (képfelismerés, gépi látás)

Forrás: Diogo Menezes Borges, Deep Learning: The When and the How, Oct 1, 2018,

<https://medium.com/diogo-menezes-borges/deep-learning-the-when-and-the-how-59b0616c4c1c>

A másik említett technikai fejlődés a nagymennyiségű adatok (big data) megjelenése. A big data, azaz olyan nagy adatkészlet, amelyet rögzíteni, továbbítani, összesíteni, tárolni és elemezni lehet (Couch–Robbins 2013: 1). Ezek az adatok általában több forrásból és platformról érkeznek, változatosak és kevésbé strukturáltak. Mára egyértelművé vált, hogy a több adat nem feltétlenül jelent jobb adatot, és nem vezet automatikusan megbízhatóbb eredményekhez. A rendelkezésre álló adatok növekedése nem zárja ki a „szubjektív” értelmezés szükségességét.

Az MI és a big data kapcsolatában látható, hogy kezdetben az adatgyűjtési tevékenységek javítására tevődött a hangsúly (pl. internetes keresés-optimalizáció), azonban a hangsúly egyre inkább az adatok elemzésére irányult, hogy az algoritmikus bizonyos paramétereken belül működve megértse a gyűjtött információkat. Nem véletlenül használom a második mondatban az információt, hiszen ez is jelzi a fejlődést ezen területeken: míg először adatgyűjtés folyt, immár információgyűjtés zajlik. Míg „az adatoknak nincsen jelentése


(értelme) vagy értéke, mivel nincs kontextusuk, és nem rendelkeznek interpretációkkal” (*Tudományos és Műszaki Tájékoztatás*), addig az információ „Formattált adat, amely a valóság reprezentációja” (*Tudományos és Műszaki Tájékoztatás*). A reprezentáció kapcsán későbbiekben visszatérek a reprezentációhoz a mentális modelleknél.

A fenti rövid áttekintés egyértelművé teszi, hogy a big data számtalan lehetőséget és kihívást jelent a nyílt forrású elemzők számára. Az automatizált eszközök, amelyek képesek mind az információ gyűjtésére, mind értelmezésére, erőteljesen segíthetnek a big data feldolgozásában (*Matheny 2013*).

Nyilvánvaló, hogy jól megtervezett alkalmazásokra van szükség, azonban a technológia fejlődés túlmutat az információgyűjtés és az elemzés alkalmazott eljárásain és olyan fontos kérdéseket vetít előre, mint az automatizálás szerepe és mértéke az OSINT területén vagy az elemzők változó szerepe a technológia fejlődés tükrében.

Kevjn Lim tömören foglalta össze az automatizált megközelítések erősségeit és gyengeségeit, megjegyezve, hogy „a Big Data elemzése a vizsgálat fókuszát az okozati összefüggésekről a korrelációkra helyezi át” (*Lim 2016*), azaz a logikai ok-okozatról a változók viszonyára. Egyetértés látszik körvonalazódni afelől, hogy az elemzők és az új technológiával ellátott gépek között a munkaerő-egyensúly megfog változni, a big data kiaknázása növeli, nem pedig csökkenti az emberi megítélés és a szakértelem szükségességét (*Lim 2016*). A jövőben fontosabbá válik az elemző fejlett kereső-eszközök beállításának képessége, amelyhez aztán hozzáteheti szakértelmét, tapasztalatát, intuícióját és emberi ítélőképességét (*Couch–Robins 2013: 10*).

Ahogy korábban tárgyaltuk, az elemzők számára az információ-telítődés az egyik fő kihívás. A hírszerzési ciklusban – főleg az időnyomásnak köszönhetően - akár egy tapasztalt elemző is gyorsan korlátozhatja a figyelmét egy adott, „kiugró” dokumentumkészletre, melyből hipotézisek születnek. Az automatizált eszközök képesek fontos szerepet játszani mind az adatgyűjtésben (minták, trendek), mind a különböző dokumentumok automatizált osztályozásában.



3. ábra. Big data – MI beépítése az elemzés értékelésben

Forrás: Lim, K. (2016) Big Data and Strategic Intelligence, *Intelligence and National Security*, Volume 31, 2016 - Issue 4, p. 23.

A fenti ábrán, Kim cikke alapján, látható, hogy hol nyújthat segítséget a big data: az általános trendek (prediktív modellezés) megalkotásában, amelyek segíthetnek a probléma – hiány feltárásában, valamint a hipotézisek felállításában. A hipotézist szisztematikusan összevetve a beérkező adatokkal elvethetjük vagy elfogadhatjuk. Ez elsősorban akkor hatékony, ha a 'megrendelés' egy rejtvény, azaz egy konkrét választ keresünk, vagy egy rejtély. Mindkettő esetében szükséges azonban az elemzői tapasztalat a hipotézisek felállításában.

A következő részben mélyebben megvizsgálom, hogy hogyan képesek a gépek segíteni az elemzők munkáját.

### 4. Gondolkodás és gépi tanulás

Egy számítógépes programban az adatszerkezetek olyan adatok tárolására szolgálnak, amelyeket egy program manipulálni fog valamilyen funkció végrehajtása érdekében. A mentális reprezentáció (ábrázolás) szerepet játszik a kognitív rendszerekben, hasonlóan a program adatszerkezetének szerepéhez. Annak érdekében, hogy ez a reprezentáció hatékonyan legyen, valamilyen módon biztosítani kell, hogy a reprezentáció a megfelelő információkat rögzítse. A adatok kapcsolatának (vagy összekötésének) módja fontos. Ezeknek a kapcsolati kötéseknek a megragadásához a strukturált reprezentációk olyan reprezentációk létrehozásának mechanizmusát tartalmazzák, amelyek olyan érveket vesznek fel, amelyek meghatározzák a reprezentáció hatókörét (*Lehmann 2006: 1-3*).

Annak érdekében, hogy valami reprezentációnak minősüljön, négy feltételnek kell teljesülnie:

(1) Van egy világ, amit reprezentálni szeretnénk (pl. szimbólumok gyűjteménye, 0-9 között számok)

(2) Van is egy reprezentált világ (az információs terület, amelyet reprezentálni kell). A világban mindig több információ van, mint amelyet a reprezentált világ megragadhat, emiatt sosem tudja teljesen hűen leképezni.

(3) A reprezentációs kapcsolatok halmaza, amely meghatározza, hogy a reprezentált világ miként igazodik a reprezentáló világhoz.

(4) Meghatározott folyamatok valamilyen feladat végrehajtásához használja az információt a reprezentált világban (*Holyoak–Morrison 2012: 39*).

A mentális modellek entitásokat és személyeket, eseményeket és folyamatokat, valamint komplex rendszerek működését ábrázolják.

(*Johnson–Laird 2008*) három alapelvet állapított meg:

- 1) A modern elmélet első alapelve az ikonikusság elve, miszerint egy mentális modell részei és szerkezeti kölcsönös kapcsolataik megegyeznek a képviselt helyzet részeivel.
- 2) A második elv a lehetőségekre vonatkozik, amelyek kulcsfontosságúak az emberi gondolkodásban. A lehetőségek alapelvei: az egyes mentális modellek különálló lehetőségeket képviselnek, vagyis megragadják azt, ami közös a különféle lehetőségek között.

- 3) A harmadik elv az igazság alapelve: a mentális modellek csak azt állítják, ami lehetséges az állítások alapján.

A számítástechnikai megközelítések, a számítási modellek a tudományos gondolkodás alapjául szolgáló kognitív folyamatok konkrét, részletes megismerését teszik lehetővé. A korai szakaszban ez a számítási munka egy tudományos felfedezés érvelési folyamatainak számítási modellének felépítéséből állt. Ezeknek a programoknak különféle induktív algoritmusok voltak beprogramozva, és amikor a tudósok által felhasznált adatokat megkapta, képesek voltak ugyanazokat a szabályokat javasolni (a korábban említett, emberi gondolkodást szimuláló MI). A közelmúltban a figyelem olyan programok felé fordult, amelyek nem szimulálnak, hanem segítenek a tudósoknak, mint például az adatbányászat, ezzel kiegészítve az ő munkájukat. Az adatbányászat esetében a rejtett és számunkra hasznos tudást (információt), összefüggéseket keressük egy nagy adathalmazban (*Bodon–Buzsáki 2014*).


### 5. Gépi tanulási technikák

A mesterséges intelligencia, ahogyan eddig láttuk, az emberi gondolkodás (pl. indukción, dedukción, reprezentáción) replikája szabályok által. A gépi tanulás a számítógép azon képességére utal, hogy nagy mennyiségű adatkészleteket (big data) felhasználva képes tanulni (tehát nem csak az előre megadott szabályrendszerek által).

A gépi tanulás alapvetően lehet felügyelt és nem-felügyelt. Felügyelt tanulás esetén a gépet ki képzik egy adott feladat végrehajtására, például a macskák felismerésére a képeken. Ehhez nagy mennyiségű adatot, több ezer képet kell címkézni, amelyek macskákat tartalmaznak (vagy nem). Ez azt is magában foglalja, hogy a gépet ellenőrizni kell, hogy megfelelő választ ad-e (*Microsoft Azure 2019*). A felügyelt képzést az információk osztályozását igénylő feladatokhoz használják. A kibervédelem területén ilyen feladat például a spam-levelek szűrése.

Felügyelet nélküli tanulás esetén a program nem kap semmilyen feladatot, és az adatok címkézetlenek. A program szabadon megtalálja saját korrelációit az adatokban. Az adatokból tanulva a gép klasztereket hoz létre a megadott adatokban, és társítási szabályokat állapít meg,

amelyek összekapcsolják az adatok különböző változóit. A kibervédelemben ilyen lehet a malware-k felismerése (*Microsoft Azure 2019*).



4. ábra: Példa rosszindulatú programok észlelésére. A gépi tanulási algoritmus malware (sötétkék) és jóindulatú szoftverek (világos kék) példáit használja a döntési határ (szagatott vonal) megtanulásához

Forrás: CSIA Reports / Learning to Win: Making the Case for Autonomous Cyber Security Solutions, <https://www.csiac.org/csiac-report/learning-to-win-making-the-case-for-autonomous-cyber-security-solutions/>

Visszatérve a macska-felismeréshez, a programnak fogalma sincs, mi a macska. A szimbolikus MI megközelítésben ez a feladat azt jelentette volna, hogy elmagyarázzuk a programnak, mi a macska, hogy az felismerje (a macska képét). Ez a gép programozását jelentette volna, hogy felismerje, mi a láb, mi a fül, mi a szőrme, és hogy a macskának négy lába, két füle van, és különféle szőrmintája lehet, mielőtt a program képes felismerni egy macska képét (*Kóczy-Tikk*). A gépi tanulási technikák megkerülik ezt az akadályt azáltal, hogy a gépek képesek hatalmas mennyiségű adatot elemezni statisztikai korrelációk megtalálására, és a visszacsatolások révén egyre jobban megbecsülni, mi az a macska.

A gépi tanulási technikák egyik alapvető problémája azonban, hogy nem lehet pontosan tudni, hogyan jut el a gép a következtetéseire, hogyan hoz döntést egy adott feladatról. A macskák képeinek példájában nem lehet tudni, mely változókat használ a program egy kép leírásában annak eldöntésére, hogy a kép macskát tartalmaz-e vagy sem. A szimbolikus MI-ban a „magyarázhatóság” fogalma, azaz a képesség megmagyarázni, hogy egy rendszer miként érte el a következtetését, központi szerepet játszott. Az adatvezérelt MI esetében a

„magyarázhatóság” már nem számít, csak az eredmény. Ez felveti annak kérdését is, hogy az adatvezérelt MI rendszerek valóban tudják-e mit várnak el tőlük (*D'Souza 2018*).

## 6. Elfogultság és mentális modellek

„Mindenki gondolkodik; ilyen a természetünk. De gondolkodásunk nagy része, önmagában, elfogult, torz, részleges, tudatlan vagy egyenesen előítéletes” (*Paul–Elder 2006*)  
Heuer megvizsgálta az hírszerzési elemzésnek hibáit, melyek szerinte a gondolkodásmód és a kognitív elfogultságban rejlenek (*Heuer 1999: 65*).

A Tradecraft Primer (*US Government Tradecraft 2009*) négy kategóriát ismertet az általános észlelési és kognitív torzításokkal: észlelési torzítások, torzulások a bizonyítékok értékelésében, torzítások a valószínűség becslésében és torzítások az ok-okozati összefüggések észlelésében:

Észlelési elfogultság Elvárások (hajlamosak vagyunk azt észrevenni, amit várunk) Ellenállás (a megfigyeléseinkben új bizonyíték ellenére) Kétértelműség	Elfogultság a bizonyítékok értékelésében Következetesség (nagyobb bizalom azon következtetésekben, amelyek kisszámú, de következetes adatból származik) Hiányzó információ (felbecsülése) Elvetett bizonyíték (az adat elvetése gyorsabb, mint a hipotézisé)
Elfogultság a valószínűségek becslésében Elérhetőség (mennyire könnyen tudjuk elképzelni az eseményt vagy emlékezni hasonló esetre) Rögzítés (valószínűségi becslések marginálisan változnak új információ hatására) Túlzott önbizalom	Elfogultság az okozati összefüggések felismerésében Racionalitás (az események rendezetten, okozati összefüggésben zajlanak, véletlenszerűség, baleset vagy hiba ritkán magyarázat egy eseményre) Tulajdonság (Mások viselkedése az adott ember természetének tulajdonított, míg a sajátunk az adott helyzetnek amiben vagyunk)

5. ábra: elfogultság-típusok

Forrás: US GOVERNMENT Tradecraft, *op.cit.* p.2.

Több tudomány szakemberei foglalkoznak a kognitív torzításokkal, elfogultságokkal és azok a gondolkodásra, elemzésre és döntéshozatalra gyakorolt hatásaival (többek között a

Nobel-díjas Daniel Kahneman a 'Gyors és lassú gondolkodás' c. könyvében). A mentális elfogultságok természetes részei az emberi gondolkodásnak. Az elemzők (és az emberek, úgy általában) az információ-telítődés miatt ezekre a mentális 'gyorsbillentyűkre' támaszkodnak. Ezeknek az elfogultságoknak a figyelembevételre és leküzdésére is fontos a strukturáltabb módszerek beépítése a hírszerzési ciklusban. A kognitív elfogultságok leküzdése időigényes az egyének számára, hiszen ezeket sok esetben tudattalanul végzik. A mesterséges intelligencia képes kiegészíteni ezen vakfoltokat, hiszen a tudományos módszerben gyökerezik. Ez biztosítja az átláthatóságot, mivel a hipotézisek szigorú empirikus kísérleteken mennek keresztül, amelyeknek megismételhető eredményeket kell szolgáltatniuk (*Russel-Norvig 2009:25*).

„A nagy monotonitással járó megfigyelések, avagy a túl nagy mennyiségű információból kiválasztandó cél követése, s különösen a gyors információfeldolgozás szükségessége, az ember teljesítőképességének határait meghaladhatja. Ez az a terület, ahol az ember fizikai jelenlétével nem konkurálva jelentős érdemeket szerezhet a mesterséges intelligenciával ellátott rendszer. Az ilyen rendszer folyamatosan gyűjti környezetének eseményeit, feldolgozza, s ezek átlaga alapján adaptálódik a gép a külvilághoz, s ad folyamatosan javuló valószínűséggel helyes válaszreakciót” (*Orbán 2017: 87*). A mesterséges intelligencia az arcfelismerés, a természetes nyelv folyamata, a gép és a mély tanulás formájában segíthet az elemzőknek az információterhelés és a kognitív torzulások elkerülésében adatbányászattal, jelentések elemzésével, csomópontok és entitások létrehozásával, hivatkozási diagramok szervezésével és az elemzés folyamatos finomításával.

### 7. Összefoglaló és ajánlások

Az OSINT területét két szinten érte változás, makro szinten az infokommunikációs társadalom, és ennek hatásaként a big data térnyerése, amely életünk legtöbb területén megjelent, és mikro szinten, az MI adta lehetőségek és eszközök megjelenésével. Az egyre növekvő mennyiségű elérhető információ telítődést eredményezhet. Az olvasási sebesség, a részletekre való figyelem és a munkaterhelés mind olyan tényezők, amelyek befolyásolják az emberi agy által feldolgozható információ mennyiségét. A tapasztalat és az intuíció torzíthatja az elemzők ítéleteit értékeléskor. A mesterséges intelligencia életképes eszköz az elemzésben az információtelítődés és a kognitív elfogultság hatásainak minimalizálásához. A gépi tanulás

segíthet az elemzőknek, hogy nagy mennyiségű adatot szűrjenek és rendszerezzenek, emellett hozzájárulhatnak minták elemzéséhez.

A mesterséges intelligencia fejlődése gyors ütemben folytatódik melyre lehetőségként kell tekinteni az információterhelés és a gondolkodás kognitív elfogultságának hatásának csökkentésére. Az együttműködés a gépek azon erősségeire támaszkodik, hogy gyorsan szétválogassa a nagy adatkészleteket és kiemelje a jelentős adatokat. Az emberek ezeket az adatokat arra használhatják, hogy a rendelkezésre álló információkat értelmezzék.

Gép	Ember
Adatfeldolgozás -> információelemzés	-> értékelés (tudás) -> hírszerzési információ

6. ábra: saját szerkesztés.

A gépek gyorsan és megkülönböztetés nélkül dolgozzák fel az adatokat és elemzik az információkat, ami segít az elemzőknek az értékelésben. Az elemzők értelmezik a mesterséges intelligencia által kikövetkeztet mintákat, és értékelik azokat, tapasztalatuk és szakértelmük, valamint az információigény ismeretük révén.

Pragmatikusabb kérdés, hogy az MI-t hogyan alkalmazzák egy szélesebb OSINT rendszer részeként. Fontos a rendszer és az eljárások ismerete, valamint az elemzők közvetlen bevonása a rendszer-tervezési folyamatba, hiszen a munka gyakorlatában bekövetkezett változások őket is érintik. Az új alkalmazások beépítése a meglévő eljárások megváltoztatását teheti szükségessé, amely változást megfelelően támogatni kell (továbbképzések). Gyakorlati szempontból az elemzők képességeit és a számítógépek feldolgozási teljesítményét ötvöző rendszer kialakításának az érintett szereplő elemzési igényeinek és céljainak átfogó áttekintésével kell kezdődnie. Ehhez a jelenlegi munkafolyamatok feltérképezése kell, beazonosítva azon területek és feladatok, amelyeknél előnyös lehet a fejlesztés. Annak felmérésekor, hogy milyen rendszerekre van szükség, mérlegelni kell az eszközök sokféleségének erősségeit és gyengeségeit.

A hírszerzés alapja az emberi elme marad, azonban az új technológiák összetettsége megköveteli folyamatos, magas szintű, speciális (tovább)képzését az elemzőknek, mind elméletben, mind gyakorlatban.

## Irodalomjegyzék

ATWOOD, Ch. P. (2015) Activity-Based Intelligence: Revolutionizing Military Intelligence Analysis. *Joint Force Quarterly*, No. 77. <https://ndupress.ndu.edu/JFQ/Joint-Force-Quarterly-77/Article/581866/activity-based-intelligence-revolutionizing-military-intelligence-analysis/> [Letöltve: 2019.10.10].

BODON F., BUZA K. (2014) *Adatbányászat*. <http://www.cs.bme.hu/nagyadat/bodon.pdf> [Letöltve: 2019.10.10].

Chess.com: *Kasparov vs. Deep Blue*. <https://www.chess.com/article/view/deep-blue-kasparov-chess> [Letöltve: 2019.10.10].

COUCH, N., ROBBINS, B.N (2013) Big Data for Defence and Security. *Occasional Paper*. Royal United Services Institute, September.

D'SOUZA, R. (2018) Symbolic AI v/s Non-Symbolic AI, and everything in between?, *Medium.com*, 2018.10.19. <https://medium.com/datadriveninvestor/symbolic-ai-v-s-non-symbolic-ai-and-everything-in-between-ffcc2b03bc2e> [Letöltve: 2019.10.10].

DOUMAS, L. A. A., HUMMEL, J. E. (2012) Computational Models of Higher Cognition. In: HOLYOAK, K. J., MORRISON, R. G. (eds) *The Oxford Handbook of Thinking and Reasoning*. Oxford University Press, New York. pp. 52-66.

ELDRIDGE, C., HOBBS, C.–MORAN, M. (2017) Fusing algorithms and analysts: open-source intelligence in the age of 'Big Data'. *Intelligence and National Security*. [https://kclpure.kcl.ac.uk/portal/files/108996612/Fusing\\_Algorithms\\_and\\_Analysts\\_ELDRIDGE\\_Published\\_Online\\_2017\\_GREEN\\_AAM.pdf](https://kclpure.kcl.ac.uk/portal/files/108996612/Fusing_Algorithms_and_Analysts_ELDRIDGE_Published_Online_2017_GREEN_AAM.pdf) [Letöltve: 2019.10.10].

HEUER, R. J. (1999) Psychology of Intelligence Analysis. *Central Intelligence Agency*. Washington DC.

HOLYOAK, K. J., MORRISON, R. G. (eds 2012) *The Oxford Handbook of Thinking and Reasoning*. Oxford University Press, New York.

INFORMATORIUM (2016) *Információs túltelítődés – Information overload*. szó-kalauz. <http://www.bgalapitvany.hu/2016/05/informacios-tultelitodes-information-overload/> [Letöltve: 2019.10.10].

JOHNSON-LAIRD, P. N. (2008) Theory of mental model deduction. In: ADLER, J. & RIPS, L. J. (eds) *Reasoning: Studies of Human Inference and Its Foundations*. Cambridge University Press, Cambridge. pp. 206-222.

KÓCZY L., TIKK D. *Számítástechnika. Informatika. Adatbázisok. Térinformatika*. <https://www.tankonyvtar.hu/hu/tartalom/tkt/fuzzy-rendszerek-fuzzy/ch01s03.html> [Letöltve: 2019.10.10].

LEHMANN M. (2006) *Mentális reprezentációk szerepe a tudatelméletekben*. <http://lehmann.hu/lm/reptudat.pdf> [Letöltve: 2019.10.10].

LIM, K. (2016) Big Data and Strategic Intelligence. *Intelligence and National Security*, Vol. 31. pp. 622.

MATHENY, J. (2013) Open Source Indicators: Intelligence ARPA. *Office of the Director of National Intelligence*. [https://www.aaas.org/sites/default/files/Jason\\_Matheny\\_AAAS\\_FBI.pdf](https://www.aaas.org/sites/default/files/Jason_Matheny_AAAS_FBI.pdf) [Letöltve: 2019.10.10].

MERCADO, S. C. (2007) Reexamining the Distinction Between Open Information and Secrets. *Studies in intelligence*, Vol. 49. no.2. [https://www.cia.gov/library/center-for-the-study-of-intelligence/csi-publications/csi-studies/studies/Vol49no2/reexamining\\_the\\_distinction\\_3.htm](https://www.cia.gov/library/center-for-the-study-of-intelligence/csi-publications/csi-studies/studies/Vol49no2/reexamining_the_distinction_3.htm) [Letöltve: 2019.10.10].

MICROSOFT Azure (2019) *Az Azure Machine Learning Studióban az algoritmusok kiválasztása*. <https://docs.microsoft.com/hu-hu/azure/machine-learning/studio/algorithm-choice> [Letöltve: 2019.10.10].

NEWELL, A., SIMON, H. (1976) Computer Science as Empirical Inquiry: Symbols and Search, *Communications of the ACM*. Vol. 19. No. 3. pp. 113–126. [http://delivery.acm.org/10.1145/370000/360022/a1975-newell\\_simon.pdf?ip=176.63.201.153&id=360022&acc=OPEN&key=4D4702B0C3E38B35](http://delivery.acm.org/10.1145/370000/360022/a1975-newell_simon.pdf?ip=176.63.201.153&id=360022&acc=OPEN&key=4D4702B0C3E38B35)

[%2E4D4702B0C3E38B35%2E4D4702B0C3E38B35%2E6D218144511F3437&\\_acm=1569866147\\_538d3ad5715e74f0b64dfaddf1cfeb8f](https://plato.stanford.edu/archives/spr2019/entries/turing-test/) [Letöltve: 2019.10.10].

OPPY, G., DOWE, D. (2019) The Turing Test. In: Edward N. ZALTA (ed) *The Stanford Encyclopedia of Philosophy*. <https://plato.stanford.edu/archives/spr2019/entries/turing-test/> [Letöltve: 2019.10.10].

ORBÁN J. (2017) Bayes-hálók a bűnügyi tudományokban. *PhD értekezés*. Pécsi Tudományegyetem Állam és Jogtudományi Karának Doktori Iskolája. <https://ajk.pte.hu/files/file/doktori-iskola/orban-jozsef/orban-jozsef-muhelyvita-ertekezes.pdf> [Letöltve: 2019.10.10].

PAUL, R., ELDER, L. (2006) *The Miniature Guide to Critical Thinking. Foundation for Critical Thinking*, Dillon Beach, California.

PRESS, G. The Brute Force Of IBM Deep Blue And Google DeepMind. *Forbes.com*, 2018.02.07. <https://www.forbes.com/sites/gilpress/2018/02/07/the-brute-force-of-deep-blue-and-deep-learning/>) [Letöltve: 2019.10.10].

RUSSELL, S., NORVIG, P. (2009) *Artificial Intelligence: A Modern Approach*. Prentice Hall, Saddle River, New Jersey.

SOLTI I. (2019) Az OSINT információgyűjtő eszközeiről. *Nemzetbiztonsági Szemle*, 7. évfolyam. 2. szám. pp. 3–18.

TREVERTON, G. F. (ed 2008) *New Frontiers in Intelligence*. Notes from seminar in Stockholm, 2008 may 27-28. The Swedish National Defence College.

TUDOMÁNYOS ÉS MŰSZAKI TÁJÉKOZTATÁS: *A bölcsesség hierarchiája: az adat-, információ-, tudás-, bölcsesség hierarchia reprezentációi*. [http://tmt-archive.omikk.bme.hu/show\\_news.html?id=4954&issue\\_id=496](http://tmt-archive.omikk.bme.hu/show_news.html?id=4954&issue_id=496) [Letöltve: 2019.10.10].

TURING, A. M. (1950) Computing Machines and Intelligence. *Mind quarterly review of psychology and philosophy*, Vol. 49. pp. 433-460. <https://www.csee.umbc.edu/courses/471/papers/turing.pdf> [Letöltve: 2019.10.10].

US GOVERNMENT: *Tradecraft Primer (2009) Structured Analytic Techniques for Improving Intelligence Analysis*. <https://www.cia.gov/library/center-for-the-study-of-intelligence/csi-publications/books-and-monographs/Tradecraft%20Primer-apr09.pdf> [Letöltve: 2019.10.10].

VADÁSZ P. (2015) Információkeresés a nyílt forrású hírszerzésben. *Felderítő Szemle*, 14. évfolyam. 1. szám. <http://www.knbsz.gov.hu/hu/letoltes/fsz/2015-1.pdf> p.88. [Letöltve: 2019.10.10].

VIDA CS. (2018) *A hírszerzés*. In: Resperger I. (szerk.) *A nemzetbiztonság elmélete a közszolgálatban*. Dialóg Campus Kiadó, Budapest