

Digitális forradalom a társadalomtudományban. A mesterséges intelligencia alkalmazása és korlátai

Az eredeti ipari forradalmat a gőz hajtotta, a második ipari forradalmat az elektromosság, a harmadikat elsősorban az automatizálás és az internet, a negyedik ipari forradalom pedig a kibertérben zajlik, vagyis az intelligens és összekapcsolt számítógépek alakítják és hajtják. A negyedik ipari forradalom a harmadik ipari forradalom – vagy digitális forradalom – találmányaira épül, amely az 1950-es évektől a 2000-es évek elejéig tartott, és amely az egyre nagyobb teljesítményű számítógépeket, más elektronikai eszközöket, mint a személyi számítógépet, mobiltelefonokat, majd magát az internetet hozta el nekünk.

Tagadhatatlan, a digitális forradalom hatása a társadalmunkra jelentős és sokirányú. A technológiai fejlődés, különösen a digitális eszközök elterjedése és az internet térnyerése radikálisan átalakította a személyes és társadalmi kapcsolatokat, a gazdaságot, a politikát, a kultúrát, az oktatást és a szolgáltatásokat is. Lényegében nincs olyan terület, amely érintetlenül maradt volna. A már évtizedek óta folyó digitális forradalom új kihívásokat fogalmazott meg, de egyben lehetőségeket is teremtett a társadalomtudósok számára is.

Gondoljunk csak a nagy mennyiségű adat keletkezésére, digitalizációjára vagy ezen adatok gépi feldolgozására. A közösségi média, az online fórumok és más digitális platformok segítségével az emberek online kifejezik véleményüket és interakcióba lépnek egymással, ami új lehetőségeket kínál a társadalmi dinamikák és egyéb folyamatok finomvizsgálatára. Az információs technológia és az adatelemzés területén elért fejlődés lehetővé tette a kutatók számára, hogy nagy mennyiségű adat birtokában új és mélyebb rétegeket azonosítsanak a társadalmi folyamatokban. Ez olyan bonyolult és összetett társadalmi folyamatok és jelenségek alaposabb megértését jelenti, amelyek korábban rejtve maradtak, vagy nem voltak nyilvánvalóak, de a nagy mennyiségű adat, a vizsgálati algoritmusok és a számítási kapacitás ugrásszerű növekedésével lehetővé vált.

Az ipar 4.0, más néven a negyedik ipari forradalom az ipar digitalizálásának következő szakasza, amelyet olyan felforgató (*disruptive*) trendek vezérelnek, mint az adatok megsokszorozódása és az összekapcsolhatóság, az analitika, az ember-gép interakció, a szenzorok, az IoT (Internet of Things), a drónok, a gépi látás, a természetes nyelvfeldolgozás, a nanotechnológia, a legújabb anyagok, az 5/6G, a 3D nyomtatás, az akkumulátortechnológia, az automatizált döntéshozatal, a blockchain és a robotika fejlődése.

Cikkünkben elsődlegesen azt vizsgáljuk, hogy az iparban megjelenő felforgató trendek, új technológiák milyen módon érintik a társadalomtudományi kutatások lehetőségeit. Tisztában vagyunk azzal, hogy a kérdés rendkívül összetett, hiszen jelen cikk keretei sem, valamint a kérdés komplexitása sem teszi lehetővé az alapos vizsgálatot, ezért elsősorban a mesterséges intelligencia (MI) társadalomtudományi kutatások terén való alkalmazására fókuszálunk.

A MI széleskörű és dinamikus fejlődése miatt kihívást jelent egyetlen, szűk meghatározást adni rá. Ezért általánosan elfogadott nézet, hogy a MI inkább egy átfogó koncepció, amelynek számos összetevője és alkalmazási területe van, mint egy technológiailag jól körülhatárolható terület.

Amikor a MI-ról beszélünk, elengedhetetlen figyelembe venni az etikai és társadalmi vonatkozásokat. Ugyanakkor ebben a cikkben csak érintőlegesen foglalkozunk ezekkel a témákkal, mivel fő célunk az, hogy bemutassuk, milyen új lehetőségeket kínálhat a MI a társadalomtudósok számára.

Bevezető

A digitális forradalom és a társadalomtudományok kölcsönös kapcsolata dinamikus. Az előrehaladott technológiai eszközök segítségével a társadalomtudósok folyamatosan fejlesztetik módszereiket, és mélyebben megérthetik a társadalmi jelenségeket. Gyakran az új technológiák, amelyeket a társadalomtudományi kutatásokban alkalmaznak, maguk indukálják a mélyreható változásokat, így ez a kapcsolat állandóan formálódik és alakul, ahogy az új technológiák és társadalmi változások folyamatosan előrehaladnak.

A történelem során az emberiség mindig is küzdött a technológiai fejlődés mélyreható társadalmi következményeivel. Az ipari forradalomtól a digitális korszakig a technológia társadalomra gyakorolt hatása egyszerre volt átalakító és bomlasztó. A technológiai fejlődés és annak társadalmi következményei közötti bonyolult kapcsolat évszázadok óta mérlegelés tárgya. Az egyének és a társadalmak egyaránt a folyamatos mérlegelés, az alkalmazkodás és néha (egy-egy vesztes csoportjaikat nézve szükségképpen, tehát mindig) az ellenállás útjára léptek, amikor megpróbálták megérteni és eligazodni ebben a bonyolult kapcsolatban (Wolff, 2021).

A mesterséges intelligencia (MI) korunk egyik legdinamikusabb és legizgalmasabb területe, amely életünk számos területét már érinti, akár tudatában vagyunk ennek, akár nem. A mesterséges intelligencia már szinte észrevétlenül beivódott mindennapi életünkbe, számos módon találkozunk vele nap mint nap. Az ipari forradalom innovációit ugyan a gyárakban vezették be, de hamar a mindennapok részévé váltak, így joggal gondolhatjuk, hogy a mesterséges intelligencia is, az intelligens eszközök, az intelligens készülékek vagy az online szolgáltatások is a mindennapi életünk részét képezik.

Az egyik ilyen jellegzetes példa a MI alkalmazására a közösségi médiumokban a hírfolyamok személyre szabása, az ismerősök ajánlása, vagy éppen a hirdetések célzott megjelenítése. Ezek mind olyan funkciók, amelyek mögött a MI áll. A hirdetési algoritmusok figyelik, milyen tartalmakra reagálunk, milyen oldalakra látogatunk el, és ezek alapján próbálják személyre szabni a hozzánk megjelenő hirdetéseket. Teszik mindezt azért, hogy a hirdetések valószínűsíthetően relevánsabbak legyenek számunkra, és így nagyobb valószínűséggel generáljanak érdeklődést.

A másik jellemző hétköznapi alkalmazás a különféle csevegőrobotok (chatbot) alkalmazása. A mesterséges intelligencia napjainkban rendkívül elterjedt a chatbotok formájában, és ezek a virtuális asszisztensek számos hétköznapi feladatot segítenek megkönnyíteni. Chatbotok szerepelnek online ügyfélszolgálatokban, weboldalakon, alkalmazásokban és más platformokon, ahol interaktív kommunikációra van szükség. Ezek

a gépiintelligencia-alkalmazások nemcsak gyors válaszokkal szolgálnak, hanem képesek tanulni és alkalmazkodni az egyes felhasználók igényeihez (Brill és mtsai, 2019).

Mi is a mesterséges intelligencia?

A mesterséges intelligenciát és annak képességeit többféleképpen értelmezik. Egyesek a mesterséges intelligenciát a feladatok automatizálásának egy fejlett eszközeinek tekintik, mások szerint az emberi intelligenciát is könnyen felülmúlhatja. Nincs egyetértés, hogy ez mikor és hogyan történik meg, de kiindulásunk az, hogy a MI már sok emberi munkát átvett és kiváló eredményeket hozott, amelyek hatékonyabbak és hatásosabbak, mint az emberi eredmények, azonban a MI nem fogja teljes mértékben felülmúlni az emberi intelligenciát a jövőben (Khanam és mtsai, 2021), mivel hiányzik belőle az igazi kreativitás és az érzelmi tudatosság.

A mesterséges intelligencia területén belül számos gyakran hallott, de nem egyértelmű kifejezés létezik. Annak érdekében, hogy tisztább képet kapjunk a témáról, most összefoglaljuk a legfontosabb alapfogalmakat.

A mesterséges intelligencia olyan számítási rendszerek vagy programok összessége, amelyek képesek intelligens döntéseket hozni, tanulni tapasztalatokból, és alkalmazkodni a változó körülményekhez. A mesterséges intelligencia alkalmazásai rendkívül széles skálán mozognak, megtalálhatóak az üzleti élet, az egészségügy, az oktatás, a közlekedés, az adminisztráció és számos egyéb humán szolgáltatás területén is.

A mesterséges intelligencia egyszerűen fogalmazva a humán intelligencia szimulációját jelenti a gépekben. Ezeket a gépeket olyan feladatokra programozzák, amelyek általában emberi intelligenciát igényelnek, például vizuális észlelés, beszédfelismerés, döntéshozatal és nyelvfelismerés.

A MI különféle algoritmikus kereteinek áttekintése elengedhetetlen, ha a társadalomtudományi felhasználásáról valamit megtudnánk, több okból is:

1. Módszertani megértés: Az egyes MI-algoritmuskok eltérő módszereken és elveken alapulnak. A különféle társadalomtudományi kutatásokhoz való hatékony alkalmazás érdekében a kutatóknak mélyreható módon meg kell érteniük ezeket a módszereket és elveket. Ez segíti a megfelelő algoritmus kiválasztását és alkalmazását a kutatási kérdésekhez és adathalmazokhoz (Sarker, 2021).
2. Adatok érzékenysége: A MI-algoritmuskok jellemzően adatokon tanulnak és dolgoznak. Az algoritmusok kezelési módjának és az adatok értelmezésének megértése kiemelten fontos, különös tekintettel az érzékeny társadalmi adatokra. Ez lehetővé teszi az etikai aggályok elkerülését és az adatvédelem biztosítását (Nazer és mtsai, 2023).
3. Interpretáció és következtetés: A MI által szolgáltatott eredmények értelmezése elengedhetetlen a társadalomtudományi összefüggésekben. Az eltérő algoritmusok különböző módon működhetnek, ezért fundamentális az eredmények helyes értelmezése, különösen a kutatási célok és a kontextus szempontjából. Ez aláhúzza a MI alkalmazásának kihívásait és azt, hogy az eredmények megértése szorosan összefügg a kutatási folyamatban meghatározott célokkal és szempontokkal (Di Franco és Santurro, 2021).
4. Replikálhatóság: A MI területén a replikálhatóság azt jelenti, hogy más kutatóknak vagy csoportoknak lehetőségük van ismételni és reprodukálni egy adott kutatás eredményeit. Ez a koncepció azért fontos, mert a tudományos kutatásokban az eredmények ismételhetősége és reprodukálhatósága alapvető követelmény a megbízható és érvényes tudományos eredmények eléréséhez. A mesterséges intelligenciában, különösen a gépi tanulás és a mélytanulás területén, a replikálhatóság kihívásokkal

járhat, mivel a modellek gyakran rendkívül érzékenyek az eredeti adathalmazokra, paraméterekre és környezeti feltételekre. A kutatások pontos reprodukálása sokszor nem triviális feladat (Köchling és Wehner 2022).

5. Algoritmikus igazságosság és diszkrimináció: A MI-rendszerek hajlamosak átvenni azokat az előítéleteket, amelyek megtalálhatók az adatokban és a betanítói halmazokban. Ezek az előítéletek, vagy más néven elfogultságok, komoly társadalmi problémákat vetnek fel, különösen az igazságosság és a diszkrimináció terén. A kutatóknak meg kell érteniük, hogy a használt algoritmusok milyen mértékben reprodukálhatják vagy csökkenthetik ezeket a torzításokat. Ezért a tudományos közösségnek figyelemmel kell kísérnie a MI alkalmazását, és olyan megoldásokat kell keresnie, amelyek minimalizálják az ilyen előítéletek hatásait a rendszerek működésében (Belenger, 2022).

Összességében a MI-algoritmusok áttekintése és megértése segít a kutatóknak felelősségteljesen és hatékonyan alkalmazni azokat a társadalomtudományi kutatásaikban. Ez kulcsfontosságú a pontos és megbízható eredmények elérése, valamint a társadalom érzékeny területein történő kutatások etikai és jogi szempontból történő megfelelésének biztosítása szempontjából.

A MI főbb algoritmikus keretei

A következőkben röviden áttekintjük a MI fejlesztési irányait és főbb algoritmizált kereteit. A technológiainak tűnő áttekintés nem öncélú: úgy véljük, fontos megismerni a különféle MI-algoritmusok alapvető működési elveit abból a célból, hogy az olvasó is el tudja dönteni, mely technológia lehet a legalkalmasabb az egyéni és kutatási felhasználás céljaira.

A különböző mesterségesintelligencia-technológiák, mint például a mesterséges neurális hálózatok (*Artificial Neural Networks*, ANN), a nagy nyelvi modellek (*Large Language Models*, LLM), a mélytanulás (*Deep Learning*, DL) és a gépi tanulás (*Machine Learning*, ML) szorosan kapcsolódnak egymáshoz, és gyakran átveszik egymás elveit és módszertanát. Ezen a folyamatosan fejlődő területen az alkalmazási határok egyre inkább elmosódnak. A leginnovatívabb megoldások elérése érdekében az új fejlesztések gyakran az egyes technológiák legjobb tulajdonságait foglalják magukba és adaptálják.

Gépi tanulás (*Machine Learning*, ML)

A gépi tanulás (ML) a mesterséges intelligencia egy olyan fejlesztési területe, amely lehetővé teszi a számítógépeknek, hogy tapasztalatokból tanuljanak és fejlesszék ki saját döntéshozatali képességeiket *anélkül, hogy explicit programozásra lenne szükség*. A gépi tanulás alkalmazza azokat az algoritmusokat és modelleket, amelyek képesek adaptálódni és javulni a rendszerükbe bevitt adatok alapján. A javulás mértéke és minősége azonban nagyon függ a bevitt adatoktól. Az ilyen rendszerek képesek felismerni mintákat, előrejelzéseket tenni és döntéseket hozni, mindezt azáltal, hogy tanulnak az ismétlődő adatokból és tapasztalatokból (Sarker, 2021).

A gépi tanulás tudományos alapja az adatlapú statisztikában, a valószínűségelméletben, az optimalizálásban és a számítástudományban gyökerezik. Az ML-algoritmusok célja, hogy az adatokból tanuljanak az adatpontok közötti minták és kapcsolatok azonosításával. Ezt a folyamatot nevezzük betanításnak. Miután egy ML-algoritmus betanításra került, az új adatpontokra vonatkozó előrejelzések vagy döntések meghozatalára

használható. Az ML-algoritmusoknak számos típusa létezik, de alapszinten három fő csoportba sorolhatók:

- Felügyelt tanulás (*supervised learning*): a felügyelt tanulás során az ML-algoritmust címkézett adathalmazon képzik ki. A címkék segítségével az algoritmus megtanulja a bemeneti adatokat a kívánt kimenethez társítani. Meghatározása szerint címkézett adathalmazokat használ olyan algoritmusok betanítására, amelyek adatokat osztályoznak vagy eredményeket jósolnak meg pontosan. Ahogy a bemeneti adatokat betáplálják a modellbe, az addig módosítja a súlyokat, amíg a modell megfelelően nem illeszkedik. A felügyelt tanulás számos alkalmazási területtel rendelkezik a társadalomtudományi kutatásokban, a klasszifikációs algoritmusok használatától kezdve (pl. adatok kategorizálása), regressziós modellek használatán keresztül az idősoros trendelemzésig, illetve előrejelzések (*predictions*) megfogalmazásáig (Liu, 2022).
- Nem felügyelt tanulás (*unsupervised learning*): a nem felügyelt tanulás (vagy felügyelet nélküli tanulás) során az ML-algoritmust egy címkézetlen adathalmazon képzik ki. A felügyelet nélküli tanulás a gépi tanulási algoritmusok egy olyan típusa, amely az adatokban lévő minták azonosítására törekszik. A „felügyelet nélküli” kifejezés arra utal, hogy ezek az algoritmusok nem igényelnek előzetes betanítási fázist, ahol a modell egy ember által megjelölt adathalmazból tanul. Ehelyett a felügyelet nélküli tanulási algoritmusok maguk fedezik fel a címkéket magukból az adatokból. A felügyelet nélküli tanulási algoritmusokat számos alkalmazásban használják, többek között az anomáliafelismerésben, az asszociációs bányászatban (*association rule mining*), a klaszterezésben és a dimenziócsökkentésben. A felügyelet nélküli tanulás lényegében a gépi tanulás olyan módszere, ahol a rendszer megtanulja felismerni az összetett mintákat, és intelligens döntéseket hoz a bemeneti adatok alapján. A leggyakoribb felügyelet nélküli tanulási módszer a klaszterelemzés, amelyet feltáró adatelemzésre használnak, hogy rejtett mintákat vagy csoportosítást találjanak az adatokban (Eckhardt, 2022).
- Megerősítéssel tanulás (*Reinforcement Learning, RL*): a megerősítéssel tanulás egy visszacsatoláson alapuló gépi tanulási technika, amelyben egy ágens úgy tanul meg viselkedni egy környezetben, hogy műveleteket hajt végre és megfigyeli az eredményeket. Az RL során az ágens kölcsönhatásba lép a környezettel, hogy megtanulja, milyen cselekvéseket kell végrehajtania egy hosszú távú cél maximalizálása érdekében. Ez a megközelítés különösen alkalmas a tervezés vagy a szekvenciális döntéshozatal problémáira. A társadalomtudományok területén a megerősítő tanulást egyre gyakrabban alkalmazzák a szociális idegtudományokban. Ez a technológia lehetővé teszi a látens mechanisztikus folyamatok kvantitatív vizsgálatát, olyan idegrendszeri képpalkotó technikákkal kombinálva, mint a funkcionális mágneses rezonancia képpalkotás. Ez a megközelítés előnyös a társadalmi döntéshozatal vizsgálatához és a mögöttes kognitív folyamatok megértéséhez (Li, 2022).

Összefoglalva, a gépi tanulás (ML) olyan terület, amelyben a gépek képesek saját maguktól tanulni és alkalmazkodni az adatokból levont mintákhoz és szabályszerűségekhez. Ennek lényege az adaptivitásban rejlik, ahol a rendszer folyamatosan finomítja modelljét a gyakorlatban meg tapasztalt adatok alapján. Ez azt jelenti, hogy a gépi tanulás képes önmagát javítani és idővel pontosabbá válni a tanulási folyamat során.

Az adaptivitás és a folyamatos finomítás révén a gépi tanuláshoz számos előnye és alkalmazási területe van. Például az automatikus képfelismerésben a gépek képesek azonosítani és kategorizálni a vizuális mintákat, például arcokat vagy objektumokat. A nyelvi feldolgozás terén a gépi tanulás lehetővé teszi a számítógépek számára, hogy

értelmezzék és válaszoljanak az emberi nyelvű inputokra, például chatbotok vagy automatikus fordítószolgáltatások révén (Sarker, 2021).

Az üzleti döntéstámogatásban a gépi tanulás alkalmazása segíthet a nagy mennyiségű adat elemzésében, előrejelzések készítésében és az üzleti stratégiák finomhangolásában. Például gépi tanulás-algoritmusokat alkalmazhatnak a vásárlói viselkedés elemzésére, a készletkezelés optimalizálására vagy akár a csalások felismerésére pénzügyi tranzakciók során.

Ez a folyamat nemcsak a tanulásra, hanem az alkalmazkodásra is kiterjed, így a gépi tanulás dinamikus és a változó környezethez alkalmazkodó módon képes reagálni. Ez teszi lehetővé számára, hogy releváns és naprakész információkkal szolgáljon a gyakorlati alkalmazások során. A gépi tanulás tehát nem csupán egy statikus modellt hoz létre, hanem egy folyamatosan fejlődő rendszert, amely hatékonyan alkalmazkodik az adatok változó természetéhez és az idő múlásához.

A gépi tanulás (ML) fokozatosan forradalmasítja a társadalomtudományokat, ahogyan azt a genomikához és az orvostudományhoz hasonlóan tette. A gépi tanulás és a mélytanulás modelljeinek különböző alkalmazásai a társadalomtudományok különböző területein törnek utat maguknak, többek között a közgazdaságtan, a szociális egészségügy, a nyelvészet, az emberierőforrás-gazdálkodás, a viselkedélemzés, a marketing, a készletellenőrzés, az oktatás stb. területén.

Neurális hálózatok

A neurális hálózatok, más néven mesterséges neurális hálózatok (*Artificial Neural Networks*, ANN) a gépi tanulás egy részhalmozát alkotják, és a mélytanulási algoritmusok középpontjában állnak. Nevüket és felépítésüket az emberi agy ihlette, azt a módot utánózza, ahogyan a biológiai neuronok jeleznek egymásnak.

A mesterséges neurális hálózatok (ANN) csomóponti rétegekből állnak, amelyek egy bemeneti réteget, egy vagy több rejtett réteget és egy kimeneti réteget tartalmaznak. Minden egyes csomópont vagy mesterséges neuron egy másikhoz kapcsolódik, és rendelkezik egy hozzá tartozó súllyal és küszöbértékkel. Ha bármelyik csomópont kimenete a megadott küszöbérték felett van, az adott csomópont aktiválódik, és adatokat küld a

A mesterséges neurális hálózatok (ANN) csomóponti rétegekből állnak, amelyek egy bemeneti réteget, egy vagy több rejtett réteget és egy kimeneti réteget tartalmaznak. Minden egyes csomópont vagy mesterséges neuron egy másikhoz kapcsolódik, és rendelkezik egy hozzá tartozó súllyal és küszöbértékkel. Ha bármelyik csomópont kimenete a megadott küszöbérték felett van, az adott csomópont aktiválódik, és adatokat küld a hálózat következő rétegébe. Ellenkező esetben a hálózat következő rétegéhez nem továbbít adatokat.

A neurális hálózatok a tanulási adatokra támaszkodnak, hogy megtanulják és idővel javítsák pontosságukat. Ha azonban ezek a tanulási algoritmusok egyszer már finomhangolódtak a pontosság érdekében, akkor az informatika és a mesterséges intelligencia nagy teljesítményű eszközeivé válnak, amelyek lehetővé teszik az adatok nagy sebességgel történő osztályozását és klaszterezését.

hálózat következő rétegébe. Ellenkező esetben a hálózat következő rétegéhez nem továbbít adatokat.

A neurális hálózatok a tanuló adatokra támaszkodnak, hogy megtanulják és idővel javítsák pontosságukat. Ha azonban ezek a tanulási algoritmusok egyszer már finomhangolódtak a pontosság érdekében, akkor az informatika és a mesterséges intelligencia nagy teljesítményű eszközeivé válnak, amelyek lehetővé teszik az adatok nagy sebességgel történő osztályozását és klaszterezését.

Ezek a hálózatok lehetővé teszik a gépek számára, hogy hierarchikusan szervezett reprezentációkat építsenek fel a bemeneti adatokból, hasonlóan ahhoz, ahogyan az emberi agy működik. Az egyes neuronok egymással való összekapcsolása és rétegekbe rendezése lehetővé teszi a rendszer számára, hogy megtanuljon és kinyerjen összetett információkat a bemeneti adathalmazból.

A neurális hálózatok sokféle feladatban alkalmazhatók, például kép- és beszédfelismerésben, gépi fordításban, játéksstratégiákban. Az ilyen típusú számítási rendszerek külön előnye, hogy gyorsan képesek alkalmazkodni az összetett és változó környezetekhez (Nwadiugwu, 2021).

E kutatási területen az irány elmozdult a tüskés neurális hálózatok (*Spiking Neural Networks*, SNN) kutatása felé, mely mesterségesintelligencia-rendszerek a biológiai neuronok működését utánozzák. Az SNN-ekben a neuronok nem folyamatos jeleket továbbítanak, hanem rövid impulzusokat, úgynevezett tüskéket. Ezek a tüskék elektromos jelek, a tüskék számából és időbeli alakjából a neuronok meg tudják határozni a bemeneti jelek erősségét.

Az SNN-ek számos előnnyel rendelkeznek a hagyományos neurális hálózatokkal szemben. Egyrészt energiahatékonyabbak, mivel csak akkor használnak energiát, amikor tüskét generálnak. Másrészt képesek dinamikusabb viselkedést modellezni, mivel a tüskék időbeli alakja is fontos információt hordoz. Harmadrészt robusztusabbak a zajjal szemben, mivel a tüskék kevésbé érzékenyek a zajra, mint a folyamatos jelek. Az SNN-ek potenciális alkalmazási területei közé tartoznak a képfelismerési, beszédhangok felismerésére és szöveg generálására szolgáló algoritmusok, valamint az autonóm rendszerek (Nwadiugwu, 2021).

A tüskés neurális hálózatok (SNN-ek) potenciális alkalmazási területei a társadalomtudományok területén elsősorban azok a területek, amelyek komplex, valós idejű döntéshozatalt és viselkedés-előrejelzést vizsgálnak. Az SNN-ek alkalmazása a társadalomtudományokban azonban még mindig kialakulóban lévő terület, és a konkrét alkalmazások a kutatási kérdéstől vagy problémától függően nagymértékben eltérhetnek.

A szociális idegtudományokban például az SNN-ek felhasználhatók a társadalmi interakciók és a döntéshozatal alapjául szolgáló idegi folyamatok modellezésére. Ez betekintést nyújthat abba, hogy az egyének hogyan hoznak döntéseket szociális kontextusban, és hogyan különbözhetnek ezek a folyamatok a szociális kognitív zavarokkal küzdő egyéneknél.

A közgazdaságtanban és a pénzügyekben az SNN-ek felhasználhatók a piaci viselkedés modellezésére és előrejelzésére. A hálózatot a múltbeli piaci adatokon betanítva megtanulhatná megjósolni a jövőbeli trendeket a múltbeli események időzítése és sorrendje alapján, de a szociológiában az SNN-ek felhasználhatók a társadalmi hálózatok modellezésére és az információ vagy viselkedés populáción belüli terjedésének előrejelzésére (Sanaullah és mtsai, 2023).

Mélytanulás (*Deep Learning, DL*)

A mélytanulás (DL) a gépi tanulás egy részterülete, amely mesterséges neurális hálózatokat használ többretegű szerkezettel (mély neurális hálózatok) bonyolult problémák modellezésére és megoldására. Ebben az eljárásban a gépi tanulás hagyományos módszerein túlmutatóan a mély neurális hálózatok képesek összetettebb mintázatokat és jelenségeket kinyerni a bemeneti adatokból. Az egymástól független rétegekből álló hálózatok lehetővé teszik a rendszer számára, hogy hierarchikus reprezentációkat építsen fel, amelyek segítségével a gép egyre magasabb szintű absztrakciókat tanul meg (Sarker, 2021).

Ez a fajta megközelítés különösen hatékony az olyan területeken, ahol a hagyományos algoritmusok és modellek korlátozott hatékonysággal teljesítenek, például a képfelismerés és a beszédfelismerés területén. A mélytanulás jelentős előrelépést eredményezett a mesterséges intelligencia terén, és továbbra is kiemelt szerepet játszik az olyan komplex problémák megoldásában, amelyek hatalmas adathalmazokat és magas szintű absztrakciót igényelnek.

A mélytanulás olyan gépi tanulási megközelítés, amely számos előnnyel rendelkezik más típusú algoritmusokhoz képest. Ezen előnyök közé tartozik elsősorban a kiemelkedő pontosság, amely lehetővé teszi a mélytanulási algoritmusoknak a rendkívül precíz eredmények elérését a feladatok széles skálájában. Ezen felül a mélytanulás kiemelkedik a skálázhatóság terén, hiszen képes hatékonyan kezelni nagy mennyiségű adatot, lehetővé téve a rendszer bővítését és alkalmazkodását a változó környezeti kihívásokhoz.

A rugalmasság az egyik kiemelkedő előnye ennek az algoritmustípusnak, hiszen ezek az algoritmusok a feladatok rendkívül változatos körére alkalmazhatók. Legyen szó kép- vagy hangfelismerésről vagy éppen nyelvi feldolgozásról, a mélytanulásnak széleskörű alkalmazási területe van, ami tovább növeli azok vonzerejét és hatékonyságát. Ezek az előnyök teszik a mélytanulást egyre inkább népszerűvé a különféle szakterületeken és tervezési feladatoknál (Sarker, 2021).

A mélytanulás technológia számos olyan előnnyel rendelkezik, amely kifejezetten alkalmassá teszi társadalomtudományi kutatásokra. Ezek közül nézzünk néhányat:

- Komplex adatkezelés: A társadalomtudományi adatok gyakran bonyolultak és többdimenziósak, gyakran szöveget, képeket és egyéb strukturált adatokat is magukban foglalnak. A mélytanulási algoritmusok képesek kezelni ilyen bonyolult adatokat és kinyerni belőlük értelmes mintákat.
- Mintafelismerés: A mélytanulás kiválóan alkalmas nagy adathalmazokban minták felismerésére. Ez különösen hasznos a társadalomtudományokban, ahol a kutatók gyakran érdeklődnek az emberi viselkedés mintázatai iránt.
- Előrejelzési (predikciós) megalapozottság: A mélytanulási algoritmusoknak erős előrejelző erejük van, amit ki lehet használni társadalmi trendek vagy viselkedések előrejelzésére a történelmi adatok alapján. Azonban fontos megjegyezni, hogy a mélytanulási modellek előrejelzési pontossága nem mindig jelenti a modell megbízhatóságát vagy használhatóságát. Például egy modell, amely nagyon pontos előrejelzéseket ad egy adott adatkészleten, nem feltétlenül teljesít jól más, új adatokon. Ezért fontos a modell teljesítményének alapos értékelése és validálása több különböző adatkészleten és különböző körülmények között.
- Interdiszciplináris integráció: A mélytanulás lehetővé teszi különböző tudományágak, mint például a pszichológia, szociológia, közgazdaságtan és számítástudomány, integrációját. Az interdiszciplináris integráció révén a mélytanulás alkalmazható azon kihívásokra, amelyek a társadalomtudományokban gyakran előfordulnak, például a nagy mennyiségű, strukturálatlan adatok elemzése, az érzelmek és vélemények kinyerése szöveges anyagokból, vagy akár a társadalmi hálózatok és

interakciók mélyebb megértése. A mélytanulás és a társadalomtudományok egyesítése segíthet a kutatóknak abban, hogy azonosítsák az összefüggéseket, mintázatokat és tendenciákat a társadalmi jelenségek mögött. Az ilyen technikai megközelítések hasznosak lehetnek a közvélemény-kutatásokban, politikai elemzésekben, szociológiai vizsgálatokban (Dehghan és mtsai, 2022).

- Skálázhatóság: A mélytanulási algoritmusok hatékonyan képesek feldolgozni nagy adathalmazokat, ami előnyös a társadalomtudományokban, ahol egyre több nagy adat áll rendelkezésre.

Natural language processing, NLP

Az NLP (*natural language processing* vagy természetes nyelvi feldolgozás) a számítógépek és az emberi nyelv interakciójával foglalkozik. Ez a terület lehetővé teszi a gépek számára, hogy megértsék, értelmezzék és olyan emberi-szerű szöveget generáljanak, amely képes a nyelvi kommunikációra. Az NLP kulcsfontosságú szerepet játszik olyan alkalmazásokban, mint a chatbotok, a nyelvfordítás és az érzelmek elemzése.

Az NLP fő feladata, hogy leküzdje a nyelvi különbségeket a gépek és az emberek között, így lehetővé téve a számítógépek számára, hogy hatékonyan értsék és válaszoljanak az emberi nyelvű bemenetekre. Ez a technológia rendkívül hasznos lehet például a chatbotok esetében, ahol a gépek interaktívan kommunikálnak az emberekkel, vagy a nyelvfordítás terén, ahol az NLP segít a szövegek pontos és érthető fordításában és javításában. Az érzelmi elemzés területén pedig az NLP lehetővé teszi a gépek számára, hogy az emberi nyelv érzelmi tartalmát értelmezzék, amely fontos például a vélemények elemzése során. Az NLP tehát elengedhetetlen eszköze az olyan alkalmazásoknak, amelyek a nyelv és a kommunikáció széles skáláját érintik a gépek és az emberi felhasználók között (Khurana és mtsai, 2023).

A természetes nyelvfeldolgozás (NLP) rendkívül értékes eszköz a társadalomtudományok területén, mivel számos területen alkalmazható. Az NLP segítségével megnyílik az út az érzelmek, vélemények, érvek, toxicitás és más komplex témák mélyebb megértése felé. Az alábbiakban néhány konkrét területet emelünk ki, ahol az NLP hozzájárulhat a társadalomtudományi kutatásokhoz és előrejelzésekhez:

1. **Érzelmek és vélemények elemzése:** Az NLP segíthet az online média, közösségi média és más szöveges források átfogó elemzésében, hogy megértsük az emberek érzéseit és véleményeit bizonyos témákról.
2. **Érvelés és struktúra feltárása:** Az NLP-technikák alkalmazása lehetővé teszi az érvelések és szövegek struktúrájának elemzését, amely segíthet az érvelések vizsgálatában és a tartalom szemantikai kibontásában.
3. **Toxicitás észlelése:** Az NLP használható a szövegekben található toxicitás és negatív kifejezések észlelésére, különösen online közösségi média környezetekben.
4. **Információkeresés és extrakció:** Az NLP-rendszerek alkalmasak nagy mennyiségű szöveges adat gyors és hatékony átvizsgálására, információk keresésére és kivonására.
5. **Entitások felismerése:** Az NLP képes felismerni és azonosítani specifikus entitásokat (pl. személyek, helyek, események) a szövegekben, ami segíthet a kutatóknak a kulcsfontosságú tényezők azonosításában (Wolf és mtsai, 2020).
6. **Szóértelmek tisztázása:** Az NLP-rendszerek segíthetnek az értelmetlen vagy homályos kifejezések értelmezésében, hozzájárulva a szövegek tisztázásához és pontosabb megértéséhez.

Az NLP tehát gazdagítja a társadalomtudományi kutatások eszköztárát, lehetővé téve a szövegek mélyebb elemzését és a szóban forgó témák sokoldalú megközelítését.

Large Language Models (Nagy Nyelvi Modellek, LLM)

Az LLM egy olyan gépi tanulási modell típusa, amely gyakran a mélytanuláson alapul, és hatalmas mennyiségű szöveges adaton tanul, hogy megértse és generálja az emberi nyelvet. A GPT-3 (Generative Pre-trained Transformer 3) az egyik elterjedt példa egy ilyen LLM-re.

Az LLM lényege az, hogy rendkívül gazdag és változatos szöveges adathalmazokon keresztül tanul, ami lehetővé teszi számára, hogy kifejlett nyelvi készségeket fejlesszen ki. Ezek a modellek képesek szövegalkotásra, válaszadásra, és akár emberi-szerű párbeszédre létrehozására is. A mélytanulás és az LLM-ek területén elért fejlesztések jelentősen hozzájárultak a gépi nyelvi megértés és generáció terén, és olyan alkalmazásokban tűnnek fel, mint a nyelvi asszisztensek, az automatikus szöveggenerálás és a nyelvfeldolgozás különböző aspektusai (Naveed és mtsai, 2023).

A nagy nyelvi modellek (LLM-ek) számos területen forradalmi változásokat hozhatnak a társadalomtudományi kutatásban. Néhány példa:

1. Adatelemzés: Az LLM-eket használhatjuk nagy mennyiségű szöveges adat, például közösségimédia-posztok, hírek és tudományos publikációk elemzésére. Ez segítheti a társadalomtudósokat olyan mintázatok és tendenciák azonosításában, amelyeket hagyományos módszerekkel nehezebb vagy lehetetlen lenne megtalálni.
2. Hipotézis-generálás: Az LLM-ek segítségével új hipotéziseket generálhatunk a társadalmi jelenségekről.
3. Modelltesztelés: Az LLM használható társadalomtudományi modellek tesztelésére, az emberi viselkedés szimulálásával. Az ilyen modellek simított változatai vagy előre tanított rétegeik felhasználhatók a kutatási modell tesztelésére és finomhangolására, különféle adathalmazokon.
4. Predikciós analízis: Az LLM-eket használhatjuk a jövőbeli társadalmi trendek előrejelzésére. Ez segíthet a társadalomtudósoknak a politikai döntések tájékoztatásában.

Az LLM-ek szélesebb körű alkalmazása révén a társadalomtudományi kutatások általános hatékonyságát is jelentős mértékben növelhetjük. Az automatizált adatgyűjtés, adattisztítás és adatkódolás könnyedén megvalósíthatóvá válik, lehetőséget teremtve ezzel a kutatók számára arra, hogy több időt fordítsanak összetettebb és kreatívabb feladatokra. Emellett az LLM-ek a hallgatók tanulási élményeit is személyre szabhatják, hozzájárulva a hatékonyabb tanulási folyamatok kialakításához. Az LLM-ek képesek javítani a kommunikációt a társadalomtudósok és a döntéshozók között, biztosítva, hogy a társadalomtudományi kutatások eredményei hatékonyan beépüljenek a döntéshozatali folyamatokba (Guo és mtsai, 2023).

CNN (Convolutional Neural Network vagy Konvolúciós Neurális Hálózatok)

A konvolúciós neurális hálózatok olyan típusú neurális hálózatok, melyeket strukturált rácsadatok feldolgozására terveztek, mint például képek. Ezek a hálózatok kiemelkedően hatékonyak olyan vizuális adatok elemzésében, ahol az adatok strukturált rácsokként rendelkeznek, például pixelmátrix formájában egy képen. A konvolúciós rétegek, amelyek nevüket innen kapják, különféle képalkotó és szűrőműveleteket alkalmaznak,

hogy kinyerjék a képekben található fontos jellemzőket. A CNN technológiát gyakran alkalmazzák olyan területeken, ahol a vizuális információk rendkívül fontosak, például képfelismerésben, arcaazonosításban, önzetű autók kamerarendszereiben és sok más alkalmazásban. Ezek a hálózatok segítenek az automatikus objektumfelismerésben és az osztályozásban, és széles körű alkalmazásra találnak a gépi látás terén (O'Shea és mtsai, 2015).

Társadalomtudományi alkalmazásuk elsősorban ott lehetséges, ahol a vizuális adatok elemzése vagy felismerése kiemelt szerepet kap, így pl. arckifejezések, környezeti elemzések, emberi viselkedésminták, különféle képeken található történések kategorizálásában kaphat kiemelkedő szerepet, de természetesen a képalkotó diagnosztikai eljárásokban is kiemelt szerepe van.

RNN: Recurrent Neural Network vagy Visszacsatolós Neurális Hálózat

Az RNN (*Recurrent Neural Network*) neurális hálózatokat olyan adatok feldolgozására fejlesztették ki, amelyek időbeli sorrendiségüket vagy függőségüket tekintve relevánsak. Kiemelkedő hatékonysággal alkalmazhatók olyan időbeli sorozatokon vagy adatokon, amelyek tartalmaznak sorrendi struktúrát. Az RNN-ek különösen alkalmazkodók olyan szituációkhoz, ahol az adatok időben vagy térben egymást követik. A hálózat rekurzív rétegei lehetőséget biztosítanak arra, hogy az előző időpillanatokból származó információkat beépítse a jelenlegi döntéshozatali folyamatokba. Ennek köszönhetően ideálisak idősoros előrejelzésekhez, szöveggeneráláshoz és beszédfelismeréshez. Gyakran alkalmazzák olyan területeken, ahol az adatok időrendi függősége kulcsfontosságú, például idősoros adatok elemzése, nyelvmodellezés és zenei kompozíciók esetében. Az ilyen hálózatok segítenek a számítógépeknek abban, hogy kihasználják és megőrizzék az idősoros struktúrákat, ami különösen előnyös a gépi tanulási alkalmazásokban.

A *Recurrent Neural Network* (RNN) alkalmazása a társadalomtudományok területén számos lehetőséget kínál a komplex adatok elemzésére. Az RNN különösen hasznos lehet az idősoros adatok vizsgálatában, ahol a változások időbeli alakulásának elemzése

Az RNN (Recurrent Neural Network) neurális hálózatokat olyan adatok feldolgozására fejlesztették ki, amelyek időbeli sorrendiségüket vagy függőségüket tekintve relevánsak. Kiemelkedő hatékonysággal alkalmazhatók olyan időbeli sorozatokon vagy adatokon, amelyek tartalmaznak sorrendi struktúrát. Az RNN-ek különösen alkalmazkodók olyan szituációkhoz, ahol az adatok időben vagy térben egymást követik. A hálózat rekurzív rétegei lehetőséget biztosítanak arra, hogy az előző időpillanatokból származó információkat beépítse a jelenlegi döntéshozatali folyamatokba. Ennek köszönhetően ideálisak idősoros előrejelzésekhez, szöveggeneráláshoz és beszédfelismeréshez. Gyakran alkalmazzák olyan területeken, ahol az adatok időrendi függősége kulcsfontosságú, például idősoros adatok elemzése, nyelvmodellezés és zenei kompozíciók esetében. Az ilyen hálózatok segítenek a számítógépeknek abban, hogy kihasználják és megőrizzék az idősoros struktúrákat, ami különösen előnyös a gépi tanulási alkalmazásokban.

fontos szerepet játszik. A modell alkalmazható például a gazdasági mutatók időbeli változásainak követésére vagy a társadalmi jelenségek időbeli trendjeinek elemzésére. Emellett az RNN segíthet a vélemények, szövegek és hozzászólások elemzésében is, különös tekintettel a közösségi média tartalmára. A modellel lehetőség nyílik a társadalmi trendek elemzésére és jövőbeli események előrejelzésére, valamint a pszichológiai és szociális adatok idősoros vizsgálatára. Az RNN tehát hozzájárulhat a társadalomtudományi kutatásokhoz, ahol az idődimenzió és a szekvenciális adatok kezelése kulcsfontosságú a mélyebb megértés eléréséhez (Salem, 2022).

A felhasználhatóság szempontjai

A mesterségesintelligencia-algoritmusok rendkívül sokrétű eszközt kínálnak a társadalomtudományi kutatások területén. Az algoritmusok elágazó struktúrájuk és működési elveik révén különböző szempontok alapján kategorizálhatók, és ezek a kategóriák különböző módon alkalmazhatók a kutatási folyamatokban. Az egyik kulcselem a megértési képesség, mely azt vizsgálja, hogy egy adott algoritmus mennyire érthető és befogadható azok számára, akik nem rendelkeznek specifikus informatikai ismeretekkel. Az átláthatóság és érthetőség növeli a bizalmat a kutatási közösségben, segítve az algoritmusok integrálását a társadalomtudományok gyakorlatába (Deranty és Corbin, 2022).

Ezenkívül az algoritmusok felhasználási területei fundamentálisak a hatékony kutatási eredmények elérésében. A különböző típusú problémákra való alkalmazhatóságuk és kiemelkedő teljesítményük egyaránt meghatározó a kutatók számára. A MI-algoritmusok tehát nem csupán eszközök, hanem dinamikus eszköztárak, amelyek adaptívak és alkalmazkodók a társadalomtudományok számos területén.

A gépi tanulási modellek értékelése és kiválasztása számos fontos tényezőtől függ, melyek kulcsfontosságúak a modellek hatékonyságának, értelmezhetőségének és előrejelző képességeinek szempontjából. Elsőként a betanításhoz szükséges adatmennyiség kiemelkedően befolyásolja a modell teljesítményét. A nagy adathalmazokon képzett modellek jobban általánosíthatnak, de a nagy mennyiségű adat feldolgozása számításgényes és erőforrásigényes lehet, így a hatékonyság szempontjából is fontos tényező.

Az értelmezhetőség szintén kulcsfontosságú, különösen olyan területeken, ahol az átláthatóság elengedhetetlen. Például az egészségügyi vagy pénzügyi területeken az értelmezhető modellek lehetővé teszik a döntéshozók számára, hogy megmagyarázzák a modell döntéseit, azonosítsák a potenciális torzításokat és növeljék a bizalmat az alkalmazások iránt.

A gépi tanulási modellek előrejelző képességei pedig alapvetőek a gyakorlati alkalmazásokban. A modellnek jól kell általánosítania a még nem látott adatokra, és megbízható előrejelzéseket kell nyújtania a változatos környezetekben. Ezek a tényezők összességében meghatározzák a gépi tanulási modellek értékelésének alapját, melyekre figyelemmel kell lenni a különböző kutatási projektek tervezése során.

Hatékonyság szempontjából kulcsfontosságúak a gépi tanulási modellek képzésének, telepítésének és üzemeltetésének költségei. Ebben a tekintetben érdemes mérlegelni, hogy mennyire gazdaságos és fenntartható a választott algoritmus alkalmazása a rendelkezésre álló erőforrásokkal. A költséghatékony modellek lehetővé tehetik a kutatások szélesebb körű alkalmazását és terjedését, különösen, ha nagyobb adathalmazokkal vagy összetett modellekkel kell dolgozni (Di Franco és Santurro, 2021).

A robusztusság azt jelenti, hogy a rendszer ellenálló és stabil marad a változatos és esetenként zajos környezetekben, a nem várt adatokkal és feltételekkel szemben. A robusztusság nem csak arra utal, hogy a modellnek csak a betanító adathalmazon

kell hatékonyan teljesítenie, hanem arra is, hogy képesnek kell lennie alkalmazkodni és helyesen működni olyan adatokkal és környezeti változókkal, amelyek nem szerepeltek a tanító adathalmazban.

A robusztusság különösen fontos a gépi tanulásban, mivel az éles környezeti változások, a zajos adatok és az ismeretlen feltételek gyakoriak lehetnek a valóságos alkalmazási területeken. Egy robosztus modell képes fenntartani teljesítményét és megbízhatóságát olyan helyzetekben is, amelyek eltérnek a tanító adathalmazban szereplő környezettől (Singla és mtsai, 2019).

A skálázhatóság kulcsfontosságú, mivel a modellnek alkalmazkodnia kell az új adatokhoz, és fenn kell tartania teljesítményét az adatmennyiség növekedésével. Rugalmasságának és alkalmazkodó képességének köszönhetően a modell hosszú távon is releváns és hatékony tud maradni, különféle környezeti változások mellett.

Az igazságosság azt jelenti, hogy a modell elfogulatlan és igazságos előrejelzéseket adjon különböző csoportok számára. Különös figyelmet kell fordítani arra, hogy az algoritmusok ne reprodukáljanak diszkriminatív mintákat, és az előrejelzéseik ne érintsenek hátrányosan bizonyos társadalmi csoportokat. Az igazságos modellek hozzájárulnak a kutatások társadalmi felelősségvállalásához és elfogadhatóságához.

Az adattorzítás (*data bias*), azaz az adatok elfogultsága olyan kihívás, amely jelentős hatással lehet a MI-rendszerek igazságosságára és elfogulatlanságára. A MI-modellek tanítása során felhasznált adathalmazok hibái és elfogultsagai a modellek predikcióit is torzíthatják, különösen, ha az adathalmazok olyan társadalmi előítéleteket tükröznek, amelyek az adott közösség vagy csoport ellen irányulnak.

Az adatok elfogultsága több dimenzióban is megjelenhet. Például, ha az adathalmaz a társadalom egyes csoportjaira koncentrálna, másokat figyelmen kívül hagyva, a modell hajlamos lehet a hangsúlyozott csoportokra irányítani, és kevésbé pontosan előrejelzéseket adni az elhanyagolt csoportok számára (Oneto és Chiappa, 2020).

Végül, de természetesen nem utolsósorban fontos szempont az ún. interpretabilitás. A mesterséges intelligencia és a gépi tanulás területén azt jelenti, hogy mennyire érthető és átlátható egy adott modell működése. Az interpretabilitás azt méri, hogy mennyire könnyen érthetők egy modell döntéseinek okai: a magasabb interpretabilitású modellek esetében könnyebb megérteni és megbízni a modellben. Az interpretabilitás nem bináris tulajdonság, hanem a modell bonyolultságától is függ.

Az interpretabilitás különösen fontos olyan területeken, ahol az átláthatóság elengedhetetlen, például az egészségügyben, pénzügyekben vagy a szociális szolgáltatások biztosításában. A magas interpretabilitású modellek lehetővé teszik a döntéshozók számára, hogy megmagyarázzák a modell döntéseit, azonosítsák a potenciális torzításokat, és növeljék a bizalmat az alkalmazások iránt. Az interpretabilitás és az érthetőség közötti különbség alapvetően az, hogy az interpretabilitás a modell általános működésének megértését jelenti, míg az érthetőség a modell egyes döntéseinek megértését jelenti (Rudner és Toner, 2021).

AI-algoritmusok	Elsődleges felhasználási területek	Társadalomtudományi felhasználhatóság	Adatigény és méret	Kiemelkedő előnyök	Kiemelkedő hátrányok	Előrejelzési pontosság	Interpretabilitás
Deep learning (DL)	Képfelismerés, nyelvi feldolgozás, prediktív analitika	Képfelismerés, nyelvi elemzés, prediktív modellek	Nagy adathalmazok, komplex struktúrák	Nagy pontosság, automatizált jellemzők kinyerése	Nagy számú adat és számítási erőforrás szükséges	Nehezen értelmezhető	Etikai kihívások (<i>adat bias</i> , diszkrimináció)
Machine learning (ML)	Osztályozás, regresszió, klaszterezés	Széles körű alkalmazások, prediktív modellezés	Kiseb adat-halmazoktól nagyokig	Könnyen értelmezhető, alacsonyabb adatigény	Nagyon függős a kézzel kiválasztott jellemzőktől	Kevésbé pontos	Könnyen értelmezhető
Recurrent neural network (RNN)	Idősorok elemzése, nyelvi modellezés	Idősorok elemzése, nyelvi modellezés	Közepes adathalmazok, időbeli szkevényciák	Rugalmas idő-sorok elemzése, szövegmodellezés	Lassú tanulás hosszú távú függőségek esetén	Közepes	Nehezen értelmezhető
Convolutional neural network (CNN)	Képfelismerés, videofeldolgozás	Képfelismerés, vizuális elemzés	Nagy képadathalmazok	Lokális jellemzők kinyerése, kiváló képfelismerés	Számításiigényes, kisebb változatosság más adattípusokban	Nagyon pontos képfelismerés	Könnyen értelmezhető
Natural language processing (NLP)	Nyelvi elemzés, gépi fordítás	Szövegelemzés, nyelvi modellezés	Nagy szöveges adathalmazok	Nyelvi szemantika megértése, szemantikus keresés	Szavak környezetének fontossága	Közepes	Nehezen értelmezhető
Spiking neural networks (SNN)	Biológiai agy modelleje, érzékelő hálózatok	Kognitív funkciók modellezése	Eltérő adathalmazok, biológiai szimulációk	Biológiai hűség, alacsony energiafogyasztás	Kevésbé alkalmazható kereskedelmi alkalmazásokban	Alacsony	Nehezen értelmezhető
Large language models (LLM)	Nyelvi modellezés, szövegenerálás	Nyelvi elemzés, szövegenerálás	Nagy szöveges adathalmazok	Kreatív szövegenerálás, információ kinyerése	Nehezen interpretálható, számításiigényes	Kiemelkedő	Nehezen értelmezhető

Befejezésül fontos hangsúlyozni, hogy jelen leírás csak felületesen érintette az mesterséges intelligencia alkalmazásának témakörét a társadalomtudományokban. Számos más aspektus és alkalmazási terület létezik, amelyek szintén megérdemlik a figyelmet. Ugyanakkor reméljük, hogy ez a rövid, és talán néha technikainak tűnő leírás inspirációt adhat, mert elsődleges célunk az volt, hogy rámutassunk arra, hogy ezek a rendszerek és algoritmusok milyen potenciállal bírnak a társadalomtudományi kutatásokban.

Összefoglalva, úgy véljük, a mesterséges intelligencia (MI) és a társadalomtudományok közötti kapcsolat rendkívül izgalmas és dinamikus terület. A MI-technológiák, mint például a gépi tanulás, a konvolúciós neurális hálózatok és a visszacsatolós neurális hálózatok, új lehetőségeket nyitnak meg a társadalomtudományi kutatásokban. Ezek az eszközök lehetővé teszik a kutatók számára, hogy mélyebb betekintést nyerjenek a társadalmi folyamatokba, és jobban megértsék, hogyan befolyásolják ezek a folyamatok az egyének és csoportok viselkedését és döntéseit. A MI alkalmazása a társadalomtudományokban hozzájárulhat a hatékonyabb és célzottabb társadalompolitikai intézkedések kialakításához, valamint a társadalomtudományi kutatások új dimenzióinak feltárásához. A jövőben várhatóan további fejlődés és innováció várható ezen a területen, ahogy a MI-technológiák egyre inkább integrálódnak a társadalomtudományi kutatásokba.

Köszönetnyilvánítás

A szerző dr. Kristóf Péternek kíván köszönetet mondani szakmai lektorként végzett hozzájárulásáért.

Irodalom

- Belenguer, L. (2022). AI bias: exploring discriminatory algorithmic decision-making models and the application of possible machine-centric solutions adapted from the pharmaceutical industry. *AI Ethics*, 2(7), 771. DOI: 10.1007/s43681-022-00138-8
- Brill, M. T., Munoz, L. & Miller, R. J. (2019) Siri, Alexa, and other digital assistants: a study of customer satisfaction with artificial intelligence applications. *Journal of Marketing Management*, 35(15–16), 1401–1436, DOI: 10.1080/0267257x.2019.1687571
- Dehghan, P., Alashwal, H. & Moustafa, A. A. (2022). Applications of machine learning to behavioral sciences: focus on categorical data. *Discover Psychology*, 2, 22. DOI: 10.1007/s44202-022-00027-5
- Deranty, J. P., Corbin, T. (2022). Artificial intelligence and work: a critical review of recent research from the social sciences. *AI & Society*. DOI: 10.1007/s00146-022-01496-x
- Di Franco, G. & Santurro, M. (2021). Machine learning, artificial neural networks and social research. *Quality & Quantity*, 55, 1007–1025. DOI: 10.1007/s11135-020-01037-y
- Eckhardt, C. M., Madjarova, S. J., Williams, R. J. és mtsaik . Unsupervised machine learning methods and emerging applications in healthcare. *Knee Surgery, Sports Traumatology, Arthroscopy*, 31(2), 376–381. PMID: 36378293. DOI: 10.1007/s00167-022-07233-7
- Guo, Z., Jin, R., Liu, C., Huang, Y., Shi, D., Supryadi, Yu, L., Liu, Y., Li, J., Xiong, B. & Xiong, D. (2023). Evaluating Large Language Models: A Comprehensive Survey. arXiv preprint. arXiv:2310.19736 [cs. CL]. DOI: 10.48550/arXiv.2310.19736
- Khanam, S., Tanweer, S. & Khalid, S. (2021). Artificial Intelligence Surpassing Human Intelligence: Factual or Hoax. *The Computer Journal*, 64(12), 1832–1839. DOI: 10.1093/comjnl/bxz156
- Khurana, D., Koli, A., Khatter, K. és mtsaik (2023). Natural language processing: state of the art, current trends and challenges. *Multimedia Tools and Applications*, 82, 3713–3744. DOI: 10.1007/s11042-022-13428-4
- Köchling, A., Wehner, M. C. (2020). Discriminated by an algorithm: a systematic review of discrimination and fairness by algorithmic decision-making in the context of HR recruitment and HR development. *Journal of Business Research*, 13, 795–848. DOI: 10.1007/s40685-020-00134-w
- Li, Y. (2022). Reinforcement Learning in Practice: Opportunities and Challenges. arXiv preprint arXiv:2202.11296 [cs.LG] (2022). arXiv:2202.11296.
- Liu, Q. & Wu, Y. (2012). Supervised Learning. In Seel, N. M. (szerk.), *Encyclopedia of the Sciences of Learning*. Springer. 3243–3245. DOI: 10.1007/978-1-4419-1428-6_451

- Naveed, H., Khan, A. U., Qiu, S., Saqib, M., Anwar, S., Usman, M., Akhtar, N., Barnes, N. & Mian, A. (2023). A Comprehensive Overview of Large Language Models. arXiv preprint arXiv:2307.06435 [cs.CL] (2023).
- Nazer, L. H., Zatarah, R., Waldrip, S., Ke, J. X. C., Moukheiber, M., Khanna, A. K. és mtsaik (2023). Bias in artificial intelligence algorithms and recommendations for mitigation. *PLOS Digital Health*, 2(6), e0000278. DOI: 10.1371/journal.pdig.0000278
- Nwadiugwu, M. C. (2021). Neural Networks, Artificial Intelligence and the Computational Brain. arXiv preprint arXiv:2101.08635 [q-bio.NC]. DOI: 10.48550/arXiv.2101.08635
- Oneto, L. & Chiappa, S. (2020). Fairness in Machine Learning. arXiv preprint arXiv:2012.15816 [cs.LG]. DOI: 10.48550/arXiv.2012.15816
- O'Shea, K. & Nash, R. (2015). An Introduction to Convolutional Neural Networks. arXiv preprint arXiv:1511.08458 [cs.NE]. DOI: 10.48550/arXiv.1511.08458
- Rudner, T. G. J. & Toner, H. (2021). *Key Concepts in AI Safety: Interpretability in Machine Learning*. Center for Security and Emerging Technology. DOI: 10.51593/20190042
- Salem, F. M. (2022). *Recurrent Neural Networks: From Simple to Gated Architectures*. Springer. DOI: 10.1007/978-3-030-89929-5
- Sanaullah, M., Koravuna, S., Rückert, U. & Jungeblut, T. (2023). Exploring spiking neural networks: a comprehensive analysis of mathematical models and applications. *Frontiers in Computational Neuroscience*, 17, 706. DOI: 10.3389/fncom.2023.1215824
- Sarker, I. H. (2021). Machine Learning: Algorithms, Real-World Applications and Research Directions. *SN Computer Science*, 2, 160. DOI: 10.1007/s42979-021-00592-x
- Singla, M., Ghosh, D. & Shukla, K.K. (2019). A survey of robust optimization based machine learning with special reference to support vector machines. *International Journal of Machine Learning & Cybernetics*, 11, 1359–1385. DOI: 10.1007/s13042-019-01044-y
- Wolf, T. és mtsai (2019). HuggingFace's Transformers: State-of-the-art Natural Language Processing. arXiv:1910.03771 [cs.CL]. DOI: 10.48550/arXiv.1910.03771
- Wolff, J. (2021). How Is Technology Changing the World, and How Should the World Change Technology? *Global Perspectives*, 2(1), 27353. DOI: 10.1525/gp.2021.27353

Absztrakt

A mesterséges intelligencia (MI) és a gépi tanulás (ML) gyors fejlődése a társadalomtudományokat sem hagyja érintetlenül. Ez a tanulmány rövid áttekintést kíván nyújtani a mesterséges intelligencia társadalomtudományi kutatásokban való alkalmazásáról. Röviden ismerteti a különböző MI-algoritmusokat, azok előnyeit és hátrányait, kiemelve azokat a kulcsfontosságú szempontokat (mint például az átláthatóság, előrejelző képesség, skálázhatóság, robusztusság és értelmezhetőség), amelyek meghatározzák a MI hasznosságát és hatékonyságát a kutatási feladatokban. A cikk arra ösztönzi a kutatókat, hogy a mesterséges intelligencia alkalmazásakor gondosan mérleljeék ezeket a tényezőket, hangsúlyozva a technológia felelősségteljes alkalmazásának fontosságát a társadalomtudományi kutatásban. A mesterséges intelligencia és a gépi tanulási eszközök csak akkor használhatók ki teljes mértékben, ha ezeket a szempontokat megfelelően figyelembe veszik és integrálják a kutatási folyamatokba.

Kulcsszavak: mesterséges intelligencia (MI), gépi tanulás (ML), társadalomtudományi kutatás, MI-algoritmusok, értelmezhetőség, előrejelző képesség