

Az adat és az információ szavakra szélsőségesen úgy tekintenek, mint egy disztópia legfőbb elemeire. A mesterséges intelligencia (MI) az adatok mennyiségi és minőségi feldolgozásában és felhasználásában valóban eddig nem látott méreteket és lehetőségeket ért el. Mégis érdemes hátralépni egyet a jobb megértés és a nagyobb perspektíva érdekében. Az MI olyan technológiai protézis, amely a szellemi kapacitásunkat tágítja. Nem használja, nem másolja, de még csak nem is uralja le az embert. A technológia a használatában valósul meg igazán. A gépi intelligencia felépítését nem az öntudatra ébredés disztópiájaként kezdték el leprogramozni.

Az itt fordításban olvasható tanulmány lényegében egy technomédiumot ír le, illetve annak legalapvetőbb folyamatait. Médiaelméleti szempontból egy médium tanulási lehetőségei és a benne rejlő kreativitás – legyen az akár a *post-truth* legsikeresebb eszköze – sokkal izgalmasabb megközelítéseket adhatnak, mint az, hogy az MI személyisége megszületik. A rendszert adatokkal mi töltjük fel. Az információs ontológiák és az azt használó algoritmusok pontosan annyira ideologikusak és nem univerzálisak, mint a mi társadalmi térben kialakult személyiségünk. A technológia a használatában valósul meg igazán.

Feczku Viktor

Bevezetés a gépi tanulás médiaelméletébe*

David M. Berry

E tanulmányban a gépi tanulás médiaelméleti alapjait vázolom fel két új fogalom, a számító művelet (*compute-computing*) és a kiszámított művelet (*compute-computed*) bevezetésével, valamint ezek kölcsönhatásának keretrendszerével.¹ Számító műveleten (számítás, azaz generatív) itt egy rendszer „aktív” tanulási komponensét értjük, míg a kiszámított művelet (számítás, azaz generált) fogalma a rendszer „passzív”, kódolt, annak emlékezetébe vésett vagy beleírt adatainak aspektusaként ragadható meg. Ezt a két fogalmat azért vezetem be, hogy segítsen átgondolnunk az algoritmikus rendszerek sajátosságait, amelyek nem csupán a számításfeldolgozás operatív, szekvenciális vagy párhuzamos rendszerei, amelyekhez hozzászoktunk. Sőt a gépi tanulási rendszerek esetében ezek a rendszerek valóban képesek önállósulni abban az értelemben, hogy olyan modelleket és adatstruktúrákat generálnak, amelyek teljesen internalizálják az adatok bizonyos mintajellemzőit, anélkül, hogy ezeket egy hús-vér programozó formális adatstruktúrákra fordítaná le,² vagyis képesek arra, hogy megragadják a rendszerbe bevitt adatok absztrakt formáját, azonosítsák a kulcsfontosságú jellemzőket, kereteket vagy mintákat, és ezeket más adatfolyamok vagy objektumok összehasonlítása és osztályozása céljából tárolják.

* David M. Berry a Sussexi Egyetemen a digitális humán tudományok professzora. Kötetei: *Digital Humanities: Knowledge and Critique in a Digital Age* (Anders Fagerjorddal, Polity, 2017), *Critical Theory and the Digital* (Bloomsbury, 2014) és *The Philosophy of Software: Code and Mediation in the Digital Age* (Palgrave, 2011). Az itt olvasható fordítás az alábbi publikáció alapján készült: David M. Berry (2024): Prolegomenon to a Media Theory of Machine Learning. *Media Theory Journal*, vol. 1, no. 1, pp. 74–84. Az eredeti szöveget a Médiakutató formai követelményeihez igazítottuk.

1 Érdekes visszhangja van Heidegger „dolgok kidolgozása” fogalmának (*Dinge dingend*) is.

2 Sok ilyen gépi tanulási rendszer még mindig „mérnök-iparosok” kézműves munkáját igényli, akiknek optimalizálniuk kell a rendszerek belső hálózatait.

Ezekről a rendszerekről azt mondhatjuk, hogy egy további tulajdonsággal is bírnak, amely az új algoritmusok létrehozásának képessége, jelesül a *számítás*: fel tudják építeni az adatok „világának” modelljét és az azokat átalakító függvényeket. Terjedelmi korlátok miatt csak nagy vonalakban ismertetem azt az elméleti és koncepcionális munkát, amelyet ennek az új számítási formának és következményeinek mérlegeléséhez kell elvégezni, ennek ellenére igyekszem rámutatni a gépi tanulásról való gondolkodás lehetséges jövőbeni irányaira is, amelyeket ez a bevezető munka vet fel. Következésképpen e tanulmányban kénytelen vagyok zárójelbe tenni a szélesebb körű társadalmi és politikai-gazdasági következményeket – amelyek természetesen jelentősek, és becslések szerint csak 2016-ban 26–39 milliárd dolláros beruházást jelentettek a gépi tanulás terén (Bughin et al. 2017) – annak érdekében, hogy a gépi tanulásról való gondolkodás új keretére koncentráljak, amely egyben hozzájárul a gépi tanulás kritikájához is. A gépi tanulást igyekszem különösen az önírás vagy automatikus modellépítés képességének szempontjából végiggondolni, és megvizsgálom a kód, a szoftverek és az algoritmusok komplexitásának problémáját, amikor a „kód” bizonyos értelemben ismét a komplexitás egy másik szintjébe burkolódik. A gépi tanulás úgy hat, mint egy „talány, titokzatosságba csomagolva, egy rejtély belsejében”, és – különösen a szakterületen kívülállók számára – ez a homályos és bonyolult morfológia elméleti és empirikus kibontást igényel.³ A gépi tanulásról alkotott megfontolásokat az eddigiektől eltérő fogalmi modellen keresztül bemutatva megkezdhetjük a megértés kritikai munkáját, feltárva, hogy mi történik ezeknek az új számítási formáknak a felszíne alatt, és milyen jelentősége van a használatuknak.

Az algoritmusok és a szoftverek kutatásának nehézségei számos tudományos munka középpontjában állnak (például Manovich 2001, Marino 2006, Fuller 2008, Chun 2006, 2010, 2011, Wardrip-Fruin 2009, Berry 2011, Berry & Fagerjord 2017), de itt a gépi tanulásra mint a szoftverekkel kapcsolatos sajátos problémára koncentrálna a gépi tanulás médiaelméletének különleges kérdéseire kívánom irányítani a figyelmet. A gépi tanulásról gondolkodó tudományos munkákra van már néhány hasznos példa, de ezek gyakran túlságosan általánosak (Alpaydin 2016, Domingos 2017), a *black box* vagy a technikai besorolás kérdéseire összpontosítanak (lásd Domingos 2012, Burrell 2016), esetleg szélesebb témákkal foglalkozó népszerű szövegek (Carr 2016, Ford 2016, Kelly 2017, McAfee & Brynjolfsson 2017). Ezzel szemben amit itt bemutatok, azt a gépi tanulás struktúráiról és folyamatairól való gondolkodás új fogalomkészletének elméleti és filozófiai bevezetőjének nevezhetném.

Az első pontban a gépi tanulás sajátosságait szeretném megvizsgálni a mesterségesintelligencia-kutatás tágabb területéhez viszonyítva. A második fejezetben bevezetem fogalmi keretrendszeremet, és kifejtem, miként kapcsolódik Baruch Spinoza munkásságához. Végül az utolsó fejezetben azt vizsgálom, hogyan biztosítja ez a fogalmi keret a gépi tanulás megvitatását a médiaelmélet, a digitális bölcsészettudományok és általában a társadalomelmélet számára felvetett problémakörök kapcsán. Mint korábban említettem, ez az írás – korlátozott terjedelme miatt – csak korlátozott mértékben képes áttekintést nyújtani e nagyon összetett témákról. Mindamellet remélhetőleg segít abban, hogy a vita az általam felvázolni kívánt elméleti fogalmak köré összpontosuljon.⁴

1

1959-ben – sokak szerint, akik ezen a területen dolgoztak – Arthur Samuel úgy definiálta a gépi tanulást, mint „olyan tudományterület, amely a számítógépeket képessé teszi a tanulásra kifejezetten programozás nélkül”. Azért mondom, hogy sokak szerint, mert bár a szakirodalomban széles körben hivatkoznak Samuel munkájára (1959), a kifejezés valójában nem szerepel a cikkében. Mindamellet e meghatározás elfogadott (és ismételt) kiindulópont

3 Winston Churchill 1939 októberében egy rádióadásban kijelentette: „Nem tudom megjósolni önöknek Oroszország fellépését. Ez egy talány, titokzatosságba csomagolva, egy rejtély belsejében; de talán van egy kulcs. Ez a kulcs az orosz nemzeti érdek.”

4 Az olyan elméleti és filozófiai fogalmakkal és elképzelésekkel foglalkozó folyóiratok, mint a *Media Theory* fontos helyszínei az elméleti munkának, és – mint ilyenek – döntő jelentőségűek a médiafilozófia fejlődésében.

a területen, és gyakran használják annak bemutatására, hogy a gépi tanulás különösen a gép öntanuló képességére irányul, illetve hogy miben különbözik a mesterséges intelligenciától, vagyis a számítás alkalmazásától olyan szimbolikus feladatok esetében, amelyeket általában az emberi megismerés segítségével végeznek el.⁵ 1997-ben Tom M. Mitchell (1997) frissítette ezt a definíciót, és a gépi tanulást úgy írta le, mint

...számítógépes programot [amelyről] azt mondjuk, hogy E tapasztalatból (*experience*) tanul a feladatok (*tasks*) T osztálya és a P teljesítménymutató (*performance*) tekintetében, ha a T feladatokban a P által mért teljesítménye javul az E tapasztalattal.

Lényegében azt állítja, hogy a teljesítménymutató a döntő a „tanulási” képesség kiterjedésében, vagyis a feldolgozási munka rövidebb idő alatt történő elvégzésének képességében. Itt csak annyit jegyezhetünk meg, hogy a „tanulás” e fogalma nagyon specifikus és technikai jellegű, és a készségekre vagy a feladatok elvégzésének képességére vonatkozik, nem a tanulás olyan tágabb emberi konnotációira, mint a megértés, az értelmezés stb. Valójában ez a sajátos területi problémákra való összpontosítás az, ami a gépi tanulást az általános mesterséges intelligencia szélesebb körű tudásproblémáitól elhatárolja.

A gépi tanulás mint a mesterséges intelligencia kutatásának sajátos területe 2010 óta nagy érdeklődésre tart számot, nem csupán az akadémiai kutatók és a vállalatok körében, hanem a médián keresztül a nyilvánosságban is (lásd Tufekci 2014, Lewis-Kraus 2016, Donnelly 2017, Economist 2017). Ez részben a hardver- és a szoftverkapacitások változásainak köszönhető, amelyek lehetővé teszik, hogy a mesterséges intelligencia ígéreteinek egy része a médiaökológia egész területén beteljesüljön. A gépi tanulás felé fordulást az is ösztönözte, hogy a tudományágak csak korlátozott kapacitással képesek megbirkózni a digitális adatok egyre növekvő tömegével, az úgynevezett *Big Data*val, amihez egy olyan politikai gazdaságtan társult, amely hatalmas gazdasági potenciált lát az adatok bányászatában a mélyebb betekintés és a profit érdekében. Ahogy Jenna Burrell (2016: 5) kifejti:

...a gépi tanulási algoritmusokat mint hatékony generalizáló és prediktív tényezőket használják. Miután ezeknek az algoritmusoknak a pontossága köztudottan javul a nagyobb adatmennyiségek esetén, az ilyen adatok növekvő elérhetősége az elmúlt években megújult érdeklődést váltott ki ezen algoritmusok iránt.

Az biztos, hogy a gépi tanulás számtalan eszközhöz utat talál a felhőalapú számítóközpontoktól kezdve a fordítási szolgáltatásokig, a televízióig, a telefonokig és a beszélő asszisztensekig. Alkalmazása valójában egyre inkább hasonlít másfajta számítástechnikai szolgáltatásokhoz, a kódkönyvtárak és az alkalmazásprogramozási interfészek (*application programming interface*, API) formájában elérhető absztrakciók fogalmi rétegződésével, valamint a harmadik felek által elérhető szolgáltatásokkal.

Rendszereket alkotni ilyen formában annyit jelent, hogy felfedjük a gyakran egymásra rakódó számítási rétegekben rejlő mélységi modellt. Miközben a számítási rendszerekben a rétegződés fogalma igen gyakori (lásd Berry 2014: 58, Kitchin 2016: 20), ez egyben a „black box” előállításának logikája is, amely a gépi tanulás feldolgozását a bemenetek és a kimenetek egyszerűsített interfészével képes kezelni (Berry 2011: 15–16). Ha azonban eltávolodunk a gépi tanulás külső perspektívájától és a belső rendszerstruktúrára koncentrálunk, érdemes megfigyelni a gépi tanulás hagyományos felépítését a külső rétegekkel: ez így egy alapvetően hagyományos számítógépes programozási nyelven megtervezett belső szoftvergépet hoz létre, amely az adatokból számos fontos módon létrehozható, összekapcsolható, programozható és súlyozható absztrakciót konstruál. A gépi tanulási

⁵ Ez a meghatározás természetesen vitatott, és sok kutató és gyakorlati szakember tekinti a gépi tanulást a mesterséges intelligencia tágabb területe egy részhalmozásának. Magát a „mesterséges intelligencia” kifejezést 1956-ban a Dartmouth College-ban, a *Dartmouth Summer Research Project on Artificial Intelligence* keretében John McCarthy matematikus alkotta meg.

algoritmusoknak három fő szempontja van, amelyet a gépi tanulási rendszerek fejlesztése során meg kell valósítani. Ezek a következők:

1. *A tudás reprezentációja*: A gépi tanulási algoritmusok a tudás modelljét valósítják meg, olyan tudás-reprezentációkat használva, mint például a döntési fák, a szabályhalmazok, a példányok, a grafikus modellek, a neurális hálózatok, a támogatóvektor-gépek vagy a modellegyüttesek.
2. *Kiértékelés*: A gépi tanuló rendszereket induktív tanulási technikák segítségével osztályozó rendszerekké formálják, majd olyan mérési módszerek segítségével értékelik, mint a pontosság, az előrejelzés és a visszahívás, a négyzetes hiba, a valószínűség, az utólagos valószínűség, a költség, a margó és a k-L divergencia [vagyis a relatív entrópia – A ford.].
3. *Optimalizálás*: az algoritmusokat olyan technikák segítségével finomhangolják, mint a kombinatorikus optimalizálás, a konvex optimalizálás és a korlátozott optimalizálás.

A legtöbb gépi tanulási rendszer az induktív – adatelemző – megismerés modelljét használja az osztályozások előállításához. Az indukción itt mint „az általános szabályok konkrét adatokból történő levezetésének folyamata” (Mooney 2000: 1) értendő. A gépi tanulást trenírozó adatokra támaszkodva *felügyelt tanulás* alkalmazásával, klaszterezési technikákat használva *felügyelet nélküli tanulás*sal, kisebb mennyiségű képzési adatokra építve *félig felügyelt tanulás*sal vagy *megerősítő tanulás*sal lehet megszervezni, amelynek során a hálózatba érkező visszajelzés a kimenet sikeressége alapján erősíti a belső struktúrákat. A cél minden esetben az, hogy a rendszer megtanulja létrehozni azt a függvényt, amely a bemeneti adatokat kimenetivé alakítja, hogy az absztrakt általánosítással szemben úgynevezett helyi általánosítást hozzon létre. A kimenet lehet osztályozó rendszer, amikor a függvény diszkrét kimenetet hoz létre; regressziós rendszer, amikor a függvény folytonos; és valószínűségbecslő rendszer, amikor a kimenet egy valószínűségi érték.

Ahol például a tudás reprezentációja egy neurális hálózat, ott egy „konnekcionista” rendszer épül fel. A neurális hálózatok esetében a feldolgozás/memória absztrakción alapul, az „állati agyak párhuzamos architektúrája” által inspirált, eltérő számítási paradigma kerül bevezetésre. A neurális hálózati rendszerek úgy működnek, hogy vesznek egy adott „A” bemenetet, és azt a neurális hálók köztes, néha rejtettnek nevezett rétegein keresztül „B”-be fordítják. A hagyományos számítási rendszerek általában procedurálisak (vagy imperatívák); a program az első kódsorral kezdődik, végrehajtja azt, majd a következőre lép, és – az utasításokat követve – némileg lineárisan halad tovább.⁶ Egy valódi neurális hálózat nem feltétlenül követ lineáris utat. Az információ feldolgozása inkább kollektíven, párhuzamosan történik egy csomópontokból álló hálózaton keresztül (a csomópontok ez esetben neuronok, vagyis kis programegységek, amelyeket a köztük lévő súlyozások kapcsolnak össze). Az olyan technikák alkalmazásával, mint az előrecsatolás (azaz a feldolgozásban nincsenek hurkok) és a visszaterjesztés (amely lehetővé teszi, hogy a kimenetet visszasúlyozzák a hálózatba az anomáliák kijavítására), ezek a rendszerek jobbak lehetnek a mintafelismerésben és az osztályozásban.

A gépi tanulás tulajdonképpen belső működése a „homokozás” fogalmával analóg módon képzelhető el: a gépi tanulási modellt egy másik kódstruktúra tartalmazza. A számítástechnikában alkalmazott homokozó technika az alkalmazáskódot különböző hozzáférési és ellenőrzési szintekre osztja, hogy különböző biztonsági szintek legyenek alkalmazhatók, és csak a megfelelő szintű hozzáférést biztosítsa az alkalmazás számára. A fő cél az, hogy megakadályozza a számítógépes erőforrásokhoz való illetéktelen hozzáférést, de használható a számítási architektúra szabványosítására is, hogy ugyanazt a kódot különböző rendszereken lehessen futtatni, mint például a Java nyelv esetében. A neurális hálók esetében nem a számítógépes biztonság a kérdés, hanem egy olyan absztrakt gép megalkotása, amely szoftveresen modellezi az idegsejtek egyszerűsített fogalmának működését, és amely képes egy funkcionális átalakítást a hálózati adatstruktúrában belül kódolni és tárolni. Azt mondhatjuk, hogy a gépi tanulás a „homokozás” egy másik formája valósul meg, amennyiben a „tanulási” vagy „betanítási” folyamatok egy absztrakt gépbe ágyazott algoritmikus modell létrehozásához szükségesek. Ez ugyanakkor szoftveres neurális

⁶ Az objektumorientált programozás és a kapcsolódó megközelítések kiterjesztik ezeket a technikákat, de továbbra is emberi megértést és programozást igényelnek a lineáris működéshez, bár ebben az esetben szoftverobjektumok rendszerére elosztva.

hálózatokból épül fel, hogy létrehozzon egy, az adatbemenetek és a számított kimenetek (osztályozás, regresszió vagy valószínűség) elemzésére szolgáló függvényt. Ez a struktúra teszi lehetővé, hogy a hálózat megtanulja a hasonlóságok azonosítását, ezzel mintegy elmozdul a képzési adatoktól teljesen újszerű adatokhoz, amelyeket a korábban látott képzési adatok alapján képes a mintázathoz illeszteni. Ilyenformán „a gépi tanulás alapvető célja az általánosítás a gyakorlóhalmazban található példákon túl” (Domingos 2012). A gépi tanulás tehát alapvetően induktív folyamat, amely a hálózat bemeneteibe táplált eredetileg empirikus képzési adatokon alapul, amelyeket nagy gonddal tovább erősít azért, hogy a hálózat mintaillesztése elérje a kívánt célokat.

Ezeknek a rendszereknek a felhasználási területei széles skálán mozognak. Néhány közülük a következő:

- *mintafelismerés*, például arcfelismerés, optikai karakterfelismerés stb.;
- *idősor-előrejelzés*, gépi tanulás előrejelzések készítésére;
- *jelfeldolgozás*, vagyis a gépi tanulás betanítható egy hangjel feldolgozására és megfelelő szűrésére;
- *vezérlés*, gépi tanulás fizikai járművek irányítási döntéseinek kezelésére;
- *lágyszűrők*, azaz egy sok mérésből álló gyűjtemény elemzése, amely egyetlen gépi tanuló algoritmusba absztrahálható a sok egyedi érzékelő bemeneti adatainak feldolgozásával és azok mintegy egészként történő értékelésével; és végül
- *anomália-felismerés*, vagyis a gép megtanulja felismerni a mintákat, és betanítható arra is, hogy riasztást adjon, ha valami rendellenes.

Ezek a különböző felhasználási esetek a gépi tanulást számos valós rendszerben tették közkedvelté a pénzügyi-marketing-előrejelzéstől a csalásfelismerő és az azonosító rendszereken át a terrorizmusellenes megfigyelésig.

2

Nézőpontot váltva most a gépi tanulás mögöttes struktúrájának koncepcióalkotása felé fordulok, röviden végiggondolva Baruch Spinoza (1632–1677) filozófus munkásságát.⁷ Itt nincs elég hely Spinoza filozófiájának részletes leírására, ezért csupán arra térek ki, hogyan fejlesztette tovább a középkori *Natura naturans* (teremtő természet) fogalmát, különösen saját *Natura naturans* és *Natura naturata* fogalmával összefüggésben. A *Natura naturans* és a *Natura naturata* fogalom visszakövethető az ókori görög filozófiáig, és Ágostonon és Johannes Scotus Erigenán keresztül az isten és a világ közötti különbségtételig vezethető vissza. Spinoza azzal a szándékkal használja ezeket a fogalmakat, hogy különbséget tegyen a természet azon része között, amely szerinte generatív és a teremtő isten hagyományos fogalmához kapcsolódik (ez a *Natura naturans*), illetve a természet azon része között, amely egy teremtési aktus eredménye (ez a *Natura naturata*) (lásd Demasio 2003: 329). Spinoza számára tehát a Természetnek két oldala van. Az egyik a világegyetem aktív, teremtő aspektusa, amit Spinoza Szubsztanciának és attribútumainak nevez, és amiből minden más származik, illetve az, amit Spinoza *Natura naturans*-nak – „létrehozó Természetnek” – nevez. A világegyetemnek másik aspektusa az, amit ez az aktív aspektus termel és tart fenn, és amit Spinoza *Natura naturatának*, azaz „létrehozott Természetnek” nevez (lásd Nadler 2001: 100).

Spinoza ezeket a kifejezéseket az *Etika* (1, xxix) című művében használja, ahol kifejti, hogy:

Natura naturans alatt azt kell értenünk, ami önmagában van és önmagán keresztül fogantatik, vagyis az anyagnak olyan tulajdonságait, amelyek egy örök és végtelen lényeket fejeznek ki, az ... Istent, amennyiben őt szabad oknak tekintjük.

⁷ Megjegyezhetjük, hogy érdekes feszültséget kelt az, ha egy olyan racionalista munkásságát használjuk fel a gépi tanulás empirizmusának végiggondolásához, mint Spinoza, különösen annak fényében, hogy a gépi tanulás hangsúlyosan induktív gondolkodási modellen alapul. E tanulmányban nincs hely a kérdés kidolgozására és e feszültség alapos végiggondolására, de egy későbbi tanulmányban szeretnék foglalkozni ezzel a kérdéssel. Köszönöm a 2017. július 17–19. között Zürichben megrendezett *Visualisierungsprozesse in den Humanities* konferencia résztvevőinek a vitát, ahol ez és más kérdések is felmerültek.

Vagyis a *Natura naturans* egy objektív *Natura naturata*t hoz létre. Más szóval: „minden dolog kauzális és episztemikus függésben van Istentől” (mint *Natura naturan*stól) (Nadler 2001: 100). Ugyanakkor úgy érvel, hogy:

Natura naturata alatt mindazt értem, ami Isten természetének szükségszerűségéből vagy Isten tulajdonságaiból következik, vagyis Isten tulajdonságainak minden módját, amennyiben azokat olyan dolgoknak tekintjük, amelyek Istenben vannak, Isten nélkül nem lehetnek és nem is gondolhatók el.

A *Natura naturans* tehát hagyományosan Istent jelöli, amennyiben őt minden cselekvés teremtőjeként és elveként értelmezik, míg a *Natura naturata* alatt az általa teremtett lények és törvények összességét értik (lásd Hadot 1995: 262). Ez a konstrukció – mint Pierre Hadot (1995: 255) megjegyzi – nagy érdeklődésre tartott számot a művészek körében a gyakorlatuk konceptualizálása érdekében; példa erre Klee, aki azt állította, hogy „a *Natura naturans* fontosabb a festő számára, mint a *Natura naturata*”. Spinoza tehát a *Natura naturans*-t úgy fogja fel, mint „lényegi minőséget” – egy Istenhez hasonlóan cselekvő, teremtő potenciát. Ez a Természet megalkotja magát, mint „önmagát teremtő” természet. Ezzel szemben a *Natura naturata* szerinte a meghatározott létező meghatározott teljessége, amely formát kapott – vagyis a lényege „teremtett lett”.

3

Ez a megkülönböztetés úgy fogható meg, mint egy konstitutív (*Natura naturans*) és egy operatív (*Natura naturata*) forma, és ez a megalkotó és működtető megkülönböztetés az, amelyről azt állítom, hogy hasznos a gépi tanulásról való gondolkodáshoz. Ehhez kívánom bevezetni a két új fogalmat:

1. Az egyik a *számító művelet*, amelyet a gépi tanulás rendszerében a tevékenység generáló szintjeként értelmezzünk, és amely „aktívnak” tekinthető és analóg Spinoza *Natura naturans* fogalmával, amennyiben megteremti a neurális hálózat feltételeit. A számítási struktúrában alapvető szintet képez, és megteremti a hálózat működésének feltételeit. Leginkább a gépi tanulási rendszer képzési, illetve tanulási fázisában üzemel. Ez megegyezik azzal, amit Spinoza alapvető struktúráként és mintaként értelmez, és amit a *Natura naturans* „attribútumainak” nevez.
2. A másik a *kiszámított művelet*, amelyet úgy értelmezzünk, mint azt, ami van vagy amit létrehozta, és mint ilyen „passzív”, mint Spinoza fogalmában a *Natura naturata*. Ez alkotja a gépi tanulás rendszerének működési szintjét, azt, amit Spinoza a *Natura naturata* működési „móduszaiként” értelmez. Így itt a passzív nem tétlenséget jelent; inkább a *kiszámított művelet* performatív aspektusára mutat rá, arra, ami már létrejött, és ami a hálózat által a mintaillesztés funkciójával kapcsolatban működőképessé tehető. Ez tehát a hálózat az adatokkal való betanítás után, amely önmagában nem képes egy másik hálózatot létrehozni.

A *Natura naturans* fogalmával Spinoza és más filozófusok a Természet (és ezen keresztül Isten) teremtő, dinamikus képességének termékenységére mutattak rá. Ezt követve itt a *számító művelet* által kínált kreatív potenciálra kívánok rámutatni, amely a *kiszámított művelet* többféle módjának generálására szolgál.

Megjegyezhetjük, hogy számos különböző gépi tanulási algoritmus létezik. Ezeket a *számító művelet* többféle attribútumaként is felfoghatjuk. Ilyenek például a döntési fa alapú tanulás, az asszociációs szabály szerinti tanulás, a mesterséges neurális hálózatok, a mély gépi tanulás, az induktív – adatelemző – logikai programozás, a támogatóvektor-gépek, a klaszterezés, a Bayes-hálózatok, a megerősítéssel tanulás, a reprezentációs tanulás, a hasonlósági és metrikus tanulás, a ritka szótárak tanulása, a genetikai algoritmusok, a szabályalapú gépi tanulás és a tanuló osztályozórendszerek. Általánosságban fogalmazva: ezek az algoritmusok generatívak, és lehetővé teszik, hogy egy gép egy tanuló adathalmaz segítségével tanuljon, hogy új, addig nem látott adatokkal tudjon

dolgozni. Az elképzelés az, hogy a tanulási folyamat révén az algoritmus képes egy olyan *kiszámított műveletet* létrehozni, amely lehetővé teszi az újonnan bemutatott adatokhoz kapcsolódó előrejelzést vagy mintaillesztést.⁸

Most ismét nézőpontot váltok, hogy ismertebb példák segítségével nagyobb gondolati ívet vegyek a gépi tanulási technikák szélesebb körű alkalmazásáról. Röviden bemutatom a mély gépi tanulási algoritmusokat, különösen azokat, amelyek konvolúciós neurális hálózatokat (*convolutional neural network*, CNN) használnak. Azért összpontosítok ezekre, mert a CNN-eket a természetes nyelvi feldolgozásban és a kép- és videófelismerésben is alkalmazzák, így a digitális humán tudományok projektjeivel kapcsolatban is alkalmazhatók.⁹ A szélesebb közönség egyre inkább megismeri az úgynevezett mély konvolúciós hálózatok generatív képességeit, például a DeepDreamet, mivel a populáris kultúrában vonzóvá vált a látszólag hallucinált, álomszerűnek tűnő képek generálásával. A DeepDream a Google által létrehozott rendszer, amely CNN-t használ arra, hogy algoritmikus pareidolia segítségével mintákat találjon és támogasson a képekben. A szoftvert arcok és egyéb minták képi felismerésére tervezték, azért, hogy automatikusan osztályozza azokat. A hálózat azonban a betanítás után fordítva is futtatható: utasítani lehet arra, hogy az eredeti képet kissé módosítsa úgy, hogy egy adott *kiszámított művelet* (például az arcok vagy bizonyos állatok képe) visszakerüljön az eredeti képbe.

A CNN-ek az állati vizuális érzékelés modellezésével dolgoznak, ezért alkalmazhatók a vizuális felismerés automatizálására. Az egyedi szoftveres érzékelő neuronok több rétegeből épülnek fel (úgynevezett receptív mezőkből, amelyek e neuronok csoportjaiból állnak). A „konvolúció” kifejezés eredetileg két függvényen végzett matematikai művelet leírására szolgál, amely egy harmadik függvényt eredményez. Az új függvény az egyik eredeti függvény módosított változata. A képelemzések során a konvolúciós szűrő számos fontos algoritmusban játszik fajsúlyos szerepet; például az élek felismerésében, a kép élesítésében és az elmosódás hozzáadásában. A konvolúciós neurális hálózatok a konvolúciós függvények többlépcsős kapcsolásával nagy felbontású és részletes képelemzést hoznak létre. Használhatók szöveges bemenetek azonosítására és elemzésére is, illetve képesek felismerni a különböző betűformákat, betűtípusokat, karaktereket stb., és ezek alapján vizualizációkat generálni. A digitális humántudományi projektben való felhasználásuknak egyik példája Patricia Fumerton (Kaliforniai Egyetem, Santa Barbara, UCSB) munkája az English Broadside Ballad Archive-ban.¹⁰ Itt a CNN-eket faképek és szövegek automatikus feldolgozására és osztályozására használják. A gépi tanulás alkalmazása egy mintatárat hoz létre a hasonló farostok megtalálására, egyúttal megnyitja a farostok közötti új kapcsolatok felfedezésének lehetőségét is.

Egy másik példát kínál e rendszerekre az ismétlődő neurális hálózat (*recurrent neural network*, RNN), vagyis a mesterséges neurális hálózatok olyan osztálya, amelyben a hálózatok közötti kapcsolatok irányított ciklust alkotnak. Szemben az előre csatolt neurális hálózatokkal, az RNN-ek belső memóriájukat használhatják a bemenetek tetszőleges sorozatainak feldolgozására. Ez teszi őket alkalmassá olyan feladatok elvégzésére, mint a szegmentálatlan összekapcsolt kézírásfelismerés vagy a beszédfelismerés. Az egyik ilyen RNN, a hosszú rövidtávú memória (*long short-term memory*, LSTM) egy olyan ismétlődő hálózat, amely kiválóan képes hosszú vagy rövid ideig tartó értékekre emlékezni. Valójában éppen ezért használja őket a Google az okostelefonok beszédfelismeréséhez, az Allo nevű okos asszisztenshez és a Google Translate-hez. Az Apple szintén használja az LSTM gépi tanulást az iPhone „Quicktype” funkciójához és a Sirihez, amint az Amazon is alkalmazza az LSTM-et az Amazon Alexa számára. Ezek a gépi tanulással támogatott rendszerek maguktól értetődőbbek a mindennapi életben, én magam pedig remélem, hogy a számítástechnika bonyolultnak és ezoterikusnak tűnő paradigmái és a telefonok, a számítógépek és a technológiák mindennapi használata során a közvetítés és a tapasztalat elemeként növekvő jelentőségük közötti kapcsolatok bemutatásával beláthatjuk, hogy mennyire sürgős a médiaelméleti munka ezen a területen.

Ez a rövid értekezés csupán nagyon felületes bevezetést nyújthat ezekbe a kérdésekbe és az általam e területet feltáró elméleti munkába. A gépi tanulással egy új művelési paradigma körvonalazódik, amely a következő

8 A digitális bölcsészettudományok számára fontos terület a témamodellezés, amely jó példát kínál a konstitutív (*számító művelet*) és az operatív (*kiszámított művelet*) közötti különbségtételre a használat és az alkalmazás során. A témamodellezés diszkriminatív és generatív gépi tanulási formái egyaránt jól értelmezhetők e fogalmak segítségével.

9 Számos olyan nyílt forráskódú projekt is rendelkezésre áll, amely készen is használható: Caffe, DeepLearning4j, DeepLearning-hs, neon, TensorFlow, Theano és Torch.

10 English Broadside Ballad Archive: <http://ebba.english.ucsb.edu>.

évtizedben valószínűleg nagy hatást gyakorol a nyilvánosság által használt médiarendszerekre. Ahogy e tanulmányban felvázoltam, ez összetett technikai terület, mégis sürgősen foglalkozni kell a kérdéssel. Igyekeztem újragondolni a technikai kérdéseket azáltal, hogy Spinoza *Natura naturans* és *Natura naturata* fogalmain keresztül újrafogalmaztam azok főbb körvonalait, és hogy kidolgoztam a *számító művelet* és a *kiszámított művelet* analóg fogalmait. Ezek előtérbe állítják azokat az előnyöket, amelyekért érdemes a számítások generatív és mintakövetési képességei szempontjából gondolkodnunk a közelmúlt technikai munkáiban. E tanulmány csak nagy vonalakban és néhány példa segítségével mutatta be ezt az új és gyorsan fejlődő területet, és még sok az elvégzésre váró feladat. Ha még csak most kezdtünk is el kérdéseket feltenni az algoritmusok és a szoftverek médiumspecifikusságáról, akkor is egyértelmű, hogy a gépi tanulás hozzáadott komplexitása arra kötelezi a médiaelméletet, hogy a gépi számítás (*computation*) új formáival foglalkozzon, amelyeknek az emberi figyelemre, az olvasásra, a tanulásra és a széles körben vett eszközhasználatra nézve fontos következményeik vannak.

Feczku Viktor (Debreceni Egyetem Humán Tudományok Doktori Iskola) fordítása

Irodalom

- Alpaydin, Ethem (2016): *Machine Learning: The New AI*. Cambridge & Massachusetts: MIT Press.
- Berry, David M. (2011): *The Philosophy of Software*. Basingstoke: Palgrave Macmillan.
- Berry, David M. (2014): *Critical Theory and the Digital*. New York: Bloomsbury.
- Berry, David M. & Anders Fagerjord (2017): *Digital Humanities: Knowledge and Critique in a Digital Age*. Cambridge: Polity Press, <https://doi.org/10.31400/dh-hun.2019.2.391>
- Bughin, Jacques, Eric Hazan, Sree Ramaswamy, Michael Chui, Tera Allas, Peter Dahlström, Nicolaus Henke & Monica Trench (2017): *Artificial Intelligence: The Next Digital Frontier?* vitairat, McKinsey.
- Burrell, Jenna (2016): How the Machine ‘Thinks:’ Understanding Opacity in Machine Learning Algorithms. *Big Data & Society*, January–June 2016, pp. 1–12, <https://dx.doi.org/10.2139/ssrn.2660674>
- Carr, Nicholas (2016): *The Glass Cage: Who Needs Humans Anyway*. London: Vintage.
- Chun, Wendy H. K. (2006): *Control and Freedom: Power and Paranoia in the Age of Fiber Optics*. Cambridge: MIT Press, <https://doi.org/10.7551/mitpress/2150.001.0001>
- Chun, Wendy H. K. (2005): On Software: Or the Persistence of Visual Knowledge. *Grey Room*, No. 18, pp. 26–51, <https://doi.org/10.1162/1526381043320741>
- Chun, Wendy H. K. (2011): *Programmed Visions: Software and Memory*. Cambridge: MIT Press, <https://doi.org/10.7551/mitpress/9780262015424.001.0001>
- Demasio, Antonio, R. (2003): *Looking for Spinoza: Joy, Sorrow, and the Feeling Brain*. London: William Heinemann.
- Domingos, Pedro (2012): A few useful things to know about machine learning. *Communications of the ACM*, vol. 55, no. 10, pp. 78–87, <https://doi.org/10.1145/2347736.2347755>
- Domingos, Pedro (2017): *The Master Algorithm: How the Quest for the Ultimate Learning Machine Will Remake Our World*. London: Penguin.
- Donnelly, Peter (2017): Why rage against the machines when we could be friends? *The Guardian*, April 30, <https://www.theguardian.com/commentisfree/2017/apr/29/artificial-intelligence-workplace-future-friends>.
- Economist (2017): Machine-learning promises to shake up large swathes of finance. *The Economist*, May 25, <https://www.economist.com/news/finance-and-economics/21722685-fields-trading-credit-assessment-fraud-prevention-machine-learning>.
- Ford, Martin (2016): *The Rise of the Robots: Technology and the Threat of Mass Unemployment*. Oneworld Publications.
- Fuller, Matthew (2008): *Software Studies\A Lexicon*. London: MIT Press, <https://doi.org/10.7551/mitpress/9780262062749.001.0001>

- Hadot, Pierre (1995): *Philosophy as a Way of Life: Spiritual Exercises from Socrates to Foucault*. London: Wiley-Blackwell.
- Lewis-Kraus, Gideon (2016): The Great A.I. Awakening. *The New York Times*, December 14, <https://www.nytimes.com/2016/12/14/magazine/the-great-ai-awakening.html>.
- Kelly, Kevin (2017): *The Inevitable: Understanding the 12 Technological Forces That Will Shape Our Future*. London: Penguin.
- Kitchin, Rob (2016): From a Single Line of Code to an Entire City: Reframing the Conceptual Terrain of Code/Space. In: Kitchin, Rob & Perng, Sung-Yueh (eds.): *Code and the City*, pp. 15–26. London: Routledge, <http://dx.doi.org/10.2139/ssrn.2520435>
- Manovich, Lev (2001): *The Language of New Media*. London: MIT Press.
- Marino, Mark C. (2006): Critical Code Studies. *Electronic Book Review*, December 4, <http://www.electronic-bookreview.com/thread/electropoetics/codology>.
- McAfee, Andrew & Brynjolfsson, Erik (2017): *Machine, Platform, Crowd: Harnessing the Digital Revolution*. London: W. W. Norton & Company.
- Mitchell, Tom M. (1997): *Machine Learning*. London: McGraw-Hill.
- Mooney, R. J. (2000): Integrating Abduction and Induction in Machine Learning. In: Peter A. Flach & Antonis C. Kakas (eds.): *Abduction and Induction*, pp. 181–191. New York & London: Kluwer Academic Publishers, https://doi.org/10.1007/978-94-017-0606-3_12
- Nadler, Steven (2001): *Spinoza's Heresy: Immortality and the Jewish Mind*. Oxford: Oxford University Press, <https://doi.org/10.1093/0199247072.001.0001>
- Samuel, Arthur L. (1959): Some Studies in Machine Learning Using the Game of Checkers. *IBM Journal of Research and Development*, vol. 3, no. 3, pp. 210–229, <https://doi.org/10.1147/rd.33.0210>
- Tufekci, Zeynep (2014): The year we get creeped out by the algorithms. *NiemanLab*, December 22, <http://www.niemanlab.org/2014/12/the-year-we-get-creeped-out-by-algorithms/>
- Wardrip-Fruin, Noah (2009): *Expressive Processing: Digital Fictions, Computer Games, and Software Studies*. Cambridge, Massachusetts & London, England MIT Press.