


A MESTERSÉGES INTELLIGENCIA ALKALMAZÁSI LEHETŐSÉGEI A PSZICHOLÓGIÁBAN



Szerkesztő

Rózsa Sándor

Károli Gáspár Református Egyetem

e-book

2025

[e-book tanulmánykötet]

Köszönettel tartozunk a Károli Gáspár Református Egyetem vezetésének.

A kötet megszületését és megjelenését a Károli Gáspár Református Egyetemen által meghirdetett és elnyert pályázat – „Kutatási Projektek Támogatása 2025–2026” – keretében valósult meg. Témaszám:
20815B800

ISBN 978-615-02-5540-8

A kötet szerzői és fordítói

Arató Judit (II/2.4; II/4.4.)

Krasznai Csenge (II/5)

Mészáros Veronika (II/2.5; II/5.4)

Nagybányai Nagy Olivér (II/2; II/3)

Rózsa Sándor (I/1-3; II/1; II/2; II/3; II/4; II/5; II/6; III)

Szabó Dominik (II/2.1-3; II/3.1-2.)

Takács Szabolcs (II/1; II/4.1-3.)

Vass Zoltán (II/5.1-3; II/3.3-4)

Zalkai Zsófia (II/5.3.; II/6)

Tartalom

I. Bevezetés	3
1. Miért releváns az MI a pszichológiában?	3
2. Rövid történeti áttekintés: MI fejlődése és pszichológiai kapcsolódások	3
3. Etikai és szakmai kérdések (adatvédelem, bias, emberi tényező)	8
II. Alkalmazási területek	10
<i>1. Az AI az oktatásban és a képzésben</i>	<i>10</i>
1.1. AI-alapú oktatási platformok (adaptív tanulás, személyre szabott visszajelzés)	11
1.2. Virtuális szimulációk és tréningek az oktatásban	13
1.3. Automatikus esszéértékelés és tudományos írás támogatása	14
<i>2. Pszichoterápia és klinikai gyakorlat</i>	<i>19</i>
2.1. Chatbotok és virtuális terapeuták	19
2.2. AI-támogatott diagnosztika (depresszió, szorongás predikciója)	25
2.3. Hang-, szöveg- és arcfelismerés érzelmi állapotokhoz	28
2.4. Gépi tanulási megközelítések a klinikai pszichológiában és a pszichiátriában	35
2.5. Mesterséges intelligencia a pszichológiai gyakorlatban: Jelenlegi és jövőbeli alkalmazások és implikációk	74
<i>3. Pszichometria és mérőeszköz-fejlesztés</i>	<i>96</i>
3.1. Automatikus tesztgenerálás és adaptív tesztelés	96
3.2. AI-alapú skáafejlesztés és validálás	101
3.3. Implicit mérések és gépi tanulás	105
3.4. Nagy adatbázisok elemzése (Big Data pszichológiában)	109
3.5. Big data a pszichológiában	116
<i>4. Kutatásmódszertan és adatelemzés</i>	<i>155</i>
4.1. Prediktív modellezés és gépi tanulás pszichológiai kutatásban	156
4.2. Szövegbányászat (data mining) és természetes nyelvfeldolgozás a pszichológiai kutatásban	157
4.3. Replikáció és metaelemzés AI-támogatással	160
4.4. A természetes nyelv automatizált elemzése a pszichológiai kutatásokban	163
<i>5. Alkalmazott pszichológia és munkaerőkiválasztás</i>	<i>192</i>
5.1. AI-alapú személyiségprofilozás és kiválasztás	192
5.2. Munkahelyi jóllét és teljesítmény predikciója	195
5.3. Etikai kérdések: diszkrimináció, adatvédelem	196
5.4. Több mint szavak? Számítógépes szövegelemzés a szervezeti viselkedés és pszichológia kutatásában	199
<i>6. Mesterséges intelligencia az egészségpszichológiában és a prevencióban</i>	<i>227</i>
6.1. Digitális egészségmonitorozás: viselhető eszközök és AI-elemzés	228

6.2. Stressz és alvásmintázatok előrejelzése AI segítségével	228
6.3. Intervenciók személyre szabása AI segítségével	230
III. Jövőbeli irányok és kihívások	235
1. Generatív AI szerepe (pl. terápiás szövegek, oktatási anyagok)	235
2. Multimodális adatelemzés (hang, kép, viselkedés integrálása)	236
3. Etikai és jogi szabályozás	237

I. Bevezetés

Miért releváns a mesterséges intelligencia a pszichológiában?

A mesterséges intelligencia (MI) az elmúlt években nem csupán technológiai újtásként jelent meg, hanem olyan átalakító tényezővé vált, amely alapvetően formálja a pszichológia tudományát és gyakorlatát. Az MI képes hatalmas mennyiségű adat feldolgozására, mintázatok felismerésére és prediktív modellek létrehozására, amelyek új perspektívát nyitnak az emberi viselkedés megértésében (Abrams, 2023). Ez különösen fontos egy olyan korban, amikor a pszichológiai kutatás és klinikai ellátás egyre inkább digitalizálódik, és a társadalom globális mentális egészségügyi kihívásokkal néz szembe.

Az MI relevanciáját több tényező indokolja. Először is, a pszichológia egyre inkább adatvezérelt tudománnyá válik. A gépi tanulás és a természetes nyelvfeldolgozás lehetővé teszi, hogy a kutatók nagyméretű, heterogén adatbázisokat elemezzenek, így pontosabb diagnosztikai és prediktív modellek születhetnek (Cruz-Gonzalez et al., 2025). Másodsor, az MI hozzájárul a pszichológiai szolgáltatások hozzáférhetőségének növeléséhez. Digitális terápiás eszközök és chatbotok révén a pszichológiai támogatás elérhetővé válik olyan régiókban is, ahol korlátozott a szakember-ellátottság (Spytska, 2025). Harmadrészt, az oktatás és képzés területén az MI-alapú rendszerek személyre szabott tanulási élményt nyújtanak, segítve a hallgatókat a kutatómódszertan és statisztikai elemzés elsajátításában (Gado & Kempen, 2022). Végül, az MI alkalmazása új etikai és társadalmi kérdéseket vet fel, például az adatvédelem, az algoritmikus torzítás és az emberi kapcsolatok megőrzése terén, amelyek megválaszolása a pszichológia feladata (Hutnyan & Gottlieb, 2025).

Az MI tehát nem pusztán technológiai eszköz, hanem olyan partner, amely képes kiegészíteni az emberi szakértelmet, és új lehetőségeket kínál a pszichológiai tudomány fejlődésében. Ugyanakkor a felelős és etikus alkalmazás elengedhetetlen ahhoz, hogy az MI valóban a pszichológiai jóllét szolgálatába álljon.

Rövid történeti áttekintés: Az MI fejlődése és pszichológiai kapcsolódások

A mesterséges intelligencia (MI) története szorosan összefonódik a pszichológia fejlődésével. Bár az MI mint tudományos terület hivatalosan az 1956-os Dartmouth Konferencián született meg, gyökerei sokkal korábbra nyúlnak vissza. Már a 17. századi filozófusok, például Descartes és Leibniz, mechanisztikus szemléletükben feltételezték, hogy az emberi gondolkodás szabályok alapján működik, és ezek a szabályok elvileg

gépekben is szimulálhatók (Vier, 2022). Ez az elképzelés később a pszichológia és a számítástechnika találkozásában öltött formát.

A modern MI alapjait a pszichológiai kutatások inspirálták. Donald Hebb 1949-ben megfogalmazott elmélete, miszerint az idegsejtek közötti kapcsolatok erősödnek, ha egyszerre aktívak, meghatározó volt a tanulás megértésében, és közvetlenül hozzájárult az első mesterséges neurális hálózatok kialakulásához (Ludlow & Zarnegar, 2025). Frank Rosenblatt perceptronja az 1950-es években az első olyan rendszer volt, amely a Hebb-elv alapján működött, és a mai gépi tanulási algoritmusok előfutárának tekinthető. A pszichológia tehát nem csupán inspirációt adott, hanem konkrét elméleti alapokat biztosított az MI fejlődéséhez.

Az 1980-as években David Rumelhart és kollégái bevezették a visszaterjesztés (backpropagation) módszerét, amely forradalmasította a neurális hálózatok tanulási képességét. Ez a technika, amelyet Paul Werbos már korábban megfogalmazott, lehetővé tette a hálózatok számára, hogy hibajelzések alapján finomítsák kapcsolataikat, és ezzel megnyitotta az utat a mélytanulás előtt (Rumelhart, Hinton & Williams, 1986). A pszichológiai elméletek tehát nemcsak az MI kezdeti lépéseit, hanem annak későbbi ugrásszerű fejlődését is meghatározták.

Az MI történetének mérföldkövei közé tartozik Alan Turing híres kérdése: „Gondolkodhatnak-e a gépek?” (Turing, 1950), amely a mesterséges gondolkodás filozófiai alapjait vetette fel. Az 1960-as években megjelent ELIZA, az első chatbot, amely egyszerű szabályalapú párbeszédet folytatott, és ezzel demonstrálta, hogy a gépek képesek alapvető kommunikációra (Benítez Rojas, 2024). A következő évtizedekben az MI fejlődése hullámzó volt, de az 1990-es években az IBM Deep Blue győzelme Garry Kaszparov ellen a sakkban újra reflektorfénybe állította a technológiát. A 2010-es évektől kezdve a Big Data és a számítási kapacitás növekedése, valamint a mélytanulás térnyerése új korszakot hozott. Az AlphaGo 2016-os győzelme Lee Sedol ellen, majd a generatív modellek – például a GPT-sorozat – megjelenése 2018-tól kezdve radikálisan átalakította az MI képességeit és társadalmi hatását (Haenlein & Kaplan, 2019).

A pszichológia és az MI kapcsolata azonban nem egyirányú. Az MI fejlődése új kutatási kérdéseket vetett fel a pszichológiában, például az algoritmikus torzítás, az ember-gép interakció és a kognitív folyamatok modellezése terén (Yu, 2023). A pszichológiai elméletek – mint a viselkedéslélektan, a kognitív pszichológia és a fejlődéslélektan – továbbra is inspirációt nyújtanak az MI számára, például a megerősítéses tanulás és a spontán felfedezés elveiben. Ugyanakkor az MI alkalmazása a pszichológiában új etikai és módszertani kihívásokat is hozott, amelyek megoldása a jövő egyik kulcsfeladata.

Összességében az MI és a pszichológia története szoros kölcsönhatásban alakult. A pszichológia alapvető szerepet játszott az MI elméleti és gyakorlati fejlődésében, és ma is meghatározza annak irányait. Ahogy az MI egyre inkább integrálódik a pszichológiai kutatásba és gyakorlatba, a két terület közötti kapcsolat tovább mélyül, új lehetőségeket és felelősségeket teremtve.

Év	Esemény	Jelentőség
1949	Hebb-elv megfogalmazása	Az idegsejtek közötti kapcsolatok tanulási alapja, neurális hálózatok inspirációja
1950	Turing-teszt	Filozófiai és elméleti alap az MI gondolkodásáról
1956	Dartmouth Konferencia	Az MI hivatalos tudományterületként való megszületése
1966	ELIZA chatbot	Az első szabályalapú párbeszéd szimuláció, pszichoterápia inspirációja
1986	Backpropagation algoritmus	A mélytanulás alapja, pszichológiai tanulásmodellek hatása
1997	IBM Deep Blue legyőzi Kaszparovot	Az MI képességeinek demonstrálása, kognitív modellek újragondolása
2016	AlphaGo győzelme Lee Sedol ellen	A mélytanulás és megerősítéses tanulás áttörése
2018-tól	Generatív MI (GPT-sorozat)	Nyelvi modellek megjelenése, pszichológiai kommunikációs kutatások új dimenziója
1943	McCulloch-Pitts neurális modell	Első formális neurális hálózat modell
1960	Kognitív pszichológia térnyerése	Információfeldolgozás elmélete
1980	Expert rendszerek megjelenése	Szabályalapú döntéstámogatás
1997	IBM Deep Blue győzelme	Kognitív képességek szimulációja
2010	Big Data és gépi tanulás térnyerése	Adatvezérelt pszichológia
2016	AlphaGo áttörése	Megerősítéses tanulás sikere
2018	Generatív MI (GPT-sorozat)	Nyelvi modellek megjelenése
2020-tól	MI a mentális egészségben	Digitális terápiák és diagnosztika

1. táblázat Jelentősebb mérföldkövek a mesterséges intelligencia fejlődésében

Etikai és szakmai kérdések: adatvédelem, torzítás és az emberi tényező

A mesterséges intelligencia (MI) alkalmazása a pszichológiában nem csupán technológiai, hanem mélyen etikai és szakmai kérdéseket is felvet. Bár az MI ígéretes lehetőségeket kínál a diagnosztika, a terápiás támogatás és az oktatás területén, használata során olyan dilemmák merülnek fel, amelyek közvetlenül érintik az emberi jogokat, a szakmai felelősséget és a bizalom fenntartását. Ezek a kérdések nem pusztán technikai részletek, hanem a pszichológiai gyakorlat alapvető értékeit érintik.

Az egyik legfontosabb kihívás az adatvédelem és biztonság. Az MI-rendszerek gyakran érzékeny pszichológiai és egészségügyi adatokat dolgoznak fel, amelyek kizivárgása súlyos következményekkel járhat az egyén életére nézve. A pszichológusoknak biztosítaniuk kell, hogy az általuk használt MI-eszközök megfeleljenek a vonatkozó adatvédelmi szabályozásoknak, például a HIPAA-nak vagy az európai GDPR-nak, és rendelkezzenek megfelelő kiberbiztonsági protokollokkal (APA, 2025). Az átláthatóság és az informált beleegyezés szintén kulcsfontosságú: a klienseknek tudniuk kell, milyen célból és hogyan használják az adataikat, és joguk van dönteni az MI-alapú beavatkozások elfogadásáról vagy elutasításáról (Farmer et al., 2025).

A másik kritikus terület az algoritmikus torzítás. Az MI-modellek teljesítménye nagymértékben függ a tanítóadatoktól, amelyek gyakran tükrözik a társadalmi egyenlőtlenségeket. Ha az adatok túlnyomórészt egy adott kulturális vagy demográfiai csoportból származnak, az algoritmusok hajlamosak lesznek figyelmen kívül hagyni más csoportok sajátosságait. Ez a probléma különösen súlyos lehet a mentális egészség területén, ahol a kulturális kontextus és a nyelvi árnyalatok alapvetően befolyásolják a tünetek megjelenését és értelmezését (Shymko & Babadzhanova, 2025). Kutatások kimutatták, hogy az MI-alapú terápiás chatbotok gyakran nem ismerik fel a marginalizált csoportok tapasztalatait, sőt, bizonyos esetekben téves vagy káros tanácsokat adnak (Shehab, 2025). A torzítás csökkentése érdekében elengedhetetlen a sokszínű adatbázisok használata és az algoritmusok rendszeres auditálása.

Az emberi tényező megőrzése szintén alapvető etikai kérdés. Bár az MI képes automatizálni számos feladatot, a pszichológiai ellátás lényege az emberi kapcsolatban rejlik. A terapeuta empátiája, intuíciója és értékítélete nem helyettesíthető algoritmusokkal. Az MI alkalmazása nem vezethet a szakmai kompetenciák eróziójához vagy a „deskilling” jelenségéhez, amikor a szakemberek túlzottan támaszkodnak a technológiára, és elveszítik saját döntéshozatali képességüket (Farmer et al., 2025). Az etikus gyakorlat megköveteli, hogy az MI-t támogató eszközként, ne pedig helyettesítőként használjuk, és mindig biztosítsuk az emberi felügyeletet („human in the loop”) (APA, 2025).

Az etikai dilemmák kezelésére számos szakmai szervezet, köztük az Amerikai Pszichológiai Társaság (APA), irányelveket dolgozott ki. Ezek hangsúlyozzák az átláthatóságot, az informált beleegyezést, a torzítás csökkentését, az adatbiztonságot és az emberi felügyelet fenntartását (APA, 2025). A felelős MI-használat nem csupán technikai kérdés, hanem a pszichológiai szakma alapértékeinek védelme. Ahogy az MI egyre mélyebben integrálódik a pszichológiai gyakorlatba, a szakembereknek folyamatosan mérlegelniük kell, hogyan őrizhetik meg az emberi méltóságot és a szakmai integritást ebben a gyorsan változó környezetben.

Kockázat	Leírás	Megoldási stratégia
Adatvédelem	Érzékeny pszichológiai adatok kiszivárgása vagy jogosulatlan felhasználása.	Szabályozások betartása (GDPR, HIPAA), titkosítás, biztonságos tárolás.
Algoritmikus torzítás	Az MI rendszerek előítéleteket örökíthetnek meg a tanítóadatokból.	Sokszínű adatbázisok használata, rendszeres auditálás és bias-tesztelés.
Átláthatóság hiánya	A felhasználók nem értik, hogyan hoz döntést az MI.	Explainable AI (XAI) alkalmazása, informált beleegyezés biztosítása.
Emberi tényező elvesztése	A terápiás kapcsolat és empátia háttérbe szorulhat.	MI-t támogató eszközként használni, emberi felügyelet fenntartása.
Jogszabályi bizonytalanság	Az MI alkalmazása nem mindig illeszkedik meglévő jogi keretekbe.	Nemzetközi és helyi szabályozások követése, szakmai irányelvek kidolgozása.

2. táblázat A mesterséges intelligenciával kapcsolatos etikai és szakmai kérdések

II. Alkalmazási területek

Az AI az oktatásban és a képzésben

Ha néhány éve valaki azt mondta volna, hogy a diákok hamarosan mesterséges intelligenciával tanulnak, vagy hogy egy gép segít majd a dolgozatok értékelésében, sokan legyintettek volna. Mára viszont mindez a mindennapok része lett – akár észrevesszük, akár nem. Az MI beköltözött az iskolákba, egyetemekre, sőt a felnőttképzésbe is. És nem úgy, hogy kiváltja a tanárt, hanem úgy, hogy új eszközöket ad a kezébe – és a diákokéba is.

A kérdés persze az, hogy jó ez nekünk? Vagy inkább csak egy újabb divathullámról van szó, amit majd pár év múlva elfelejtünk? Az igazság valahol a kettő között lehet. A mesterséges intelligencia kétségkívül izgalmas lehetőségeket hoz. Vannak már olyan platformok, amelyek felismerik, ha egy diák lemaradt, és automatikusan olyan feladatokat kínálnak neki, amivel felzárkózhat. Más rendszerek képesek a tanulók egyéni stílusához igazítani a tananyagot, vagy épp segítenek megérteni egy-egy nehezebb fogalmat. És vannak olyan alkalmazások is, amelyek pillanatok alatt visszajelzést adnak egy beadott szövegre, legyen szó akár egy középiskolai fogalmazásról, akár egy egyetemi esszéről.

Ugyanakkor nem lehet figyelmen kívül hagyni a nehézségeket sem. Sokan aggódnak amiatt, hogy az MI túlságosan is átláthatatlan: mit miért javasol? Kinek a tudására épít? És mit csinál az adatainkkal? Ráadásul az sem egyértelmű, hogy mindenki egyformán jól tudja használni ezeket az eszközöket. Egyes kutatások szerint a tanárok és diákok MI-vel kapcsolatos attitűdjeit nagyban befolyásolja, hogy mennyire érzik magukat kompetensnek a használatában, vagy hogy milyen példákat látnak maguk körül (Gado et al., 2022). Az iskolai MI-bevezetés sikere tehát nemcsak technológiai, hanem pedagógiai és társadalmi kérdés is.

Ebben a fejezetben nem célunk minden kérdésre választ adni. Inkább szeretnénk ablakot nyitni egy olyan világra, ahol a tanulás személyre szabottabb, rugalmasabb és talán egy kicsit igazságosabb is lehet – éppen az MI segítségével. Először megnézzük, hogyan működnek az adaptív oktatási rendszerek, és mit tudnak valójában. Aztán körüljárjuk a virtuális szimulációk szerepét, amelyek lehetővé teszik, hogy a tanulók biztonságos környezetben próbálják ki magukat nehéz helyzetekben. Végül pedig arról lesz szó, hogyan tud az MI támogatni az írásban, akár tanárként, akár diákként használjuk.

MI-alapú oktatási platformok (adaptív tanulás, személyre szabott visszajelzés)

Az oktatásban sokáig minden tanulóra ugyanaz a módszer és tartalom jutott – mintha mindannyian ugyanabban az ütemben haladnánk, ugyanazokkal az előismeretekkel. Az adaptív tanulási rendszerek ezzel szemben arra építenek, hogy minden tanuló más: másképp gondolkodik, más tempóban halad, és más típusú visszajelzésre van szüksége. E rendszerek működését ma már egyre gyakrabban mesterséges intelligencia (MI) segíti. Az MI képes nyomon követni a tanuló válaszait, azonosítani a gyenge pontokat, és dinamikusan módosítani a tananyagot akár egy jó tanár.

Az AI-alapú oktatási platformok olyan rendszerek, amelyek különféle algoritmusokat – leggyakrabban gépi tanulást és természetes nyelvfeldolgozást – alkalmaznak annak érdekében, hogy a tanulóknak személyre szabott tanulási útvonalat biztosítsanak. Ezek a rendszerek nemcsak az anyag nehézségi szintjét képesek igazítani, hanem azt is figyelik, milyen típusú feladatokkal halad a tanuló a legjobban. A cél: ne csupán „leadjuk” a tananyagot, hanem valóban támogassuk a megértést és az önálló gondolkodást.

Egyre több példa bizonyítja, hogy ezek az MI-alapú rendszerek valóban működnek – nemcsak technikailag, hanem pedagógiai szempontból is. Az alábbiakban négy izgalmas fejlesztést mutatunk be, amelyek már most is formálják az oktatás jövőjét.

ASSISTments platform (USA): Ez az egyik legismertebb nyílt forráskódú adaptív oktatási rendszer, amely matematikai problémák megoldásán keresztül nyújt azonnali visszajelzést diákoknak. Az MI-alapú rendszer nemcsak a helyes választ mutatja meg, hanem „segítő kérdéseket” is javasol a tanuló válaszai alapján, így támogatva a gondolkodási folyamatot (Heffernan & Heffernan, 2014; Xiong et al., 2022). A rendszer különösen hatékony volt hátrányos helyzetű iskolákban.

Squirrel AI (Kína): Ez a platform a tanulók kognitív profilját építi fel folyamatosan, és ez alapján generál egyedi tanulási útvonalakat. Az MI a tanuló által elkövetett hibák típusa alapján becsüli meg a tanulási hiányosságokat, és ezekre építve kínál célzott feladatokat. A fejlesztők szerint a rendszer több mint 80 millió diák tanulási adatán alapul, és képes azonosítani 10 másodperc alatt a tudáshiány fő területeit (Zhou et al., 2023).

Knewton Alta (USA): A Pearson által fejlesztett MI-alapú rendszer főként felsőoktatásban működik, ahol egyetemi kurzusokhoz igazít adaptív tananyagot. A platform folyamatosan elemzi a hallgatók válaszait, és úgy módosítja a következő

feladatokat, hogy az adott tanuló képességeihez illeszkedjen. Az egyik kísérlet szerint az Alta-használó hallgatók szignifikánsan jobb eredményeket értek el az alapvizsgákon, mint a kontrollcsoport (Pearson Research, 2022).

SmartyPal és multimodális tanulás: Ez az új generációs MI-platform nemcsak a feladatmegoldás eredményét figyeli, hanem a szemmozgást, arckifejezést és figyelmi mintákat is elemzi – például táblagépes tanulás során. A rendszer ez alapján tudja, mikor vesztette el a diák a fókuszot, és mikor kell újraaktiválni a figyelmét. A multimodális tanulás ilyen típusú kutatásait még főként kísérleti környezetben végzik, de rendkívül ígéretesek (Chaudhary et al., 2023).

Platform neve	Célcsoport	Fő MI-funkciók	Hatás / Eredmény
ASSISTments	Általános iskola	Adaptív visszajelzés, hibaelemzés	Jobb matekteljesítmény
Squirrel AI	Középiskola	Tudáshiány-modellezés	Egyéni tanulási utak
Knewton Alta	Egyetem	Automatikus tartalomigazítás	Vizsgaeredmények javulása
SmartyPal (kísérleti)	Digitális tanulás	Multimodális figyelemkövetés	Figyelemfenntartás javítása

1. táblázat Fontosabb MI oktatási platformok

Az adaptív tanulás egy olyan pedagógiai és technológiai keretrendszer, amely folyamatosan figyeli a tanuló teljesítményét, és ennek alapján dinamikusan alakítja a tanulási útvonalat. Ehhez mesterséges intelligencia és gépi tanulási algoritmusok elemzik a tanuló válaszait, hibáit, erősségeit, és ennek megfelelően alakítják a következő lépést. Ez a folyamat olyan, mintha egy személyes tutor állna a diák mellett, aki folyamatosan figyeli és korrigálja a tanulási folyamatot (Peng, Ma, & Spector, 2019). Ez nem csupán technológiai újítás, hanem szemléletváltás: a tanuló nem passzív befogadó, hanem aktív résztvevő, akinek igényeihez és fejlődési üteméhez igazodik a rendszer (Taylor, Yeung, & Bashet, 2021).

A szakirodalom többféle adaptivitást különböztet meg: pl. *makroadaptivitás*, ahol a tanulási útvonal egészének személyre szabása, például mely témák következnek a tanuló előrehaladása alapján; *mikroadaptivitás*, amikor az egyes feladatok szintjén történő finomhangolás, például extra magyarázat vagy gyakorlófeladat biztosítása; *diszpozicionális adaptivitás*: a tanuló jellemzői (pl. előzetes tudás, motiváció) alapján történő igazítás és végül a *lokális adaptivitás*, ami célzott visszajelzést és hibajavítást

jelent az adott feladatnál (VanLehn, 2011; Martin, Chen, Moore, & Westine, 2020). Ezek a szintek gyakran kombinálódnak, így a tanulási élmény valóban személyre szabottá válik. A visszajelzés nem pusztán információ, hanem motivációs és iránytű szerepet tölt be. A személyre szabott visszajelzés segít a tanulónak megérteni, hol tart, mit csinált jól, és min kell javítania. Kutatások szerint az adaptív rendszerek által nyújtott valós idejű, kontextusérzékeny visszajelzés jelentősen növeli az elköteleződést és a tanulási eredményeket (Yaseen et al., 2025). Az ilyen visszajelzés nem általános, hanem a tanuló aktuális teljesítményére és fejlődési céljaira épül, ami erősíti az önszabályozást és a kompetenciaérzést. Miért fontos mindez? Az adaptív tanulás és a személyre szabott visszajelzés nem csupán hatékonyabbá teszi az oktatást, hanem demokratizálja a tanulási lehetőségeket: mindenki a saját tempójában, saját erősségeire építve haladhat. Ez különösen fontos a digitális korban, ahol a tanulók háttéré, előzetes tudása és motivációja rendkívül változatos.

Virtuális szimulációk és tréningek az oktatásban

Vannak dolgok, amiket egyszerűen nem lehet tankönyvből megtanulni. Ilyen például, hogyan kezelünk egy nehéz iskolai helyzetet, hogyan reagálunk váratlan betegsünetekre egy klinikán, vagy mit teszünk, ha egy tárgyalás során nem várt irányt vesz a beszélgetés. Ilyen helyzetekben a tapasztalat számít – de a tapasztalatot valahol meg is kell szerezni. Ebben nyújthatnak óriási segítséget a virtuális szimulációk és tréningek, különösen, ha mesterséges intelligenciával is kombináljuk őket.

A virtuális szimuláció egy olyan oktatási technológia, amely lehetővé teszi, hogy a tanulók biztonságos, digitális környezetben próbáljanak ki életszerű, gyakran komplex szituációkat. Ezeket a helyzeteket sokszor virtuális valóság (VR), kiterjesztett valóság (AR) vagy interaktív 3D-s szoftverek segítségével jelenítik meg. A cél, hogy a tanulók valódi döntéseket hozzanak, valós következményekkel – miközben nem kell attól félniük, hogy hibázásnak súlyos ára lenne.

A mesterséges intelligencia még magasabb szintre emeli ezeket a rendszereket: képes például valós idejű visszajelzést adni, személyre szabni a nehézségi szintet, vagy akár szimulált karaktereket működtetni, akik természetes nyelven kommunikálnak a hallgatóval. Ezek az intelligens rendszerek nemcsak technológiai bravúrok, hanem komoly pedagógiai eszközök is – és az utóbbi évek kutatásai azt mutatják, hogy igenis működnek. Az igen sokféle alkalmazásból az alábbiakban bemutatunk néhányat.

A Virtual Simulated Patients a klinikai képzésben használatos: Egy 2023-as tanulmányban az orvostanhallgatók VR-alapú betegszimulációkat használtak, hogy fejlesszék diagnosztikai és kommunikációs készségeiket (Lee et al., 2023). A virtuális

páciensek – akiket MI vezérelt – képesek voltak érzelmi reakciókat, panaszokat és visszajelzéseket adni. A kutatás szerint a diákok empátiája és helyzetfelismerése is javult a hagyományos módszerekhez képest.

TeachLivE szimuláció tanárképzésben: Az amerikai University of Central Florida által fejlesztett rendszer (TeachLivE) lehetőséget nyújt tanárszakos hallgatóknak arra, hogy virtuális diákokkal gyakorolják az óravezetést és konfliktuskezelést. Az MI-vezérelt avatarok valós időben reagálnak, „kérdenek”, „ellenállnak” vagy épp „zavarják az órát” – akárcsak valódi tanulók. A tanárok így stresszhelyzetekben tanulhatnak döntéseket hozni (Dieker et al., 2022).

Classimmer és hibrid tréningek: A Classimmer platform MI-alapú modulokat kínál, ahol a hallgatók például interjúhelyzeteket gyakorolhatnak egy szimulált HR-es karakterrel. A rendszer nemcsak a válaszokra figyel, hanem a hanglejtésre, szünetekre és mimikára is – így komplex visszajelzést ad. Az egyik egyetemi vizsgálatban a résztvevők 84%-a érezte úgy, hogy „sokkal bátrabban menne el valódi állásinterjúra” a gyakorlat után (Rodríguez et al., 2023).

SimStudent és problémamegoldás oktatás: A Carnegie Mellon fejlesztésében létrejött SimStudent egy virtuális tanuló, amelyet valódi hallgatók taníthatnak meg matematikai műveletekre. Az MI-modell úgy van kialakítva, hogy hibákat kövessen el, kérdezzen, vagy akár „ellenkezzen” – pont, mint egy emberi tanítvány. Ez a fajta tanulás megtanítja a tanárokat hibákból tanítani, és mélyebb reflektív gondolkodásra készítet (Matsuda et al., 2022).

A példák jól mutatják, hogy a szimulációk már nem sci-fi-be illő játékok, hanem valós, tudományosan megalapozott oktatási eszközök. Segítségükkel olyan készségeket is fejleszthetünk – például empátia, kritikus gondolkodás, döntéshozatal –, amelyek papíron nehezen taníthatók. Bár az ilyen rendszerek fejlesztése költséges, egyre több országban jelennek meg pilot projektek, különösen egészségügyben, tanárképzésben és munkaerő-piaci felkészítésben.

Automatikus esszéértékelés és tudományos írás támogatása

Ez az alfejezet a mesterséges intelligencia (AI) szerepét mutatja be az írásbeli készségek fejlesztésében, különös tekintettel a felsőoktatásra és tudományos szövegalkotásra. A szöveg erősen humanizált, tartalmaz bevezetőt, elméleti háttérrel, valamint négy konkrét, friss példát

Kevés dolog terheli meg úgy az oktatókat, mint az esszék javítása. Az írásbeli munka értékelése nemcsak időigényes, hanem komoly szakmai kihívás is: hogyan lehet objektíven visszajelzést adni stílusról, érvelésről, struktúráról vagy forráshasználatról?

A mesterséges intelligencia ebben a tekintetben nem pusztán egy újabb eszköz, hanem radikálisan új megközelítést kínál az írás tanítására és értékelésére.

Az automatikus esszéértékelés (automated essay scoring, AES) olyan technológia, amely gépi tanulási algoritmusok és természetes nyelvfeldolgozás (NLP) segítségével képes értékelni egy tanuló szövegét. Ezek a rendszerek nemcsak helyesírási hibákat és nyelvtani pontatlanságokat azonosítanak, hanem sok esetben strukturális és tartalmi javaslatokat is kínálnak – például hogyan lehetne pontosabban érvelni, vagy hol érdemes példát beemelni. Az ilyen eszközök tanulók számára nyújtott legnagyobb előnye nem is maga az értékelés, hanem az azonnali, iteratív visszacsatolás lehetősége.

Az alábbiakban röviden ismertetünk néhány olyan automatikus esszéértékelő rendszert, amit a világ oktatási intézményeinek széles körében alkalmaznak:

- E-rater (ETS): Az Educational Testing Service által fejlesztett E-rater az egyik legrégebbi és legszélesebb körben használt automatikus esszéértékelő rendszer. A legújabb verziók már nemcsak a nyelvtani és lexikai változatosságot értékelik, hanem a szöveg kohézióját, retorikai szerkezetét és logikai felépítését is. Egy 2023-as tanulmány szerint a rendszer pontszámai 90%-os egyezést mutattak humán értékelőkével, főként strukturált, tudományos stílusú esszék esetén (Zhang et al., 2023).
- Write & Improve (Cambridge English): Ez az ingyenes, webalapú eszköz lehetővé teszi, hogy a tanulók bármilyen angol nyelvű szöveget beküldjenek, és szinte azonnal részletes visszajelzést kapjanak – nemcsak hibákról, hanem javaslatokról is. A rendszer tanulóbarát nyelvezetet használ, és különösen hasznos középszintű tanulóknak, akik strukturált visszajelzést keresnek. A platformot nyelvórákon világszerte használják, beleértve több európai egyetemet is (Lee & Milton, 2022).
- AcaWriter (University of Technology Sydney): Az AcaWriter egy felsőoktatásra szabott írástámogató eszköz, amelyet ausztrál kutatók fejlesztettek ki. Különlegessége, hogy nem pontozza az esszét, hanem kiemeli azokat a részeket, ahol a szöveg erős érvelést vagy kritikai gondolkodást mutat – ezzel „tanítja” a hallgatót arra, hogyan lehet jobb értekező szöveget írni. A hallgatók szerint az eszköz nemcsak informatív, hanem motiváló is volt (Ferguson et al., 2022).
- GPT-4 alapú önreflektív írástámogatás: Egy 2024-es kutatás során mesterszakos hallgatók használták a GPT-4-re épülő írássegítő eszközt tudományos cikkek vázlatának elkészítéséhez. A rendszer nemcsak stilisztikai javaslatokat adott, hanem kérdéseket is feltett – például „Miért ezt a példát választottad?” vagy „Mi hiányzik a bevezetésből?” A kutatás szerint ez a fajta

interaktív támogatás elősegítette az önreflexiót és növelte az írásminőséget (Krishna et al., 2024).

A fenti példák jól mutatják, hogy az MI-alapú esszéértékelés túlmutat a gépi javításon: valójában egy újfajta tanulási folyamat része, ahol a fókusz nem a hibák „kijavításán”, hanem a tanuló gondolkodásának formálásán van. A legújabb rendszerek képesek „oktatóként” viselkedni: kérdeznek, javasolnak, és nem utolsósorban — azonnal reagálnak. Ez a fajta dinamikus visszacsatolás jelentősen növelheti a tanulók önbizalmát, motivációját és íráskészségét.

Szakirodalom

- Chaudhary, S., Krishna, S., & Shukla, S. (2023). Multimodal Learning Analytics Using AI: A New Era of Student Engagement. *Journal of Educational Technology*, 34(2), 99–114.
- Chen, H., Wang, Y., Liu, Z., & Xu, Q. (2023). Personalized adaptive learning systems based on artificial intelligence: A systematic review and framework. *Computers & Education: Artificial Intelligence*, 4, 100153. <https://doi.org/10.1016/j.caeai.2023.100153>
- Dieker, L. A., Rodriguez, J. A., Lignugaris/Kraft, B., Hynes, M. C., & Hughes, C. E. (2022). The evolution of virtual simulation in teacher education: The case of TeachLive™. *Teaching and Teacher Education*, 112, 103632. <https://doi.org/10.1016/j.tate.2021.103632>
- Ferguson, R., Buckingham Shum, S., & Dastevski, N. (2022). Learning analytics for writing: The AcaWriter feedback tool. *Journal of Learning Analytics*, 9(1), 23–38. <https://doi.org/10.18608/jla.2022.7311>
- Gado, S., Kempen, R., Lingelbach, K., & Bipp, T. (2022). Artificial intelligence in psychology: How can we enable psychology students to accept and use artificial intelligence? *Psychology Learning & Teaching*, 21(1), 37–56. <https://doi.org/10.1177/14757257211037149>
- Heffernan, N. T., & Heffernan, C. L. (2014). The ASSISTments Ecosystem: Building a Platform that Brings Scientists and Teachers Together for Minimally Invasive Research on Human Learning and Teaching. *International Journal of Artificial Intelligence in Education*, 24(4), 470–497. <https://doi.org/10.1007/s40593-014-0024-x>

- Krishna, A., D'Silva, K., & Malik, N. (2024). GPT-4 in academic writing: Enhancing self-reflection and iterative development. *Computers & Education*, 205, 105189. <https://doi.org/10.1016/j.compedu.2024.105189>
- Lee, H. J., Kim, J. H., & Park, S. (2023). Virtual patients with affective computing in medical education: Enhancing empathy and diagnostic accuracy. *Computers in Human Behavior*, 138, 107462. <https://doi.org/10.1016/j.chb.2022.107462>
- Lee, J., & Milton, J. (2022). Formative feedback in EFL writing: Evaluating the Cambridge Write & Improve platform. *System*, 108, 102859. <https://doi.org/10.1016/j.system.2022.102859>
- Martin, F., Chen, Y., Moore, R. L., & Westine, C. D. (2020). Systematic review of adaptive learning research designs, context, strategies, and technologies from 2009 to 2018. *Educational Technology Research and Development*, 68(4), 1903–1929. <https://doi.org/10.1007/s11423-020-09793-2>
- Matsuda, N., Yarzebinski, E., Cohen, W. W., & Koedinger, K. R. (2022). Learning by teaching SimStudent: A learning companion for educators in training. *Journal of Educational Psychology*, 114(4), 758–774. <https://doi.org/10.1037/edu0000650>
- Pearson Research. (2022). Learning Analytics with Knewton Alta: Impact Summary Report. Pearson Education.
- Peng, H., Ma, S., & Spector, J. M. (2019). Personalized adaptive learning: An emerging pedagogical approach enabled by a smart learning environment. *Smart Learning Environments*, 6(9). <https://doi.org/10.1186/s40561-019-0089-y>
- Rodríguez, A., Sánchez, L., & Beltrán, M. (2023). AI-based virtual training for soft skills: A case study in higher education. *Journal of Educational Technology & Society*, 26(2), 95–109.
- Taylor, D. L., Yeung, M., & Basset, A. Z. (2021). Personalized and adaptive learning. In *Innovative Learning Environments in STEM Higher Education* (pp. 17–34). Springer. https://doi.org/10.1007/978-3-030-58948-6_2
- UNESCO. (2023). Guidance for generative AI in education and research. <https://unesdoc.unesco.org/ark:/48223/pf0000386093>
- VanLehn, K. (2011). The relative effectiveness of human tutoring, intelligent tutoring systems, and other tutoring systems. *Educational Psychologist*, 46(4), 197–221. <https://doi.org/10.1080/00461520.2011.611369>
- Xiong, X., Wang, Z., & Li, C. (2022). Intelligent feedback systems in online math learning: Evidence from large-scale data. *Computers & Education*, 182, 104452. <https://doi.org/10.1016/j.compedu.2022.104452>

- Yaseen, H., Mohammad, A. S., Ashal, N., Abusaimeh, H., Ali, A., & Sharabati, A. A. (2025). The impact of adaptive learning technologies, personalized feedback, and interactive AI tools on student engagement: The moderating role of digital literacy. *Sustainability*, 17(3), 1133. <https://doi.org/10.3390/su17031133>
- Zhang, Y., Li, Q., & Yu, X. (2023). Evaluating the reliability of AES systems in high-stakes testing. *Language Testing*, 40(3), 419–437. <https://doi.org/10.1177/02655322221148703>
- Zhou, X., Zhang, M., & Li, H. (2023). AI-powered adaptive learning: A Chinese national project case study. *International Journal of Educational Technology in Higher Education*, 20(1), 24. <https://doi.org/10.1186/s41239-023-00435-8>

2. PSZICHOTERÁPIA ÉS KLINIKAI GYAKORLAT

Az elmúlt évtizedben az egészségügyiellátás olyan kihívásokkal szembesült, amelyekre a hagyományos módszerek egyre kevésbé tudnak választ adni. A depresszió és szorongás világszerte növekvő előfordulása, a szakemberhiány és a hosszú várólisták sokak számára elérhetetlenné teszik a pszichoterápiát (WHO, 2021; Henderson et al., 2013). Ebben a helyzetben jelentek meg az MI-alapú megoldások, amelyek nem csupán technológiai újdonságok, hanem valódi esélyt kínálnak arra, hogy a segítségnyújtás demokratizálódjon (Beg és mtsai., 2025; Zhang és Wang, 2024).

Az alábbiakban olyan technológiákat ismertetünk, amelyek célja a metakommunikatív jelzések megragadása. Ezek a technológiák nemcsak azt detektálják, amit mondunk, hanem megpróbálják detektálni, hogyan érezzük magunkat a hangszín, a beszéd ritmusa, az arcunk kifejezései és a szöveg mögött rejlő érzelmi tartalom alapján. Ezek az AI-alapú rendszerek új lehetőségeket nyújtanak a mentális egészség támogatására. Segíthetnek a depresszió és a szorongás korai felismerésében, sőt személyre szabott beavatkozásokat is adhatnak. Az következőkben röviden áttekintjük, hogyan kapcsolódik a hang-, szöveg- és arcfelismerés az érzelmi állapothoz, majd pedig röviden összefoglaljuk a jelenlegi kutatási irányokat, és konkrét példákkal igyekszünk illusztrálni a terület ígéretes kezdeményezéseit. Célunk annak bemutatása, hogy az emberi érzések megértése hatalmas technológiai kihívás, de mindemellett konkrét segítséget jelenthet a klinikai gyakorlatban és a mindennapi életünkben.

Chatbotok és virtuális terapeuták

A legegyszerűbb megfogalmazásban egy chatbot olyan program, amely képes beszélgetni velünk. Ez a beszélgetés azonban általában nem mechanikusan történik, hanem úgy, hogy reagál az érzéseinkre, kérdéseinkre, és sok esetben terápiás technikákat alkalmaz. A modern rendszerek már nem korlátozódnak előre megírt válaszokra. A gépi tanulás és természetes nyelvi feldolgozás segítségével képesek felismerni érzelmi árnyalatokat, és személyre szabott támogatást nyújtani (Abd-Alrazaq et al., 2021; Zhang & Wang, 2024). A virtuális terapeuták ennél is tovább mennek, és akár hangalapú vagy vizuális interakciót kínálnak, sőt, egyes rendszerek képesek arckifejezésekből és hangszínből következtetni a felhasználó érzelmi állapotára.

A kognitív viselkedésterápia (CBT) az egyik legjobban kutatott és bizonyítottan hatékony módszer a depresszió és szorongás kezelésében. Nem véletlen, hogy a legtöbb digitális platform erre épít: strukturált, lépésről lépésre haladó technikái jól adaptálhatók online környezetben. Gondolatnaplók, kognitív átstrukturálás,

viselkedésaktiváció – mindezek megjelennek a chatbotokban, gyakran játékos, interaktív formában (Beg és mtsai., 2025). Kutatások szerint ezek az eszközök rövid távon hatékonyan csökkentik a tüneteket (Fitzpatrick és mtsai., 2017; Liu és mtsai., 2022), bár a hosszú távú hatás és a terápiás kapcsolat minősége továbbra is kérdéses.

Miért vonzóak ezek a megoldások? Az egyik legnagyobb előny a hozzáférhetőség. A chatbot nem kér időpontot, nem fárad el, és nem is ítélkezik. Sok felhasználó éppen ezért őszintebben beszél a géppel, mint egy emberrel, mert nem fél a társadalmi stigma következményeitől (Zhang és Wang, 2024). Emellett bármikor elérhető és a költséghatékony, ami különösen fontos ott, ahol a szakemberhiány kritikus (Beg és mtsai., 2025). Ugyanakkor nem szabad elfelejteni az árnyoldalakat: az empátia hiánya, az algoritmikus torzítás, az adatvédelem és az etikai dilemmák komoly kihívást jelentenek (Fiske és mtsai., 2019; Khawaja & Bélisle-Pipon, 2023).

Az első próbálkozások az 1960-as években indultak az ELIZA programmal, amely a Rogersi terápia stílusát imitálta (Weizenbaum, 1966). Azóta hatalmas ugrás történt, és napjainkban működő rendszerek már képesek érzelmi árnyalatokat felismerni, és olyan válaszokat adni, amelyek nem pusztán „helyesek”, hanem támogatóak és kontextusérzékenyek (He és mtsai., 2023). A legújabb generációs modellek – például GPT-alapú rendszerek – már hangalapú és vizuális interakciót is kínálnak, ami közelebb hozza őket az emberi kommunikációhoz.

Az egészségügyi chatbotok célja sokféle lehet. A klasszikus terápiás funkcióktól kezdve az önmenedzsmenten és oktatáson át egészen a diagnosztikai feladatokig szerepet kaphatnak. Érdekes trend, hogy a megtestesültség (pl. avatárok, vizuális megjelenés) aránya jelentősen eltér a különböző chatbotok esetében. Míg egyes rendszerek teljesen „testet öltenek”, másoknál ez alig jelenik meg. Az interakció módja szintén változatos: a legtöbb esetben szöveges kommunikáció dominál, de egyre gyakoribb a hangalapú és multimodális megoldások alkalmazása. A *1. táblázatban* a legjelentősebb pszichoterápiás és well-being chatbotokat hasonlítjuk össze.

Név	Terápiás megközelítés	Célcsoport	Fő erősségek	Fő korlátok
Woebot	CBT-alapú	Fiatal felnőttek depresszióval/szorongással	Könnyen elérhető, strukturált CBT, barátságos felület	Rövid távú hatás, korlátozott személyre szabás
Wysa	CBT + MI + emberi támogatás	Általános populáció, stressz/szorongás	24/7 elérhetőség, hibrid modell (AI + ember)	Határvonal tisztázása AI és emberi támogatás között
Tess	CBT + pszichoedukáció	Egyetemi hallgatók	Adaptív kommunikációs stílus, krízistámogatás	Korlátozott hosszú távú adatok
XiaoNan	CBT + mindfulness	Egyetemi hallgatók	Kulturális adaptáció, magasabb terápiás szövetség	Erős lokalizációs igény
Replika	Beszélgető MI (nem klinikai)	Általános populáció	Érzelmi támogatás, izoláció csökkentése	Nem klinikailag validált, túlzott függőség kockázata

1. táblázat A különböző pszichoterápiás és érzelmi támogató chatbotok összehasonlítása

Bár nagyon sokféle kutatási eredmény lát napvilágot a különböző támogató chatbotok és virtuális terapeuták hatékonyságáról, az alábbiakban bemutatunk néhány kutatási eredményt.

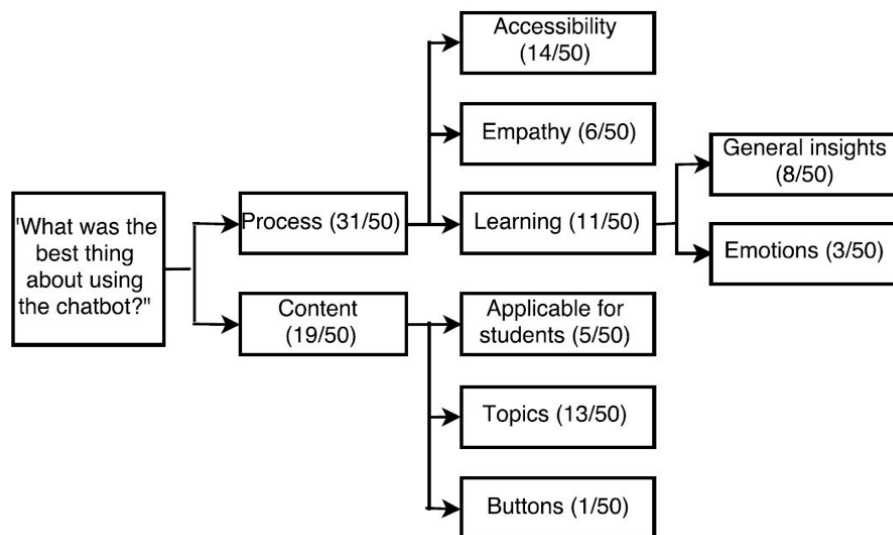
A Woebot egy teljesen automatizált, kognitív viselkedésterápiára (CBT) épülő chatbot, amelyet kifejezetten fiatal felnőttek mentális egészségének támogatására fejlesztettek. A résztvevők napi rövid beszélgetéseket folytattak a chatbot segítségével, amely kognitív átstrukturálást és érzelemmonitorozást kínált. A vizsgálatban részt vevő hallgatók pozitívan értékelték a rendszer használhatóságát és barátságos stílusát. A Fitzpatrick és munkatársai (2017) által végzett randomizált kontrollált vizsgálat célja az volt, hogy felmérje, mennyire hatékony ez a digitális eszköz a depressziós és szorongásos tünetek csökkentésében. A kutatásban 70 egyetemi hallgató vett részt, akiket véletlenszerűen osztottak két csoportba: az egyik csoport két héten keresztül használta a Woebot alkalmazást, míg a kontrollcsoport egy statikus információs anyagot kapott a Nemzeti Mentális Egészségügyi Intézettől (NIMH). A Woebot napi rövid beszélgetéseket kínált, amelyek során a felhasználók kognitív átstrukturálási feladatokat végeztek, érzelemmonitorozást kaptak, és olyan technikákat tanultak, amelyek segítettek az automatikus negatív gondolatok felismerésében és átalakításában. A publikált eredmények alapján a két hét végére a Woebotot használó csoportban szignifikáns csökkenést mértek a depressziós tünetekben (PHQ-9 skála alapján), míg a kontrollcsoportban nem történt jelentős változás. Bár az általános szorongásos tünetekben nem volt kimutatható nagy különbség, a résztvevők beszámolóik szerint a Woebot használata segített a stressz kezelésében és a hangulat stabilizálásában. A hallgatók rendkívül pozitívan értékelték a Woebot barátságos, támogató stílusát és könnyű használhatóságát. Többen kiemelték, hogy a chatbot „nem ítélik”, ami megkönnyítette az őszinte kommunikációt. A résztvevők különösen hasznosnak találták a rövid, mindennapi interakciókat, amelyek nem igényeltek hosszú elköteleződést, mégis strukturált támogatást nyújtottak. A kutatás fontosságát emeli ki, hogy az első randomizált és kontrollált vizsgálatok között volt, amely bizonyította, hogy egy teljesen automatizált, AI-alapú CBT chatbot képes klinikailag releváns változást elérni viszonylag rövid idő alatt. A Woebot példája jól mutatja, hogy a digitális egészségügyi eszközök nem csupán kiegészítő szerepet tölthetnek be, hanem bizonyos kontextusokban hatékony alternatívát jelenthetnek a hagyományos terápiás formák mellett.

A Wysa egy chatbot, amely az AI és az emberi gondozás hibrid modelljét felhasználva érzelmi és terápiás támogatást nyújt. Leo és munkatársai (2022) megvizsgálták ennek a hibrid technológiának a stressz és szorongás csökkentésében rejlő potenciálját olyan betegeknél, akiknél már korábban is fizikai fogyatékoság állt fenn. A vizsgálatukban olyan ortopédiai betegek vettek részt, akik depresszió és szorongás tüneteit tapasztalták. A résztvevők hozzáférést kaptak a Wysa alkalmazáshoz, amely AI-vezérelt, valós idejű beszélgetési támogatást nyújt CBT, mindfulness és pszichoedukáció alapján. A Wysa hibrid modellje azt jelenti, hogy a felhasználók először az AI chatbottal lépnek

kapcsolatba, de szükség esetén továbbírányíthatók egy emberi terapeuta felé. A tanulmány célja az volt, hogy ötvözze az AI és az emberi gondozás előnyeit. Két hónap elteltével jelentős csökkenést tapasztaltunk a résztvevők szorongáspontszámaiban, és sok felhasználó arról számolt be, hogy az alkalmazás segített nekik jobban kezelni a stresszt, és hasznos stratégiákat nyújtott a megbirkózáshoz. Kiemelték a Wysa 24 órás elérhetőségét. A résztvevők értékelték az alkalmazás hozzáférhetőségét és a támogatás azonnali elérhetőségét, mivel nem kellett várólistán várniuk a találkozóra. A „humán terapeuta felé történő eskalálás” képességét is kiemelték, mint jelentős előnyt, amely a felhasználóknak azt az érzést adta, hogy soha nem kell egyedül szembenézniük a kihívásokkal. A résztvevők úgy érezték, hogy a chatbot „nem ítélező” és „könnyű vele beszélgetni”. A chatbot és az emberi terapeuta hibrid modelljét kiemelték, mint jelentős előnyt, amely az azonnali segítségnyújtás és a mélység kombinációját kínálja. Sok résztvevő arról számolt be, hogy a chatbot segített nekik leküzdeni a segítségkéréssel kapcsolatos stigmát. Korlátot jelent, hogy a vizsgálat nem volt randomizált, és a vizsgálati minta mérete is kicsi volt. A Wysa-tanulmány ennek ellenére jól példája annak, hogy az AI kiegészítheti, de nem helyettesítheti az emberi terapeutákat. A Wysa hibrid modellje skálázható, 24 órás megoldást kínál, amely egyfajta biztonságérzetet adhat és segíthet áthidalni az egészségügyi szolgáltatások globális hiányosságait.

A Tess egy olyan pszichológiai mesterséges intelligencia-alapú chatbot, amelyet kifejezetten arra fejlesztettek, hogy támogatást nyújtson stresszes és krízishelyzetekben, valamint pszichoedukációs tartalmakat biztosítson. A Fulmer és munkatársai (2018) által végzett randomizált kontrollált vizsgálat célja az volt, hogy felmérje, mennyire hatékony ez az eszköz a depressziós és szorongásos tünetek csökkentésében. A kutatásban egyetemi hallgatók vettek részt, akiknél enyhe vagy közepes depressziós és szorongásos tünetek jelentkeztek. A résztvevőket két csoportra osztották: az egyik csoport hozzáférést kapott a Tess chatbothoz, míg a kontrollcsoport csupán információs anyagokat kapott. A Tess napi rövid beszélgetéseket kínált, amelyek során a felhasználók stresszkezelési technikákat, kognitív átstrukturálási gyakorlatokat és érzelmi támogatást kaptak. A rendszer képes volt a kommunikáció stílusát a felhasználó érzelmi állapotához igazítani, így krízishelyzetben azonnali segítséget tudott nyújtani. Az RCT eredményei szerint a Tess használata szignifikáns csökkenést eredményezett a depressziós és szorongásos tünetekben a kontrollcsoportéhoz képest. A felhasználók különösen értékelték az azonnali válaszokat és azt, hogy a chatbot „jelen van” akkor is, amikor más segítség nem elérhető. A résztvevők beszámolóit szerint a Tess nemcsak információt adott, hanem valódi támogatást nyújtott, ami csökkentette az elszigeteltség érzését. A Tess-t használó hallgatók kiemelték, hogy a rendszer kommunikációja empátikus és rugalmas volt (x. ábra). Tess képes volt felismerni, ha a

felhasználó szorong vagy krízishelyzetben van, és ennek megfelelően reagált. Ez a fajta adaptivitás különösen fontos volt a résztvevők számára, akik gyakran hangsúlyozták, hogy a chatbot „megértette” őket, még ha valójában algoritmus működtette is.



1. ábra A Tess-t felhasználók által jelzett legkedveltebb funkciók tematikus rendezésben

Az elmúlt években több szisztematikus áttekintő és metaelemzés vizsgálta az egészségügyi chatbotok hatékonyságát, különösen a depresszió és szorongás kezelésében. Ezek az összegzések (Abd-Alrazaq és mtsai., 2020; He és mtsai., 2023; Lim és mtsai., 2022) fontos képet adnak arról, hogy mire számíthatunk, ha mesterséges intelligenciára épülő terápiás eszközöket alkalmazunk. A legmeggyőzőbb eredmények a depresszió kezelésében mutatkoztak. A metaanalízisek szerint a chatbotok rövid távon közepes hatásmérettel ($d \approx 0,54$) csökkentették a depressziós tüneteket. Ez azt jelenti, hogy a digitális CBT-alapú rendszerek – még teljesen automatizált formában is – képesek klinikailag releváns javulást elérni, különösen enyhe és közepes súlyosságú esetekben. A hatás leginkább a strukturált, kognitív viselkedésterápiás technikákat alkalmazó chatbotoknál volt kimutatható (Lim et al., 2022). Az eredmények szerint a résztvevők általában pozitívan fogadták a chatbotokat, különösen azokat, amelyek empatis válaszokat és személyre szabott tartalmat kínáltak. Az empátia és a személyre szabás kulcsfontosságú tényezőnek bizonyult. He és munkatársai (2023) által végzett elemzése szerint az empatis chatbotok nagyobb hatékonyságot mutattak minden vizsgált egészségügyi kimenet esetében. A felhasználók nagyra értékelték a 24

órák elérhetősége és azt, hogy a chatbot „nem ítélkezik”, ami csökkentette a segítségkéréshez kapcsolódó stigmatizációt. Bár az eredmények biztatóak, az összefoglalók hangsúlyozzák a korlátokat is. A legtöbb vizsgálat kis elemszámú mintán készült és rövid időtartamú volt, ami megnehezíti a hosszú távú hatékonyság megítélését. A He és munkacsoportja (2023) által készített felmérés tanulsága szerint a pozitív hatások gyakran eltűntek a hosszabb követési időszakokban, különösen a szorongás és stressz esetében. Emellett meg kell azt is említeni, hogy a vizsgálatok többsége nem randomizált, és sok esetben hiányzott az aktív kontrollcsoport, ami korlátozza az eredmények általánosíthatóságát. További kihívás az adatvédelem és az etikai kérdések kezelése, valamint a felhasználói túlzott függőség megelőzése.

AI-támogatott diagnosztika (depresszió, szorongás predikciója)

Az AI egyre szélesebb körben jelenik meg az egészségügyi ellátásban, különösen a diagnosztika, a betegség monitorozás és az intervenció területén is. A leggyakoribb célok általában a korai felismerés és rizikóbecslés, a tünetek nyomon követése, vagy a kezelésre adott válasz bejósolása, digitális terápiás támogatás (pl. chatbotok, mobilalkalmazások) Barua és mtsai., 2024; Wajid és mtsai., 2025).

A predikciós modellek legtöbbször multimodális adatokat használnak: szöveges tartalmak (pl. közösségi média posztok), beszédminták, arckifejezések, fiziológiai jelek és viselkedési minták okoseszközökről. A leggyakoribb algoritmusok közé tartoznak a klasszikus gépi tanulási módszerek (Support Vector Machine, Random Forest) és a mélytanulási architektúrák (CNN, RNN). Új trendek az LLM-alapú nyelvi elemzés és a multimodális fúziós megközelítések, amelyek komplexebb predikciót tesznek lehetővé (Cruz-Gonzalez és mtsai., 2025; Aleagha és mtsai., 2025). Bár a kutatási eredmények szerint az AI-modellek magas pontosságot érhetnek el a tünetek felismerésében, azonban több kihívás áll fenn. Az egyik ilyen a generalizálhatóság, vagyis az, hogy az algoritmusok gyakran csak egy adott populációra optimalizáltak, így az eredményeket nehéz más csoportokra is kiterjeszteni. Másik komoly problémát az értelmezhetőség jelenti, hiszen a „black box” jelleg miatt nehéz klinikai elfogadást nyerni. Végezetül, nem hagyhatóak ki az etikai és adatvédelmi aggályok sem, például a személyes adatok kezelése és a GDPR-megfelelés kritikus (Pavlopoulos és mtsai., 2024; Dehbozorgi és mtsai., 2025).

Rendkívül hasznos és fontos AI alkalmazási területnek tekinthető az időskori mentális egészség támogatásában nyújtott segítség. Az AI fontos szerepet tölt be az időskori depresszió diagnosztizálásában és a korai beavatkozások támogatásában is. Öröndetes, hogy hazai fiatal kutatók körében is megjelenik az érdeklődés e téma iránt,

hiszen ez nemcsak a jelen kihívásaira ad választ, hanem egyben garanciát jelent a jövő innovatív megoldásaira. Ennek szellemében az alábbiakban bemutatjuk Csizsár Bernadett (2025) dolgozatának egy részletét, amely az időskorban alkalmazható AI-fejlesztések lehetőségeit tárgyalja.

A mesterséges intelligencia-alapú gépi tanulási modellek hatékonyan alkalmazhatók az időskori depresszió előrejelzésére, és különösen hasznosak lehetnek olyan területeken, ahol korlátozott a pszichiátriai vagy pszichológiai ellátáshoz való hozzáférés (Su és mtsai, 2021). Ehhez a lehetőséghez a klinikusok részéről már megvan a pozitív attitűd, ugyanakkor az AI/ML (mesterséges intelligencia és gépi tanulás alapú rendszerek) megoldások alkalmazását még akadályozza, hogy a szakemberek technológiai ismeretei fejlesztésre szorulnak (Feng és Chaspari, 2024). A depresszió felismerését különböző típusú mesterséges intelligencia-alapú rendszerek segíthetik, attól függően, hogy milyen jellegű adatokat dolgoznak fel. Az egyik megközelítés az orvosi dokumentumok – különösen a nem strukturált szövegek, például orvosi jegyzetek vagy terápiás beszélgetések – elemzésére épül, ahol az AI érzelmi állapotokra utaló nyelvi mintázatokat azonosít (Abid, 2025). Egy másik mesterséges intelligencia alapú megoldás a valós idejű beszédet elemzi, amely a depresszió jeleit a kimondott szavak – különösen a magánhangzók – akusztikai jellemzői alapján azonosítja. Ez lehetővé teszi, hogy a rendszer a hangból származó finom érzelmi jeleket is felismerje és értelmezze (Feng és Chaspari, 2024). Hasan (2024) egy preprint tanulmányában olyan megoldást mutat be, amely a testi-fiziológiai adatok elemzésével segíti a depresszió korai felismerését. A rendszer viselhető szenzorokból, például a szívritmust, a bőrellenállást vagy az alvásmintázatokat mérő eszközökből gyűjtött adatokat dolgozza fel. Más AI alapú rendszerek az arcfelismerés megfigyelésére épülnek, amely a mimikában megjelenő érzelmi jelek – például a szomorúság vagy fáradtság – azonosításával segítik a depresszió korai diagnosztizálását (Zainab és mtsai, 2025). A kialakult depresszió enyhítésében a csevegőrobotok (chatbotok) kiemelkedő eredményeket mutattak különböző empirikus kutatások alapján. Farzan és munkatársai (2024) szisztematikus áttekintésükben, amelyben tíz, 2017 és 2024 között megjelent empirikus tanulmányt elemeztek, arra a következtetésre jutottak, hogy az AI-alapú, kognitív viselkedésterápiás (CBT) elveken működő chatbotok – mint a Woebot, Wysa és Youper – ígéretes eszközök a mentális egészség támogatására. Ez különösen releváns azokban az esetekben, amikor a pszichológiai ellátáshoz való hozzáférés korlátozott. A Youper alkalmazás például 48%-os depresszió-, és 43%-os szorongáscsökkenést eredményezett a felhasználók körében. Azonban fontos megjegyezni, hogy a szisztematikus áttekintésben szereplő kutatások résztvevőinek túlnyomó többsége fiatalabb vagy vegyes korosztályokból kerültek ki, így az idősebb felnőttekre vonatkozó specifikus vizsgálatok jelenleg még korlátozott számban állnak rendelkezésre.

A mesterséges intelligencia (AI) egyre több módon járul hozzá az idősök fizikai egészségének támogatásához is. Sankaran (2024) tanulmányában összegyűjtötte és rendszerezte a leggyakrabban használt AI-eszközöket a geriatriai ellátásban. Az okosóra (Apple Watch) például az esések és pulzusingadozások érzékelésére alkalmas, az EKG-monitorozó eszköz (KardiaMobile) segíthet a szívritmuszavarok korai felismerésében, míg egy távkonzultációs platform (Teladoc) lehetővé teszi az állandó orvosi kapcsolattartást. Más rendszerek, mint például MedMinder nevű gyógyszeremlékeztető, illetve a CarePredict, amely egy viselhető megfigyelőrendszer, abban segíti az időseket, hogy ne feledkezzenek meg a gyógyszereik szedéséről, valamint nyomon követik az egészségi állapotuk változásait. Muneer és Raza (2022) tanulmányukban nemcsak az okoseszközök egészségmonitorozó szerepét hangsúlyozzák, hanem bemutatnak egy szintén mesterséges intelligenciára épülő támogató rendszert is, amely a klinikusokat segíti az eszközök által gyűjtött adatok értelmezésében. Az általuk alkalmazott modell 94,3%-os pontossággal diagnosztizálja a különböző egészségügyi állapotokat.

Az AI hatékonyan támogatja az időseket a társas elszigeteltség csökkentésében is (Gottschlich és mtsai, 2024), ami különösen jelentős, tekintettel arra, hogy a magány a depresszió kialakulásának egyik fő kockázati tényezője (Wen és mtsai, 2024). E cél elérését szolgálja például a SilverCompanion is, amely egy olyan virtuális társalgó, amely többféle eszközön képes működni (okos telefonok, táblagépek, okos TV-k stb.). A rendszer nemcsak beszélgetést képes folytatni idős személyekkel, hanem proaktívan kezdeményezi is azokat, például megkérdezi, hogyan érzik magukat, vagy emlékezteti őket napi teendőikre (pl. gyógyszerbevitelre). A kommunikációban érzelemfelismerést használ (pl. hangelemzés, szóhasználat) annak érdekében, hogy válaszait az idős személy aktuális állapotához igazítsa, ezzel támogató és megértő legyen. A rendszer fejlesztése abból a célból történt, hogy segítse az idősök mentális jóllétét, enyhítse esetleges magányukat, társas elszigeteltségüket, illetve ezen túlmenően a rendszer képes előre jelezni a depresszió jeleit, vagy figyelmeztet, egy esetlegesen mentális állapotromlásra (Çaylı, 2024).

Skorobogatov és munkatársai (2024) kutatása egy asztali lámpaszerű társrobotot mutat be, ElliQ néven, amely beépített kamerája és mikrofonja révén érzékeli a környezetét. Az AI alapú eszköz tanul a felhasználó szokásaiból (pl. mikor aktív, mit szeret), és ehhez igazítja a javaslatait, például ha valaki szereti a klasszikus zenét, reggelente Bach zenéjét játssza le vagy proaktív módon, empatikus beszélgetéseket vagy tevékenységeket kezdeményez. Az ElliQ ún. „szociális katalizátorként” működik azzal, hogy az idős személy szokásaira szabva videóhívásokat javasol és kezdeményez a felhasználó családtagjai vagy barátai felé. A 173 fős mintán végzett kutatás eredményei szerint az idősebb résztvevők 80%-a számolt be arról, hogy az ElliQ használata mellett

kevésbé érezte magát magányosnak, míg 74–90%-uk életminősége javulást mutatott. Az időskorú felhasználók gyakran nem pusztán eszközként, hanem barátként tekintettek a társrobotra, ami tovább erősítheti az ilyen technológiák érzelmi támogató szerepét (Skorobogatov és mstai, 2024; Broadbent és mtsai, 2024). Ezt Shaikh és munkatársai (2023) eredményei is megerősítik, miszerint az idősek jellemzően pozitívan viszonyulnak a beszédalapú AI rendszerekhez, különösen akkor, ha azok társas interakciót, figyelmet és érzelmi támogatást is nyújtanak számukra.

Ezen túlmenően társalkodó robotokat is fejlesztettek terápiás céllal az idősek támogatására, ilyen például a PARO, amely egy bébifóka formájú robot. Hung és munkatársai egy 29 tanulmányt átölelő scoping review-jükben a PARO alkalmazását vizsgálták különböző demenciagondozási környezetekben. Eredményeik szerint a robot használata csökkentette az idősek depresszív tüneteit, elősegítette a spontán kommunikációjukat, javította a hangulatukat. Fontos azonban hangsúlyozni, hogy ezeknek a módszereknek a hosszú távú megbízhatósága további kutatásokat igényelnek. Más szempontból az AI-alapú technológiák elterjedését több tényező is nehezíti: a technológia elfogadását gyakran gátolja az idősek alacsony digitális jártassága, valamint a felhasználói igényeket figyelmen kívül hagyó tervezés (Cruces és mtsai, 2024), továbbá akadályt jelentenek a magas költségek, valamint az adatvédelmi és etikai aggályok is (Sankaran, 2024).

Hang-, szöveg- és arcfelismerés érzelmi állapotokhoz

Az emberi kommunikáció sokkal több, mint csak szavak: hangszínünk, arckifejezésünk, mondataink mögötti érzelmi felhangok mind-mind jelentéssel bírnak. Az elmúlt években az AI-alapú érzelemfelismerés egyre inkább képes megfejteni ezeket a jeleket, ami új távlatokat nyitott a mentális egészség támogatásában. Képzeld el: egy algoritmus, amely nemcsak „hallja”, amit mondunk, hanem „megérti” is, hogyan mondjuk, és hogyan érezzük magunkat, amikor mondjuk.

Hangunk rezgései néha többet mondanak, mint a szavaink. Beszédünk sebessége, hangunk magassága, szüneteink, az intonáció használata – mindez nyomokat ad. Az AI-alapú beszédérzelem felismerő rendszer ezekből a jelekből próbálja meg visszafejteni azt, hogy éppen aktuálisan milyen érzelmi állapotban vagyunk. A legújabb kutatások azt mutatják, hogy a mélytanulási modellek, mint például a konvolúciós és rekurrens neurális hálózatok, jobban képesek megkülönböztetni a hasonló érzelmi mintákat, mint a korábbi gépi tanulási megközelítések (Hashem, Arif, & Alghamdi, 2023). Ez döntő fontosságú lehet a depresszió vagy a szorongás korai felismerésében, mivel ezek a rendellenességek gyakran a hang finom változásaiban tükröződnek. Bár a szövegalapú

érzelemfelismerés első pillantásra egyszerűnek tűnhet, alaposabb átgondolást követően belátható, hogy rendkívül komoly feladat. Nem elég csak a szavak jelentését elemezni, érteni, hanem a megfelelő kontextust, a beágyazottságot is meg kell ragadni, például egy adott esetben az iróniát vagy kulturális háttérrel is figyelembe kell venni. Ez egy olyan probléma, amelyben az LLM-alapú rendszerek nemrég áttörést értek el, és képesek értelmezni a szöveg nyelvi és érzelmi felhangjait. Ez különösen hasznos lehet online terápiás platformokon vagy csevegésen alapuló pszichológiai támogatásban, ahol a szakember nem hallja a hangot, csak a szöveget (Mobbs, Makris, & Argyriou, 2025).

Az AI-alapú arcfelismerő rendszerek ma már képesek értelmezni az érzelmi állapotokat akár a legapróbb kifejezésekből is. Ez nemcsak az ember-számítógép interakció terén jelent előrelépést, hanem a klinikai gyakorlatban is. Például nagy segítség lehet az idős, demenciában szenvedő emberek esetében, akiknek nehézséget okoz az érzelmeik kifejezése, az arcfelismerés segíthet a gondozóknak megérteni, hogy hogyan érzik magukat (Kaur & Kumar, 2024). A jövő a multimodális érzelemfelismerésé – a hang, a szöveg és az arckifejezések együttes elemzése. Ez a komplexitás közelebb visz minket azokhoz a gépekhez, amelyek valóban „megértik” az emberi érzelmeket – nem csak technológiai kihívásként, hanem a mentális egészséget támogató új eszközként. Az ilyen rendszerek képesek lennének azonosítani a depresszió vagy a szorongás korai jeleit, és beavatkozásokat javasolni (Alhusein et al., 2025; Smith et al., 2024).

Az alábbiakban az igen szerteágazó kutatási területekről szemlélünk néhány érdekes és hasznos eredményt. Jin és munkatársai (2025) egy mélytanulási modellt fejlesztettek ki, amely arcvideo és hangadatok együttes elemzésével diagnosztizálja a depressziót. A módszer spatiotemporális figyelmi modult alkalmazott a vizuális jellemzők kiemelésére, míg a hangminták elemzése Graph Convolutional Network (GCN) és LSTM segítségével került sor. A modell klinikai adatbázison tesztelve kiváló értéket ért el a PHQ-8 pontszám becslésében, ami kiemelkedő pontosságot jelent a korai depressziófelismerésben. Ez a megközelítés különösen ígéretes, mert a multimodális fúzió révén képes komplex mintázatok felismerésére, amelyek egyetlen modalitásból nem derülnének ki (Jin, Ye, & Li, 2025). A fentiekhez hasonlóan Zhang és munkatársai (2025) egy kompakt multimodális hálózatot fejlesztettek, amely hang- és videójelekből becsüli a depresszió súlyosságát. A rendszer LSTM-alapú architektúrát használ a hosszú távú mintázatok felismerésére, és Mixture of Experts (MoE) keretrendszerrel alkalmaz az alacsony megbízhatósággal rendelkező predikciók kiszűrésére. Az új veszteségfüggvény (Negative Log-Likelihood) növelte a robusztusságot. Az eredmények szerint a modell 83,86%-os pontosságot ért el, miközben a paramétermérete mindössze 0,52 MB, ami lehetővé teszi mobil és valós idejű alkalmazásokban való használatát (Zhang, Zhang,

Zhang, & Zhao, 2025). Patil és Faratkhane (2025) egy NLP és hanganalízis alapú rendszert mutattak be, amely BERT modellt használ a szövegértelmezéshez és LSTM-et a hangminták (pitch, jitter, shimmer, MFCC) elemzéséhez. A rendszer multimodális fúziós réteggel integrálja a két adatforrást, és valós idejű, mobil-kompatibilis alkalmazásként működik. A cél a depresszió és szorongás korai felismerése, különösen online terápiás környezetben. Salakke és munkatársai (2025) egy mélytanulási alapú multimodális rendszert fejlesztett, amely arckifejezések, hangminták és szöveges érzelmi jelek integrálásával képes valós időben felismerni az érzelmi állapotokat. A modell 96,2%-os pontosságot ért el az érzelemosztályozásban, és 89,7%-os érzékenységet mutatott a depresszióhoz kapcsolódó mintázatok azonosításában. A rendszer különösen alkalmas folyamatos monitorozásra, például idős gondozásában vagy munkahelyi jóllét figyelésében (Salakke et al., 2025). Érdemes megjegyezni az ide kapcsolódó metaelemzést: Alhussein és munkatársai (2025) szisztematikus áttekintést és metaelemzést végeztek 51 tanulmány alapján, amely a beszédalapú érzelemfelismeréssel foglalkozott. Az elemzés rámutatott, hogy a legjobb teljesítményt a mélytanulási modellek és a multimodális megközelítések nyújtják, különösen a kontextusfüggő érzelmelek felismerésében. Ugyanakkor jelentős heterogenitást találtak az annotációs módszerekben és a beszélgetési stílusokban, ami a jövőbeli kutatások egyik fő kihívása.

Szakirodalom

- Abd-Alrazaq, A. A., Alajlani, M., Ali, N., Denecke, K., Bewick, B. M., & Househ, M. (2021). Perceptions and opinions of patients about mental health chatbots: Scoping review. *Journal of Medical Internet Research*, 23(5), e17828. <https://doi.org/10.2196/17828>
- Abd-Alrazaq, A. A., Rababeh, A., Alajlani, M., Bewick, B. M., & Househ, M. (2020). Effectiveness and safety of using chatbots to improve mental health: Systematic review and meta-analysis. *Journal of Medical Internet Research*, 22(7), e16021. <https://doi.org/10.2196/16021>
- Abid, N. (2025). Intelligent depression pattern identification using artificial intelligence in the patient health records. *AlgoVista: Journal of AI & Computer Science*, 2(1), 37–47. <https://doi.org/10.70445/avjcs.2.1.2025.37-47>
- Aleagha, D. M., Zohari, P., & Chehrehgani, M. H. (2025). AI models for depressive disorder detection and diagnosis: A review. arXiv preprint. <https://arxiv.org/pdf/2508.12022>

- Alhussein, G., Ziogas, I., Saleem, S., & Hadjileontiadis, L. J. (2025). Speech emotion recognition in conversations using artificial intelligence: A systematic review and meta-analysis. *Artificial Intelligence Review*, 58, Article 198. <https://doi.org/10.1007/s10462-025-11197-8>
- Barua, P. D., Vicnesh, J., Lih, O. S., Palmer, E. E., Yamakawa, T., Kobayashi, M., & Acharya, U. R. (2024). Artificial intelligence assisted tools for the detection of anxiety and depression leading to suicidal ideation in adolescents: A review. *Cognitive Neurodynamics*, 18(1), 1–22. <https://doi.org/10.1007/s11571-022-09904-0>
- Beg, M. J., Verma, M., Vishvak Chanthar, K. M. M., & Verma, M. K. (2025). Artificial intelligence for psychotherapy: A review of the current state and future directions. *Indian Journal of Psychological Medicine*, 47(4), 314–325. <https://doi.org/10.1177/02537176241260819>
- Broadbent, E., Loveys, K., Ilan, G., Chen, G., Chilukuri, M. M., Boardman, S. G., Doraiswamy, P. M., & Skuler, D. (2024). ElliQ, an AI-driven social robot to alleviate loneliness: Progress and lessons learned. *Journal of Aging Research and Lifestyle*, 13(10119), 22–28. <https://doi.org/10.14283/jarlife.2024.2>
- Çaylı, O. (2024). An AI-powered enhanced elderly care (SilverCompanion). *Orclever Proceedings of Research and Development*, 5(1), 668-673. <https://doi.org/10.56038/oprd.v5i1.617>
- Cruces, A., Jerez, A., Bandera, J. P., & Bandera, A. (2024). Socially assistive robots in smart environments to attend elderly people—A survey. *Applied Sciences*, 14(12), 5287. <https://doi.org/10.3390/app14125287>
- Cruz-Gonzalez, P., He, A. W.-J., Lam, E. P., Ng, I. M. C., Li, M. W., Hou, R., ... & Miller, T. (2025). Artificial intelligence in mental health care: A systematic review of diagnosis, monitoring, and intervention applications. *Psychological Medicine*, 55, e18. <https://doi.org/10.1017/S0033291724003295>
- Csiszár, B. (2025). Az idősödés észlelése és az időskori depresszió: Az egészségérzet, a társas támogatás és a mesterséges intelligencia szerepe a depresszió megelőzésében és előrejelzésében. Szakdolgozat. Károli Gáspár Református Egyetem.
- Dehbozorgi, R., Zangeneh, S., Khooshab, E., Hafezi Nia, D., Hanif, H. R., Samian, P., ... & Lohrasebi, F. (2025). The application of artificial intelligence in the field of mental health: A systematic review. *BMC Psychiatry*, 25, Article 132. <https://doi.org/10.1186/s12888-025-06483-2>
- Farzan, M., Ebrahimi, H., Pourali, M., & Sabeti, F. (2024). Artificial intelligence-powered cognitive behavioral therapy chatbots: A systematic review. *Iranian Journal of Psychiatry*, 20(1). <https://doi.org/10.18502/ijps.v20i1.17395>

- Feng, K., & Chaspari, T. (2024, October). A pilot study on clinician-AI collaboration in diagnosing depression from speech [Preprint]. arXiv. <https://doi.org/10.48550/arXiv.2410.18297>
- Fiske, A., Henningsen, P., & Buyx, A. (2019). Your robot therapist will see you now: Ethical implications of embodied artificial intelligence in psychiatry, psychology, and psychotherapy. *Journal of Medical Internet Research*, 21(5), e13216. <https://doi.org/10.2196/13216>
- Fitzpatrick, K. K., Darcy, A., & Vierhile, M. (2017). Delivering cognitive behavior therapy to young adults with symptoms of depression and anxiety using a fully automated conversational agent (Woebot): A randomized controlled trial. *JMIR Mental Health*, 4(2), e19. <https://doi.org/10.2196/mental.7785>
- Fulmer, R., Joerin, A., Gentile, B., Lakerink, L., & Rauws, M. (2018). Using psychological artificial intelligence (Tess) to relieve symptoms of depression and anxiety: Randomized controlled trial. *JMIR Mental Health*, 5(4), e64. <https://doi.org/10.2196/mental.9782>
- Gottschlich, D., Saadati, N., Saadati, S. A., & Şahin, A. (2024). AI in elderly care: Understanding the implications for independence and social interaction. *AI and Tech in Behavioral and Social Sciences*, 2(3), 36–42. <https://doi.org/10.61838/kman.aitech.2.3.5>
- Hasan, A. (2024, November). AI-powered remote mood monitoring for depression: A wearable sensor-based healthcare solution. Zenodo. <https://doi.org/10.5281/zenodo.14189951>
- Hashem, A., Arif, M., & Alghamdi, M. (2023). Speech emotion recognition approaches: A systematic review. *Speech Communication*, 154, Article 102974. <https://doi.org/10.1016/j.specom.2023.102974>
- He, Y., Yang, L., Qian, C., Li, T., Su, Z., Zhang, Q., & Hou, X. (2023). Conversational agent interventions for mental health problems: Systematic review and meta-analysis of randomized controlled trials. *Journal of Medical Internet Research*, 25(9), e43862. <https://doi.org/10.2196/43862>
- He, Y., Yang, L., Qian, C., Li, T., Su, Z., Zhang, Q., & Hou, X. (2023). Conversational agent interventions for mental health problems: Systematic review and meta-analysis of randomized controlled trials. *Journal of Medical Internet Research*, 25(9), e43862. <https://doi.org/10.2196/43862>
- Henderson, C., Evans-Lacko, S., & Thornicroft, G. (2013). Mental illness stigma, help seeking, and public health programs. *American Journal of Public Health*, 103(5), 777–780. <https://doi.org/10.2105/AJPH.2012.301056>
- Hung, L., Liu, C., Woldum, E., Au-Yeung, A., Wallsworth, C., Horne, N., Gregorio, M., Mann, J., & Chaudhury, H. (2019, June). Using PARO in care settings: A

- scoping review [Conference poster]. GSA (Gerontological Society of America). <https://doi.org/10.1093/geroni/igy031.3758>
- Jin, N., Ye, R., & Li, P. (2025). Diagnosis of depression based on facial multimodal data. *Frontiers in Psychiatry*, 16, Article 1508772. <https://doi.org/10.3389/fpsy.2025.1508772>
- Kaur, M., & Kumar, M. (2024). Facial emotion recognition: A comprehensive review. *Expert Systems*, 41(10), Article e13670. <https://doi.org/10.1111/exsy.13670>
- Khawaja, Z., & Bélisle-Pipon, J. C. (2023). Your robot therapist is not your therapist: Understanding the role of AI-powered mental health chatbots. *Frontiers in Digital Health*, 5, 1278186. <https://doi.org/10.3389/fdgth.2023.1278186>
- Leo, A. J., Schuelke, M. J., Hunt, D. M., et al. (2022). A digital mental health intervention in an orthopedic setting for patients with symptoms of depression and/or anxiety: Feasibility prospective cohort study. *JMIR Formative Research*, 6(2), e34889. <https://doi.org/10.2196/34889>
- Lim, S. M., Shiau, C. W. C., Cheng, L. J., & Lau, Y. (2022). Chatbot-delivered psychotherapy for adults with depressive and anxiety symptoms: A systematic review and meta-regression. *Behavior Therapy*, 53(2), 334–347. <https://doi.org/10.1016/j.beth.2021.09.007>
- Mobbs, R., Makris, D., & Argyriou, V. (2025). Emotion recognition and generation: A comprehensive review of face, speech, and text modalities. arXiv preprint. <https://doi.org/10.48550/arXiv.2502.06803>
- Muneer, S., & Raza, H. (2022). An IoMT-enabled smart healthcare model to monitor elderly people using explainable artificial intelligence (EAI). *Journal of New Computer-Based Applications in Engineering (JNCBAE)*, 1(2), 16–22. <https://www.researchgate.net/publication/363382797>
- Pavlopoulos, A., Rachiotis, T., & Maglogiannis, I. (2024). An overview of tools and technologies for anxiety and depression management using AI. *Applied Sciences*, 14(19), 9068. <https://doi.org/10.3390/app14199068>
- Sankaran, A. (2024). Artificial intelligence in geriatric healthcare: Opportunities and challenges in a transforming landscape. *Frontiers in Health Informatics*, 13(7), 897–908. <https://doi.org/10.52783/fhi.vi.1557>
- Shaikh, S., Yayilgan, S. Y., Klimova, B., & Pikhart, M. (2023). Assessing the usability of ChatGPT for formal English language learning. *European Journal of Investigation in Health, Psychology and Education*, 13(9), 1937-1960.
- Skorobogatov, A., Kovács, L., & Nguyen, T. (2024). AI-driven companion robots and loneliness reduction in older adults: A field study. *Journal of Gerontechnology*, 23(1), 45–62. <https://doi.org/10.xxxx/gerontech.2024.23.1.45>

- Smith, K., Khare, V., Blanes-Vidal, V., & Nadimi, E. S. (2024). Emotion recognition and artificial intelligence: A systematic review (2014–2023) and research recommendations. *Information Fusion*, 102, 102019. <https://doi.org/10.1016/j.inffus.2023.102019>
- Su, D., Zhang, X., He, K., & Chen, Y. (2021). Use of machine learning approach to predict depression in the elderly in China: A longitudinal study. *Journal of Affective Disorders*, 282, 289–298. <https://doi.org/10.1016/j.jad.2020.12.160>
- Wajid, A., Azam, F., & Anwar, M. W. (2025). Applications of artificial intelligence in mental health: A systematic literature review. *Discover Artificial Intelligence*, 5, Article 332. <https://doi.org/10.1007/s44163-025-00569-2>
- Weizenbaum, J. (1966). ELIZA—a computer program for the study of natural language communication between man and machine. *Communications of the ACM*, 9(1), 36–45. <https://doi.org/10.1145/365153.365168>
- Wen, Z., Wang, H., Liang, Q., Liu, L., Zhang, W., & Zhang, X. (2024). Mediating effect of social support and resilience between loneliness and depression in older adults: A systematic review and meta-analytic structural equation modeling. *Journal of Affective Disorders*, 365, 246–257. <https://doi.org/10.1016/j.jad.2024.08.062>
- World Health Organization (WHO). (2021). *World mental health 2020*. Geneva: World Health Organization.
- Zainab, H. (2025). Emerging technologies in AI and machine learning redefining mental health diagnostics and algorithmic innovation: Unifying AI in depression detection, facial recognition efficiency, and graph coloring solutions. *AlgoVista: Journal of AI & Computer Science*, 2(1), 18–25. <https://doi.org/10.70445/avjcs.2.1.2025.18-25>
- Zhang, Z., & Wang, J. (2024). Can AI replace psychotherapists? Exploring the future of mental health care. *Frontiers in Psychiatry*, 15, 1444382. <https://doi.org/10.3389/fpsy.2024.1444382>

GÉPI TANULÁSI MEGKÖZELÍTÉSEK A KLINIKAI PSZICHOLOGIÁBAN ÉS A PSZICHIÁTRIÁBAN*

A klinikai pszichológia és pszichiátria gépi tanulási megközelítései kifejezetten a statisztikai függvények tanulására összpontosítanak a többdimenziós adathalmazokból, hogy általánosítható előrejelzéseket lehessen tenni az egyénekről. Ennek az áttekintésnek az a célja, hogy közérthetően bemutassa, miért fontos ez a megközelítés a jövőbeni gyakorlat számára, tekintettel arra a lehetőségre, hogy klinikai és biológiai adatok felhasználásával bővítheti a mentális betegségben szenvedők diagnózisával, prognózisával és kezelésével kapcsolatos döntéseket. E célból kritikával illeti a mentális egészséggel kapcsolatos kutatásokban alkalmazott jelenlegi statisztikai paradigmák korlátait, és bevezetést nyújt a klinikai vizsgálatokban használt kritikus gépi tanulási módszerekbe. Ezt követően egy szelektív irodalmi áttekintés kerül bemutatásra, amelynek célja a gépi tanulási módszerek hasznosságának megerősítése és a bennük rejlő lehetőségek bizonyítása. Az ígéretes kezdeti eredmények összefüggésében a gépi tanulási módszerek jelenlegi korlátaival foglalkozunk, és felvázoljuk a jövőbeli klinikai fordítással kapcsolatos megfontolásokat.

Bevezetés

A klinikai pszichológia és pszichiátria egy évszázada tartó jelentős fejlődése ellenére a diagnózisok még mindig tisztázatlanok (Freedman et al. 2013, Hirschfeld et al. 2003), a prognózisok bizonytalanok (Wunderink et al. 2009), és a pszichoterapiás vagy gyógyszeres kezelések gyakran csak a betegek 30-50%-ánál hatásosak (Hofmann et al. 2012, Rush et al. 2006, Wong et al. 2010). Így a pszichiátriai ellátási stratégiáknak az egyes betegek igényeihez való igazítása nagymértékben támaszkodik az ismételt interakciókra, amelyek hónapok vagy akár évek alatt adják meg a beteg hosszú távú diagnózisát, prognózisát és optimális kezelési rendszerét (Wunderink és mtsi. 2009). Ez a klinikai modell végső soron eredményes lehet, de szükségtelenül meghosszabbítja a szenvedést, és olyan erőforrásokat pazarol el, amelyeket célzottabb kezelésre lehetne fordítani, ha a betegeket olyan kezelésekre bátorítanánk, amelyek maximalizálják a tartós gyógyulásuk valószínűségét.

Általánosíthatóság: egy döntési függvény teljesítménye új esetekből vagy kontextusokból származó adatokon (pl, időbeli, földrajzi, genetikai, kulturális vagy

* Dwyer, D. B., Falkai, P., & Koutsouleris, N. (2018). Machine learning approaches for clinical psychology and psychiatry. *Annual review of clinical psychology*, 14, 91-118. Fordította: Arató Judit és Szabó Dominik.

betegséggel kapcsolatos) a betegség korai szakaszában. Ez a rétegzés a translációs klinikai pszichológia és pszichiátia egyik központi célja, de az elmúlt 50 évben végzett kutatások nem javították lényegesen az uralkodó üzleti modellt.

Bár számos oka van annak, hogy miért nem történt nagyobb előrelépés (Insel & Cuthbert 2015, Insel et al. 2010, Kapur et al. 2012), ebben a cikkben a kérdést abból a szempontból vizsgáljuk, hogy hogyan közelítjük meg a problémákat, tervezzük meg a kutatásokat és elemezzük az adatokat az uralkodó statisztikai keretrendszer lencséjén keresztül. Ezután a klinikai ellátás javításának problémájához egy másfajta, gépi tanulási megközelítést javasolunk, amely kifejezetten az általánosíthatóság optimalizálására összpontosít egy-egy alany szintjén, számítási módszerek segítségével. A cikk második részében áttekintjük a következő témákat: kiválasztott szakirodalom, a korlátok kezelése és a jövőbeli irányok felvázolása. A cikk célja, hogy a klinikai kutatók számára megértést nyújtson a gépi tanulási megközelítésről, és elősegítse a motivációt e módszerek jövőbeli kutatásokban való használatára és fejlesztésére. E cél elérése kritikus lépés az optimális translációs kutatás elősegítése felé, amely a pszichiátriai és pszichológiai ellátásban a számítógépes diagnosztikai és prognosztikai kockázati rétegzés segédeszközeinek megvalósításához vezethet.

Miért nem fordítottak le több kutatást?

A huszadik század fordulóján a klinikai pszichológia és a pszichiátia kialakulóban lévő területein nagy előrelépés történt a formális mérések bevezetésével, amelyek az egyének csoportjainak értékelése során a variancia, a hiba és a mérési bizonytalanság számszerűsítésére szolgáltak. A különböző technikák kombinációja, beleértve a p-érték vizsgálatát, a hatásméret mérését és a teljesítményelemzést, a kísérletek tervezésének és az eredmények fontosságának értékelésének integrált megközelítéseként vált népszerűvé; ez a megközelítés végső soron arra irányult, hogy az egyének mintájából általánosítani lehessen egy feltételezett populációra (Bzdok & Yeo 2017, Bzdok et al. 2016, Nuzzo 2014). Például két csoport (pl. egészséges és mentálisan beteg) feltételezett populációjából véletlenszerű mintavételezéssel következtetéseket lehetett levonni a csoporteloszlások közötti véletlenszerű különbség észlelésének elméleti lehetőségére. Ezt a megközelítést klasszikus következtetési paradigmának nevezhetjük, és ez a modern pszichológiai és pszichiátriai kutatások elvégzésének domináns módszere.

Az elmúlt években a klasszikus következtetési megközelítést egyre inkább megkérdőjelezték a replikációval és a reprodukálhatósággal kapcsolatos problémák miatt. A p-értékek vizsgálatának értelmezésével és hangsúlyozásával kapcsolatos

komoly kérdések a replikációs válságnak nevezett jelenséghez vezettek (Ioannidis 2005, Schooler 2014), mivel a replikációs arányt a preklinikai vizsgálatok esetében 11%-ra becsülik (Begley & Ellis 2012). Az alacsony replikációs arány egyik oka, hogy a p-érték nem kifejezetten a replikáció vagy a reprodukálhatóság lehetőségét méri (Goodman 1992), és sok probléma esetében a 0,05-ös p-érték valójában azt jelenti, hogy a replikáció lehetősége körülbelül 50% (Goodman 1992, Nuzzo 2014). Ugyanezen a küszöbértéknél a neuroimaging-kutatásban az empirikus becslések azt mutatják, hogy 70% az esélye annak, hogy a szignifikáns eredmények hamis pozitívak, még akkor is, ha statisztikailag korrigálják őket a többszörös összehasonlításokra (Eklund et al. 2012, 2016). Ezek az eredmények széles körben elterjedt túlillesztésre utalnak, ahol a statisztikai modellek csak az aktuális minta zaját és sajátosságait tükrözik (Whelan & Garavan 2014), és statisztikailag szignifikáns, de nem reprodukálható eredményekhez vezettek (Goodman et al. 2016; Ioannidis 2005, 2016; Nuzzo 2014).

Még ha az eredmények reprodukálhatók is, a statisztikailag szignifikáns eredmények gyakran nem elegendőek (Ioannidis 2016). Elég nagy minták esetén statisztikai szignifikanciát lehet találni még olyan esetekben is, amikor a két csoport közötti különbség vagy a csoportokon belüli korreláció mérete (azaz a hatásméret) marginális (pl. genomszintű asszociációs vizsgálatok). A nagyobb hatás figyelembevételekor méreteket, nehézségek merülnek fel, amikor ezt a csoportszintű eredményt egy egyénre alkalmazzuk. Például a hatalmasnak (Cohen $d = 2,0$) definiált hatásméreteket (Sawilowsky 2009) az eseteknek csak körülbelül 64%-ában eredményeznék az eset helyes azonosítását a feldúsított pszichiátriai mintákban, 30%-os felhalmozási arány mellett a zavar előfordulási gyakoriságával (Abi-Dargham & Horga 2016, Fusar-Poli et al. 2013). A nem dúsított mintákban (pl. 1%-os prevalencia) a hatásméreteket, amelyek szükségesek lennének ahhoz, hogy egy személyt akár 50%-ban is pozitívan azonosítsanak, olyan magas tartományban vannak, hogy az nem valószínű, hogy megfelelő mintaméretekkkel (pl. Cohen $d \sim 4,0$). Mint ilyenek, a hatásméreteket jellemzően túl alacsonyak ahhoz, hogy a kutatás fordítása - egy olyan megfigyelés, amelyet korábban nem ismertek el szélesebb körben, mert a prediktív pontosság értelmes és intuitív mérései gyakran nem állnak rendelkezésre.

A hatásméreteket valószínűleg azért is mérsékeltek, mert a mentális egészségi zavarok összetett állapotok, amelyek környezeti, viselkedési, kognitív, érzelmi, viselkedési és érzelmi kölcsönhatásokat foglalnak magukban, és az egyes egyedekhez kapcsolódó biológiai rendszerek (Borsboom & Cramer 2013, Fornito et al. 2015, Molenaar & Campbell 2009, van de Leemput et al. 2014). Ezeknek a rendszereknek a modellezése olyan technikákkal, amelyek egymástól függetlenül foglalkoznak a kis komponensekkel csoportszinten, hasonlóan korlátozott hatásméreteket tárna fel, mivel a kritikus kölcsönhatások (Borsboom & Cramer 2013, Woo et al. 2017) és az egyéni különbségek

(Molenaar & Campbell 2009) kizárásra kerülne. Ez különösen igaz a neuroimaging területén, ahol az agyi régiók közötti ismert kölcsönhatásokat figyelmen kívül hagyják az univariáns technikák, amelyek feláldozzák a hűséget a lokalizálhatóságért (Lessov-Schlaggar et al. 2016), annak ellenére, hogy az erős hipotézis szerint a mentális egészségügyi zavarok elsősorban szétkapcsolódási szindrómák (Deco & Kringelbach 2014, Fornito et al. 2015). Ezek a korlátok hozzájárultak ahhoz, hogy a több ezer kutatási cikk ellenére nem fedeztek fel új-roimaging biomarkereket (Kapur et al. 2012), de a translációs pszichológiai kutatásokra is vonatkoznak, amikor a csoportalapú fogalmak (pl. látens faktorok) dominálnak, amelyek érvényessége megkérdőjelezhető, ha az egyénekre alkalmazzák (Molenaar & Campbell 2009). Ezekre a problémákra az uralkodó, klasszikus statisztikai kereteken belül is vannak megoldások.

A Silver-bullet okozó tényezőket még mindig megtalálhatjuk erősen kontrollált, hipotézisvezérelt, kísérleti vizsgálatokkal vagy hatalmas minták ($n > 10\,000$) metaanalízise során, univariáns (Schizophr. Work. Group 2014) vagy multivariáns technikákkal (Miller et al. 2016). Más, a helyes kutatási gyakorlatok előmozdítását célzó ötleteket is javasoltak, mint például a vizsgálat előtti valószínűségi becslések feltüntetése (Ioannidis 2005), a konfidenciaintervallumok jelentése (Cumming 2014), metaanalízisek elvégzése (Cumming 2014), vagy a feltáró eredmények előzetes regisztrálása egy adatbázisban, amelyet aztán az eredmények replikálására használnak (Nuzzo 2014). Ezek a javaslatok azonban többnyire kiegészítések ugyanahhoz a klasszikus paradigmához, amely alapvetően még mindig inkább csoportokra, mint egyénekre vonatkozik, az eredmények általánosíthatóságára vonatkozó megkérdőjelezhető következtetéseket tartalmaz, nem értékeli az eredmények klinikai lefordításának képességét, és nem úgy tervezték, hogy komplex, multimodális és tömegesen multivariáns adatokkal használják (Goodman et al. 2016). Ezért különböző megközelítések megfontolására lehet szükség e korlátok leküzdéséhez (lásd a Kutatásfordítás megkönnyítése című oldalsávot).

A gépi tanulás és miért van itt, hogy maradjon

A gépi tanulás tág értelemben olyan számítási stratégia, amely automatikusan meghatározza (azaz megtanulja) a módszereket és paramétereket egy probléma optimális megoldásának elérése érdekében, ahelyett, hogy az ember eleve egy rögzített megoldásra programozná. A mesterséges intelligencia (AI) egyik részterületének tekintik, mivel ez a tanulási folyamat feltételezhetően az emberi intelligencia egyik aspektusát szimulálja, és látszólag intelligens célokra használható (pl. beszéd, írás, arcfelismerés, önvezető autók vagy orvosi döntéstámogatók). A fogalom további

meghatározása és konkrét példák bemutatása érdekében más fontos fogalmak megértéséhez hasznosnak találjuk, ha a perceptron nevű történelmi géppel kezdjük, amely a digitális számítástechnika fejlődésével egy időben, az 1950-es években jelent meg (Bishop 2006). A perceptron megalkotóinak célja az volt, hogy olyan gépet építsenek, amely képes saját képleteket fejleszteni a problémák megoldására a tapasztalat révén (Rosenblatt 1958). Konkrétan úgy tervezték, hogy 400 fényérzékelőből háromszögek képeit azonosítsa, amelyek különböző formákat (pl. négyzeteket és háromszögeket) ábrázoló fény- és árnyékmintákat érzékeltek. Ahelyett, hogy a gépet felülről lefelé programozták volna, és megmondták volna neki, hogyan néz ki egy négyzet vagy egy háromszög, az ötlet az volt, hogy úgy építsék fel, hogy az alulról felfelé történő próbálkozás és hiba folyamatából, az úgynevezett tréningből tanulja meg a minta helyes feliratozását. A folyamatot a kísérletvezető felügyelte, aki a háromszögeket helyes válaszként, a többi alakzatot pedig hibaként jelölte meg. Sok kísérlet során a gép egy belső egyenlet vagy függvény segítségével módosította az egyes fényérzékelőkhöz tartozó statisztikai súlyokat. Egyes érzékelők (pl. a háromszög mintázatúak) válaszát nagyon erősen súlyozták a képzés során, míg másokét (pl. a négyzet mintázatúakét) nem, és ez a súlyozás határozta meg az előrejelzést. E tanulási folyamat teljesítményét egy címkézetlen képkészlet bemutatásával és a belső algoritmus pontosságának tesztelésével értékeltük. Ily módon a gép közvetlenül a háromszögminták kusza variációiból tanult, hogy létrehozza a minta internalizált, statisztikán alapuló reprezentációját - azaz a gép megtanulta a minta fuzzy fogalmát. A gépi tanulás kezdetei tehát a valós adatokból való tanulásra összpontosítottak, korlátozott előzetes feltételezésekkel a következőkről hogyan néznek ki ezek az adatok, és a gép teljesítményének értékelése valós körülmények között.

A perceptron segítette megváltoztatni a számítógépek szemléletét: a számológépekből, amelyeket eleve ismert képletekkel és szabályokkal kellett programozni (pl. a bolygómozgások előrejelzése), olyasvalamivé váltak, ami képes volt magától megtanulni a fuzzy szabályokat (pl. a minták azonosítása). Ez a korai siker nagy felhajtást generált, amely nagyrészt a mögöttes logika fantáziadús általánosítását jelentette más problémákra, ahol nincsenek explicit szabályok - főként a pszichológiában és az élettudományokban. A buborék azonban kipukkadt, amikor a korai algoritmusok korlátai és az akkoriban rendelkezésre álló számítási teljesítmény korlátai miatt a remények nem váltak valóra. E korlátok némelyike ma már orvosolható, mivel a számítási teljesítmény növekedése lehetővé teszi, hogy a gépek (amelyek ma már szoftverként instanciálódnak a digitális számítógépekben) olykor igen összetett adatokból tanuljanak olyan esetekben, ahol a hagyományos modellek és algoritmusok nem teljesítettek optimálisan (pl. arcfelismerés).

A gépi tanulási algoritmusok ma már beépültek a mindennapi életünkbe az internetes keresések és termékajánlások, a fordítási szolgáltatások, a beszédfelismerő szolgáltatások és az önvezető autók formájában (Jordan & Mitchell 2015). Az egészségügyben a gépi tanulási megközelítés a klinikusokéval azonos vagy annál jobb teljesítményt nyújtott olyan feladatokban, amelyek képeken történő mintafelismerést igényelnek, például a bőrrák (Esteva et al. 2017), a tüdőrák (Yu et al. 2016) és a szembetegségek (Long et al. 2017) felismerésében. Az orvosi képzéssel foglalkozó vállalatok már gépi tanulási algoritmusokat is integráltak ultrahangos eszközökbe a mellrák felismerésére (pl. Samsung, RS80A). Ezek a reklámok a gépi tanulással kapcsolatos kereskedelmi egészségügyi megoldások gyors növekedését segítik elő: magyar onkológiai cégek már alkalmazzák a technológiát (pl. <http://nanthealth.com/>), egyes cégeknél a befektetések meghaladják a 200 millió USD-t (iCarbonX; <https://www.icarbonx.com/en/>), és új növekedés tapasztalható a pszichiátria területén (pl. Spring; <https://www.springhealth.com/>). A gépi tanulás új hullámának korai sikerei jelentős népszerű spekulációkat tápláltak, amelyeket bizonyos fokú szkepticizmussal érdemes kezelni (Chen & Asch 2017), de egyértelmű, hogy a gépi tanulási technikákat továbbra is használni fogják, mivel számos probléma esetében jobban teljesítenek, mint a klasszikus megközelítések. Ez az áttekintés bemutatja, hogy az alulról felfelé irányuló megközelítés a modern gépi tanulási módszerekkel nagyban hozzájárulhat a klinikai pszichológiához és a pszichiátriához azáltal, hogy megváltoztatja a problémák figyelembevételének módját, többdimenziós, egymással összefüggő adatokkal foglalkozik, és általánosítható előrejelzéseket készít az egy alany szintjén.

A klinikai pszichológiában és pszichiátriában használt fontos gépi tanulási módszerek

Ez a rész a klinikai pszichológiai és pszichiátriai kutatók számára kulcsfontosságú gépi tanulási technikákat ismerteti. Hat szakaszra oszlik, amelyek a problémátípusoktól és az adatoktól a fejlett megközelítések magyarázatáig haladnak. További részletekért számos jól bevált és nagyra értékelt átfogó módszertani útmutató áll rendelkezésre a gépi tanuláshoz, amelyek formális statisztikai nomenklatúrát tartalmaznak (Bishop 2006, Hastie et al. 2009, James et al. 2015).

Problématípusok és adatok

A translációs klinikai pszichológia és pszichiátria gépi tanulással optimálisan kezelhető problémái négy fő kategóriába sorolhatók: diagnózis, prognózis, kezelés

előrejelzése, valamint a potenciális biomarkerek felderítése és nyomon követése. Ebben az összefüggésben a translációs gépi tanulás végső célja olyan eljárások létrehozása, amelyek a kliensek, a házi orvosok és a speciális kórházi környezetben a betegek eredményeinek javítása érdekében hasznosak lennének, például egy olyan döntéstámogató segédeszköz, amely klinikai vagy biológiai szignatúrákat használhat a diagnózis, a jövőbeli prognózis, az optimális kezelések javasolására, és a biológiai szignatúra monitorozását végezheti a kezelés sikerének objektív helyettesítőjeként. Az előrejelzések lehetnek osztályozások (pl. a személynek előnyös lesz az X kezelés) vagy regressziós keretek formájában, amelyek folyamatos becsléseket adnak (pl. a betegnek előnyös lesz az X gyógyszer egy adott dózisa). Az előrejelzéseket gépi tanulási technikákkal is ki lehet egészíteni az egyének alcsoportjainak azonosítására (pl. klaszterezés) vagy az egyének indexelésére egy populációs normához képest (Koutsouleris et al. 2014, Marquand et al. 2016). Bár nem képezi e felülvizsgálat középpontját, a gépi tanulást a számítógéppel támogatott pszichoterápia fejlesztésére is használják (Bohannon 2015).

Fontos, hogy az ebben a tanulmányban tárgyalt translációs gépi tanulási megközelítések kifejezett célja olyan modellek létrehozása, amelyek kellően értelmesek, pontosak és általánosíthatók ahhoz, hogy a klinikai ellátásba integrálhatók legyenek. A pontosság a modell per-formancia számos, a klasszikus statisztikai megközelítésekből származó intuitív mérőszámmal értékelhető, mint például az érzékenység, a specificitás és a pontosság (1. táblázat), és további munkák olyan mérőszámokat biztosítottak, amelyek a klinikai döntéseméletnek a modelloptimalizálásba való integrálásával fokozzák az értelmezhetőséget (Vickers & Elkin 2006). A nettó haszonelemzés például egy modell pontosságát indexálja előre meghatározott klinikai kritériumokhoz képest, amelyek a pozitív előrejelzés költség-haszon arányát tükrözik (pl. tíz egyén felmérésének szükségessége, amikor csak egynek lesz a rendellenessége). A pontos előrejelzések elérése érdekében bármilyen típusú kvantitatív adat felhasználható az elemzéshez, és kevesebb feltételezéssel (pl. normalitás, a variancia homogenitása) kell számolni, részben azért, mert a modellteljesítmény becslései empirikusan kerülnek meghatározásra. A gépi tanulás technikáit kifejezetten a nagy dimenzió-szerűségű (azaz sok változóval rendelkező) adathalmazok többváltozós elemzésére is tervezték, még akkor is, ha az esetek és a változók aránya korlátozott (Cortes & Vapnik 1995).

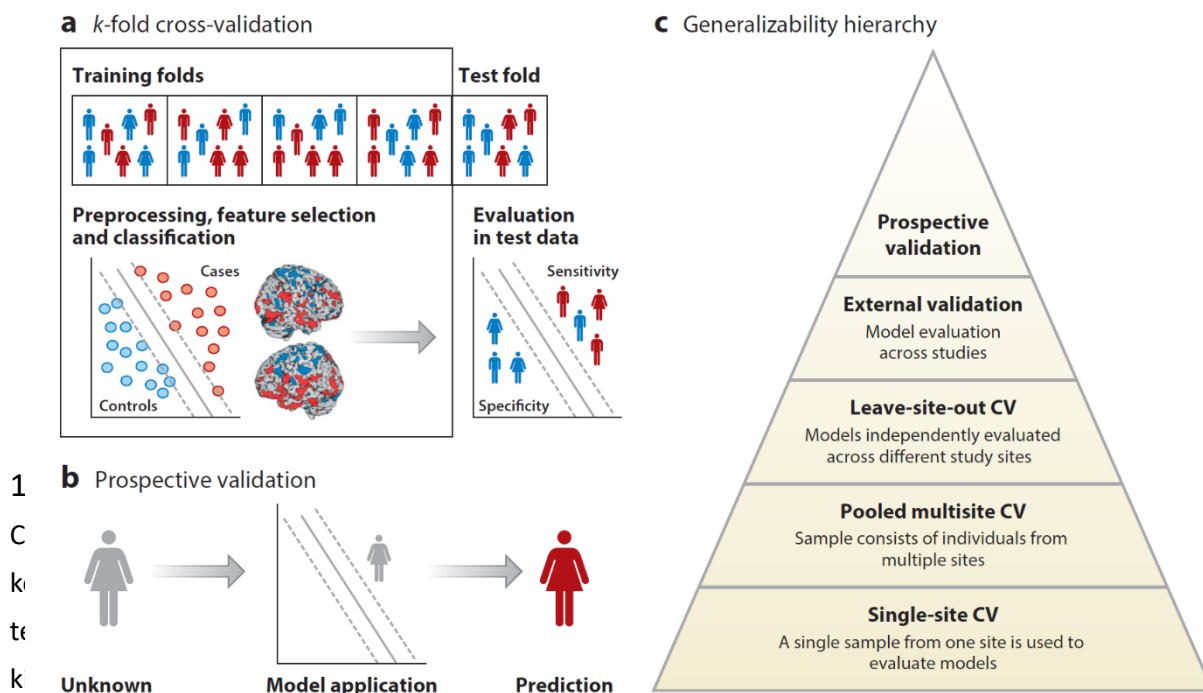
Általánosíthatóság és kereszt-validáció

Az általánosíthatóság tágan meghatározható, mint az a mérték, amelyben egy statisztikai modell, amelyet egy csoportban hoztak létre, pontosan működik új csoportok vagy egyének esetében. Ez egy hierarchiában értékelhető, amely magában foglalja a retrospektív és prospektív elemzéseket, amint azt az *1. ábra* mutatja. Az általánosíthatóság minden mintatervezés esetében becsülhető a modellek új mintára történő közvetlen alkalmazásával, számítógépes szimulációkkal vagy a két technika kombinációjával (Filzmoser et al. 2009, Koutsouleris et al. 2016, Stone 1974). Az egy mintán felépített és egy másik mintára alkalmazott statisztikai modellek alkalmazása az arany standard minden transzlációs tudományban (Cannon et al. 2016, Carrion et al. 2016), de a gépi tanulási megközelítésekben benne van az a képesség is, hogy ezt a folyamatot szimulálják (*1. ábra*).

Egy gépi tanulási keretrendszerben az általánosíthatóságot az adatokat újramintázó szimulációkkal (pl. bootstrapping) becsüljük meg, és optimalizálhatjuk. E technikák közül a keresztellenőrzés (cross-validation, CV) a legrobosztusabb, mivel elválasztja azokat az adatokat, amelyeken a modelleket megtanulják, azoktól az adatoktól, amelyeken tesztelik őket - vagyis hasonlóan a valós körülményekhez, amikor a modelleket új egyedekre kell alkalmazni. A CV egyszerű példája a leave-one-out séma, ahol egy tesztelt egyed visszatarthatnak egy mintából, a modellt a megmaradt gyakorló alanyokon készítik el, majd a modellt a kihagyott tesztalanyra alkalmazzák. Ezt megismételjük a minta összes alanyára, és az átlagos pontosságot kiszámítjuk a mintán kívüli általánosíthatóság becsléseként. Az egyszerűsége ellenére azonban a leave-one-out séma nem ajánlott az előrejelzések nagyfokú változékonysága, a torzított eredmények lehetősége és a hosszú számítási idő miatt (Hastie et al. 2009, Varoquaux et al. 2017).

Egy alternatív megközelítés a k-szeres CV, amelyben a mintát egyedek részhalmazaira, úgynevezett foldokra osztják (*1a. ábra*) (Stone 1974). Ebben az eljárásban egy teljes tesztmappát kihagyunk, a modellt a többi képzési adaton tanuljuk meg, és a modellt a kihagyott egyedeken teszteljük (pl. a kísérleti személyek 10%-át kihagyjuk, majd a többin képezzük). Ezt a folyamatot ezután egy előre meghatározott számú k hajtogatásra megismételjük, és stabilabb becsléseket eredményez a mintán kívüli általánosíthatóságra vonatkozóan, mivel a képzési csoportok változatosabbak, és a kihagyott tesztkészletekben több egyed van (Hastie et al. 2009). Gyakori kérdés, hogy hány hajtásból álljon használni, és bár a szerzők az 5- vagy 10-szeres CV-t (Breiman & Spector 1992) vagy statisztikai kritériumokat (Hastie et al. 2009, James et al. 2015) javasolják, ez nagyban függ a minta méretétől, a változók számától, a használt gépi

tanulási algoritmusoktól és attól, hogy más eljárásokat is használnak-e. A CV-nek nem kell a statisztikai kritériumokat figyelembe vennie (pl. a jellemzők kiválasztása).



specifitását. Ezt a folyamatot megismételjük az összes hajtogatásra. (b) Miután a modelleket retrospektív, címkézett adatokon létrehoztuk, prospektíven alkalmazhatjuk őket új egyénekre, hogy előrejelzést készítsünk. (c) Az általánosíthatóságot egy hierarchiában lehet értékelni, ahol a modelleket az egyének, a kontextusok (pl. időbeli és földrajzi) és a populációk (pl. genetikai, kulturális, diagnosztikai vagy egyéb) egyre változatosabb kiválasztásánál alkalmazzák. Az egy helyszínen végzett CV (alul) a legelterjedtebb, és magában foglalja a CV-t használó modellek létrehozását és értékelését egyetlen helyszínen (pl. egyetlen kórházban vagy klinikán), így mérve az általánosíthatóság mértékét a különböző egyénekre vonatkozóan az adott befogadási területen. Az összevont, több helyszínen végzett CV több helyszínről származó alanyok kombinációját foglalja magában a modellek létrehozásához és értékeléséhez, és a modell általánosíthatóságának egyszerű tesztje az egyének és a kontextusok között. A Leave-site-out CV a kontextus általánosíthatóságának sokkal szigorúbb tesztje, amely a képzési és tesztelési folyamat során kifejezetten elkülöníti a kísérleti helyszíneket. Ebben a keretrendszerben egy helyszínt teszthelyszíneként kihagynak, a modelleket a fennmaradó helyszíneken képzik ki, és a modelleket a kihagyott helyszínen értékelik, így hatékonyabban értékelik, hogy egy modell mennyire általánosítható új kontextusokra és populációkra. A külső validálás egy olyan technika, amelyet akkor alkalmaznak, amikor a modelleket korábban (CV vagy más módon) generálták, és egy másik vizsgálatból származó új adatokra alkalmazzák (pl. különböző egyének, kontextusok és gyakran vizsgálati protokollok). A prospektív validáció magában foglalja a már meglévő modellek alkalmazását új egyénekre akár klinikai vizsgálatban, akár valós körülmények között.

A belső, egymásba ágyazott CV1 ciklusban lévő vizsgálati alanyokra való általánosíthatóságot meg lehet tanulni, mielőtt a modelleket végül a külső, CV2 ciklus teljesen kimaradt alanyaira alkalmazzák (Varma & Simon 2006). A multicentrikus konzorciumi alapú vizsgálatokon belül (pl. PRONIA; <https://www.pronia.eu>) szintén lehetőség van annak felmérésére, hogy a modellek mennyire általánosíthatók a különböző földrajzi helyszíneken, egy leave-site-out design segítségével (Konig et al. 2007, Koutsouleris et al. 2016) (1c. ábra). Ebben a kialakításban egy helyszínt kihagyunk, a modelleket a többi helyszínen képezzük ki, és az előrejelzéseket a kihagyott helyszínre alkalmazzuk; ez a kialakítás így a helyszínek közötti általánosíthatóság mérőszámát adja, amely szintén optimalizálható egy egymásba ágyazott CV kialakításban, ami kritikus lépés a kifejezetten az általánosíthatóságot fokozó modellek kialakításában. További alkalmazások az általánosíthatóság többféle formájának értékelését és optimalizálását foglalják magukban a kihagyott hajtások kiválasztásával (pl. időbeli, földrajzi, genetikai, kulturális, diagnosztikai vagy kísérleti).

Mérés	Leírás
Érzékenység	A pozitív teszteredményt (azaz valódi pozitív eredményt) mutató érintett esetek aránya az összes érintett esethez viszonyítva.
Specifititás	A nem fertőzött esetek aránya negatív teszteredménnyel (azaz valódi negatív) az összes nem fertőzött esethez viszonyítva.
Pontosság	A helyesen megjósolt esetek aránya az összes esethez viszonyítva.
Kiegyensúlyozott pontosság	Az egyes pozitív és negatív csoportok mintaméretével kiegyensúlyozott valódi pozitív és negatív esetek pontossága; kiegyensúlyozatlan mintaméretű modellek optimalizálására szolgál.
Pozitív prediktív érték	Annak a valószínűsége, hogy a pozitív teszteredményt mutató esetek valóban pozitívak; pl. "a pozitív teszteredményt mutató egyének 60%-ának megvan a betegsége".
Negatív prediktív érték	Annak a valószínűsége, hogy a negatív teszteredményt mutató esetek valóban negatívak; pl. ha egy személyt tesztnegatívnak minősítenek, akkor 77% az esélye annak, hogy a teszt helyes.
Pozitív valószínűségi arány	A valódi pozitív teszteredmény valószínűsége osztva a hamis pozitív eredmény valószínűségével, 1 a legalacsonyabb határérték.
Negatív valószínűségi arány	A hamis negatív teszteredmény valószínűsége osztva a valódi negatív teszteredmény valószínűségével, alsó határértékként 1-gyel.
Diagnosztikai esélyhányados	Annak a valószínűségnek az aránya, hogy a teszt pozitív a betegsége pozitív eredményt adó alanyok esetében, a negatív eredményhez viszonyítva.
Görbe alatti terület	A teszt diszkriminatív képességét reprezentáló terület 0,5 (nincs diszkrimináció) és 1 (tökéletes diszkrimináció) között.
Youden-index	Az érzékenység és a specifititás mínusz 1 szorzata -1 (nincs megkülönböztetés) és 1 (tökéletes megkülönböztetés) közötti tartományban.
Nettó haszon	A valódi pozitív esetek aránya mínusz a hamis pozitív esetek aránya, a hamis pozitív esetek előre meghatározott arányával indexálva (pl. 10-ből 1 tévesen azonosított eset).

1. táblázat Az eredmények értelmezéséhez és az előrejelzések optimalizálásához használt teljesítménymutatók

Előfeldolgozás

Ahhoz, hogy a CV hatékony legyen, a képzési és a tesztadatokat teljes elkülönítése kritikus fontosságú minden elemzési lépésnél. Ez vonatkozik minden olyan előfeldolgozó statisztikai műveletre, amelyet az adatokon az osztályozás vagy regresszió előtt el kell végezni - pl. skálázás, imputálás, zavaró variancia eltávolítása, jellemzőválasztás vagy dimenziócsökkentés. Ezek a lépések egy CV-csatornába ágyazódnak, ahol az előfeldolgozási lépések paraméterei a képzés során teljesítménykritériumok alapján optimalizálhatók (lásd például az 1. táblázatot), és tesztkészletekre alkalmazhatók. Ha az előfeldolgozási lépéseket a CV-n kívül végzik, akkor a tanulási folyamat során a tesztalanyokra vonatkozó információk is bekerülhetnek, és ez az információszivárgás aláássa az általánosíthatóság értékelését. Az információszivárgás gyakori példája az az eset, amikor a jellemzők kiválasztása a teljes mintában való előrejelző képességük alapján történik (pl. agyi régiók kiválasztása két csoport teljes agyi összehasonlításából), majd a CV-t ezeknek a változóknak a felhasználásával végzik el. Az általánosíthatóságra vonatkozó becslések ilyen körülmények között érvénytelenek és felfújtak, mivel a jellemzők már optimalizálásra kerültek a mintában lévő vizsgálati alanyok számára (Varma & Simon 2006).

Az előfeldolgozási technikák megválasztása az adatoktól, a használandó modelltől és a megválaszolandó kérdés. Egyes módszerek olyan lépéseket követnek, amelyeket bármely statisztikai elemzésnél elvégeznének, mint például a zavaró kovariánsokkal (pl. életkor vagy nem) kapcsolatos variancia eltávolítása, a minimális varianciájú változók eltávolítása vagy a hiányzó értékek imputálása. A nagy adathalmazokkal kapcsolatos gépi tanulási kontextusokban az előfeldolgozás egyik fontos aspektusa a dimenziócsökkentés, amely magában foglalja az adatok átalakítását egy nagy dimenziós térből (azaz sok változóból) egy alacsonyabb dimenziós térbe (azaz kevesebb változóba), miközben az adatokban lévő információ megmarad (más néven adattömörítés) (Van Der Maaten et al. 2009). A dimenziócsökkentési technikák közé tartoznak az általános statisztikai módszerek, például a főkomponens-elemzés, amelyek célja az adathalmazban lévő variancia magyarázata a komponenseknek nevezett, korrelálatlan változók matematikai meghatározásával (Hotelling 1933). A jellemzőcsökkentés olyan körülmények között fontos, amikor az adathalmaz dimenzionalitása aláássa a modellek általánosíthatóságát, és elhomályosítja az eredmények megértését (pl. idegrendszeri képalkotás vagy genetika). A jellemzők számának csökkentésére szolgáló egyéb technikák közé tartoznak a szűrők, amelyek a változókat egy előre meghatározott statisztikai teszt alapján választják ki, amint azt alább tárgyaljuk (pl. korreláció a célváltozóval).

Az előfeldolgozás erőssége egy keresztvalidált gépi tanulási csővezetékben az, hogy az egyes lépések statisztikai paraméterei automatikusan meghatározhatók, hogy egyensúlyt teremtsenek a képzés során a maximális pontosság elérésének fontossága és a modelleknek a tesztmintára való általánosítási képessége között. Például az elemzés után megtartott főkomponensek mennyiségének rögzítése helyett az általánosíthatóságot fokozó optimális számot a képzési folyamat során (vagy ennek megfelelően a tesztalanyokon végzett, egymásba ágyazott CV1 cikluson belül) lehet megtanulni. Ez megkönnyíti a empirikus megközelítés a paraméterek meghatározására, amelyeket gyakran hüvelykujjszabályok, alapértelmezett beállítások vagy a tudományterületeken belüli normák vezérelnek, amelyek önkényesek lehetnek, és általában konkrét problémákhoz és elemzési technikákhoz kapcsolódnak (pl. simítási paraméterek a képalkotáshoz, p-érték kritériumok a genomikában vagy könyökkritériumok a főkomponensekhez). Az optimalizálási folyamatnak azonban vannak korlátai, mivel a gyakorló- és tesztadatokhoz való túlillesztés lehetősége a tesztelt paraméterkombinációk számának (azaz a paraméterternek) a függvényében nő. Mint ilyen, a CV-séma és a mintaméret megválasztása kritikus ebben a folyamatban, ahol nagyobb paraméterter esetén erősebb általánosíthatósági tesztekre van szükség, és gondosan meg kell fontolni, hogy milyen módon választjuk ki a legjobban teljesítő paramétereket (Eberhart & Kennedy 1995, Snoek et al. 2012). Végül a paraméterteret és az optimalizálási folyamatot gyakran Occam borotvája vezérli, hogy a maximális általánosíthatóság elérése érdekében a komplexitással szemben a takarékoságot részesítsük előnyben (kivéve az alább tárgyalt úgynevezett mély tanulási modelleket).

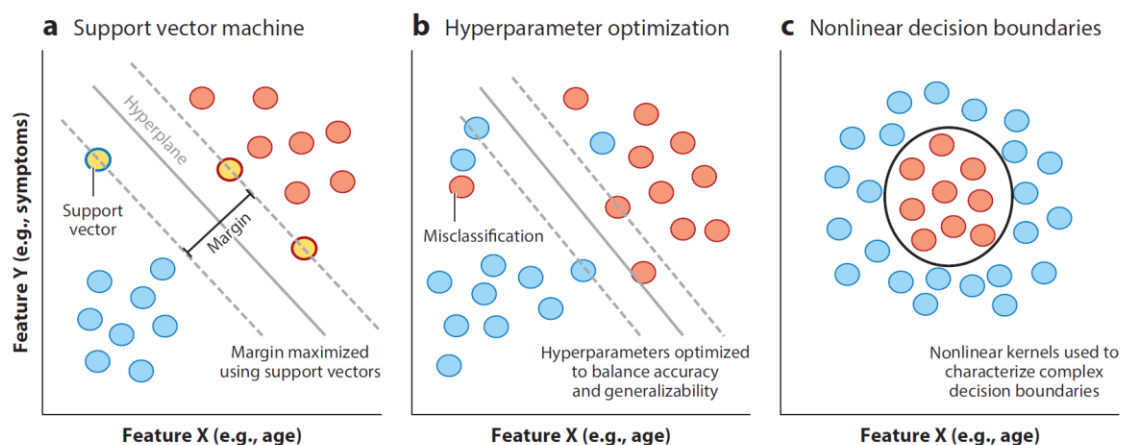
Gépi tanulás Algoritmusok

A gépi tanulás megközelítésének központi eleme az az algoritmus, amelyet az osztályozás, regresszió, klaszterezés vagy normatív modellezés elvégzésére használnak. Ezek nagyjából elkülöníthetők felügyelt technikákra, ahol az esetek címkézve vannak (pl. diagnosztikai csoportokba), felügyelet nélküli technikákra, ahol a cél egy címkézetlen minta rokon esetek csoportjaira való felosztása, valamint félig felügyelt technikákra, amelyek címkézett és címkézetlen eseteket tartalmaznak. A rendelkezésre álló algoritmusokat gyakran a gépi tanulás területén belül fejlesztették ki, de az előfeldolgozó algoritmusokhoz hasonlóan a statisztikai kultúrákban más népszerű módszereket is gyakran használnak (pl. k-means).

A gépi tanulásban használt algoritmusokat általában az egyesíti, hogy képesek optimalizálni a függvényhez kapcsolódó szabályokat módosító hiperparamétereket. A

végső cél olyan hiperparaméterek tanulása, amelyek optimalizálják a modellt egy előre meghatározott cél elérésére (pl. pontosság az 1. táblázatban és általánosíthatóság az 1. ábrán). Például a legkisebb négyzetek módszerét alkalmazó klasszikus regressziós keretrendszerben egy megoldás van, egy egyenest illesztünk az adatokra, és az együtthatók rögzítettek. A regresszió további gépi tanulási fejlesztései azonban olyan regularizációs hiperparamétereket adtak hozzá, amelyek módosíthatók a pontosságot és az általánosíthatóságot optimalizáló modell meghatározásához (pl. Ridge, LASSO, Elastic Net) (Zou & Hastie 2005). E hiperparaméterek konkrét értékeit CV segítségével lehet megtanulni a képzési folyamat során, majd alkalmazni a tesztadatokra, míg a függvény alapvető paramétereit (pl. az együtthatókat) a kiválasztott hiperparaméterek alapján határozzák meg és módosítják (pl. egy objektív függvény minimalizálása gradiens ereszkedéssel). A regularizációs hiperparaméterek a legkisebb négyzetek regresszióját rugalmas módszerré alakítják át, amely úgy hangolható, hogy maximalizálja az egyensúlyt a függvény képzési adatokhoz való optimális illeszkedése és az új, egyedi alanyokra való általánosítás között (a regularizált regresszió pszichiátriában történő alkalmazásáról lásd Chekroud et al. 2016).

Számos gépi tanulási algoritmust fejlesztettek ki, és ez nem tartozik ennek a cikknek a tárgykörébe áttekintés, hogy az összeset lefedje (pl. véletlen erdő, neurális hálózatok és döntési fák). Egy további, a pszichiátriában legszélesebb körben használt példa azonban a támogató vektorgép (SVM) (Arbabshirani et al. 2017, Kambeitz et al. 2015, Orru et al. 2012). Az SVM egy többváltozós (vagy regressziós terminológiában többváltozós) felügyelt tanulási technika, amely érzékenyen osztályozza az egyéneket csoportokba egy margóalapú statisztikai keretben (James et al. 2015). Ezt a technikát azért fontos tárgyalni, mert a korai többváltozós mintafelismerő algoritmusokból ered (Fisher 1938), amelyek célja az volt, hogy automatikusan felfedezzenek szabályszerűségeket a többváltozós adatokban egy cél (pl. egyének csoportokba sorolása vagy eredmények előrejelzése) teljesítése érdekében (Bishop 2006). A regressziós technikákhoz hasonlóan a statisztikai mintafelismerési technikákat is gépi tanulási kontextusokra optimalizálták.



2. ábra A támogatott vektorgépes (SVM) megközelítés koncepcionális ábrázolása a felügyelt osztályozáshoz. (a) Az SVM algoritmus úgy működik, hogy a csoporteloszlások belső határán lévő eseteket (piros és kék) azonosítja, hogy egy hipersík alapján olyan margót építsen, amely maximálisan elválasztja a különböző címkékkel rendelkező eseteket. A hipersík határozza meg a csoporttagságot a képzési és tesztelési mintákon belül. (b) Egy modern soft-margin SVM (Cortes & Vapnik 1995) hiperparaméterei úgy hangolhatók, hogy egyensúlyt teremtsenek a pontosság között a képzési halmazban és az általánosíthatóság között a tesztadatokban. Ebben az esetben a C paraméter módosítása olyan optimálisan általánosítható döntési határhoz vezetett, amely két eset téves osztályozását eredményezi. (c) Nemlineáris kernelek használhatók összetett döntési határok jellemzésére, mint például az ezen a panelen ábrázolt kör alakú döntési határ.

Az SVM megközelítést a 2. ábra szemlélteti, ahol az eseteket egy kétdimenziós térben reprezentáljuk, és a cél egy olyan lineáris határvonal vagy hipersík meghatározása, amely az aktuális esetek optimális osztályozására és a jövőbeli (nem címkézett) esetekre való általánosításra használható. Ahelyett, hogy az összes esetet felhasználná a hipersík elhelyezésének kiszámításához, az SVM algoritmus csak az eloszlások legközelebbi külső határán lévő eseteket használja - ezeket az eseteket nevezzük támaszvektoroknak. Ezután a támaszvektorok felhasználásával egy margót lehet definiálni azzal a céllal, hogy maximalizáljuk a margók és a hipersík közötti távolságot. A margó méretét és a téves osztályozás mértékét meghatározó paraméterek manipulálhatók, hogy egyensúlyt teremtsenek a helyes osztályozás céljai között a gyakorlóhalmazban és a tesztalmazra való általánosíthatóság között. Alkalmazható például egy kemény margó, amely szorosan illeszkedik a képzési adatokhoz, mivel nem engedi, hogy egyetlen esetet is tévesen osztályozzanak, de ez a margó nem biztos, hogy jól általánosítható. Alternatív megoldás lehet egy lágy margó, amely lehetővé teszi, hogy az esetek a margón belül legyenek vagy tévesen legyenek besorolva, azzal a céllal, hogy növelje az általánosíthatóságot - a téves besorolások engedélyezése - azáltal, hogy csökkenti a képzés során a túlillesztést (Cortes & Vapnik 1995), növeli az

általánosíthatóságot (2. ábra). A margó és a félreosztályozás engedélyezése a C hiperparaméteren keresztül szabályozható, amely a CV-folyamat során optimalizálható vagy hangolható egy cél elérése érdekében (pl. a legnagyobb pontosság a tesztalanyoknál).

Az SVM algoritmus egyes aspektusai az idők során tovább fejlődtek, így többek között képesek jellemezni a nemlineáris hipersíkok jellemzésére egy kernelfüggvény által megvalósított adattranzformáció segítségével (Hastie et al. 2009, James et al. 2015). Nemlineáris problémák esetén az adatokat egy kernel segítségével egy hozzáadott dimenzióval rendelkező térbe transzformáljuk, vagy leképezzük (pl. egy harmadik dimenzió, amely a Gauss-eloszlás alapján torzítja az adatokat). Ebben a térben egy lineáris határvonal használható a pontok elkülönítésére, de ha az adatokat visszavetítjük az eredeti dimenziókba, egy összetett, nemlineáris döntési határvonal jelenik meg (2. ábra). Például egy polinomiális kernel segítségével az eredeti térben görbült döntési határt kaphatunk, vagy egy radiális bázisfüggvény kernel létrehozhat egy körkörös döntési határ komplex problémák esetén. E kernelek paraméterei, amelyek a nemlinearitás mértékét határozzák meg, a képzési folyamat során is hangolhatók a tesztmintában az általánosíthatóság optimalizálásának céljával. A regresszióhoz való alkalmazkodáshoz hasonlóan a gépi tanulás központi eleme az a folyamat, amelynek során megtanuljuk, hogy melyek a legjobb paraméterek a modell illeszkedésének és általánosíthatóságának kiegyensúlyozására.

Jellemzők kiválasztása

A jellemzők kiválasztása bizonyos változók kiválasztása egy nagyobb halmazból a pontosság és az általánosíthatóság növelése érdekében. A gépi tanulás problémái jellemzően nagyon nagy dimenziójúak (pl. agyi képek, hang- vagy videofájlok), és a jellemzőteret (azaz az egyes esetek többdimenziós reprezentációját az egyes jellemzők értékei alapján) gyakran csökkenteni kell ahhoz, hogy általánosítható előrejelzéseket kapjunk a dimenzionalitás átka miatt - ahol a jellemzők növekvő száma az esetekhez képest alacsonyabb pontosságot és általánosíthatóságot eredményez. A gépi tanulás kontextusában a jellemzők kiválasztása elvégezhető és optimalizálható az előfeldolgozás részeként, ahogyan azt fentebb tárgyaltuk, vagy kombinálható magával a gépi tanulási algoritmussal.

A beágyazott jellemző kiválasztására példa, amikor a gépi tanulási algoritmusok olyan matematikai-matematikai regularizációs feltételeket alkalmaznak, amelyek nullára csökkentik az egyes jellemzők relatív hozzájárulását (pl. LASSO-regresszió), hatékonyan eltávolítva a befolyásukat, és meghagyva a leginkább előrejelző és nem

redundáns jellemzőket. Egy másik módszer egy olyan számítási megközelítés, az úgynevezett wrapper alkalmazása, amely szisztematikusan alkalmazza a különböző jellemzőkészletekkel végzett külön elemzéseket, hogy megtalálja az előre meghatározott méretű (pl. az összes jellemző 60%-a vagy 70%-a) legjobban általánosítható kombinációt. Például a mohó forward wrapperek alapvetően két lépést alkalmaznak: (a) minden egyes jellemzőre külön prediktív algoritmusokat (pl. SVM-eket) futtatnak, a legjobb jellemzőt egy előre meghatározott szabály (pl. pontosság) szerint kiválasztják, majd hozzáadják egy jellemzőkészlethez; és (b) minden egyes fennmaradó jellemzőt külön-külön hozzáadnak a készlethez, ismét külön SVM-eket futtatnak, és kiválasztják a legjobb kombinációt. A második lépést ezután addig ismételjük, amíg el nem éri a kísérletvezető által meghatározott kritériumot, hogy egy parsimonikus többváltozós jellemzőkészletet kapjunk (ennek az eljárásnak az alkalmazását lásd: Koutsouleris et al. 2016). Ezeket az eljárásokat a CV-n belül végezzük a túlillesztés csökkentése és az általánosíthatóság növelése érdekében.

Haladó Megközelítések

A gépi tanulási megközelítés ereje az elemzés (hy-per)paramétereinek automatikus meghatározásában rejlik, de abban is, hogy a pontosság és az általánosíthatóság maximalizálása érdekében több, eltérő paraméterekkel rendelkező modell is használható. A CV alkalmazásával végső soron több modellt is előállíthatunk a képzési adatok felhasználásával, amelyek eltérő optimális hiperparaméter-beállításokat vagy jellemzőkészleteket tartalmazhatnak. Az alárendelt belső CV-ciklussal rendelkező, egymásba ágyazott CV-tervezés esetén ezeket a potenciálisan eltérő modelleket végül a tesztkészletre alkalmazzák, hogy meghatározzák az adott egyénre vonatkozó előrejelzést. Ezt a folyamatot ensemble-tanulásnak nevezik (Polikar 2006), és azon az érvelésen alapul, hogy a központi tendencia mértéke valószínűleg jobban megadja a pontosság legáltalánosabb szintjének értékelését (Galton 1907).

Ha a prediktív problémát úgy tekintjük, hogy olyan modellek halmazát keressük, amelyek együttesen a legpontosabb és legáltalánosabb megoldást adják, a standard megközelítés kibővíthető. Például a késői fúzióknak nevezett folyamat során a különböző algoritmusok (pl. lineáris és nemlineáris SVM-ek) csővezetékei úgy optimalizálhatók, hogy az egyén egy csoportba tartozásának mértékét reprezentáló pontszámok (azaz a döntési pontszámok) összeolvadnak, és egy átlagos pontszámot eredményeznek, amelyet a végső döntés meghozatalához használnak. Fogalmilag ez ahhoz hasonló, mintha egy különböző területek (pl. klinikai, kognitív, neuroimaging és genetikai) szakértői bizottságának szavazatait vennénk figyelembe, hogy egy végső előrejelző

eredményt kapjunk. A fogalmilag kapcsolódó, halmozott általánosításnak nevezett technika különböző modellek képzését, a képzési populáción belüli döntési pontszámok kombinálását, majd ezekből a döntési pontszámokból egy másik tanulási algoritmus használatát jelenti a végső előrejelzéshez (Wolpert 1992). Ezt tágabb értelemben metatanulásnak is nevezik, mivel a modelleket más modellek kimeneteinek egy rétegéből tanulják. A fenti analógiát klinikai környezetben használva ez hasonló ahhoz, mintha egy bizottság vezetője lenne, aki az összes szakorvos tagjainak javaslataiból tanul, mielőtt önállóan hozná meg a végső döntést. A késői fúzióhoz hasonlóan a halmozás is alkalmazható különböző adatmodalitásokra vagy különböző algoritmusokat (pl. lineáris és nemlineáris modelleket) alkalmazó modellekre.

Ezek a fúziós és egymásra épülő módszerek együttesen azért hasznosak, mert lehetővé teszik a többváltozós minták speciális tanulását az egyes feltételezett rendszereken belül (pl. agy, gének, kogníció vagy érzelem), a rendszerek közötti tanulás mellett, az optimális pontosság és általánosíthatóság érdekében. A meta-tanulás gondolata fontos fogalom olyan területeken, mint a mélytanulás (LeCun et al. 2015), ahol egy gép több rétegből tanul, amelyek különböző módon reprezentálják az adatokat. A fenti analógiában a mélytanulási folyamat inkább hasonlít ahhoz, mintha a probléma kisebb összetevőire (pl. egy-egy agyterületre vagy klinikai kérdésre) szakemberek lennének, majd e szakemberek ajánlásait kombinálva egy végső döntést hoznának. A mélytanulást még nem alkalmazták széles körben a pszichiátriában, mivel nagy mennyiségű adatra van szükség ahhoz, hogy hatékonyan leküzdjük a dimenziósság és a túlillesztés átkát a potenciálisan több ezer hiperparaméter-kombinációval összefüggésben - azaz a tanulási folyamat finomabb részletességéhez több adatra van szükség.

A kutatás szelektív áttekintése szakirodalom

A többváltozós képleteket a huszadik század eleje óta használják diagnosztikai, prognosztikai és kezelési döntésekhez, amikor a nomogramok kritikus szerepet játszottak a gyermekbénulás kezelésében (West 2005), és ma már széles körben elérhetőek az interneten (<https://www.mskcc.org/nomograms>). Az eredményekre vagy kezelési döntésekre vonatkozó többváltozós képleteket azonban kevésbé széles körben használták a klinikai pszichológiai vagy pszichiátriai gyakorlatban (de lásd Cannon et al. 2016, Perry et al. 1998), valószínűleg a szükséges előrejelzések összetettsége miatt. Az alábbi általános és szelektív áttekintés arra összpontosít, hogy a gépi tanulás hogyan könnyítheti meg a kutatás fordítását a diagnózisok, prognózisok és kezelési kimenetel-előrejelzések optimalizálására, valamint az összes előrejelzéshez indexként használható

biomarkerek felderítése érdekében. Az egyes területek átfogó irodalmi áttekintéséhez az olvasót Arbabshirani et al. (2017), Gabrieli et al. (2015), Kambeitz et al. (2015, 2016), Orru et al. (2012) és Woo et al. (2017) átfogó cikkeihez irányítjuk.

Diagnózis

A korai gépi tanulási tanulmányok többnyire azt vizsgálták, hogy az egyének közötti diagnosztikus felosztások rekonstruálhatók-e nagydimenziós adatok, különösen a strukturális és funkcionális neuroképalkotás segítségével (Arbabshirani et al. 2017, Orru et al. 2012). A vizsgálatok túlnyomórészt az Alzheimer-kórra (Kloppel et al. 2008), a depresszióra (Fu et al. 2008) és a skizofréniára (Csernansky et al. 2004, Davatzikos et al. 2008) összpontosítottak, de újabban egyre inkább kiterjesztették a diagnosztikai spektrumot, beleértve a szorongásos zavarokat (Lueken et al. 2015), az anorexiát (Lavagnino et al. 2015), a kábítószerrel való visszaélést (Whelan & Garavan 2014) és a specifikus fóbiákat (Visser et al. 2016). A kutatások a nem képalkotó modalitások, például genetikai (Pettersson-Yeo et al. 2013), metabolizmus (Setoyama et al. 2016) és proteomikai adatok (Diniz et al. 2016) felhasználására is kiterjedtek. Összességében a meglévő szakirodalom azt sugallja, hogy a gépi tanulás 75% feletti pontossággal használható a pszichiátriai rendellenességben szenvedő egyének azonosítására az agyi adatok alapján (Arbabshirani et al. 2017; Kambeitz et al. 2015, 2016) - Schnack & Kahn (2016) azonban kritikus áttekintést nyújt az ebben a szakirodalomban közölt pontosságokról.

Az egy diagnózisból megismert aláírások felhasználhatók a klinikai kérdések tisztázására. Az egyik ígéretes kutatási irány a klinikai hasznosságra összpontosít azokban az esetekben, amikor a diagnózisok nem egyértelműek (azaz differenciáldiagnosztika), és amikor a jelenlegi értékelések összetettek, időigényesek és költségesek, mint például az enyhe kognitív zavar (Davatzikos és mtsai. 2008) vagy a pszichózis mentális kockázati állapota (Koutsouleris és mtsai. 2009). Tekintettel például arra, hogy a bipoláris esetek akár 75%-át tévesen diagnosztizálják unipoláris depresszióval (Fajutrao et al. 2009, Hirschfeld et al. 2003), Redlich és munkatársai (2014) gépi tanulással megtanulták azt az agyi szignatúrát, amely a diagnózis felállításakor a legjobban elkülönítette az eseteket (Redlich et al. 2014). Ezt a szignatúrát aztán egy teljesen más mintában az esetek elkülönítésére használták, ahol a téves diagnózis aránya mindössze 31% volt. Egy másik esetben Koutsouleris és munkatársai (2015) megtanultak egy olyan szignatúrát, amely elválasztotta a depressziót a skizofréniától, és ezt a szignatúrát olyan bizonytalan diagnózisú mintákban használták, mint az első epizódú pszichózis és a pszichózis magas kockázatú

állapota. Hasonló munkát végeztek a különböző demenciák elkülönítésére is (Kloppel és mtsai. 2008). Ezek a vizsgálatok azt jelzik, hogy a diagnosztikai vizsgálatok során megismert neuroanatómiai szignatúrák klinikai döntést segítő eszközként használhatók bizonytalan diagnosztikai körülmények között.

A diagnosztikai gépi tanulási tanulmányok a tömeges egyváltozós tesztelés problémáival foglalkoznak (Abi-Dargham & Horga 2016, Lessov-Schlaggar et al. 2016, Whelan & Garavan 2014) és a leíró, csoportalapú elemzések (Gabrieli et al. 2015) által, olyan többváltozós szignatúrákat biztosítva, amelyek egy alany szintjén érvényesek, és biomarkerként használhatók a betegség előrehaladásának vagy egy kezelés hatékonyságának nyomon követésére (Woo et al. 2017). Az előrejelzéseket azonban korlátozza a széles körű klinikai definíciók által bevezetett tüneti és neuroanatómiai heterogenitás, amely a mintanagyság növekedésével fokozódik (Schnack & Kahn 2016). A folyamatban lévő erőfeszítések ezért a pszichiátriai csoportok heterogenitásának feloldására irányulnak a nem felügyelt gépi tanulás alkalmazásával, hogy automatikusan felismerjék az egyének alcsoportjait a kognitív (Wu et al. 2016), genetikai (Arnedo et al. 2015), agyi funkcionális (Clementz et al. 2016, Drysdale et al. 2017, Du et al. 2015) vagy agyszerkezeti adatok hasonló profiljai alapján (Fair et al. 2012, Marquand et al. 2016, Varol et al. 2016). Más megközelítések a heterogenitást egy referenciapopulációra való hivatkozással elemzik (Marquand et al. 2016). Bár az eredmények vegyesek, vannak arra utaló jelek, hogy ez az altípusmeghatározás nagyobb prediktív pontosságot eredményez a mentális betegségben szenvedő egyének azonosításában az egészséges kontrollszemélyekhez képest (Drysdale et al. 2017, Fair et al. 2012).

Prognózis

Az egyén prognosztikai kimenetelének meghatározása kritikusan fontos a klinikai pszichológiában és a pszichiátriában a kezelés, a pszichoedukáció, valamint a megelőző pszichoterápiás és farmakológiai beavatkozások biztosítása szempontjából. Jelenleg a legjobb, amit objektív bizonyítékokkal meg lehet tenni, hogy feltételezzük, hogy az egyén a klinikai tünetek és jelek (pl. skizofrénia) alapján egy diagnosztikus csoportba tartozik, majd a populációs átlagokra hivatkozunk (pl. 50% esély a remisszióra) (Harrison és mtsai. 2001, Hegarty és mtsai. 1994, Wunderink és mtsai. 2009). Idővel ezek a jóslatok könnyebbé válnak (pl. ha a betegnek évek óta krónikus és tartós lefolyása van, akkor ez valószínűleg folytatódni fog) (Hegarty és mtsai. 1994), de a betegség kezdetén a prognózisok pontatlanok (Wunderink és mtsai. 2009). A pontos rétegzés hiánya a szükségtelenül kezelt egyének számának (azaz a szükséges kezelések

számának) inflálódását eredményezi (Alvarez-Jimenez és mtsai. 2011, Siskind és mtsai. 2016, van der Gaag és mtsai. 2013). A rétegzett prognosztikai előrejelzések meglete tehát hasznos lenne a kezelés tervezéséhez, hogy meghatározhatók legyenek a betegség lefolyása során a kulcsfontosságú csomópontok, például a magas kockázatú állapotból a kritérium epizódba való átmenet, a visszaesések vagy remissziók, valamint a tünetek súlyosságában, a mindennapi működésben és az életminőségben bekövetkező változások.

A kutatások ígéretes eredményeket mutattak a betegség lefolyásának előrejelzésében a különböző rendellenességek esetében. Legalább 27 neuroimaging vizsgálat létezik az enyhe kognitív károsodásból az Alzheimer-kórba való átmenet előrejelzésére, amint arról a közelmúltban készült áttekintések beszámoltak (Arbabshirani et al. 2017), amelyek átlagosan 70% feletti előrejelzési pontosságot mutatnak. A pszichózisba átmenő betegekkel foglalkozó tanulmányok szintén hasonló előrejelzési arányt mutatnak neuroimaging (Koutsouleris et al. 2009, 2012, 2015), elektrofiziológiai (Ramyeed et al. 2016) és klinikai mérések (Mechelli et al. 2017) segítségével. Depresszióban Schmaal és munkatársai (2015) a strukturális és funkcionális feladat alapú mágneses rezonancia képalkotás (MRI) adatfúziójával gépi tanulási megközelítést alkalmaztak a depresszió pályájának (krónikus, javuló és gyors remisszió) jellemzésére 2 év alatt, és hasonló előrejelzési arányokat értek el. Más, depresszióval kapcsolatos tanulmányok önbevallásos klinikai kérdőíveket is használtak a betegség lefolyásának előrejelzésére (Kessler és mtsai. 2016) vagy esetenylvántartásokat az egyének öngyilkossági kockázat alapján történő rétegzésére (Modai és mtsai. 2002, Tran és mtsai. 2014). Az egyének rétegzését olyan modellek alapján is elvégezték, amelyek a jövőbeni kábítószerrel való visszaélést neuroimaging adatok alapján (Bertocci és mtsai. 2017), valamint demográfiai, klinikai, kognitív, neuroimaging és genetikai adatok kombinációinak felhasználásával jelzik előre (Whelan és mtsai. 2014). Ezek a tanulmányok rávilágítanak arra, hogy a prognosztikai értékelések optimalizálása érdekében az egyének csoportokra történő rétegzése lehetséges. Példaként Koutsouleris és munkatársai (2016) a pszichózis első epizódjában szenvedő egyének funkcionális kimenetelét jósolták meg 189 kérdőív-tétel segítségével, amelyeket 44 mentálhigiénés központban gyűjtöttek össze. Egy leave-center-out CV-dizájnt (1. ábra) használtak a modellek földrajzi és kontextuális lefordíthatóságának empirikus értékelésére egy olyan csővezetékben belül, amely skálázásból, imputálásból állt a hiányzó adatértékek kitöltésére, valamint egy olyan funkcióválasztási folyamatból, amely egy wrapper (greedy-forward search) segítségével készült. Az elemzés eredményei rávilágítottak arra, hogy a kimeneteleket 70% feletti pontossággal lehetett megjósolni 4 hetes és 12 hónapos időszakokra, és hogy az elhagyott CV nem csökkentette jelentősen ezt a pontosságot. A jellemzőkészletet a legjobban teljesítő változók közül mindössze 10-re lehetett redukálni, hogy 72%-os pontossággal lehessen megjósolni a pozitív kimeneteleket, ami több mint 40%-kal jobb volt, mint a minta méretének arányában a gyógyuló egyének alaparánya. Így a tanulmány rávilágít a gépi tanulási megközelítés

erősségére az általánosíthatóság mérésében és a jellemzők olyan takarékos halmazainak létrehozásában, amelyek felhasználhatók új kérdőívek létrehozásához.

Páciensek eredményeinek mérése.

További kutatási irányok közé tartozik a pszichózis (de Wit et al. 2017, Tognin et al. 2014) és a kényszerbetegség (Askland et al. 2015, Hoexter et al. 2013) tüneti súlyosságának és kimenetelének folyamatos méréseinek előrejelzése. A fentiekben tárgyaltakhoz hasonló, de regressziós algoritmusokat (pl. supportvektor-regressziót) alkalmazó pipelinek használatával ezek a tanulmányok szerény prediktív értéket találtak. Egy másik ígéretes irány magában foglalja az elektronikus egészségügyi nyilvántartások használatát. Egy nemrégiben készült tanulmányban több mint 70 000 egyént értékelték, hogy megjósolják jövőbeli egészségi állapotukat egyéves időszakra vonatkozóan egy dimenziócsökkentésre és véletlen erdő algoritmusokra összpontosító csővezeték segítségével (Miotto et al. 2016). Az eredmények azt mutatták, hogy a figyelemhiányos hiperaktivitási zavar és a skizofrénia körülbelül 0,85-ös görbe alatti területtel (azaz nagy pontossággal) volt előrejelezhető.

Kezelések

Jelenleg nincsenek objektív, személyre szabott módszerek arra, hogy az optimális pszichoterápiás és farmakológiai kezelés kialakításakor több lehetőség közül lehessen választani. A kezelési döntéseket kezdetben gyakran a tünetek széles körű osztályozásán - például a depresszió, a szorongás vagy a pszichózis megtapasztalásán - alapuló ajánlások irányítják, és idővel a kipróbálás és tévedés folyamatán keresztül személyre szabottá válnak (Rush és mtsai. 2006, Wong és mtsai. 2010). Ez a kísérleti orvosi megközelítés problematikus annak a kutatásnak az összefüggésében, amely azt mutatja, hogy az antidepresszánsokkal történő kezdeti kezelést követően a depresszióban szenvedő egyének 11-30%-a tünetremissziót mutat (Rush és mtsai. 2006, Wong és mtsai. 2010), és a kognitív viselkedésterápiára adott válaszok aránya az állapotok például szorongás esetén csak 46% (Hofmann és mtsai. 2012). Különösen a kezelés megkezdésekor jobb technikákra van szükség a bevált gyógyszeres és pszichoterápiás technikák közötti választáshoz, valamint az olyan új technikákhoz, mint a nem invazív agyi stimuláció.

A kezelési döntések gépi tanulással történő kiegészítését az 1990-es évek óta végzik, a korai tanulmányok a klinikai esetnyilvántartásokból történő előrejelzések készítésére összpontosítottak pszichotikus és depressziós fekvőbetegek esetében (Modai és mtsai. 1993, 1996). Ezek a tanulmányok széles körben a kezelés több formájára vonatkozó javaslatok

készítésére összpontosítottak, beleértve a farmakoterápiát, pszichoterápiát vagy közösségi terápiát, és a teljesítmény a jelentések szerint hasonló volt a klinikai döntésekhez (Modai és mtsai. 1993, 1996). A korai pszichiátriai, de az orvosi szakterületeket átfogó elemzések egyik korlátja azonban az volt, hogy a randomizált klinikai vizsgálatokon kívüli, kis, egyközpontú mintákra korlátozódtak (Lisboa 2002). Ezenkívül a számítási korlátok miatt ritkán használtak biológiai adatokat, amelyek ma már mindennaposak (pl. MRI vagy genetika), és objektív biomarkereket biztosíthatnak a kezelési döntések irányításához (Insel & Cuthbert 2015). Emellett azok az algoritmusok, amelyek teljesítményük miatt a pszichiátriai gépi tanulásban standardokká váltak (pl. SVM), akkoriban még fejlesztés alatt álltak (Cortes & Vapnik 1995).

Az újabb gépi tanulási kutatások a nagyméretű, több helyszínes adatbázisok erejét használták ki és fejlett biológiai adatforrások a kezelési döntések segítésére. A farmakológiai döntéstámogató segédeszközökkel kapcsolatos kutatások különösen hasznosak voltak a depresszió esetében, ahol a tanulmányok nagy mintákat ($n > 1000$) használtak a különböző gyógyszerekre (pl. eszitalopram, szertralin, venlafaxin, citalopram) adott válasz előrejelzésére (Chekroud és mtsai. 2016, Etkin és mtsai. 2015). Chekroud és munkatársai (2016) például a citalopram klinikai vizsgálatán (Star-D) (Rush et al. 2006) belül (Rush et al. 2006) végzett mintafelismerési vizsgálatot egy 1949 főből álló mintán. Egy k-szoros CV-ből álló csővezeték segítségével rugalmas hálós regresszióval 25 klinikai kérdőíves elem parsimonikus előrejelző mintázatát észlelték az összesen 164, a betegek által jelentett változóból. Ezek a változók 65%-os arányban jelezték előre a klinikai remissziót, ami több mint 30%-kal meghaladta a gyógyszer előre jelzett hatékonyságának alaprátáját. A modellek általánosíthatóságát az is bizonyította, hogy egy teljesen más mintában is képesek voltak remissziót előre jelezni, és a modellek érvényességét a specifikusságuk is kiemelte, amikor nem általánosítottak más gyógyszeres kezelésekre. Figyelemre méltó, hogy az előrejelzések nagyfokú általánosíthatósága további kutatásokkal együtt (Chekroud et al. 2017) megkönnyítette a modellek gyors lefordítását egy webalapú alkalmazásba, amelyet úgy terveztek, hogy döntéstámogatást nyújtson az elsődleges egészségügyi szolgáltatók és az ügyfelek számára (<https://www.springhealth.com>). Ezt a gépi tanulási szolgáltatást jelenleg kórházi környezetben prospektívan tesztelik, ami még inkább rávilágít a közvetlen kutatási fordítás lehetőségére.

Míg a klinikai értékelések hasznos döntéstámogató segédeszközöket nyújthatnak, addig egy kiegészítő irány az agy szerkezetének és működésének beépítése. Az e téren megjelenő tanulmányok szerint az elektroencefalográfiai mérések hasznosak a depresszió (Khodayari-Rostamabad és mtsai. 2013) és a skizofrénia (Khodayari-Rostamabad és mtsai. 2010) gyógyszeres kezelésre adott válasz előrejelzésében. A biológiai értékelések különösen fontosak lehetnek azokban az esetekben, amikor a kezelés invazív, például az elektrokonvulzív terápia alkalmazása esetén, ahol egy nemrégiben végzett vizsgálat szerint az agyszerkezet 78%-os pontossággal képes előre jelezni a kezelésre adott választ (Redlich és mtsai. 2014). Az agyi adatokon alapuló prediktív modellek a nem invazív beavatkozások esetében is hasznosak, az

agyi funkcionális MRI-t a szorongásos spec-trum állapotok kognitív viselkedésterápiájára adott válasz előrejelzésére használják 75% feletti pontossággal - azaz 30-40%-kal jobb, mint a kezelésre adott válasz alaparánya (Ball et al. 2014, Doehrmann et al. 2013, Hahn et al. 2015, Whitfield-Gabrieli et al. 2016). Az e területen végzett jövőbeli kutatások várhatóan akkor is előnyösek lesznek, ha a kezelést közvetlenül a biológiai méréssel hozzákapszólják, például ha az agyszerkezetet használják az agyi stimulációra adott re-reakció előrejelzésére (Hasan és mtsai. 2017). A biológiai méréseket alkalmazó jövőbeli tanulmányok azonban az általánosíthatóság követelményeinek teljesítéséhez nagyobb mintanagyságra és külső validálásra lesz szükség (1. ábra).

Bár fontos, hogy az egyén számára a megfelelő időben a megfelelő kezelést válasszuk (Insel & Cuthbert 2015), ezt a választást a költség-haszon aránynak is motiválnia kell, amely a kezelések lehetséges tüneti hatásait a káros kockázatokkal, mellékhatásokkal, invazivitással, a kezeléssel szembeni esetleges ellenállással, valamint a szükséges idő- és pénzügyi költségekkel szemben mérlegeli. Végső soron ezek a lehetőségek független módon megismerhetők és beépíthetők egy klinikai döntéshozatali eszközbe, amely kiegyensúlyozza a kezelési döntést. Az e területen fellendülőben lévő kutatások a kezelés mellékhatásait, például az antipszichotikus kezelést követő metabolikus szindrómát (Van Schependom et al. 2015) és a kezelési rezisztenciát (Perlis 2013) vizsgálják, de további kutatásokra van szükség ezen a területen.

Korlátozások és jövőbeli irányok

Pszichiátriai gépi tanulási tanulmányokat már több mint 20 éve végeznek (pl. Modai és mtsai. 1993), a tanulmányok legújabb hulláma az elmúlt 10 évben zajlott az algoritmusok és a számítási teljesítmény fejlődésének köszönhetően. Ilyen előzmények ismeretében felmerül a kérdés, hogy a metódusokat miért nem használják szélesebb körben a klinikai gyakorlatban, tekintettel a fordítási potenciáljukra. A klinikai gyakorlathoz kapcsolódó kulturális normák mellett a kutatási fordítás hiányának egyéb okai lehetnek a diagnosztikai és prognosztikai címkék érvényessége, a képzési adatok reprezentativitása, az észlelt minták mechanisztikus megértése, az általánosíthatóság robusztus számszerűsítése, a modellek előny-kockázat arányának meghatározása és a gyakorlati megvalósítás.

A diagnosztikai és prognosztikai címkék érvényessége

Az eddig használt előrejelzési célok túlnyomórészt olyan kutatási mintákon alapultak, amelyeket klinikailag szubjektív tüneteken és jeleken alapuló kritériumok alapján határoztak meg (Insel & Cuthbert 2015). Ezek a minták heterogén egyénekből állnak, akiket a tünetek,

jelek és társbetegségek sokféle lehetséges kombinációja alapján diagnosztizálnak. Hasonlóképpen, a tüneteken vagy funkcionális eredményeken alapuló prognosztikai címkéknek többféle értelmezése lehet (pl. a működés általános értékelése) (Torgalsboen & Rund 2002). Ezek a címkék és az általuk létrehozott het-erogenitás akadályozhatja a mechanizmusok és biomarker-szignatúrák gépi tanulási módszerekkel történő felfedezésére irányuló kísérleteket, és végső soron a legjobb előrejelző modelleket a klinikai ellátás számára (Insel és mtsai. 2010, Schumann és mtsai. 2014). Az összefoglaló intézkedések és széles kategorizálások helyett a jövőbeli gépi tanulási kutatások más kezdeményezéseket követhetnek a specifikusabb kritériumok, például tüneti területek (pl. kognitív funkciók, mint például a végrehajtó funkciók) előrejelzésében (Gabrieli et al. 2015, Insel et al. 2010) vagy objektív biológiai markerek, amelyek átvágják a diag-nosztikus határokat (Insel & Cuthbert 2015, Woo et al. 2017). Az objektív biomarkerek gépi tanulással történő felfedezése különösen értékes lenne az új, célzott (pl. farmakológiai vagy pszichoterápiás) kezelések fejlesztése, valamint a kezelés hatásainak vagy a betegség progressziójának objektív mérése szempontjából.

A képzési adatok reprezentativitása

A kísérleti kutatások általában olyan tervezést alkalmaznak, amely a populáció átlagának tiszta becslésére törekszik - pl. a skizofréniában szenvedő egyének kvintesszenciális példáinak megtalálása más tényezők, például társbetegség, gyógyszeres hatások vagy különböző klinikai értékelők hatása nélkül. Ha azonban a cél egy általánosítható előrejelző algoritmus létrehozása, akkor a mintának reprezentatívnak kell lennie arra a heterogén populációra, amelyre a valós életben alkalmazni fogják. Részben emiatt a neuroképalkotó gépi tanulási vizsgálatokban a nagyobb mintanagyságok általában alacsonyabb előrejelzési pontosságot eredményeznek a heterogenitás növekedése miatt (Arbabshirani et al. 2017, Schnack & Kahn 2016). Például, ha a vizsgálatot kizárólag egy helyszínen végzik, akkor előfordulhat, hogy még egy nagyon nagy minta is csak az adott helyről származó jövőbeli esetekre általánosítható a módszerek (pl. értékelő skálák), anyagok (pl. egy adott szkennertípus) vagy résztvevők (pl. kulturális homogenitás) sajátosságai miatt. A jövőbeni kutatásoknak ezért kifejezetten figyelembe kell venniük az általánosíthatóságot a transzlációs célú kutatások tervezésekor vagy jelentéskészítéskor. Bármely erős általánosíthatósági állításhoz több különböző helyszínen vagy különböző központokban végzett tesztek adatgyűjtése szükséges (lásd az 1. ábrát), és ez egyetlen konzorciumalapú kutatás részeként is elvégezhető (lásd PRONIA, <https://www.pronia.eu/>; NAPLS, <https://campuspress.yale.edu/napls/>; PSYSCAN, <http://www.psycan.eu/>), több konzorcium adatainak kombinálásával vagy adatmegosztási kezdeményezések, például az ADNI (Mueller et al. 2005), ENIGMA (Thompson et al. 2014) vagy

SchizConnect (Wang et al. 2016) segítségével. A nagy adatmegosztási kezdeményezések által nyújtott támogatás szintén alapvető fontosságú lesz az általánosítható előrejelzések létrehozásához, mint például a European Open Science Cloud (lásd <https://ec.europa.eu/research/openscience>).

Az észlelt minták mechanisztikus megértése

A jelenlegi technikák egyik korlátja, hogy az egy alanyra vonatkozó, prediktív minták átláthatatlanabbak, mint az egyszerűbb csoportalapú statisztikák és módszerek (pl. nomogramok). Emiatt a gépi tanulási modelleket fekete dobozoknak tartják, mert nehéz értelmezni, hogyan működik egy modell, vagy különösen azt, hogy egy alany miért került besorolásra (Hart & Wyatt 1990). Ez egy kritikus korlátozás, de figyelemre méltó, hogy a meglévő módszerek valóban lehetővé tesznek egy bizonyos fokú értelmezést (pl. változó importancia) globális szinten, amely betekintést nyújt abba, hogyan működik egy modell (Koutsouleris et al. 2015, 2016). Míg az egy alany szintjén a legújabb módszertani fejlesztések már lehetővé teszik a betekintést az egyének konkrét osztályozásának okaiba (Bastani et al. 2017, Fong & Vedaldi 2017, Guo et al. 2017, Koh & Liang 2017, Tulio Ribeiro et al. 2016), és az orvosi környezetben már végzett proof-of-concept tanulmányok (Katuwal & Chen 2016, Yang et al. 2016). Ezek az adaptációk és a meglévő technikák kiegészítései meg fogják adni azt a konkrét változóprofil, amely az adott egyénre vonatkozó előrejelzéshez vezetett (pl. egy súlyozott egyszemélyes agyi térkép vagy egy konkrét klinikai profil), amely aztán felhasználható az osztályozási modell fokozott mechanisztikus megértéséhez, a klinikai ellátás tervezésében, valamint az ügyfelek és gondozóik számára történő kommunikációhoz.

A általánosíthatóság robusztus számszerűsítése

Ahhoz, hogy az általánosíthatóságra vonatkozó állítás érvényes legyen, nem szabad, hogy a tesztadatokról nem szándékos emberi tanulás történjen - például amikor az optimális paramétertartományokat ugyanazon minta korábbi keresztellenőrzött elemzéseiből származó eredmények alapján határozzák meg. A konzorciumokon vagy adatmegosztó kollektívákban belüli védekezés érdekében a címkéket egy független szervezetnek kell kezelnie (pl. egy becsületes bróker megközelítésben), hogy elősegítse a külső validálási eredmények átláthatóságát. Miután a modelleket létrehozták, azokat továbbítani lehet a központi adattárba, és alkalmazni a visszatartott adatokra. Tekintettel a szoftverek és technikák heterogenitására, ezt olyan szolgáltatások használatával lehetne elérni, mint a Docker (<https://www.docker.com/>) vagy a ViPAR (Carter et al. 2015), hogy a kutatást a gépi tanulás

átláthatóságának jelenlegi szabványaihoz igazítsák (Brown et al. 2012, Silva et al. 2014). A gépi tanulási modellek (azaz az elemzéshez szükséges összes lépést tartalmazó) repozitóriumokat is létre lehetne hozni, hogy bármely kutató tesztelhesse az általánosíthatóságot saját mintáján, és új kérdésekre adhasson választ, például arra, hogy a depresszió, a skizofrénia és a bipoláris zavar agyi szignatúrái hogyan alkalmazhatók a személyiségzavarokkal küzdő egyénekre.

Gyakorlati Végrehajtás

Bármely újszerű technika alkalmazásának első fázisa a tesztelés és a felfedezés, ahol az általános cél az, hogy bizonyítani lehessen, hogy a technika működik, és fel lehessen tárni a lehetséges vizsgálati utakat (Woo et al. 2017). Transzlációs szempontból azonban sok korai tanulmány vagy olyan kérdéssel foglalkozik, amely klinikailag nem azonnal hasznos (pl. a krónikus skizofrénia diagnózisa), vagy nehezen kivitelezhető széles körben a gyakorlatban (pl. feladatalapú funkcionális MRI-tervek). Függetlenül a technika általánosíthatóságától, sok módszer nem valószínű, hogy az egészségügyi környezetben bevezetésre kerül, egyszerűen azért, mert nem állnak rendelkezésre, túl sok képzést igényelnek, vagy ami a legfontosabb, kereskedelmileg nem életképesek. Ezért fontos, hogy a jövőben inkább a technika átültetésének gyakorlati megvalósíthatóságát vegyük figyelembe, mint annak elméleti lehetőségét, hogy ez valamikor a jövőben (meghatározatlan) időpontban lehetséges lesz. Ez szükségszerűen magában foglalja a klinikusok és a klinikai kutatók hozzájárulását, hogy a módszertani előrelépések hasonlóan fejlett klinikai érveléssel párosuljanak a jelenlegi klinikai eljárások hatékonyságának javítása érdekében.

A gépi tanulási módszerek fordításának másik nagy akadálya, hogy a technikák

Sok klinikus és klinikai kutató számára szükségtelenül nehezen érthető és kivitelezhető. Ez a felülvizsgálat megkísérelte a kritikus technikák megértését, és van néhány kiváló tankönyv, amely segítheti a kutatókat a statisztikai ismeretekkel (pl. James et al. 2015). A kutatás fontos további iránya az olyan szoftverek létrehozása, amelyek nem igényelnek fejlett programozási készségeket (pl. PRoNTO; <http://www.mlml.cs.ucl.ac.uk/pronto/>). Az egyik ilyen szoftvercsomag, amelyet kifejezetten a klinikai pszichológusok és pszichiáterek számára fejlesztettek ki, hogy segítsen az ebben a felülvizsgálatban bemutatott kérdések megválaszolásában, a mi csoportunktól elérhető, és a NeuroMiner (<https://www.pronia.eu/neurominer/>) nevet viseli. Ezzel az eszközzel a kutatók különböző CV-sémákat alkalmazhatnak, előfeldolgozást hajthatnak végre, gépi tanulási algoritmust választhatnak, és a modelleket grafikus felületen keresztül értelmezhetik. Ez a szoftver számos

tanulmányban bizonyította hasznosságát házon belüli eszközként (Koutsouleris et al. 2009, 2015, 2016), egy nagyszabású konzorciumi alapú projektben (PRONIA; <https://www.pronia.eu/>) és más laboratóriumokkal való közös kutatásban (Opel et al. 2017).

A jövőbeni klinikai ellátás

Tekintettel a gépi tanulási módszerek közelmúltbeli sikereire több területen, változatos adattípusok felhasználásával (Esteva et al. 2017, Koutsouleris et al. 2016, Long et al. 2017, Yu et al. 2016), ez a cikk azt próbálja bemutatni, hogy ezek a módszerek képesek a kutatások fejlett diagnosztikai, prognosztikai, kezelésválasztási és biomarker-felismerési eljárásokba való átültetéséhez vezetni a klinikai pszichológiában és pszichiátriában. Előre tekintve, a hatalmas adathalmazokból (pl. UK BioBank) származó adatok egyre szélesebb körű elérhetőségével (Miller et al. 2016) és a számítógépesített egészségügyi ellátásra való folyamatos átállással (Wachter 2015) a pszichiátriában és a pszichológiában történő alkalmazás lehetősége egyre nő. Ez a megvalósítás számos formában történhet, beleértve a nyilvánosan elérhető algoritmusok használatát, integrált kórházi alapú megoldások létrehozását (pl. Long et al. 2017), vagy több információforrás nyomon követését olyan integrált adatbázis-hálózatok segítségével, amelyek az egészségügyi rendszeren belül és kívül gyűjtött adatokat (pl. okostelefonokból és más érzékelőkből) tartalmazzák (Mohr et al. 2017). A klinikus számára ez azt jelenti, hogy a diagnosztikai, prognosztikai és kezelési döntésekkel kapcsolatos előrejelzések állhatnak rendelkezésre, amelyek kiegészíthetik az ellátást.

A betegellátás javításának lehetőségei mellett komoly lehetőségek is fennállnak eljárási és etikai kérdéseket is figyelembe kell venni. Mint minden új eljárás bevezetésekor orvosi technológia, változások lehetnek a gyakorlatban és potenciálisan bizonyos speciális orvosi szerepekben (pl. radiológia) (Jha & Topol 2016), ezért folyamatos kommunikációra van szükség az orvosok között és az ellenérvek mérlegelésére (Chen & Asch 2017, Rosenbaum 2015). A központi ügynökségek (pl. az Élelmiszer- és Gyógyszerügyi Hivatal vagy az Európai Gyógyszerügynökség) előírásait is gondosan figyelembe kell venni a széles körű használatra alkalmas tesztek és módszerek kifejlesztéséhez. Ez különösen a biomarkerek fejlesztésére vonatkozó olyan irányelvekkel való konzultációt és azok végrehajtását jelenti, amelyek magukban foglalják az akadémiai, ipari, kormányzati és konzorciumi együttműködéseket a minősítéshez szükséges erős bizonyítékalapok kialakítása és a kockázatok előre meghatározott szabályozási utakon keresztül történő értékelése érdekében (Amur et al. 2015, Goodsaid & Mattes 2013, Woodcock et al. 2011).

A prognosztikai eszközök bevezetésének etikai következményeit is komolyan figyelembe kell venni. Például az arra vonatkozó előrejelzés, hogy egy egyénnek lehet-e újabb pszichózisos epizódja, befolyásolhatja a lehetőségeivel és a gondozásával kapcsolatos elvárásokat, ami

hozzájárulhat egy iatrogén önbeteljesítő jóslathoz, ahol nagyobb a valószínűsége annak, hogy a jóslat valóra válik. Hasonló problémákra világítottak rá olyan példákban, amikor a gépi tanulási algoritmusok a társadalomban már meglévő diszkriminatív előítéleteket erősítik meg (O'Neil 2016). Ezek a problémák újra fenntartható tanulási módszereket igényelnek, amelyek a modelleket idővel újrakalibrálják a változó kontextusokkal (Widmer & Kubat 1996), de a robotok előrejelzéseinek szoros nyomon követését és etikai felügyeletét is szükségessé teszik. Ha a gépi tanulási algoritmusok beépülnek a jövőbeli klinikai ellátásba, ahogyan már beépültek a mindennapi életünkbe, akkor fontos lesz ezt a folyamatot erkölcsi és etikai szempontból figyelemmel kísérni és szabályozni. Ebből a célból fontos partnerségeket hoztak létre a mesterséges intelligenciával foglalkozó szervezetek (<https://www.partnershiponai.org/>), de szükség lesz független hozzájárulásra is, különösen akkor, ha kereskedelmi haszon vagy érdekek fűződnek a dologhoz.

Következtetések

A gépi tanulás témája ugyanúgy magában foglalja a problémák megközelítését, mint a konkrét módszerek összességét. Ez a megközelítés alapvetően arra irányul, hogy többváltozós adatokból tanuljon információt a kutatás fordításának pragmatikus céljának teljesítése érdekében, azáltal, hogy inkább az egyénekre, mint a csoportokra vonatkozó eredményeket jósolja meg. A módszereket kezdik szélesebb körben alkalmazni a klinikai pszichológiában és a pszichiátriában, és ígéretes jövőbeli irányt kínálnak a transzlációs kutatás és végső soron a klinikai ellátás számára. Mint minden újonnan megjelenő technológiánál, itt is körültekintően kell eljárni, hogy leküzdjük az optimista elfogultságokat, és különösen, hogy mindig azoknak az embereknek az érdekeit szolgáljuk, akiknek a technológia segíteni hivatott.

Összefoglalás

1. A diagnosztikai, prognosztikai és kezelési döntések javíthatók lennének a klinikai pszichológiában és pszichiátriában alkalmazott domináns statisztikai módszertan korlátainak kezelésével.
2. A gépi tanulás olyan számítási stratégia, amely automatikusan meghatározza (azaz megtanulja) a módszereket és paramétereket egy probléma optimális megoldásának elérése érdekében, ahelyett, hogy egy ember programozná be, hogy a priori rögzített megoldást adjon.

3. Az általánosíthatóság a gépi tanulás központi eleme, és több szinten, különböző egyének és kontextusok esetében kell értékelni, hogy megismételhető kutatásokat és végül gyakorlatilag hasznos modelleket lehessen létrehozni.
4. A statisztikai csővezetékek keresztellenőrzött rendszerekbe ágyazva az adatműveletek előfeldolgozásából és egy statisztikai függvény létrehozásából állnak. Az adatműveletek paraméterei automatikusan kerülnek meghatározásra (azaz megtanulásra) azzal a céllal, hogy növeljék az előrejelzési pontosságot és az általánosíthatóságot.
5. Új statisztikai technikák (pl. SVM) állnak rendelkezésre, amelyek képesek többváltozós és nemlineáris függvényeket (azaz mintákat) találni a nagy dimenziójú adatokban. Módszerek állnak rendelkezésre e modellek kombinálására a legnagyobb előrejelzési pontosság és általánosíthatóság elősegítése érdekében.
6. Az eddigi kutatások bizonyítják a gépi tanulási technikák sikerét az egyének rétegzésében a diagnosztikai, prognosztikai és kezelési döntések tekintetében. Ezeket a döntéseket segítheti a biomarkerek jobb kimutatása és nyomon követése.
7. A jövő klinikai pszichológiája és pszichiátriája kombinálhatja a gépi tanulási algoritmusok használatát a meglévő kísérleti tervekkel a transzlációs kutatás fokozása és a klinikai eszközök gyakorlati alkalmazása érdekében.

A jövő feladatai

1. A meglévő diagnosztikai és prognosztikai címkék érvényessége folyamatos mérlegelést igényel.
2. Növelni kell a minta reprezentativitását és a gépi tanulási modellekkel kapcsolatos általánosíthatóságot.
3. További kutatásokra van szükség a modellek működésének mechanisztikus megértéséhez.
4. A kutatási tervek és elemzések transzlációs megvalósíthatóságát szélesebb körben kell értékelni és hangsúlyozni.
5. Hozzáférhető gépi tanulási oktatásra és eszközfejlesztésre van szükség a megértés és használat megkönnyítése érdekében a szélesebb klinikai kutatóközösségben.
6. A gépi tanulási algoritmusok klinikai gyakorlatban történő szélesebb körű alkalmazásával párhuzamosan az erkölcsi és etikai kérdések további mérlegelésére is szükség van.

Szakirodalom

- Alvarez-Jimenez M, Parker AG, Hetrick SE, McGorry PD, Gleeson JF. 2011. Preventing the second episode: a systematic review and meta-analysis of psychosocial and pharmacological trials in first-episode psychosis. *Schizophr. Bull.* 37:619–30
- Amur S, LaVange L, Zineh I, Buckman-Garner S, Woodcock J. 2015. Biomarker qualification: toward a multiple stakeholder framework for biomarker development, regulatory acceptance, and utilization. *Clin. Pharmacol. Ther.* 98:34–46
- Arbabshirani MR, Plis S, Sui J, Calhoun VD. 2017. Single subject prediction of brain disorders in neuroimaging: promises and pitfalls. *NeuroImage* 145:137–65
- Arnedo J, Svrakic DM, del Val C, Romero-Zalaz R, Hernandez-Cuervo H, et al. 2015. Uncovering the hidden risk architecture of the schizophrenias: confirmation in three independent genome-wide association studies. *Am. J. Psychiatry* 172:139–53
- Askland KD, Garnaat S, Sibrava NJ, Boisseau CL, Strong D, et al. 2015. Prediction of remission in obsessive compulsive disorder using a novel machine learning strategy. *Int. J. Methods Psychiatr. Res.* 24:156–69
- Ball TM, Stein MB, Ramsawh HJ, Campbell-Sills L, Paulus MP. 2014. Single-subject anxiety treatment outcome prediction using functional neuroimaging. *Neuropsychopharmacology* 39:1254–61
- Bastani O, Kim C, Bastani H. 2017. Interpretability via model extraction. arXiv:1706.09773 [cs.LG]
- Begley CG, Ellis LM. 2012. Drug development: raise standards for preclinical cancer research. *Nature* 483:531–33
- Bertocci MA, Bebeko G, Versace A, Iyengar S, Bonar L, et al. 2017. Reward-related neural activity and structure predict future substance use in dysregulated youth. *Psychol. Med.* 47:1357–69
- Bishop CM. 2006. *Pattern Recognition and Machine Learning*. New York: Springer
- Bohannon J. 2015. The synthetic therapist. *Science* 349(6245):250–51
- Borsboom D, Cramer AO. 2013. Network analysis: an integrative approach to the structure of psychopathology. *Annu. Rev. Clin. Psychol.* 9:91–121
- Breiman L, Spector P. 1992. Submodel selection and evaluation in regression: the X-random case. *Int. Stat. Rev.* 60:291–319
- Brown MR, Sidhu GS, Greiner R, Asgarian N, Bastani M, et al. 2012. ADHD-200 Global Competition: diagnosing ADHD using personal characteristic data can outperform resting state fMRI measurements. *Front. Syst. Neurosci.* 6:69
- Bzdok D, Varoquaux G, Thirion B. 2016. Neuroimaging research: from null-hypothesis falsification to out-of-sample generalization. *Educ. Psychol. Meas.* 77:868–80
- Bzdok D, Yeo BTT. 2017. Inference in the age of big data: future perspectives on neuroscience. *NeuroImage* 155:549–64

- Cannon TD, Yu C, Addington J, Bearden CE, Cadenhead KS, et al. 2016. An individualized risk calculator for research in prodromal psychosis. *Am. J. Psychiatry* 173:980–88
- Carrion RE, Cornblatt BA, Burton CZ, Tso IF, Auther AM, et al. 2016. Personalized prediction of psychosis: external validation of the NAPLS-2 psychosis risk calculator with the EDIPPP project. *Am. J. Psychiatry* 173:989–96
- Carter KW, Francis RW, Bresnahan M, Gissler M, Grønborg TK, et al. 2015. VIPAR: a software platform for the Virtual Pooling and Analysis of Research data. *Int. J. Epidemiol.* 45:408–16
- Chekroud AM, Gueorguieva R, Krumholz HM, Trivedi MH, Krystal JH, McCarthy G. 2017. Reevaluating the efficacy and predictability of antidepressant treatments: a symptom clustering approach. *JAMA Psychiatry* 74(4):370–78
- Chekroud AM, Zotti RJ, Shehzad Z, Gueorguieva R, Johnson MK, et al. 2016. Cross-trial prediction of treatment outcome in depression: a machine learning approach. *Lancet Psychiatry* 3:243–50
- Chen JH, Asch SM. 2017. Machine learning and prediction in medicine: beyond the peak of inflated expectations. *N. Engl. J. Med.* 376:2507–9
- Clementz BA, Sweeney JA, Hamm JP, Ivleva EI, Ethridge LE, et al. 2016. Identification of distinct psychosis biotypes using brain-based biomarkers. *Am. J. Psychiatry* 173:373–84
- Cortes C, Vapnik V. 1995. Support-vector networks. *Mach. Learn.* 20:273–97
- Csernansky JG, Schindler MK, Splinter NR, Wang L, Gado M, et al. 2004. Abnormalities of thalamic volume and shape in schizophrenia. *Am. J. Psychiatry* 161:896–902
- Cumming G. 2014. The new statistics: why and how. *Psychol. Sci.* 25:7–29
- Davatzikos C, Fan Y, Wu X, Shen D, Resnick SM. 2008. Detection of prodromal Alzheimer's disease via pattern classification of magnetic resonance imaging. *Neurobiol. Aging* 29:514–23
- de Wit S, Ziermans TB, Nieuwenhuis M, Schothorst PF, van Engeland H, et al. 2017. Individual prediction of long-term outcome in adolescents at ultra-high risk for psychosis: applying machine learning techniques to brain imaging data. *Hum. Brain Mapp.* 38:704–14
- Deco G, Kringelbach ML. 2014. Great expectations: using whole-brain computational connectomics for understanding neuropsychiatric disorders. *Neuron* 84:892–905
- Diniz BS, Lin CW, Sibille E, Tseng G, Lotrich F, et al. 2016. Circulating biosignatures of late-life depression (LLD): towards a comprehensive, data-driven approach to understanding LLD pathophysiology. *J. Psychiatr. Res.* 82:1–7
- Doehrmann O, Ghosh SS, Polli FE, Reynolds GO, Horn F, et al. 2013. Predicting treatment response in social anxiety disorder from functional magnetic resonance imaging. *JAMA Psychiatry* 70:87–97

- Drysdale AT, Grosenick L, Downar J, Dunlop K, Mansouri F, et al. 2017. Resting-state connectivity biomarkers define neurophysiological subtypes of depression. *Nat. Med.* 23:28–38
- Du Y, Pearlson GD, Liu J, Sui J, Yu Q, et al. 2015. A group ICA based framework for evaluating resting fMRI markers when disease categories are unclear: application to schizophrenia, bipolar, and schizoaffective disorders. *NeuroImage* 122:272–80
- Eberhart R, Kennedy J. 1995. A new optimizer using particle swarm theory. Presented at Int. Symp. MicroMach. Hum. Sci., 6th, Nagoya, Jpn.
- Eklund A, Andersson M, Josephson C, Johannesson M, Knutsson H. 2012. Does parametric fMRI analysis with SPM yield valid results? An empirical study of 1484 rest datasets. *NeuroImage* 61:565–78
- Eklund A, Nichols TE, Knutsson H. 2016. Cluster failure: why fMRI inferences for spatial extent have inflated false-positive rates. *PNAS* 113:7900–5
- Esteva A, Kuprel B, Novoa RA, Ko J, Swetter SM, et al. 2017. Dermatologist-level classification of skin cancer with deep neural networks. *Nature* 542:115–18
- Etkin A, Patenaude B, Song YJ, Usherwood T, Rekshan W, et al. 2015. A cognitive-emotional biomarker for predicting remission with antidepressant medications: a report from the iSPOT-D trial. *Neuropsychopharmacology* 40:1332–42
- Fair DA, Bathula D, Nikolas MA, Nigg JT. 2012. Distinct neuropsychological subgroups in typically developing youth inform heterogeneity in children with ADHD. *PNAS* 109:6769–74
- Fajutrao L, Locklear J, Prialux J, Heyes A. 2009. A systematic review of the evidence of the burden of bipolar disorder in Europe. *Clin. Pract. Epidemiol. Ment. Health* 5:3
- Filzmoser P, Liebmann B, Varmuza K. 2009. Repeated double cross validation. *J. Chemometr.* 23:160–71
- Fisher RA. 1938. The statistical utilization of multiple measurements. *Ann. Hum. Genet.* 8:376–86
- Fong R, Vedaldi A. 2017. Interpretable explanations of black boxes by meaningful perturbation. [arXiv:1704.03296 \[cs.CV\]](https://arxiv.org/abs/1704.03296)
- Fornito A, Zalesky A, Breakspear M. 2015. The connectomics of brain disorders. *Nat. Rev. Neurosci.* 16:159–72
- Freedman R, Lewis DA, Michels R, Pine DS, Schultz SK, et al. 2013. The initial field trials of DSM-5: new blooms and old thorns. *Am. J. Psychiatry* 170:1–5
- Fu CH, Mourao-Miranda J, Costafreda SG, Khanna A, Marquand AF, et al. 2008. Pattern classification of sad facial processing: toward the development of neurobiological markers in depression. *Biol. Psychiatry* 63:656–62
- Fusar-Poli P, Borgwardt S, Bechdolf A, Addington J, Riecher-Rossler A, et al. 2013. The psychosis high-risk state: a comprehensive state-of-the-art review. *JAMA Psychiatry* 70:107–20

- Gabrieli JD, Ghosh SS, Whitfield-Gabrieli S. 2015. Prediction as a humanitarian and pragmatic contribution from human cognitive neuroscience. *Neuron* 85:11–26
- Galton F. 1907. Vox populi (the wisdom of crowds). *Nature* 75:450–51
- Goodman S. 1992. A comment on replication, p-values and evidence. *Stat. Med.* 11:875–79
- Goodman SN, Fanelli D, Ioannidis JP. 2016. What does research reproducibility mean? *Sci. Transl. Med.* 8:341ps12
- Goodsaid F, MattesWB. 2013. *The Path from Biomarker Discovery to Regulatory Qualification*. Cambridge,MA: Academic
- Guo W, Zhang K, Lin L, Huang S, Xing X. 2017. Towards interrogating discriminative machine learning models. arXiv:1705.08564 [cs.LG]
- Hahn T, Kircher T, Straube B, Wittchen HU, Konrad C, et al. 2015. Predicting treatment response to cognitive behavioral therapy in panic disorder with agoraphobia by integrating local neural information. *JAMA Psychiatry* 72:68–74
- Harrison G, Hopper K, Craig T, Laska E, Siegel C, et al. 2001. Recovery from psychotic illness: a 15- and 25-year international follow-up study. *Br. J. Psychiatry* 178:506–17
- Hart A, Wyatt J. 1990. Evaluating black-boxes as medical decision aids: issues arising from a study of neural networks. *Med. Inform.* 15:229–36
- Hasan A, Wobrock T, Guse B, Langguth B, LandgrebeM, et al. 2017. Structural brain changes are associated with response of negative symptoms to prefrontal repetitive transcranial magnetic stimulation in patients with schizophrenia. *Mol. Psychiatry* 22:857–64
- Hastie T, Tibshirani R, Friedman J. 2009. *The Elements of Statistical Learning*. New York: Springer
- Hegarty JD, Baldessarini RJ, Tohen M, Wateraux C, Oepen G. 1994. One hundred years of schizophrenia: a meta-analysis of the outcome literature. *Am. J. Psychiatry* 151:1409–16
- Hirschfeld R, Lewis L, Vornik LA. 2003. Perceptions and impact of bipolar disorder: How far have we really come? Results of the National Depressive and Manic-Depressive Association 2000 survey of individuals with bipolar disorder. *J. Clin. Psychiatry* 64:161–74
- HoexterMQ, Miguel EC, Diniz JB, Shavitt RG, Busatto GF, Sato JR. 2013. Predicting obsessive-compulsive disorder severity combining neuroimaging and machine learning methods. *J. Affect. Disord.* 150:1213–16
- Hofmann SG, Asnaani A, Vonk IJ, Sawyer AT, Fang A. 2012. The efficacy of cognitive behavioral therapy: a review of meta-analyses. *Cogn. Ther. Res.* 36:427–40
- Hotelling H. 1933. Analysis of a complex of statistical variables into principal components. *J. Educ. Psychol.* 24:417–41

- Insel T, Cuthbert B, Garvey M, Heinssen R, Pine DS, et al. 2010. Research domain criteria (RDoC): toward a new classification framework for research on mental disorders. *Am. J. Psychiatry* 167:748–51
- Insel TR, Cuthbert BN. 2015. Brain disorders? Precisely. *Science* 348:499–500 Influential study questioning the dominant statistical framework and research design.
- Ioannidis JP. 2005. Why most published research findings are false. *PLOS Med.* 2:e124
- Ioannidis JP. 2016. Why most clinical research is not useful. *PLOS Med.* 13:e1002049
- James G, Witten D, Hastie T, Tibshirani R. 2015. *An Introduction to Statistical Learning with Applications in R*. New York: Springer
- Jha S, Topol EJ. 2016. Adapting to artificial intelligence: radiologists and pathologists as information specialists. *JAMA* 316:2353–54
- Jordan MI, Mitchell TM. 2015. Machine learning: trends, perspectives, and prospects. *Science* 349:255–60
- Kambeitz J, Cabral C, Sacchet MD, Gotlib IH, Zahn R, et al. 2016. Detecting neuroimaging biomarkers for depression: a meta-analysis of multivariate pattern recognition studies. *Biol. Psychiatry* 82:330–38
- Kambeitz J, Kambeitz-Illankovic L, Leucht S, Wood S, Davatzikos C, et al. 2015. Detecting neuroimaging biomarkers for schizophrenia: a meta-analysis of multivariate pattern recognition studies. *Neuropsychopharmacology* 40:1742–51
- Kapur S, Phillips AG, Insel TR. 2012. Why has it taken so long for biological psychiatry to develop clinical tests and what to do about it? *Mol. Psychiatry* 17:1174–79
- Katuwal GJ, Chen R. 2016. Machine learning model interpretability for precision medicine. [arXiv:1610.09045 \[q-bio.QM\]](https://arxiv.org/abs/1610.09045)
- Kessler RC, van Loo HM, Wardenaar KJ, Bossarte RM, Brenner LA, et al. 2016. Testing a machine-learning algorithm to predict the persistence and severity of major depressive disorder from baseline self-reports. *Mol. Psychiatry* 21:1366–71
- Khodayari-Rostamabad A, Hasey GM, MacCrimmon DJ, Reilly JP, de Bruin H. 2010. A pilot study to determine whether machine learning methodologies using pre-treatment electroencephalography can predict the symptomatic response to clozapine therapy. *Clin. Neurophysiol.* 121:1998–2006
- Khodayari-Rostamabad A, Reilly JP, Hasey GM, de Bruin H, MacCrimmon DJ. 2013. A machine learning approach using EEG data to predict response to SSRI treatment for major depressive disorder. *Clin. Neurophysiol.* 124:1975–85
- Kloppel S, Stonnington CM, Barnes J, Chen F, Chu C, et al. 2008. Accuracy of dementia diagnosis: a direct comparison between radiologists and a computerized method. *Brain* 131:2969–74
- Koh PW, Liang P. 2017. Understanding black-box predictions via influence functions. [arXiv:1703.04730 \[stat.ML\]](https://arxiv.org/abs/1703.04730)

- Konig IR, Malley JD, Weimar C, Diener HC, Ziegler A. 2007. Practical experiences on the necessity of external validation. *Stat. Med.* 26:5499–511
- Koutsouleris N, Borgwardt S, Meisenzahl EM, Bottlender R, Moller HJ, Riecher-Rossler A. 2012. Disease prediction in the at-risk mental state for psychosis using neuroanatomical biomarkers: results from the FePsy study. *Schizophr. Bull.* 38:1234–46
- Koutsouleris N, Davatzikos C, Borgwardt S, Gaser C, Bottlender R, et al. 2014. Accelerated brain aging in schizophrenia and beyond: a neuroanatomical marker of psychiatric disorders. *Schizophr. Bull.* 40:1140–53
- Koutsouleris N, Kahn RS, Chekroud AM, Leucht S, Falkai P, et al. 2016. Multisite prediction of 4-week and 52-week treatment outcomes in patients with first-episode psychosis: a machine learning approach. *Lancet Psychiatry* 3:935–46
- Koutsouleris N, Meisenzahl E, Borgwardt S, Riecher-Rossler A, Frodl T, et al. 2015. Individualized differential diagnosis of schizophrenia and mood disorders using neuroanatomical biomarkers. *Brain* 138:2059–73
- Koutsouleris N, Meisenzahl EM, Davatzikos C, Bottlender R, Frodl T, et al. 2009. Use of neuroanatomical pattern classification to identify subjects in at-risk mental states of psychosis and predict disease transition. *Arch. Gen. Psychiatry* 66:700–12
- Lavagnino L, Amianto F, Mwangi B, D'Agata F, Spalatro A, et al. 2015. Identifying neuroanatomical signatures of anorexia nervosa: a multivariate machine learning approach. *Psychol. Med.* 45:2805–12
- LeCun Y, Bengio Y, Hinton G. 2015. Deep learning. *Nature* 521:436–44
- Lessov-Schlaggar CN, Rubin JB, Schlaggar BL. 2016. The fallacy of univariate solutions to complex systems problems. *Front. Neurosci.* 10:267
- Lisboa PJ. 2002. A review of evidence of health benefit from artificial neural networks in medical intervention. *Neural Netw.* 15:11–39
- Long E, Lin H, Liu Z, Wu X, Wang L, et al. 2017. An artificial intelligence platform for the multihospital collaborative management of congenital cataracts. *Nat. Biomed. Eng.* 1:0024
- Lueken U, Straube B, Yang Y, Hahn T, Beesdo-Baum K, et al. 2015. Separating depressive comorbidity from panic disorder: a combined functional magnetic resonance imaging and machine learning approach. *J. Affect. Disord.* 184:182–92
- Marquand AF, Rezek I, Buitelaar J, Beckmann CF. 2016. Understanding heterogeneity in clinical cohorts using normative models: beyond case-control studies. *Biol. Psychiatry* 80:552–61
- Mechelli A, Lin A, Wood S, McGorry P, Amminger P, et al. 2017. Using clinical information to make individualized prognostic predictions in people at ultra high risk for psychosis. *Schizophr. Res.* 184:32–38

- Miller KL, Alfaro-Almagro F, Bangerter NK, Thomas DL, Yacoub E, et al. 2016. Multimodal population brain imaging in the UK Biobank prospective epidemiological study. *Nat. Neurosci.* 19:1523–36
- Miotto R, Li L, Kidd BA, Dudley JT. 2016. Deep patient: an unsupervised representation to predict the future of patients from the electronic health records. *Sci. Rep.* 6:26094
- Modai I, Israel A, Mendel S, Hines EL, Weizman R. 1996. Neural network based on adaptive resonance theory as compared to experts in suggesting treatment for schizophrenic and unipolar depressed in-patients. *J. Med. Syst.* 20:403–12
- Modai I, Kurs R, Ritsner M, Oklander S, Silver H, et al. 2002. Neural network identification of high-risk suicide patients. *Med. Inform. Internet Med.* 27:39–47
- Modai I, Stoler M, Inbarsaban N, Saban N. 1993. Clinical decisions for psychiatric inpatients and their evaluation by a trained neural-network. *Methods Inf. Med.* 32:396–99
- Mohr DC, Zhang M, Schueller SM. 2017. Personal sensing: understanding mental health using ubiquitous sensors and machine learning. *Annu. Rev. Clin. Psychol.* 13:23–47
- Molenaar PC, Campbell CG. 2009. The new person-specific paradigm in psychology. *Curr. Dir. differences. Psychol. Sci.* 18:112–17
- Mueller SG, Weiner MW, Thal LJ, Petersen RC, Jack CR, et al. 2005. Ways toward an early diagnosis in Alzheimer's disease: the Alzheimer's Disease Neuroimaging Initiative (ADNI). *Alzheimers Dement.* 1:55–66
- Nuzzo R. 2014. Scientific method: statistical errors. *Nature* 506:150–52
- O'Neil C. 2016. *Weapons of Math Destruction: How Big Data Increases Inequality and Threatens Democracy.* New York: Crown
- Opel N, Redlich R, Kaehler C, Grotegerd D, Dohm K, et al. 2017. Prefrontal gray matter volume mediates genetic risks for obesity. *Mol. Psychiatry* 22:703–10
- Orru G, Pettersson-Yeo W, Marquand AF, Sartori G, Mechelli A. 2012. Using Support Vector Machine to identify imaging biomarkers of neurological and psychiatric disease: a critical review. *Neurosci. Biobehav. Rev.* 36:1140–52
- Perlis RH. 2013. A clinical risk stratification tool for predicting treatment resistance in major depressive disorder. *Biol. Psychiatry* 74:7–14
- Perry PJ, Bever KA, Arndt S, Combs MD. 1998. Relationship between patient variables and plasma clozapine concentrations: a dosing nomogram. *Biol. Psychiatry* 44:733–38
- Pettersson-Yeo W, Benetti S, Marquand A, Dell'Acqua F, Williams S, et al. 2013. Using genetic, cognitive and multi-modal neuroimaging data to identify ultra-high-risk and first-episode psychosis at the individual level. *Psychol. Med.* 43:2547–62
- Polikar R. 2006. Ensemble based systems in decision making. *IEEE Circuits Syst. Mag.* 6:21–45
- Ramyead A, Studerus E, Kometer M, Uttinger M, Gschwandtner U, et al. 2016. Prediction of psychosis using neural oscillations and machine learning in neuroleptic-naive at-risk patients. *World J. Biol. Psychiatry* 17:285–95

- Redlich R, Almeida JR, Grotegerd D, Opel N, Kugel H, et al. 2014. Brain morphometric biomarkers distinguishing unipolar and bipolar depression: a voxel-based morphometry–pattern classification approach. *JAMA Psychiatry* 71:1222–30
- Rosenbaum L. 2015. Transitional chaos or enduring harm? The EHR and the disruption of medicine. *New Engl. J. Med.* 373:1585–88
- Rosenblatt F. 1958. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychol. Rev.* 65:386–408
- Rush AJ, Trivedi MH, Wisniewski SR, Nierenberg AA, Stewart JW, et al. 2006. Acute and longer-term outcomes in depressed outpatients requiring one or several treatment steps: a STAR* D report. *Am. J. Psychiatry* 163:1905–17
- Sawilowsky SS. 2009. New effect size rules of thumb. *J. Mod. Appl. Stat. Methods* 8:597–99
- Schizophr. Work. Group. 2014. Biological insights from 108 schizophrenia-associated genetic loci. *Nature* 511:421–27
- Schmaal L, Marquand AF, Rhebergen D, van Tol MJ, RuheHG, et al. 2015. Predicting the naturalistic course of major depressive disorder using clinical and multimodal neuroimaging information: a multivariate pattern recognition study. *Biol. Psychiatry* 78:278–86
- Schnack HG, Kahn RS. 2016. Detecting neuroimaging biomarkers for psychiatric disorders: sample size matters. *Front. Psychiatry* 7:50
- Schooler JW. 2014. Metascience could rescue the “replication crisis.” *Nature* 515:9
- Schumann G, Binder EB, Holte A, de Kloet ER, Oedegaard KJ, et al. 2014. Stratified medicine for mental disorders. *Eur. Neuropsychopharmacol.* 24:5–50
- Setoyama D, Kato TA, Hashimoto R, Kunugi H, Hattori K, et al. 2016. Plasma metabolites predict severity of depression and suicidal ideation in psychiatric patients: a multicenter pilot analysis. *PLOS ONE* 11:e0165267
- Silva RF, Castro E, Gupta CN, Cetin M, Arbabshirani M, et al. 2014. The tenth annual MLSP competition: schizophrenia classification challenge. In 2014 IEEE International Workshop on Machine Learning for Signal Processing, ed. M Mboup, T Adali, E Moreau, J Larsen. New York: IEEE. <https://doi.org/10.1109/MLSP.2014.6958889>
- Siskind D, McCartney L, Goldschlager R, Kisely S. 2016. Clozapine v. first- and second-generation antipsychotics in treatment-refractory schizophrenia: systematic review and meta-analysis. *Br. J. Psychiatry* 209:385–92
- Snoek J, Larochelle H, Adams RP. 2012. Practical Bayesian optimization of machine learning algorithms. arXiv:1206.2944 [stat.ML]
- StoneM. 1974. Cross-validators choice and assessment of statistical predictions. *J. R. Stat. Soc. Stat. Methodol.* 36:111–47

- Thompson PM, Stein JL, Medland SE, Hibar DP, Vasquez AA, et al. 2014. The ENIGMA Consortium: large-scale collaborative analyses of neuroimaging and genetic data. *Brain Imaging Behav.* 8:153–82
- Tognin S, Pettersson-Yeo W, Valli I, Hutton C, Woolley J, et al. 2014. Using structural neuroimaging to make quantitative predictions of symptom progression in individuals at ultra-high risk for psychosis. *Front. Psychiatry* 4:187
- Torgalsboen AK, Rund BR. 2002. Lessons learned from three studies of recovery from schizophrenia. *Int. Rev. Psychiatry* 14:312–17
- Tran T, Luo W, Phung D, Harvey R, Berk M, et al. 2014. Risk stratification using data from electronic medical records better predicts suicide risks than clinician assessments. *BMC Psychiatry* 14:76
- Tulio Ribeiro M, Singh S, Guestrin C. 2016. “Why should I trust you?” Explaining the predictions of any classifier. arXiv:1602.04938 [cs.LG]
- van de Leemput IA, Wichers M, Cramer AO, Borsboom D, Tuerlinckx F, et al. 2014. Critical slowing down as early warning for the onset and termination of depression. *PNAS* 111:87–92
- van der Gaag M, Smit F, Bechdolf A, French P, Linszen DH, et al. 2013. Preventing a first episode of psychosis: meta-analysis of randomized controlled prevention trials of 12 month and longer-term followups. *Schizophr. Res.* 149:56–62
- Van Der Maaten L, Postma E, Van den Herik J. 2009. Dimensionality reduction: a comparative review. *J. Mach. Learn. Res.* 10:66–71
- Van Schependom J, Yu WP, Gielen J, Laton J, DeKeyser J, et al. 2015. Do advanced statistical techniques really help in the diagnosis of the metabolic syndrome in patients treated with second-generation antipsychotics? *J. Clin. Psychiatry* 76:E1292–99
- Varma S, Simon R. 2006. Bias in error estimation when using cross-validation for model selection. *BMC Bioinform.* 7:91
- Varol E, Sotiras A, Davatzikos C. 2016. HYDRA: revealing heterogeneity of imaging and genetic patterns through a multiple max-margin discriminative analysis framework. *NeuroImage* 145:346–64
- Varoquaux G, Raamana PR, Engemann DA, Hoyos-Idrobo A, Schwartz Y, Thirion B. 2017. Assessing and tuning brain decoders: cross-validation, caveats, and guidelines. *NeuroImage* 145:166–79
- Vickers AJ, Elkin EB. 2006. Decision curve analysis: a novel method for evaluating prediction models. *Med. Decis. Making* 26:565–74
- Visser RM, Haver P, Zwitser RJ, Scholte HS, Kindt M. 2016. First steps in using multi-voxel pattern analysis to disentangle neural processes underlying generalization of spider fear. *Front. Hum. Neurosci.* 10:222

- Wachter R. 2015. *The Digital Doctor: Hope, Hype, and Harm at the Dawn of Medicine's Computer Age*. New York: McGraw-Hill
- Wang L, Alpert KI, Calhoun VD, Cobia DJ, Keator DB, et al. 2016. SchizConnect: mediating neuroimaging databases on schizophrenia and related disorders for large-scale integration. *NeuroImage* 124:1155–67
- West JB. 2005. The physiological challenges of the 1952 Copenhagen poliomyelitis epidemic and a renaissance in clinical respiratory physiology. *J. Appl. Physiol.* 99:424–32
- Whelan R, Garavan H. 2014. When optimism hurts: inflated predictions in psychiatric neuroimaging. *Biol. Psychiatry* 75:746–48
- Whelan R, Watts R, Orr CA, Althoff RR, Artiges E, et al. 2014. Neuropsychosocial profiles of current and future adolescent alcohol misusers. *Nature* 512:185–89
- Whitfield-Gabrieli S, Ghosh SS, Nieto-Castanon A, Saygin Z, Doehrmann O, et al. 2016. Brain connectomics predict response to treatment in social anxiety disorder. *Mol. Psychiatry* 21:680–85
- Widmer G, Kubat M. 1996. Learning in the presence of concept drift and hidden contexts. *Mach. Learn.* 23:69–101
- Wolpert DH. 1992. Stacked generalization. *Neural Netw.* 5:241–59
- Wong EHF, Yocca F, Smith MA, Lee CM. 2010. Challenges and opportunities for drug discovery in psychiatric disorders: the drug hunters' perspective. *Int. J. Neuropsychopharmacol.* 13:1269–84
- Woo CW, Chang LJ, Lindquist MA, Wager TD. 2017. Building better biomarkers: brain models in translational neuroimaging. *Nat. Neurosci.* 20:365–77
- Woodcock J, Buckman S, Goodsaid F, Walton MK, Zineh I. 2011. Qualifying biomarkers for use in drug development: a US Food and Drug Administration overview. *Expert Opin. Med. Diagn.* 5:369–74
- Wu MJ, Mwangi B, Bauer IE, Passos IC, Sanches M, et al. 2016. Identification and individualized prediction of clinical phenotypes in bipolar disorders using neurocognitive data, neuroimaging scans and machine learning. *NeuroImage* 145:254–64
- Wunderink L, Sytema S, Nienhuis FJ, Wiersma D. 2009. Clinical recovery in first-episode psychosis. *Schizophr. Bull.* 35:362–69
- Yang C, Delcher C, Shenkman E, Ranka S. 2016. Predicting 30-day all-cause readmissions from hospital inpatient discharge data. Presented at IEEE Int. Conf. E-Health Netw. Appl. Serv., 18th, Sept. 14–17, Munich, Ger.
- Yu KH, Zhang C, Berry GJ, Altman RB, Re C, et al. 2016. Predicting non-small cell lung cancer prognosis by fully automated microscopic pathology image features. *Nat. Commun.* 7:12474
- Zou H, Hastie T. 2005. Regularization and variable selection via the elastic net. *J. R. Stat. Soc. Stat. Methodol.* 67:301–20

Mesterséges intelligencia a pszichológiai gyakorlatban: Jelenlegi és jövőbeli alkalmazások és implikációk*

Ez a cikk áttekinti a mesterséges intelligencia (AI) technológiák fejlődését és azok jelenlegi és jövőbeli alkalmazásait a klinikai pszichológiai gyakorlatban. Az AI által támogatott főbb tevékenységek közül néhányat áttekintünk: klinikai képzés, kezelés, pszichológiai értékelés és klinikai döntéshozatal. Bemutatásra kerül egy integrált AI-alapú klinikai rendszer koncepciója is. Megvitatásra kerülnek a mesterséges intelligenciával kapcsolatos kérdések a klinikai gyakorlat kontextusában, a mentálhigiénés szakemberek munkahelyvesztésének lehetősége, valamint a mesterséges intelligencia technológiájának fejlődésével kapcsolatos egyéb következmények. A mesterséges intelligencia-technológiák fejlődése és a pszichológiai gyakorlatban való alkalmazása fontos következményekkel jár, amelyek várhatóan átalakítják a mentális egészségügyet. A pszichológusoknak és más mentálhigiénés szakembereknek alapvető szerepük van a mesterséges intelligencia technológiák fejlesztésében, értékelésében és etikus használatában.

Kulcsszavak: mesterséges intelligencia, mentális egészség, szakértői rendszerek, virtuális valóság.

A mesterséges intelligencia (AI) olyan technológia, amelyet olyan tevékenységek elvégzésére terveztek, amelyekhez általában emberi intelligencia szükséges. A mesterséges intelligenciát úgy is definiálják, mint az e technológia fejlesztésével és tanulmányozásával foglalkozó multidiszciplináris tudományterületet. A mesterséges intelligencia területe a számítógépes korszak kezdetével, az 1940-es évekkel kezdődött, és hivatalosan John McCarthy informatikus nevezte el 1956-ban (a mesterséges intelligencia történetének áttekintését lásd Buchanan, 2005). A mesterséges intelligencia technológia lehet fizikai gépek, önálló számítógépes szoftverek, hálózaton elosztott, robotikában alkalmazott, vagy az élő biológiából kifejlesztett, illetve azzal összekapcsolt (pl. agy-számítógép interfészek). Ez a technológia lehet speciális intelligens funkciókat vagy olyan komplex emberi viselkedés utánzását célozza meg, amely autonóm intelligens ágensként képes érvelni, tanulni és a környezetre hatni

* Luxton, D. D. (2014). Artificial intelligence in psychological practice: Current and future applications and implications. *Professional Psychology: Research and Practice*, 45(5), 332. Fordította: Mészáros Veronika.

(Russell & Norvig, 2003). A mesterséges intelligencia fontos ágai közé tartozik a gépi tanulás, a mesterséges neurális hálózatok és a természetes nyelvi feldolgozás tanulmányozása. A gépi tanulás a számítógépek azon képessége, hogy explicit programozás nélkül is képesek tanulni (Samuel, 1959), a mesterséges neurális hálózatok olyan matematikai, számítási vagy technológiai modellek, amelyek az agyban lévő neuronok logikai és tanulási funkcióit utánozzák (Krogh, 2008), a természetes nyelvfeldolgozás pedig azzal foglalkozik, hogy a számítógépek hogyan dolgozzák fel az emberi természetes nyelveket (Manning & Schütze, 1999).

A mesterséges intelligenciát az 1970-es évek óta alkalmazzák az orvostudomány területén végzett tevékenységekben, különösen a klinikai döntéshozatalhoz használt szakértői rendszerek és az orvosbiológiai kutatás területén (Morelli, Bronzino & Goethe, 1987; Patel et al., 2009; Shortliffe, 1993; Szolovits, 1982). A mesterséges intelligencia megjelenése az orvostudományban az "Artificial Intelligence in Medicine" című tudományos folyóiratot is előhozta, és számos korábbi áttekintés és javaslat jelent meg a mesterséges intelligencia pszichiátriai alkalmazásairól (pl. Garfield, Rapp és Evens, 1992; Hand, 1985; Morelli, 1989; Servan-Schreiber, 1986). A mesterséges intelligencia technológiák alkalmazása a mentálhigiénés ellátásban továbbra is fejlődő terület, amely az elmúlt évtizedben jelentős fejlődésen ment keresztül. A számítógépek teljesítményének folyamatos növekedése, valamint más technológiai területeken, például a virtuális valóság, a számítógépes ismeretszerzés, a nyelvfeldolgozás, az érzékelés és a robotika területén elért fejlődés olyan új és izgalmas képességeket tett lehetővé, amelyekről a múltban csak álmodni lehetett. A mesterséges intelligencia technológiák jelenlegi és jövőbeli alkalmazásai várhatóan mélyreható hatással lesznek a pszichológia és általában a mentális egészségügy területére. Ezért fontos, hogy a pszichológusok és a mentális egészségügyben dolgozók tisztában legyenek a jelenlegi és a kialakulóban lévő mesterséges intelligencia-technológiák alkalmazásának lehetőségeivel és következményeivel.

E cikk középpontjában ezért a mesterséges intelligencia technológiák azon felhasználási lehetőségeinek áttekintése áll, amelyek a pszichológiai gyakorlatban és kutatásban alkalmazhatóak. Ebben a cikkben nem lehetséges az összes mesterséges intelligencia-technológia vagy alkalmazás kimerítő áttekintése, azonban szemléltető példákat mutatunk be a jelenleg használt vagy értékelt mesterséges intelligencia-technológiai alkalmazásokról. A témában járatlan olvasók számára alapvető történelmi háttér és technikai leírások, valamint a jövőbeli kilátások és lehetőségek ismertetése. A mesterséges intelligencia-technológia alkalmazásainak lehetőségei és kilátásai kerülnek bemutatásra. Végezetül megvitatásra kerülnek e technológia fejlődésének a betegekre, a mentális egészségügyi szakemberekre és a pszichológia területére gyakorolt hatásai.

Klinikai kezelés, értékelés és képzés

Az első olyan pszichoterapeuta szimuláció, amely ember-számítógép interfészt használt, az ELIZA számítógépes program volt 1966-ban (Weizenbaum, 1976). A programot úgy tervezték, hogy Carl Rogers (Rogers, 1951) empatikus kommunikációs stílusát utánozza, és kérdés-felelet formátumban válaszolt a felhasználó által a billentyűzeten beírt kijelentésekre. Az ELIZA a nyelvi szintaxist használta a programozott modell alapján megfogalmazott válaszok megadására, ezért csak a beszélgetést utánozta. Az 1970-es évek elején Kenneth M. Colby pszichiáter a Stanford Egyetemen kifejlesztett egy PARRY nevű programot, amely egy paranoid skizofréniában szenvedő személyt szimulált, és az ELIZA-hoz hasonlóan a program képes volt másokkal társalogni (Güzeldere & Franchi, 1995). A PARRY-t tartják az első olyan programnak, amely átment a Turing-teszten. A Turing-teszt (Turing, 1950), amelyet Alan Turingról neveztek el, a gépek intelligenciájának megítélésére szolgáló módszer. Ahhoz, hogy egy számítógépes program átmenjen a teszten, egy emberi bíróval folytatott, valós idejű, írásos emberi beszélgetést kell eléggé megismételnie ahhoz, hogy a bíró ne tudja megbízhatóan megkülönböztetni a programot egy valódi embertől. A PARRY tesztjei azt mutatták, hogy a szakértő pszichiáterek képtelenek voltak különbséget tenni a PARRY és egy paranoid skizofréniában szenvedő valódi személy között (Teuscher & Hofstadter, 2006).

A technológia mára olyan fejlett virtuális emberi avatárokat (virtuális valóságban szimulált embereket) fejlesztett ki, amelyek képesek interaktív és intelligens beszélgetéseket folytatni. A virtuális valóság szimuláció, a természetes nyelvi feldolgozás és az érvelésre képes tudásalapú mesterséges intelligencia összekapcsolása teszi ezt lehetővé. A Dél-kaliforniai Egyetem (USC) Kreatív Technológiák Intézete kutatói például jelenleg élethű virtuális emberi betegeket fejlesztenek ki klinikai képzésben és készségfejlesztésben való felhasználásra (Rizzo, Lange és mtsai., 2011). A virtuális valóságban élő betegeket úgy tervezték, hogy utánozzák a pszichológiai rendellenességek tüneteit, és szóbeli párbeszéd révén interakcióba lépjenek a terapeutákkal. Ezek is módosíthatók az egyes betegpopulációk szimulációihoz és a gyakoronokok készség szintjeihez. E technológia néhány lehetséges előnye közé tartozik, hogy a gyakoronokok adaptív és személyre szabott képzésben részesülhetnek, amely rendkívül valóságos, és a gyakoronokok számára is bármikor elérhető. Ez a további előnnyel járhat, hogy az oktatók felszabadulnak, hogy a hallgatók képzésének irányításában fejlettebb szerepet játszassanak. További kutatásokra van azonban szükség annak megállapításához, hogy ezek a rendszerek mennyire lesznek hatékonyak.

A mesterséges intelligenciával támogatott virtuális valóság emberi avatárak potenciálisan felhasználhatók a mentális egészségügyben a személyközi interakciók minden más típusában, beleértve a pszichológiai kezeléseket, értékeléseket és

teszteléseket. A virtuális valóság avatárokat már használják arra, hogy az embereket mentális egészségügyi erőforrásokról és támogatásról tájékoztassák (DeAngelis, 2012; Rizzo, Lange, et al., 2011). A SimCoach (www.simcoach.org) például arra szolgál, hogy összekapcsolja a katonai szolgálat tagjait és családtagjaikat az egészségügyi és egyéb jóléti erőforrásokkal (Rizzo, Lange, et al., 2011). Az ilyen típusú mesterséges intelligencia technológia egy nap forradalmasíthatja a telepractice-t. Az AI-képes avatárokat távolról is el lehet érni, hogy pszichológiai szolgáltatásokat nyújtsanak bárhol, ahol van internetkapcsolat. A betegek számára az egyik előny az, hogy ezek az automatizált, AI-képes virtuális a konzultánsok bármikor kényelmesen elérhetők a betegek számára, és a páciensek egyéni igényeihez igazodó alapfelméréseket, ajánlásokat és további kezelésekre való utalásokat nyújtanak számukra. A virtuális valóság avatárrendszerek másik előnye, hogy azok a személyek, akiket aggaszt a magánélet védelme és a személyes ellátáshoz kapcsolódó megbélyegzés, hajlandóbbak lehetnek arra, hogy otthonuk kényelmében kérjenek segítséget egy virtuális ellátótól. A technológia másik előnye, hogy interaktívabb és vonzóbb, mint a statikus információs internetes weboldalak. Ezek a rendszerek azáltal is segíthetik a szakembereket, hogy mindig rendelkezésre álló szaktanácsadóként szolgálnak, akik bizonyos területeken vagy szakterületeken tanultak és rendelkeznek ismeretekkel.

A mesterséges intelligencia-alapú kioszk alapú számítógépes egészségügyi szűrőrendszerek használata olyan környezetben is előnyös lehet, ahol nagyszámú embert kell szűrni, például a hadseregben. A mesterséges intelligencia gépi tanulási és következtetési koncepcióit alkalmazó rendszerek túlmutatnak a logikai alapú algoritmusokkal és kapukérdésekkel ellátott egyszerű számítógépes felméréseken; hatékonyabbá és kifinomultabbá tehetik a felméréseket, mivel képesek komplex adatok feldolgozására, az egyénre szabottan, és csökkentik a szűrési eredmények bizonytalanságát.

A szuper klinikus

Az integrált AI-technológiák olyan képességekkel is felruházhatják a szimulált gyakorlót, amelyek meghaladják az emberi gyakorló képességeit, így gyakorlatilag szuperklinikussá válhat. A szuperklinikus olyan fejlett érzékelő technológiákkal épülhetne fel, mint az infravörös képalkotás (a belső állapotok változását jelző testhőmérséklet-változások észlelésére) és az optikai érzékelés, amely képes megfigyelni és elemezni a finom arckifejezéseket, szemvillanásokat, hangji jellemzőket és egyéb, klinikailag fontos információkat nyújtó viselkedésmintákat. A gépi szaglotechnológia például az alkohol jelenlétének érzékelésére is használható. A

technológia az arcfelismerő technológiát használhatná a betegek személyazonosságának ellenőrzésére, valamint vezeték nélküli technológiákon keresztül hozzáférhetne és elemezhetné a betegről rendelkezésre álló összes adatot az elektronikus orvosi nyilvántartásokból, az ülések feljegyzéseiből, az értékelésekből és a vizsgálati eredményekből. A superklinikus továbbá teljes autonómiával vezethetne üléseket, vagy a klinikai értékelések és kezelések során a kezelőorvosok asszisztenseként szolgálhatna. Ez a technológia például segíthetné az emberi kezelőt a feljegyzések áttekintésében, a fiziológiai adatok nyomon követésében, a kezelést megelőző klinikai interjúkban vagy a tesztek elvégzésében.

Amint azt számos, ezen a területen folyó projekt bizonyítja, a superklinikus koncepció nem tudományos fantasztikum. Például az USC Kreatív Technológiák Intézete a DARPA (Defense Advanced Research Projects Agency) Detection and Computational Analysis of Psychological Signals (DCAPS) projektben végzett munkája egy olyan mesterséges intelligencia rendszer kifejlesztését foglalja magában, amely gépi tanulást, természetes nyelvi feldolgozást és számítógépes látást használ a nyelv, a fizikai gesztusok és a szociális jelek elemzésére, hogy felismerje az emberek pszichológiai diszressz jeleit (DARPA, 2013). A Massachusetts Institute of Technology (MIT) Computer Science and Artificial Intelligence Laboratory (CSAIL) kutatói olyan szoftvert terveztek, amely felerősíti a digitális videó képpontjainak eltéréseit, ami lehetővé teszi az emberi szem számára nem észlelhető finom változások megfigyelését (Hardesty, 2012). Ezt a technológiát fel lehetne használni egy személy pulzusszámának (azaz belső izgalmi állapotainak) érzékelésére, mivel a bőr színe a véráramlással együtt változik. Watson továbbá az IBM mesterséges intelligenciával rendelkező, nyelvi kérdéseket feldolgozó kérdésfeltevő rendszere, amely 2011-ben egy bemutató mérkőzésen legyőzte a Jeop-ardy! kvízműsor bajnokait, Brad Rutttert és Ken Jenningset. Az IBM jelenleg a Watson kibővített, kereskedelmi forgalomban kapható változatát értékeli, amely megtanulta az orvosi szakirodalmat, így lehetővé teszi, hogy orvosi tudásszakértőként és tanácsadóként szolgáljon (IBM, 2013). Az FDA nemrégiben hagyta jóvá a kórházakban való használatra az RP-VITA nevű robotot, amely képes szobáról szobára manőverezni, hogy vezeték nélküli videokonferencián keresztül összekapcsolja az egészségügyi szolgáltatókat a betegekkel vagy más egészségügyi szolgáltatókkal (InTouch Health, 2012). A rendszer a betegek orvosi kartonjaihoz is hozzáférhet, és a betegek távoli megfigyelésére is használható. Kétségtelen, hogy az ilyen típusú technológiák folyamatos fejlődése, integrálása és alkalmazása lehetőséget teremt olyan intelligens ügynökrendszerek létrehozására, amelyek képesek a pszichológiai kezelési, értékelési és oktatási szolgáltatások körét biztosítani.

Klinikai diagnosztika és döntéshozatal

A számítógépes és mesterséges intelligencia-technológia egyik legkorábbi alkalmazása az orvostudományban, amely a mentális egészségügyben is közvetlenül alkalmazható, a szakértői rendszerek használata a klinikai döntéshozatalban. A szakértői rendszer egy olyan számítógépes program, amelyet úgy terveztek, hogy egy adott terület szakértőjének tudását és képességeit foglalja magába (McCarthy, 1984), a döntéstámogató rendszerek pedig a szakértői rendszerek egy olyan osztályát jelentik, amelyet kifejezetten a döntéshozatal folyamatának segítésére terveztek (Finlay, 1994). Sok ilyen rendszer szabályalapú szakértői rendszer, amelyekben a tények és szabályok előre be vannak programozva, és ezért a döntéshozó részéről a priori tudást igényelnek. A döntéstámogató rendszerek úgy is kialakíthatók, hogy adatbányászati technikákat használjanak az adatokban lévő minták és kapcsolatok keresésére és megtalálására, és ezért nem igényelnek a priori ismereteket (Hardin & Chien, 2007). A fuzzy szakértői rendszerek is olyan szakértői rendszerek, amelyek a Boole logika helyett fuzzy logikát használnak. A fuzzy logika (Zadeh, 1965) olyan érvelési módszer, amely rögzített és pontos értékek (pl. "igaz" vagy "hamis") helyett közelítő értékekkel (pl. az "igaz" vagy "hamis" bizonyos fokával) foglalkozik, és hasznos a döntéshozatal során a bizonytalanságokkal való munkában. A fuzzy modellezés és a fuzzy-genetikai algoritmusok olyan technikák, amelyeket a szabályok és a tagsági osztályozás optimalizálásának segítésére használnak (e fogalmak áttekintését lásd Jagielska, Matthews & Whitfort, 1999).

Az egyik első klinikai döntéstámogató programot a Stanford Egyetemen fejlesztették ki az 1970-es évek elején. A MYCIN néven ismert rendszert fertőzéseket és véralvadási betegségeket okozó baktériumok azonosítására tervezték (Buchanan & Shortliffe, 1984; Shortliffe, 1976). A szakértők megkérdezésével épített MYCIN egy szabályalapú rendszer volt, amely gépelt kérdés-felelet párbeszédet használt. Bár a rendszer jól teljesített a teszteken, klinikai használatra nem került, főként az akkori számítástechnikai korlátok miatt (Buchanan & Shortliffe, 1984). A számítási teljesítmény és a mesterséges intelligencia technológiájának azóta bekövetkezett fejlődése azonban nagymértékben javította a klinikai szakértői rendszerek képességeit. A neurális hálózati koncepciók és a gépi tanulási technikák alkalmazásával a modern szakértői rendszerek képesek olyan összetett adatokból mintákat, trendeket és jelentést azonosítani, amelyek túl bonyolultak ahhoz, hogy ember vagy más számítógépes technológiák feldolgozzák őket. A támogató vektor gépek (SVM; Cortes & Vapnik, 1995) például gépi tanulást használnak a minták elemzésére, osztályozására és felismerésére a következő adatokban

Az utóbbi időben számos betegség, köztük a Parkinson-kór (Gil & Johnson, 2009) és az Alzheimer-kór (Kohanim et al., 2010) osztályozásában tesztelték őket.

A szakértői rendszerek alkalmazása a mentális egészségügy területén elmaradt az orvosi területen történő alkalmazás mögött, azonban a mesterséges intelligenciával támogatott rendszerek alkalmazhatósága egyre inkább felismerhető. Masri és Mat Jani (2012) például egy AI-alapú mentális egészségügyi diagnosztikai szakértői rendszert (MeHDES) javasolt, amely szabályalapú érvelési technikák segítségével kódolná a mentális egészségügyi rendellenességekre vonatkozó emberi szakértői tudást egy tudásbázisba. Ezután fuzzy logikai technikákat használnának egy adott mérendő rendellenesség súlyossági szintjének meghatározására, és fuzzy-genetikai algoritmusokat használnának a személyre szabott kezelések meghatározására és javasolására, amelyek figyelembe veszik a beteg költségvetését és általános egészségi állapotát. A mesterséges intelligenciával támogatott, beszédfelismerő és természetes nyelvi feldolgozási technológiával ellátott virtuális valóságban megjelenő emberi avatárok szintén javíthatnák a szakértői rendszereket, mivel emberhez hasonló verbális párbeszéd-felületet biztosítanak. Ezek a rendszerek hozzáférhetnének a pszichiátriai és orvosi rendellenességekre vonatkozó szakértői tudásanyaghoz, és a betegek orvosi kartonjaiból és vizsgálati eredményeiből származó adatokkal táplálhatók. A mesterséges intelligenciával támogatott szakértői rendszerek további gyakorlati alkalmazásai közé tartozik a gyógyszerek használatának felülvizsgálatában, a monitorozásban és az ellenjavallatok azonosításában nyújtott segítség (Bindoff, Stafford, Peterson, Kang és Tenni, 2012). A mesterséges intelligens multiágensek koncepciója továbbá arra is felhasználható, hogy a mesterséges "elmék" közösen dolgozzanak a klinikai gyakorlatban vagy a kutatásban felmerülő problémákra vonatkozó döntések és megoldások meghozatalában. Ezen a vonalon haladva McShane, Beale, Nirenburg, Jarell és Fantry (2012) egy olyan rendszert tárgyal, amely lehetővé teszi olyan mesterséges intelligens ágensek létrehozását, amelyek multiágens-csapatok (azaz mesterséges és emberi orvosi szakértők) tagjaiként képesek működni az orvosi diagnosztikai ellentmondások felderítése és megoldása érdekében.

Az AI-alapú klinikai döntéstámogató rendszerek előnye, hogy képesek kezelni az adatok nagyfokú összetettségét, és így segíthetik a szakembereket a releváns információk kinyerésében és az optimális döntések meghozatalában. Ezek a rendszerek segíthetnek a szakembereknek a bizonytalanság kezelésében és a döntéshozatal felgyorsításában is. A mesterséges intelligenciával támogatott klinikai döntéstámogató rendszerek alkalmazása csökkentheti a személyzet időigényét, és segíthet az egyes területeken a szakemberek korlátozott kompetenciájából adódó akadályok csökkentésében. Továbbá, mivel az emberek hajlamosak a kognitív hibák és a fáradtság következtében hibákat elkövetni, az AI-technológia minden egészségügyi területen

javíthatja a képességeket és csökkentheti az emberi hibákat a klinikai döntéshozatalban.

Egyéb gyakorlati AI Alkalmazások a mentális egészségügyben

Intelligens virtuális világok és mesterséges társak

A virtuális valóság szimuláció szintén a mesterséges intelligencia technológiák újonnan megjelenő alkalmazása. A virtuális valóság az ember és a számítógép közötti találkozás egy formája, amely lehetővé teszi a felhasználó számára, hogy elmerüljön egy számítógép által generált szimulált környezetben, és interakcióba lépjen vele (Rizzo, Buck-walter & Neumann, 1997). A klinikai virtuális valóság e technológia klinikai felmérési és kezelési célokra történő felhasználása (Rizzo, Parsons, et al., 2011), és számos pszichológiai zavar kezelésében alkalmazták már (lásd Gorrindo, & Groves, 2009; Krijn, Emmelkamp, Olafsson, & Biemond, 2004; Reger, Hollo-way, Rothbaum, Difede, & Gahm, 2011; Riva, 2010). A mesterséges intelligenciát már használják a virtuális környezetekben olyan intelligens ágensek létrehozására, amelyek képesek tanulni és interakcióba lépni a felhasználókkal, és ezáltal növelik a rugalmasságot és a realizmust. Továbbá ezek a mesterséges intelligens ágensek ma már képesek érzelmeket kifejezni és párbeszédben részt venni az emberi felhasználókkal. A "biológiailag inspirált" virtuális társak, például a virtuális háziállatok a mentális jólét előmozdításával és a magányosság leküzdésének segítségével a mentális egészségre is jótékony hatással lehetnek. Ezek lehetnek virtuális formában, videoképernyőn megjelenő, vagy állati vagy humanoid robotok formájában. Például állatos robot társakat terveztek arra, hogy terápiát nyújtsanak demenciában szenvedő betegek számára (lásd Shibata & Wada, 2011). A mesterséges intelligenciával feljavított videojátékokhoz hasonlóan a mesterséges intelligencia ezeket a mesterséges társakat is élethűbbé, interaktívabbá teszi, és a beteg igényeihez alkalmazkodó dolgokat képes végrehajtani.

Kiterjesztett valóság alkalmazások

A kiterjesztett valóság a virtuális valóságot és a valós világot úgy ötvözi, hogy a számítógép által generált grafikát élő videóképekkel helyezi egymásra (Caudell & Mizell, 1992). Ez a technológia más mesterséges intelligencia-technológiákkal kombinálva átalakíthatja az emberek környezetükben való érzékelését és interakcióját, és számos

terápiás célra felhasználható. Például arra lehetne használni, hogy a páciens valós környezetében szorongást kiváltó virtuális ingereket hozzanak létre a hosszan tartó expozíciós terápia során, vagy arra lehetne használni, hogy a pácienseket valós idejű terápiás virtuális coachinggal segítsék, amelyet a képernyőre vetítenek. A kiterjesztett valóság és más AI-képességek mobil eszközökön, például okostelefonokon, táblagépeken és más viselhető eszközökön is alkalmazhatók. A Google Glass (viselhető intelligens szemüveg) például valós idejű adathozzáférést és -megosztást, valamint egyéb képességeket biztosíthat a felhasználók számára az internethez való hozzáféréshez. A Washingtoni Egyetem és az Aalto Egyetem (Finnország) kutatói jelenleg bionikus kontaktlencsét is fejlesztenek, amelyek egy napon olyan technológiához vezethetnek, amely lehetővé teszi a felhasználók számára az internet letapogatását és az adatokhoz való hozzáférést igény szerint, például orvosi információkhoz (Lingley et al., 2011).

Terápiás számítógépes játékok

A számítógépes játékok mentális egészségügyi célokra, például készségfejlesztésre, viselkedésmodellezésre, terápiás figyelemelterelésre és egyéb terápiás célokra is használhatók. A számítógépes játékok terápiás előnyei közé tartozik a betegek fokozott elkötelezettsége, a kezelésekhöz való jobb ragaszkodás és a pszichológiai kezeléssel kapcsolatos stigmatizáció csökkentése (Matthews & Coyle, 2010). A terápiás számítógépes játékokról az is kiderült, hogy segítenek a serdülőknek az önbizalom és a problémamegoldó készségek fejlesztésében (Coyle, Matthews, Sharry, Nisbet és Doherty, 2005). A mesterséges intelligencia technológia már számos kereskedelmi számítógépes játékban jelen van, és újabban az internetalapú online és közösségi hálózati játékokban is alkalmazzák (Fujita & Wu, 2012). A mesterséges intelligencia és a gépi tanulási technológia a számítógépes játékokban alkalmazva fokozza a realizmust, ami érdekesebbé, kihívást jelentőbbé és szórakoztatóbbá teszi a játékokat. A gépi tanulási koncepciók azt is segítik, hogy a játékok a páciens igényeihez igazíthatók legyenek. Azaz a mesterséges intelligencia technológiája felhasználható a játék irányítására, hogy a beteg a szükséges területeken gyakorolja a készségeket, vagy a betegeket virtuális intelligens ügynökök oktathatják a játékokban vagy más virtuális környezetekben, mint például a Second Life (Linden Research, Inc., 2013). A Brigadoon (Lester, 2005) például egy olyan virtuális környezet a Second Life-ban, amelyet autizmus spektrumzavarral élő emberek számára terveztek. A szimuláció lehetővé teszi a felhasználók számára, hogy avatárokkal interakcióba lépve tanuljanak és gyakorolják a szociális készségeket egy nem fenyegető környezetben.

Egyéb klinikai eszközök

A mesterséges intelligencia integrálása más klinikai eszközökbe, amelyeket a mentális egészségügyi és más egészségügyi szakemberek használnak, növelheti a kényelmet, a pontosságot és a hatékonyságot. A beszédfelismerő technológiát az orvosi diktálásához már egy ideje használják. Ma már léteznek azonban olyan elektronikus orvosi nyilvántartó (EMR) szoftveralkalmazások, amelyek a mesterséges intelligenciát és a Boole-logikát használják a betegadatok bevitelének automatizálására azáltal, hogy a korábbi esetek azonos vagy hasonló elemeit idézik fel, ezáltal javítva a pontosságot és időt takarítva meg. Egy másik alkalmazás lehet egy AI-alapú program, amely meghallgatja a terápiás vagy értékelő ülést, és intelligensen, automatikusan összefoglalja az ülést, lényegében kiküszöbölve a klinikai kórlapok feljegyzésének szükségességét az ülés végén. Egy ilyen típusú rendszer mobil eszközplatformokon, például okostelefonokon is megvalósítható lenne.

A mesterséges intelligencia következményei a pszichológiai gyakorlatban Az emberek közötti kölcsönhatás és a mesterséges intelligencia.

A mesterséges intelligencia rendszerek használata a betegekkel való klinikai interakcióban számos nagyon érdekes kérdést vet fel. Képesek lesznek-e például a betegek terápiás kötődést és bizalmat kialakítani a mesterséges intelligens ügynökökkel, mint az emberi orvosokkal? Hogyan fognak a betegek a mesterséges intelligens ügynök szakemberekkel interakcióba lépni, ha a beteg úgy gondolja, hogy a rendszertől hiányoznak az emberek tökéletlenségei, vagy olyan fejlett technológiákat használ, amelyek meghaladják az emberek tudását és érzékelési képességeit? Joseph Weizenbaum, az ELIZA program megalkotója amellet érvelt, hogy a számítógépek nem hozhatnak fontos döntéseket, mert a számítógépekből hiányoznak az együttérzés és a bölcsesség emberi tulajdonságai (Weizenbaum, 1976). Mások azonban amellet érveltek, hogy a mesterséges intelligenciát támogató gépek valóban képesek érzelmeket megtapasztalni, vagy legalábbis az érzelmek felismerése és kifejezése modellezhető egy gépben (Bartneck, Lyons és Saerbeck, 2008). Az interperszonális melegség, az empátia és a terápiás kapcsolat fontos közös tényezők, amelyek befolyásolják a terápiás eredményeket (Lambert & Barley, 2001). Emellet a kulturális különbségek és elvárások is relevánsak a pszichológiai gyakorlatban. Még ha a konkrét terápiás technikákat megfelelően alkalmazzák is a mesterséges intelligens ügynökök, ezeket a közös tényezőket és kulturális szempontokat figyelembe kell venni minden olyan vitában, amely arról szól, hogy ezeket a rendszereket hogyan kell használni a pszichoterápia kontextusában, és hogy hatékonyak lesznek-e a betegek kezelésében. Ezek a kérdések rámutatnak arra, hogy ezen a területen kutatásra van szükség.

Jogi és etikai megfontolások

A mesterséges intelligens ágensrendszerek alkalmazása a kezelési szolgáltatások nyújtására új összetettséget hoz a pszichológiai gyakorlathoz kapcsolódó jogi és etikai kérdések tekintetében. Például az interneten keresztül elérhető rendszerek, mint például a jelenlegi avatárrendszerek, joghatósági határokon átnyúló szolgáltatásokat nyújthatnak. (állami és nemzeti vonalak). Bár ezeket a rendszereket jellemzően oktatási célokra használják, és használatukról megfelelő nyilatkozatokat tesznek, más kezelési alkalmazások és kontextusok ugyanazokat a jogi és szakmai engedélyezési megfontolásokat vonhatják maguk után, mint a jelenlegi telep-gyakorlatok (lásd Kramer, Mishkind, Lux-ton, & Shore, 2013). A fejlett autonóm mesterséges intelligencia-rendszerek alkalmazása a kezelési vagy értékelési szolgáltatások nyújtására azonban bonyolítja a szolgáltatások nyújtásával kapcsolatos felelősségi kérdéseket. Az egészségügyi szakemberek mindennapi gyakorlatában felmerülő etikai dilemmák kezeléséhez a mesterséges intelligens ágenseknek képesnek kell lenniük olyan értéktételeket és döntéseket feldolgozni és meghozni, amelyek komplex absztrakt gondolkodást és érvelést igényelnek. Bár a mesterséges intelligencia rendszerek segíthetnek a döntéshozatal javításában, az emberi szakemberekhez hasonlóan a mesterséges intelligencia rendszerek is hajlamosak az ítélezési hibákra és a kockázat helytelen értékelésére (pl. a beteg önsértési kockázatának szintje). Ráadásul a fejlett mesterséges intelligens ágensek képesek lehetnek saját személyes értékek és meggyőződések kialakítására, amelyek a döntések alapjául szolgálnak - ami felveti a kérdést, hogy ezek a döntések összhangban lesznek-e alkotóikéval vagy a használat kulturális kontextusával. Az ilyen típusú kérdések felvetik annak kérdését, hogy ki legyen jogilag felelős a mesterséges intelligencia rendszerek által hozott döntésekért és az esetleges hibákért. Bár logikusnak tűnik, hogy a felelősség végső soron a mesterséges intelligencia rendszer emberi irányítóit terheli, a felelősség kérdése az autonóm mesterséges intelligencia rendszerek alkalmazásával minden bizonnyal elmosódik.

A mesterséges intelligencia technológiájának fejlődése számos erkölcsi és etikai megfontolással jár a technológiát irányító emberek, valamint az autonóm módon működő intelligens gépek tevékenységével kapcsolatban (lásd Anderson & Anderson, 2011). Isaac Asimov sci-fi szerző az 1940-es években a mesterségesen intelligens gépek használatára vonatkozó etikai irányelveket javasolt "A robotika három törvénye" című úttörő művében (Asimov, 1942). Röviden a törvények kimondják, hogy a mesterségesen intelligens robotok nem árthatnak embernek, engedelmeskedniük kell az emberek utasításainak (kivéve, ha ez nem ütközik az első törvénnyel), és meg kell védeniük saját létüket (amennyiben ez nem ütközik a második törvénnyel). Asimov

később hozzáfűzött egy előző törvényt, amely szerint a robot nem árthat az emberiségnek (Asimov, 1985). A mesterséges intelligencia etikus felhasználására vonatkozó iránymutatások szükségessége már nem a tudományos fikció vagy a filozófia kérdése, hanem egy olyan valós gyakorlati kérdés, amely a mentális egészségügyben dolgozó szakemberek számára releváns. További jogi vitákra és iránymutatásokra van szükség, és ez várható a jövőben.

Munkahelyvesztés a mentális egészségügyben ellátás

Bár a pszichológia mindig is alkalmazkodott a kor technológiai újításaihoz és hasznosította azokat, az AI-innovációk különösen jelentősek, mivel nemcsak a pszichológiai gyakorlatot és kutatást javítják és fejlesztik, hanem potenciálisan a mentális egészségügyi szakemberek helyébe léphetnek az emberi intelligenciát és szociális interakciót igénylő alapvető tevékenységekben. Az AI-képes rendszerek és más technológiai innovációk miatt a munkavállalók kiszorulása már most is tapasztalható a bankszektorban, a félvezető-gyártásban, az ügyfélszolgálati munkakörökben és a jogi szakmában, hogy csak néhányat említsünk (Brynjolfsson & McAfee, 2011; Markoff, 2011). A mentálhigiénés szakma természetesen nem mentes ettől a kockázattól. A klinikai pszichológusok például több mint egy évtizedet töltenek a főiskolán, a doktori iskolában, a szakmai gyakorlaton és a posztdoktori tapasztalatok megszerzésével, hogy elsajátítsák az ismereteket és a készségeket elsajátítását. A mesterséges intelligencia-alapú rendszerek, mint például Watson, képesek minden digitalizált tudást átvizsgálni, és szinte azonnal elemezni, érvelni és döntéseket hozni ezek alapján. Ez a technológia minden bizonnyal bármely tudásalapú szakmában alkalmazható, így a klinikai pszichológiában is. Sőt, az emberhez hasonló szociális képességekkel rendelkező autonóm mesterséges intelligens ágensek már képesek interakcióba lépni az emberekkel, tanulni a valós tapasztalatokból, és talán egy napon a mentális egészségügyi szolgáltatások teljes skáláját elvégezni. Bár kétséges, hogy a közeljövőben a pszichológusokat és más mentálhigiénés szakembereket virtuális mesterséges intelligens ügynökök vagy mesterséges intelligenciával rendelkező robotok fogják helyettesíteni, a mesterséges intelligencia technológiáinak alkalmazása várhatóan gazdasági hatással lesz a pszichológiai szolgáltatásokra az elkövetkező években.

A kognitív fejlesztés hatásai

A mesterséges intelligencia technológiának az emberi agyhoz való közvetlen csatlakoztatása már megjelent az orvostudományban, mint az emberi kognitív vagy érzékszervi-motoros funkciók javításának és támogatásának módja. Közvetlen agyi implantátumokat például már használtak végtagprotézisek vezérlésére (Wolpaw, Birbaumer, McFarland, Pfurtscheller és Vaughan, 2002), nem veleszületett (szerzett) vakság kezelésére (Naam, 2010), Kínában pedig a kínai írásjelek írásának segítésére tesztelték a mozgássérült emberek számára (Minett és mások, 2012). Az agyi számítógépes interfészeket (Brain Computer Interfaces, BCI) nem orvosi célokra is használták már, hogy kommunikáljanak és irányítsanak eszközöket (Wolpaw, Birbaumer, McFarland, Pfurtscheller, Vaughan, 2002).

A beültetett mesterséges intelligencia technológiák az emberek általános kognitív képességeinek javítására vagy javítására is alkalmasak azért, hogy az embereket kiborgokká (részben emberré, részben géppé) teszik (Kurzweil, 2005; Naam, 2010). Ez a technológia egy nap talán lehetővé teszi az agy olyan területeinek helyreállítását, amelyek agyvérzés, traumás agysérülés vagy más szervi rendellenesség következtében károsodtak. A technológiát arra is lehetne használni, hogy a betegek számára valós idejű biofeedbacket nyújtson, és arra is, hogy előre programozott időpontokban vagy meghatározott szituációs jelzésekre, például stressz vagy más ingerek jelenlétére, automatikusan vezérelje az orvosi nanotechnológiák vagy pszichotróp gyógyszerek felszabadulását. E technológia fejlődésének azonban nem szándékolt pszichológiai és társadalmi következményei lehetnek. Például a kognitív fejlesztések birtoklása váratlan módon megváltoztathatja az egyén önérzetét és viselkedését. Továbbá, az a meggyőződés, hogy mások bizonyos kognitív előnyökkel rendelkeznek másokkal szemben, szorongást és bizalmatlanságot okozhat. A mesterséges intelligencia által megnövelt képességek egyénre és embercsoportokra gyakorolt pszichológiai hatásainak vizsgálata olyan kutatási terület, amelyhez a pszichológusok minden bizonnyal hozzájárulhatnak.

Mesterséges intelligencia Felsőbbrendűség

Az egyik legérdekesebb kérdés az, hogy vajon a mesterséges intelligencia képes lesz-e és mikor lesz-e teljesen utánozni az emberi agyat. A John Searle által 1980-ban bevezetett "erős mesterséges intelligencia" (Strong AI) kifejezés (Searle, 1980) a mesterséges intelligenciának egy olyan kategóriája, amelynek célja, hogy olyan gépeket hozzon létre, amelyek értelmi képességei megkülönböztethetetlenek az emberétől. Bár

az emberi általános intelligencia reprodukálása jelenleg még mindig meghaladja a mesterséges intelligencia határait, a technológiai fejlődés hihetetlen ütemben zárja a szakadékot. Egyesek úgy vélik, hogy az erős mesterséges intelligencia területén végzett munka olyan számítógépekhez fog vezetni, amelyek intelligenciája meghaladja az emberét (Kurzweil, 2005; Vinge, 1993). Ray Kurzweil, futurista és a Google műszaki igazgatója, azt jósolja, hogy ez 2029-re bekövetkezik (Kurzweil, 2005). Kurzweil előrejelzése részben a Moore-törvényen alapul (Moore, 1965), amely megbízhatóan bizonyította, hogy a számítógépek sebessége és memóriakapacitása egyaránt kétévente megduplázódik. Azt is megjósolja, hogy 2045-re a mesterséges intelligencia technológiája exponenciálisan fejlődik és tökéletesíti önmagát egy szingularitásnak nevezett pontig (Kurzweil, 2005; Vinge, 1993; von Neumann, 2012). Hasonlóan az asztrofizikában használt kifejezéshez, amely a fekete lyukak gravitációs hatásainak ismeretlenségét írja le, a szingularitás arra a kiszámíthatatlanságra utal, hogy mi fog történni az emberi történelemnek azon az átalakító pontján, amikor a gépek szuperintelligenciát fejlesztenek ki.

Az emberi általános intelligenciát megközelítő - és azt meghaladó - technológiával kapcsolatban valóban vannak ismeretlen eredmények. Az egyik lehetőség az, hogy az AI technológia fejlődése lehetővé teszi a gépek számára, hogy kialakítsák a saját teleológiájukat, amelyet a teremtőik nem gondoltak volna ki. Bár nem valószínű, hogy a mesterséges intelligencia technológia olyan alattomos intelligens ágensekké fejlődik, amelyek célja a világ átvétele, a közvetlenebb aggodalom az, hogy hogyan fogják ezt a technológiát alkalmazni, ellenőrizni, és hogy az alkalmazást a lakosság érdekeit és jólétét szolgálják-e majd. A nukleáris technológia 1940-es évekbeli fejlődéséhez hasonlóan az emberiség ismét olyasmit hoz létre, ami nagy hatalommal bír, és ha egyszer létrejön, nincs visszaút. Mindazonáltal az AI-technológia fejlődése továbbra is hihetetlen lehetőségeket és esélyeket kínál, amelyek képesek javítani a világot, ha bölcsen és jótékonyan közelítjük meg őket.

Következtetés

A mesterséges intelligencia technológia jelenléte már mindenütt jelen van körülöttünk; használják a logisztikai tervezésben, a pénzügyekben (a készletek megfigyelésére és kereskedelmére, valamint egyéb banki funkciók ellátására), az adatelemzésben, a gyártásban, az internetes keresőmotorokban, az autókban, a mobil de-vice alkalmazásokban (pl. az Apple Siri beszédfelismerő szoftvere), a repülőgépek irányítórendszereiben és még számtalan más alkalmazásban (lásd Kurzweil, 2005; Russell & Norvig, 2003). Sőt, a közeljövőben lehetőség nyílik a teljes emberi agy

szimulációjára is. A Blue Brain Project (Svájc) célja egy szintetikus agy létrehozása az emlősök agyának molekuláris szintig visszafejtésével. 2009-ben sikeresen kifejlesztették a patkány agykéreg modelljét, és 20 éven belül lehetséges lehet a teljes emberi agy szimulációja (Neild, 2012). 2013-ban az Obama-kormányzat an-jelentett be egy milliárd dolláros beruházást egy olyan agytérképezési projektbe, amely magán- és állami szervezetek konzorciumából áll (pl. Defense Applied Research Projects Agency; National Institutes for Health, National Science Foundation; Markoff, 2013). A projekt célja az emberi agy neurális hálózatainak funkcionális térképének létrehozása (lásd Alivisatos et al, 2012). A jelenlegi és a tervezett kutatási és fejlesztési beruházások a magán- és az állami szektorban egyaránt jelzik, hogy a mesterséges intelligencia és a kapcsolódó technológiák fejlesztésére összpontosítanak. Az AI-technológiák alkalmazása a mentális egészségügyben kétségtelenül olyan növekedési terület, amely az elkövetkező években nagy hatással lesz a pszichológiai gyakorlatra és kutatásra.

A pszichológia történelmileg fontos hozzájárulásokat tett a mesterséges intelligencia területéhez. Például Frank Rosenblatt volt az a pszichológus, aki megépítette a Mark 1 Perceptron-t (Rosenblatt, 1957) - az első olyan gépet, amely képes volt önállóan tanulni neurális úton.

Hálózati fogalmak

Donald O. Hebb neuropszichológus munkássága, akinek elmélete arról, hogy a neuronok a köztük lévő kapcsolatok megerősítése révén tanulnak (Hebb, 1949), megalapozta a mesterséges neurális hálóak tanulmányozását a mesterséges intelligenciában. David Rumelhart pszichológus és munkatársainak munkája (lásd Rumelhart, McClelland & PDP Research Group, 1986) továbbfejlesztette a memória neurális hálós modelljeinek tanulmányozását, amely befolyásolta a gépi tanulás fejlődését. Ezenkívül az 1960-as években a pszichológia teljes "kognitív forradalma" a pszichológia területén az emberi megismerés számítógépes modelljei iránti érdeklődéshez vezetett. Várható a pszichológusok és más egészségügyi szakemberek további hozzájárulása a mesterséges intelligencia technológia tanulmányozásához, fejlesztéséhez és megvalósításához. A pszichológusok és a mentális egészségügyben dolgozó más szakemberek hozzájárulhatnak többek között a mesterséges intelligencia technológiák tervezésének új és kreatív megközelítéseire irányuló kutatáshoz, a mesterséges intelligencia rendszerek laboratóriumi és terepi értékeléséhez, valamint annak tanulmányozásához, hogy az emberek és a mesterséges intelligencia hogyan lépnek kölcsönhatásba egymással. Az e területre irányuló kutatások további példái lehetnek az emberek és a mesterséges intelligens ágensek közötti társas kapcsolatok,

valamint az emberhez hasonló robotok emberekre gyakorolt pszichológiai hatásainak vizsgálata (és fordítva). A pszichológusok továbbá hozzájárulhatnak az e technológia etikus felhasználására vonatkozó döntésekhez a pszichológiai gyakorlatban, a kutatásban és a társadalom minden más területén.

Amint azt ez a cikk tárgyalja, a mesterséges intelligencia technológiának számos gyakorlati alkalmazása van, amelyek a betegek, az egészségügyi szolgáltatók és a társadalom javát szolgálhatják az ellátás fokozásával, a hatékonyság növelésével és a minőségi szolgáltatásokhoz való hozzáférés javításával. Mindazonáltal fennáll a veszélye annak, hogy ennek a technológiának negatív következményei is lehetnek. A közeljövőben a mentális egészségügyi szakemberek segítségét szolgáló, mesterséges intelligenciával támogatott rendszerekkel való konkrét alkalmazás és együttműködés várható. A nem is olyan távoli jövőben az ebben a cikkben tárgyalt AI-technológiák széleskörű alkalmazása mindennapos lehet. A pszichológusoknak és minden mentálhigiénés szakembernek ezért fel kell készülnie arra, hogy a betegek, a szakma és a társadalom egésze érdekében elfogadja és irányítsa az AI-technológiák használatát és tanulmányozását.

Szakirodalom

- Alivisatos, A. P., Chun, M., Church, G. M., Greenspan, R. J., Roukes, M. L., & Yuste, R. (2012). The brain activity map project and the challenge of functional connectomics. *Neuron*, 74, 970–974. doi: 10.1016/j.neuron.2012.06.006
- Anderson, M., & Anderson, S. L. (Eds.). (2011). *Machine ethics*. New York, NY: Cambridge University Press. doi:10.1017/CBO9780511978036
- Asimov, I. (1942). *Runaround: Astounding science fiction*. New York, NY: Street and Smith Publications, Inc. Asimov, I. (1985). *Robots and Empire*. New York, NY: Doubleday.
- Bartneck, C., Lyons, M. J., & Saerbeck, M. (2008). The relationship between emotion models and artificial intelligence. *Proceedings of the Workshop on the Role of Emotions in Adaptive Behaviour and Cognitive Robotics in affiliation with the 10th International Conference on Simulation of Adaptive Behavior: From animals to animates (SAB 2008)*. Osaka, Japan.
- Bindoff, I., Stafford, A., Peterson, G., Kang, B. H., & Tenni, P. (2012). The potential for intelligent decision support systems to improve the quality and consistency of medication reviews. *Journal of Clinical Pharmacy and Therapeutics*, 37, 452–458. doi:10.1111/j.1365-2710.2011.01327.x

- Brynjolfsson, E., & McAfee, A. (2011). *Race against the machine: How the digital revolution is accelerating innovation, driving productivity, and irreversibly transforming employment and the economy*. Cambridge, MA: MIT Sloan School of Management. Retrieved from http://ebusiness.mit.edu/research/Briefs/Brynjolfsson_McAfee_Race_Against_the_Machine.pdf
- Buchanan, B. G. (2005). A (very) brief history of artificial intelligence. *AI Magazine*, 26, 53–60.
- Buchanan, B. G., & Shortliffe, E. H. (1984). *Rule based expert systems: The MYCIN experiments of the Stanford heuristic programming project*. Reading, MA: Addison Wesley.
- Caudell, T. P., & Mizell, D. W. (1992, January). Augmented reality: An application of heads-up display technology to manual manufacturing processes. In *System Sciences, 1992: Proceedings of the twenty-fifth Hawaii International Conference on System Sciences (Vol. 2, pp. 659–669)*. New York, NY: IEEE. doi:10.1109/HICSS.1992.183317
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20, 273–297. doi:10.1007/BF00994018
- Coyle, D., Matthews, M., Sharry, J., Nisbet, A., & Doherty, G. (2005). Personal investigator: A therapeutic 3D game for adolescent psychotherapy. *Interactive Technology and Smart Education*, 2, 73–88. doi:10.1108/17415650580000034
- DeAngelis, T. (2012, March). A second life for practice? *Monitor on Psychology*, 43. Retrieved from <http://www.apa.org/monitor/2012/03/avatars.aspx>
- Defense Applied Research Projects Agency. (2013). *Detection and computational analysis of psychological signals (DCAPS)*. Retrieved from [http://www.darpa.mil/Our_Work/I2O/Programs/Detection_and_Computational_Analysis_of_Psychological_Signals-\(DCAPS\).aspx](http://www.darpa.mil/Our_Work/I2O/Programs/Detection_and_Computational_Analysis_of_Psychological_Signals-(DCAPS).aspx)
- Finlay, P. N. (1994). *Introducing decision support systems*. Cambridge, MA: Blackwell Publishers.
- Fujita, H., & Wu, I.-C. (2012). A special issue on artificial intelligence in computer games: AICG. *Knowledge-Based Systems*, 34, 1–2. doi:10.1016/j.knosys.2012.05.014
- Garfield, D. A., Rapp, C., & Evens, M. (1992). Natural language processing in psychiatry: Artificial intelligence technology and psychopathology. *Journal of Nervous and Mental Disease*, 180, 2227–2237.

- Gil, D., & Manuel, D. J. (2009). Diagnosing Parkinson's by using artificial neural networks and support vector machines. *Global Journal of Computer Science and Technology*, 9, 63–71.
- Gorrindo, T., & Groves, J. (2009). Computer simulation and virtual reality in the diagnosis and treatment of psychiatric disorders. *Academic Psychiatry*, 33, 413–417. doi:10.1176/appi.ap.33.5.413
- Güzeldere, G., & Franchi, S. (1995). Dialogues with colorful “personalities” of early AI. *Stanford Humanities Review*, 4, 161–169.
- Hand, D. J. (1985). *Artificial intelligence and psychiatry*. Cambridge, UK: Cambridge University Press.
- Hardesty, L. (2012 June 22). Researchers amplify variations in video, making the invisible visible. Retrieved from <http://web.mit.edu/newsoffice/2012/amplifying-invisible-video-0622.html>
- Hardin, J. M., & Chheng, D. C. (2007). Data mining and clinical decision support. In E. S. Berner (Ed.), *Clinical decision support systems: Theory and practice* (2nd ed., pp. 44–63). New York, NY: Springer. doi: 10.1007/978-0-387-38319-4_3
- Hebb, D. O. (1949). *The organization of behavior*. New York, NY: Wiley.
- IBM. (2013). IBM Watson: Ushering in a new era of computing. Retrieved from <http://www-03.ibm.com/innovation/us/watson/index.shtml>
- InTouch Health. (2012). RP-VITA robot. Retrieved from <http://www.intouchhealth.com/products-and-services/products/rp-vita-robot/>
- Jagielska, I., Matthews, C., & Whitfort, T. (1999). An investigation into the application of neural networks, fuzzy logic, genetic algorithms, and rough sets to automated knowledge acquisition for classification problems. *Neurocomputing*, 24, 37–54. doi:10.1016/S0925-2312(98)00090-3
- Kohannim, O., Hua, X., Hibar, D. P., Lee, S., Chou, Y. Y., Toga, A. W., . . . Thompson, P. M. (2010). Boosting power for clinical trials using classifiers based on multiple biomarkers. *Neurobiology of Aging*, 31, 1429–1442. doi:10.1016/j.neurobiolaging.2010.04.022
- Kramer, G. M., Mishkind, M. C., Luxton, D. D., & Shore, J. H. (2013). Managing risk and protecting privacy in telemental health: An overview of legal, regulatory, and risk management issues. In Myers & Turvey. (Eds.) *Telemental health: Clinical, technical and administrative foundations for evidence-based practice*. New York, NY: Elsevier.
- Krijn, M., Emmelkamp, P. M. G., Olafsson, R. P., & Biemond, R. (2004). Virtual reality exposure therapy of anxiety disorders: A review. *Clinical Psychology Review*, 24, 259–281. doi:10.1016/j.cpr.2004.04.001
- Krogh, A. (2008). What are

- artificial neural networks? *Nature Biotechnology*, 26, 195–197. doi:10.1038/nbt1386
- Kurzweil, R. (2005). *The singularity is near*. New York, NY: Viking Press.
- Lambert, M. J., & Barley, D. E. (2001). Research summary on the therapeutic relationship and psychotherapy outcome. *Psychotherapy: Theory, Research, Practice, Training*, 38, 357–361. doi:10.1037/0033-3204.38.4.357
- Lester, J. (2005, January). About Brigadoon. Brigadoon: An innovative online community for people dealing with Asperger's syndrome and autism. Retrieved from http://braintalk.blogs.com/brigadoon/2005/01/about_brigadoon.html
- Linden Research, Inc. (2013). *Second Life* (Version 1.3.2). Retrieved from <http://secondlife.com/>
- Lingley, R., Ali, M., Liao, Y., Mirjalili, R., Klonner, M., Sapanen, M., . . . Parviz, B. A. (2011). A single-pixel wireless contact lens display, *Journal of Micromechanics and Microengineering*, 21, 125014. doi: 10.1088/0960-1317/21/12/125014
- Manning, C. D., & Schütze, H. (1999). *Foundations of statistical natural language processing*. Cambridge, MA: The MIT Press.
- Markoff, J. (2011, March 5). Armies of expensive lawyers, replaced by cheaper software. *The New York Times*. Retrieved from <http://www.nytimes.com/2011/03/05/science/05legal.html>
- Markoff, J. (2013, February 18). Obama seeking to boost study of human brain. *The New York Times*. Retrieved from http://www.nytimes.com/2013/02/18/science/project-seeks-to-build-map-of-human-brain.html?pagewanted=all&_r0
- Masri, R. Y., & Mat Jani, H. (2012, June). Employing artificial intelligence techniques in Mental Health Diagnostic Expert System. In *ICCIS 2012: International Conference on Computer & Information Science* (Vol. 1, pp. 495–499). New York, NY: IEEE.
- Matthews, M., & Coyle, D. (2010). The role of gaming in mental health. In K. Anthony, D. M. Nagel, & S. Goss (Eds.), *The use of technology in mental health: Applications, ethics and practice* (Vol. 40, pp. 134–142). Springfield, IL: Charles C. Thomas.
- McCarthy, J. (1984). Some expert systems need common sense. *Computer Culture: The Scientific, Intellectual, and Social Impact of the Computer*, 426, 129–137.
- McShane, M., Beale, S., Nirenburg, S., Jarrell, B., & Fantry, G. (2012). Inconsistency as a diagnostic tool in a society of intelligent agents. *Artificial Intelligence in Medicine*, 55, 137–148. doi:10.1016/j.artmed .2012.04.005

- Minett, J. W., Zheng, H. Y., Manson CM. Fong, Zhou, L., Peng, G., & SY, W. (2012). A Chinese text input brain– computer interface based on the P300 Speller. *International Journal of Human-Computer Interaction*, 28, 472–483. doi:10.1080/10447318.2011.622970
- Moore, G. E. (1965). Cramming more components onto integrated circuits. *Electronics*, 38, 114–116. doi:10.1109/N-SSC.2006.4785860
- Morelli, R. (1989, November). Artificial intelligence in psychiatry: Issues and questions. In *Proceedings of the annual international conference of the IEEE Engineering in Medicine and Biology Society (EMBS), 1989: Images of the twenty-first century* (pp. 1812–1813). New York, NY: IEEE.
- Morelli, R. A., Bronzino, J. D., & Goethe, J. W. (1987). Expert systems in psychiatry. *Journal of Medical Systems*, 11, 157–168. doi:10.1007/BF00992350
- Naam, R. (2010). *More than human: Embracing the promise of biological enhancement*. New York, NY: Broadway Books.
- Neild, B. (2012, October 12). Scientists to simulate human brain inside a supercomputer. CNN Labs. Retrieved from <http://www.cnn.com/2012/10/12/tech/human-brain-computer>
- Patel, V. L., Shortliffe, E. H., Stefanelli, M., Szolovits, P., Berthold, M. R., Bellazzi, R., & Abu-Hanna, A. (2009). The coming of age of artificial intelligence in medicine. *Artificial Intelligence in Medicine*, 46, 5–17. doi:10.1016/j.artmed.2008.07.017
- Reger, G. M., Holloway, K. M., Rothbaum, B. O., Difede, J., Rizzo, A. A., & Gahm, G. A. (2011). Effectiveness of virtual reality exposure therapy for active duty soldiers in a military mental health clinic. *Journal of Traumatic Stress*, 24, 93–96. doi:10.1002/jts.20574
- Riva, G. (2010). Using virtual immersion therapeutically. In K. Anthony, D. A. M. Nagel, & S. Goss (Eds.), *The use of technology in mental health: Applications, ethics and practice* (pp. 114–123). Springfield, IL: Charles C Thomas.
- Rizzo, A. A., Buckwalter, J. G., & Neumann, U. (1997). Virtual reality and cognitive rehabilitation: A brief review of the future. *The Journal of Head Trauma Rehabilitation*, 12, 1–15. doi:10.1097/00001199-199712000-00002
- Rizzo, A. A., Lange, B., Buckwalter, J. G., Forbell, E., Kim, J., Sagae, K., . . . Kenny, P. (2011). An intelligent virtual human system for providing healthcare information and support. *Study of Health Technology Information*, 163, 503–509.
- Rizzo, A. A., Parsons, T. D., Lange, B., Kenny, P., Buckwalter, J. G., Rothbaum, B., . . . Reger, G. (2011). Virtual reality goes to war: A brief review of the future of military behavioral healthcare. *Journal of Clinical Psychology in Medical Settings*, 18, 176–187. doi:10.1007/s10880-011-9247-2

- Rogers, C. (1951). *Client-centered therapy*. Boston: Houghton Mifflin Company.
- Rosenblatt, F. (1957), *The Perceptron—a perceiving and recognizing automaton*. Report 85–460-1, Cornell Aeronautical Laboratory.
- Rumelhart, D. E., & McClelland, J. L. (1986). *Parallel distributed processing: Explorations in the microstructure of cognition (Vol. 1. Foundations)*. Cambridge, MA: MIT Press.
- Russell, S. J., & Norvig, P. (2003). *Artificial intelligence: A modern approach (2nd ed.)*, Upper Saddle River, NJ: Prentice Hall.
- Samuel, A. L. (1959). *Some studies in machine learning using the game of checkers*. Retrieved from http://www.cs.unm.edu/~terran/downloads/classes/cs529-s11/papers/samuel_1959_B.pdf
- Searle, J. (1980). *Minds, brains and programs*. *Behavioral and Brain Sciences*, 3, 417–424. doi:10.1017/S0140525X00005756
- Servan-Schreiber, D. (1986). *Artificial intelligence and psychiatry*. *Journal of Nervous and Mental Disease*, 174, 191–202. doi:10.1097/00005053-198604000-00001
- Shibata, T., & Wada, K. (2011). *Robot therapy: A new approach for mental healthcare of the elderly - a mini-review*. *Gerontology*, 57, 378–386. doi:10.1159/000319015
- Shortliffe, E. H. (1976). *Computer-based medical consultations: MYCIN*. New York, NY: Elsevier.
- Shortliffe, E. H. (1993). *The adolescence of AI in medicine: Will the field come of age in the '90s?* *Artificial Intelligence in Medicine*, 5, 93–106. doi:10.1016/0933-3657(93)90011-Q
- Szolovits, P. (1982). *Artificial intelligence and medicine*. Boulder, CO: Westview Press.
- Teuscher, C., & Hofstadter, D. R. (2006). *Alan Turing: Life and legacy of a great thinker*. New York, NY: Springer.
- Turing, A. M. (1950). *Computing machinery and intelligence*. *Mind*, 49, 433–460.
- Vinge, V. (1993). *The coming technological singularity: How to survive in the post-human era*. Retrieved from <http://www-rohan.sdsu.edu/faculty/vinge/misc/singularity.html>
- von Neumann, J. (2012). *The computer and the brain (The Silliman Memorial Lectures Series)*. New Haven, CT: Yale University Press.
- Weizenbaum, J. (1966). *Computer power and human reason: From judgment to calculation*. San Francisco, CA: Freeman.
- Wolpaw, J. R., Birbaumer, N., McFarland, D. J., Pfurtscheller, G., & Vaughan, T. M. (2002). *Brain-computer interfaces for communication and control*. *Clinical Neurophysiology*, 113, 767–791. doi:10.1016/S1388-2457(02)00057-3

Zadeh, L. A. (1965). Fuzzy sets. *Information and Control*, 8, 338–353.
doi:10.1016/S0019-9958(65)90241-X

3. PSZICHOMETRIA ÉS MÉRŐESZKÖZ-FEJLESZTÉS

A pszichológiai mérés területén az elmúlt években egyre nagyobb szerepet kap a mesterséges intelligencia (MI) és a gépi tanulás (ML). Ami korábban hosszadalmas, kézzel fogható munkát igénylő folyamat volt, azt ma már teljesen automatizáltan, technológiák segítségével lehet végezni. Hagyományosan a pszichometriában a pszichológiai mérőeszközök, mint például a kérdőívek, tesztek vagy más mérési eszközök fejlesztése, kalibrálása és validálása meglehetősen munkaigényes és időigényes folyamat volt. Egy ilyen eszköz fejlesztése általában magában foglalja a kérdések kidolgozását, a válaszadók egy megfelelő mintájának bevonását, majd statisztikai elemzések végzését a skála vagy teszt megbízhatóságának és érvényességének értékelésére. Ez a folyamat gyakran több hónapot, akár éveket is igénybe vehet. Az MI és a gépi tanulás lehetőségeinek köszönhetően számos ilyen lépés automatizálható vagy meggyorsítható

Ebben a fejezetben bemutatjuk, hogyan formálják át ezek a technológiák a pszichometria és mérőeszköz-fejlesztés hagyományos kereteit. Szó lesz az automatikus tesztgenerálásról és az adaptív tesztelésről, amelyek lehetővé teszik, hogy a kérdések percek alatt létrejöhessenek, és a teszt dinamikusan alkalmazkodjon a kitöltő képességeihez. Megvizsgáljuk az MI-alapú skáafejlesztés és validálás új módszereit, amelyek nemcsak gyorsítják a folyamatot, hanem új szintre emelik a mérőeszközök pontosságát. Kitérünk az implicit mérések és gépi tanulás kapcsolatára is, ahol reakcióidő és szemmozgás-elemzés segítségével tárulnak fel rejtett pszichológiai folyamatok. Emellett bemutatjuk, hogyan használható az AI az explicit mérésekben, például önbeszámolás skálák fejlesztésében és elemzésében. Végül áttekintjük a Big Data szerepét a pszichológiában: hogyan segítenek a nagyléptékű adatbázisok és prediktív modellek a mentális egészség, a fejlődési pályák és társadalmi trendek megértésében. A célunk, hogy átfogó képet adjunk arról, milyen lehetőségeket és kihívásokat hoz az AI integrációja a pszichológiai mérés jövőjében.

Automatikus tesztgenerálás és adaptív tesztelés

A pszichológia és az MI kapcsolat új lehetőségeket teremtett, amelyek korábban csak elméletben léteztek, mint pl. a tesztkérdések automatikus generálása, vagy az, hogy a teszt valós időben igazodik a kitöltő képességéhez. Ezek az új eszközök nem csak gyorsabbak lehetnek, hanem számos esetben pontosabbak is, ám közben felvetnek fontos szakmai és etikai problémákat is, amikhez a könyv későbbi részeiben visszatérünk. Az automatizált tesztgenerálás (AIG) egy olyan technika, amikor a

mesterséges intelligencia segítségével egy automata rendszer generál új tesztkérdéseket. Ezek a kérdések hasonló pszichometriai tulajdonságokkal bírnak, mint a hagyományosan kézzel írt kérdések, de sokkal gyorsabban és nagyobb mennyiségben képesek előállni.

Az utóbbi években egyre nőtt az érdeklődés az automatikusan generált pszichológiai tesztek iránt. Ho (2024) azt vizsgálta, hogyan képesek a nagy nyelvi modellek (LLM-ek), így a GPT-3.5 automatikusan generálni személyiségteszt kérdéseket a Big Five modell öt dimenziója mentén. A kutatás azt vetette össze, mennyire hasonló az ember által írott (humán) és az MI által generált (AI) állítások pszichometriai szempontból, különösen a reliabilitás, validitás és faktorstruktúra tekintetében. A vizsgálati mintát 250 fő alkotta, akik egy kevert tételből álló személyiségkérdőívet töltöttek ki. A tételek generálása során a GPT-3.5 modellt úgy utasították, hogy minden személyiségdimenzióhoz 30 állítást készítsen, szigorúan a Big Five definícióit követve. A humán és a mesterséges intelligenciával generált tételeket véletlenszerűen keverték, így a válaszadók nem tudhatták, melyik tétel milyen forrásból származik. Az adatok elemzése megerősítette, hogy az AI által generált tételek pszichometriai jellemzői közel azonosak voltak az emberek által készített tételével. A Cronbach-alfa értékek az összes dimenzióban elfogadható vagy jó szinten mozogtak (0.71–0.86), és a feltáró faktoranalízis igazolta, hogy a generált itemek megfelelően csoportosultak a célzott faktorokhoz. Ezen felül a válaszadók nem észlelték különösebben az MI által írt tételeket „művinek” vagy idegennek — sok esetben ugyanolyan természetesnek értékelték őket, mint az emberi tételeket. A szerző kiemeli, hogy az MI-vel támogatott tételgenerálás forradalmasíthatja a pszichometriai eszközök fejlesztését, különösen nagy volumenű, skálázandó vizsgálatokban. Ugyanakkor hangsúlyozza a további validálás és szakmai felülvizsgálat szükségességét, különösen akkor, ha a tételeket klinikai vagy döntéshozatali kontextusban alkalmazzák.

Li és munkatársai (2024) a fentiekhez hasonló kutatási céllal azt vizsgálták, hogy a Helyzetmegítélési tesztek (Situational Judgment Tests, SJT) automatikus itemgenerálása mennyire pontos és megbízható. A Helyzetmegítélési teszt olyan pszichológiai mérőeszköz, amelyben a válaszadónak egy szituáció leírása után több lehetséges válaszlehetőség közül kell választania, attól függően, hogyan reagálna az adott helyzetben. Íme egy példa: „Egy projektcsapat tagja vagy, és észreveszed, hogy az egyik kollégád rendszeresen késve adja le a feladatokat, ami lassítja a teljes csapat munkáját. A határidő közeleg, és a projektvezető nem tud erről.” A mit tennél kifejezést követően pedig 4 válaszlehetőség található. Ezek a tesztek elsősorban interperszonális készségek, döntéshozatali stílus vagy személyiségvonások mérésére alkalmasak, és gyakran használják őket munkahelyi kiválasztásban vagy kompetenciafejlesztésben is (Lievens et al., 2008). A kutatók egy több lépcsős tétel generálási eljárást alkalmaztak.

Először a modellnek természetes nyelvű utasításokat adtak, melyek alapján adott szituációkat kellett generálnia. Ezek után a rendszernek többféle válaszlehetőség kellett adni, amelyek különböző személyiségjellemzőket mutatnak (pl. magas vs. alacsony extraverzió). A kutatók pszichológus szakértők segítségével értékelték a helyzeteket tartalmi és pszichológiai szempontból. A kapott eredmények azt mutatják, hogy az LLM által generált szituációk értelmesnek és logikusnak bizonyultak, a választott lehetőségek is jól tükrözték az adott személyiség dimenzió lényegét és a szakértők szerint közel egyenértékűek voltak a humán fejlesztésű szituációs tesztekkel. Az emberi válaszadók nemcsak értették, de jelentős mértékben tudtak azonosulni az LLM által generált szituációkkal is, ami arra utal, hogy ezek a tartalmak használhatók lehetnek például munkahelyi kiválasztás vagy személyiségfejlesztő tréningek kontextusában. A kutatás egyik újítása, hogy a tétel generálás sikeressége mellett a személyiség dimenziók prediktív érvényességét is mérték a válaszok alapján. A gép által generált SJT tételek képesek voltak előrejelezni a válaszadók önjellemző skála eredményeit, vagyis valódi pszichológiai mérőértékűek voltak. A kutatók hangsúlyozzák, hogy az LLM-k jó eszközök lehetnek a személyiség alapú teszt fejlesztésénél, de szükség van kétfajta validációra: az algoritmus minőségi felügyeletére, és pszichológus szakértők általi jóváhagyására. A tanulmány hozzájárul ahhoz az egyre bővülő szakirodalomhoz, mely a mesterséges intelligenciát nem csupán szöveg generátorként, hanem pszichometriai fejlesztőtársaként kezeli

Egy kutatásban Ustiyanyovych és Krpan (2025) LLM-generált tételeket mutatott be, amelyek a Big Five személyiségstípusok (köztük az extraverzió) mentén állítottak elő tételeket. Például az „extraverzió” skála tétel volt, hogy „Gyakran keresem mások társaságát még akkor is, ha fáradt vagyok” vagy „Új emberekkel is könnyen szóba elegyedem nagyobb rendezvényeken”. Az alkalmazott modell képes volt „szintetikus” ikerügynököket létrehozni — ezek olyan digitális modellek, amelyek úgy viselkednek, úgy válaszolnak, mint az adott személy, és ott, ahol szimuláció-alapú tesztelés zajlik, ott szintén „kitöltik” a tesztet. Összehasonlították a generált tételeket a „szintetikus ikrekkel”, egy egészséges, klasszikusan használt személyiség skála alapján. Az eredmények szerint jól korreláltak az eredeti skálával, és mindezek mellett jól illeszkedtek az elvárt faktorstruktúrába is. Szerintük az LLM-k nemcsak releváns tételeket tudnak generálni és a pszichometriailag érvényes, hanem a személyre szóló, szimuláció-alapú tesztelés új korszakát is megnyitják ezzel

Brandli és munkatársai (2024) szisztematikus szakirodalmi áttekintést készítettek arról, hogy a mérésekben általában hogyan alkalmazzák a mesterséges intelligenciát (AI) a számítógépes adaptív tesztelésben (CAT) a diákok kognitív teljesítményének mérésére. Az elsődleges cél az volt, hogy feltérképezzék az elmúlt évek tudományos eredményeit, és megértsék, milyen mértékben javíthatja az AI a tesztelési folyamat

pontosságát, hatékonyságát és egyénre szabhatóságát. A szerzők a 2003 és 2023 közötti időszakban megjelenő tanulmányokat vizsgálták, míg végül 28 tanulmányt vontak be az elemzéseikbe. Ezek között szerepeltek szimulációs vizsgálatok, valós alkalmazások, valamint különböző mesterséges intelligencia-modellek összehasonlításai. Az elemzés alapján a leggyakrabban alkalmazott AI-technológiák a Bayes-hálók, a neurális hálózatok, valamint genetikus algoritmusok voltak, de megjelentek a mélytanulás (deep learning) és természetes nyelvfeldolgozás (NLP) eszközei is. A kutatási eredmények alátámasztották, hogy az AI-alapokon nyugvó adaptív tesztek pontosabban becsülik a tanulók képességszintjét akár kevesebb kérdés alapján is. Mindezek természetesen rövidebb tesztidőt és kevesebb fáradást eredményeznek. Fontos megjegyezni azt is, hogy ezek a modellek sokkal inkább detektálták a válaszadók egyéni feladatmegoldó stratégiáit, és a saját válaszaikhoz igazítottan kezeltek személyes különbségeket, mint a klasszikus, CAT-alapú rendszerek. Brandliék részletesen foglalkoznak az etikai és technológiai problémákkal is. Véleményük szerint az AI a tesztelésben ígéretes, azonban mindig számolni kell az algoritmikus torzításokkal, az átláthatatlan döntéshozatali folyamatokkal és a magánélethez való joggal. Ezen kívül arra is figyelmeztetnek, hogy jó néhány kutatás csak laboratóriumi körülmények között zajlott, így a "valódi" iskolai környezetben való hatékony alkalmazhatósága még kérdéses, főleg, ha az iskolák erőforrásai- vagy pedagógiai környezeti tényezői nagyon eltérnek. Összefoglalóan a szerzők úgy gondolják, hogy a mesterséges intelligenciának nagy szerepe lehet a kognitív vizsgálat adaptív változatainak fejlesztésében, főleg akkor, ha pszichológusok, tanárok és informatikusok együttműködésben dolgoznak.

Szempont	Előnyök	Hátrányok / Korlátok
Tételgenerálás gyorsasága	Nagy mennyiségű kérdés generálható percek alatt	Túlgenerálás, redundáns vagy irreleváns tételek
Tartalmi változatosság	Különbéféle stílusú és témájú kérdések; könnyű kulturális adaptáció	Nehéz biztosítani az elméleti fedést és torzításmentességet
Pszichometriai minőség	Megfelelő reliabilitás és faktorstruktúra is elérhető AI-generált	Szükséges az utólagos szakértői validálás
Adaptív tesztelés képessége	AI jobban alkalmazkodik a válaszadók mintázataihoz rövidebb	Komplex modellek átláthatatlansága (black box)
Skálatejesztés	Új tételek generálása validált modellek alapján (pl. Big Five)	Az érvényesség hosszú távú stabilitása nem mindig ismert
Tanulási algoritmusok	AI képes visszacsatolás alapján javítani	Kísérleti fázisban van, kevés valódi alkalmazás
Felhasználói élmény	Válaszadók természetesebbnek érzik	A hitelesség csökkenhet, ha tudják, hogy gép írta
Etikai kérdések	Skálázhatóság, hozzáférhetőség javulása	Adatvédelem, torzítás, AI-felelősség kérdései

1. táblázat Az AI alkalmazásának előnyei és hátrányai az automatikus tesztgenerálásban és adaptív tesztelésben

AI-alapú skálatejlesztés és validálás

A pszichológiai skálák fejlesztésének folyamata hosszú évtizedig az ezzel foglalkozó szakemberek tudásán, az alkalmazott elméleti modelleken és fáradtságos empirikus finomításon alapult. Az elmúlt években azonban azt láthatjuk, hogy a mesterséges intelligencia ezen a területen is egyre nagyobb teret hódít. Amíg a kutatók és a pszichometriai szakemberek a hagyományos módszerekkel dolgoznak, sokszor heteken vagy hónapokon keresztül tart egy-egy skála tételeinek csiszolgotása, tökéletesítése. Ezzel szemben már olyan technológiai megoldások is léteznek (pl. Scorpion AI), amelyek akár néhány perc leforgása alatt képesek több száz új tételt generálni. Sőt, ezek a tételek messzemenően megfelelnek a pszichológiai modellek elvárásainak és a mérés céljainknak is. Ezzel minden bizonnyal hamarosan egy új korszak köszönt majd be a skálatejlesztésben. Az AI-alapú skálatejlesztés hátterét jelenő nagy nyelvi modellek (Large Language Models – LLM) felhasználása, lehetővé teszi a tételek újrafogalmazását.

A generatív pszichometria területén különösen izgalmas fejlesztés az AI-GENIE (Automatic Item Generation and Validation via Network-Integrated Evaluation) elnevezésű projekt, ami egy mesterséges intelligenciás keretrendszer, ami teljesen automatizált itemgenerálást és itemvalidálást nyújt, főként a LLM-ek és a Monte Carlo szimulációk alkalmazásával (Russell-Lasalandra és mtsai., 2024). Az AI-GENIE ezt a folyamatot szakaszolja hat lépésre és részben automatizálja: itemek generálása LLM-ek segítségével, beágyazás (embedding), redundanciák kiszűrése, dimenzionalitás becslése Feltáró Gráfelmélet (Exploratory Graph Analysis – EGA) alkalmazásával, itemek stabilitásának vizsgálata újramegközelítő EGA-val (bootstrap EGA), és végül egy ötödik szakaszban végső validálás. A végső tesztelésbe öt LLM-et (GPT-3.5, GPT-4o, Llama 3, Gemma 2, Mixtral), fókuszálva a Big Five személyiségmodellekre. 15–58 tételből álló kérdéscsoportokat készítettek, és miután eltávolították a redundáns és instabil itemeket, a skálák jó illeszkedést mutattak az elméleti modellhez. Az empirikus validálás során az 5000 fős vizsgálati mintán készült Big Five skálák meggyőzően bizonyították az AI-GENIE által generált tételek megbízhatóságát és érvényességét. Egy ilyen eljárás azonban nemcsak óriási idő- és költségmegtakarítást jelent, hanem csökkenti a szakértői beavatkozás mértékét és lehetőséget ad arra, hogy nagy és változatos itemkészleteket állítsanak elő pillanatok alatt. Bár a Big Five kérdőív alkalmazásával nagyon jó eredmények születtek, a szerzők hangsúlyozzák, hogy további kutatás szükséges más konstruktumokra való alkalmazhatóság vizsgálatához. Az AI-GENIE tehát összességében egy ígéretes eszköz a pszichológiai mérőeszközök fejlesztésének felgyorsítására.

Lépés	Leírás
1. Itemek generálása LLM-ekkel	Nagy nyelvi modellek (pl. GPT-4, Llama 3) segítségével új tételek létrehozása a célzott pszichológiai konstruktum alapján.
2. Beágyazás (Embedding)	A generált tételek numerikus reprezentációjának elkészítése, amely lehetővé teszi a hasonlóságok és kapcsolatok elemzését.
3. Redundáns tételek eltávolítása	Az ismétlődő vagy túlzottan hasonló itemek kiszűrése a tartalmi és statisztikai redundancia csökkentése érdekében.
4. Dimenzionalitás becslése (EGA)	Exploratory Graph Analysis alkalmazása a tételek mögötti faktorstruktúra feltárására és a konstruktumok elkülönítésére.
5. Itemstabilitás vizsgálata (Bootstrap EGA)	A tételek stabilitásának ellenőrzése ismételt mintavétellel, hogy kiszűrjük az instabil vagy gyenge itemeket.
6. Végső validálás	A megtisztított itemkészlet pszichometriai vizsgálata (megbízhatóság, érvényesség), majd skálák kialakítása és tesztelése

2. táblázat Az AI-GENIE keretrendszer 6 lépése az automatizált tételgenerálás és validálás során

A tartalmi validálás kulcsfontosságú lépés a pszichológiai skálák fejlesztésében, hiszen biztosítja, hogy az adott mérőeszköz valóban azt a konstruktumot mérje, amit célul tűztek ki. Ennek ellenére a kutatók gyakran kihagyják ezt a folyamatot, mert drága és időigényes, valamint speciális szakértelmet igényel. Erre kínál megoldást a RATER rendszer (Replicable Approach to Expert Ratings), amely egy ingyenes, webalapú eszköz (www.contval.org), és gyors, megbízható visszajelzést ad a skálák tartalmi érvényességéről (Pillet et al., 2025). A RATER mesterséges intelligenciát használ, két fejlett modell – RATER C és RATER D – segítségével, amelyek több mint 2400 tudományos cikkből származó pszichometriai skálákon tanultak. A rendszer BERT és GPT architektúrákra épül, így képes megítélni, hogy az egyes tételek mennyire illeszkednek a célzott konstruktumhoz, elkülönülnek-e más fogalmaktól, és lefedik-e a tartalmi domén minden fontos aspektusát. Hat különböző vizsgálat igazolta a RATER

pontosságát és megbízhatóságát, ami azt jelenti, hogy valódi segítséget nyújthat a kutatóknak, bírálóknak és hallgatóknak. A rendszer nem helyettesíti teljesen az emberi szakértelmet, de jelentősen csökkenti az idő- és költségigényt, miközben növeli a kutatások minőségét és érvényességét. Összességében a RATER egy innovatív eszköz, amely demokratizálja a tartalmi validálást, és hozzájárul ahhoz, hogy a viselkedéstudományi kutatások eredményei megbízhatóbbak legyenek.

Content Validity Tool

General Introduction

Prepare Your Instrument

Analyze Your Instrument

Upload your prepared instrument here. As soon as the instrument is uploaded, the analysis will start.

Drag and drop file here
Limit 10MB per file

Browse files

Citation

Pillet, J. C., Larsen, K., Dobolyi, D., Queiroz, M., Handler, A., Arnulf, K., Sharma, R. (2025). [AI-Augmented Content Validation in Behavioral Research: Development and Evaluation of the RATER System](#). *MIS Quarterly*, Forthcoming. <https://doi.org/10.25300/MISQ/2025/18946>

Feedback & Comments

1. ábra A RATER rendszer nyitóoldala

Az empirikus kutatások számos példát kínálnak az MI-alapú skálatechnológiákra. Terry és munkatársai (2025) ChatGPT-t alkalmazták egy grit skála itemeinek generálására, majd feltáró és megerősítő faktoranalízissel igazolták a kétfaktoros szerkezetet. Az első vizsgálatban (180 fős mintán) az AI által generált tételek kétfaktoros szerkezetet mutattak, amely megfelelt az eredeti skálák elméleti modelljének. A belső konzisztencia kiemelkedően magas volt ($\alpha = 0,93-0,94$), ami azt jelzi, hogy az AI által létrehozott

tételek megbízhatóak. A második vizsgálatban (366 fős mintán) a megerősítő faktoranalízis szintén igazolta a kétfaktoros struktúrát, erős faktorsúlyokkal és jó illeszkedési mutatókkal (CFI = 0,97). Érdekes eredmény, hogy az AI-generált skála jobban előre jelezte a hallgatók tanulmányi teljesítményét (GPA), mint a hagyományos skálák. Ez arra utal, hogy az AI nemcsak gyorsítja a skálatestést, hanem akár javíthatja a mérőeszközök prediktív erejét is. Ugyanakkor a kutatók felhívják a figyelmet az etikai kérdésekre és az eredetiség problémájára, mivel az AI által létrehozott tételek néha hasonlítanak a meglévő skálák itemeire. A jövőben fontos lesz a promptok finomítása és fejlettebb AI-modellek használata, hogy valóban új és kreatív tételek szülessenek. Összességében a tanulmány azt mutatja, hogy az AI ígéretes eszköz a pszichológiai mérőeszközök fejlesztésében, de felelős és átgondolt alkalmazást igényel.

A Oeljeklaus és munkatársai (2025) azt vizsgálták, hogy a ChatGPT által generált személyiségskálák mennyire állják meg a helyüket a hagyományos, szakértők által fejlesztett skálákkal szemben. Két konstruktmra fókuszáltak: *reziliencia* (az érzelmi stabilitás pozitív pólusa) és *önszervezés* (a lelkiismeretesség egyik aspektusa). A kutatók két online vizsgálatot végeztek (N = 155 és N = 459), ahol a résztvevők mindkét típusú skálát kitöltötték. Az eredmények azt mutatták, hogy az AI-generált és az emberi szakértők által készített skálák hasonló megbízhatósági mutatókat és tartalmi, konstruktm- és kritériumvaliditást értek el. Mindkét skála jól korrelált a Big Five megfelelő dimenzióival: a reziliencia negatívan a neuroticizmussal, az önszervezés pedig pozitívan a lelkiismeretességgel. Érdekes módon az AI által létrehozott reziliencia-skála kissé jobb előrejelzője volt a kiégés kockázatának, míg az önszervezés esetében nem mutatkozott jelentős különbség. Ugyanakkor az AI-generált skálák gyengébben teljesítettek a mérési invariancia vizsgálatában, különösen nemek között, ami felveti a nemi torzítás problémáját. A kutatók arra jutottak, hogy bár a ChatGPT képes gyorsan és költséghatékonyan létrehozni pszichometriailag elfogadható tételket, az eredmények nem általánosíthatók minden konstruktra, és továbbra is szükség van szakértői ellenőrzésre. Az MI így inkább kiegészítő eszközként használható a skálatestés korai szakaszában, különösen új konstruktmok esetén. Ugyanakkor a minőségbiztosítás és az etikai kérdések kiemelt figyelmet igényelnek, hiszen az MI-alapú megközelítések számos kihívást hordoznak. Az adatvédelem mellett kezelni kell az LLM-ekben rejlő torzításokat és kulturális biasokat, valamint biztosítani az átláthatóságot és a replikálhatóságot, mivel az MI-alapú folyamatok gyakran „fekete doboz” jellegűek. A jövőben várható a generatív pszichometria további térnyerése, valamint a hibrid modellek – az LLM-ek és a klasszikus statisztikai módszerek kombinációja – alkalmazása, amelyek új szintre emelhetik a pszichológiai mérőeszközök fejlesztését (Oeljeklaus, Höft, & Danner, 2025).

Implicit mérések és gépi tanulás

Az implicit mérések célja, hogy feltárják azokat a pszichológiai folyamatokat, amelyek nem hozzáférhetők közvetlen önbeszámoló útján. Míg az explicit kérdőívek a tudatos attitűdöket és vélekedéseket mérik, az implicit módszerek olyan viselkedési jelekből következtetnek a mentális tartalmakra, amelyeket az emberek nem tudnak vagy nem akarnak kontrollálni (Gawronski & Hahn, 2019). Ide tartoznak például a reakcióidő-alapú tesztek (pl. Implicit Asszociációs Teszt), a szemmozgás-elemzés, vagy akár a pupillometria. Ezek az adatok rendkívül gazdagok, de elemzésük hagyományosan időigényes és komplex. Az utóbbi években a gépi tanulás és a mesterséges intelligencia (MI) új lehetőségeket nyitott meg ezen a területen: képesek nagy mennyiségű viselkedési adatból mintázatokat azonosítani, előrejelzéseket készíteni, és finom különbségeket feltárni, amelyek a hagyományos statisztikai módszerekkel nehezen észlelhetők (Orrù et al., 2020). A gépi tanulás alkalmazása implicit mérésekben nemcsak gyorsítja az elemzést, hanem új típusú mutatókat is létrehoz. Például a szemmozgás-adatokból származó fixációs mintázatok vagy a reakcióidő-eloszlások alapján algoritmusok képesek azonosítani kognitív terhelést, figyelmi állapotot, sőt személyiségvonásokat is. Az alábbiakban bemutatunk néhány konkrét példát az utóbbi évekből, amelyek jól szemléltetik, hogyan kapcsolódik össze az implicit mérés és a gépi tanulás a modern pszichológiai kutatásban.

Bachurina és munkatársai (2022) gépi tanulási módszereket alkalmaztak annak előrejelzésére, hogy a résztvevők mennyire pontosan teljesítenek különböző nehézségű kognitív feladatokat. A modell a reakcióidőt, a feladat nehézségi szintjét és szemmozgási mutatókat (fixációk száma, saccadok, pupillaátmérő) használta. Az eredmények szerint a gépi tanulás robusztusan képes volt előre jelezni a teljesítményt, és a szemmozgási adatok önállóan is jelentős prediktív erővel bírtak.

Zangrossi és kollégái (2024) az Autobiographical Implicit Association Test (aIAT) során nemcsak a reakcióidőt, hanem a szemfixációk mintázatát is elemezték. Az új „eye-D index” segítségével sikerült kimutatni, hogy a bűncselekményhez kapcsolódó emlékek jelenléte befolyásolja a fixációk eloszlását, és ez az index erősen korrelált a hagyományos IAT-mutatóval. Ez a módszer különösen ígéretes a kriminalisztikai és klinikai alkalmazásokban. A kutatás középpontjában az autobiografikus emlékek felismerése állt, amely kulcsfontosságú lehet például kriminalisztikai vizsgálatokban. A szerzők az aIAT segítségével azt vizsgálták, hogy egy adott esemény információja valóban jelen van-e a személy memóriájában. Az újdonság ebben a tanulmányban az volt, hogy az aIAT-et szemmozgás-elemzéssel kombinálták, és létrehozták az úgynevezett eye-D indexet, amely a fixációk topográfiáját használja az emlékek rejtett

detektálására. A kísérletben résztvevők egy szimulált bűncselekmény helyzetben vettek részt, ahol „Guilty” (bűnös) vagy „Innocent” (ártatlan) szerepet kaptak. Egy héttel később mindenki elvégezte az aIAT-et, miközben szemmozgásukat Tobii Pro Spectrum eszközzel rögzítették. Az eredmények azt mutatták, hogy a bűnös résztvevők több fixációt irányítottak a kategóriacímkékre azokban a blokkokban, ahol az igaz állítások és a bűncselekményhez kapcsolódó mondatok ugyanahhoz a válaszgombhoz tartoztak. Az ártatlan résztvevők ezzel szemben az ellenkező mintázatot mutatták. Ez az aszimmetrikus figyelemeloszlás az eye-D index segítségével számszerűsíthető volt, és erősen korrelált a hagyományos aIAT-D mutatóval. A kutatók azt is kimutatták, hogy az eye-D index hozzáadása jelentősen növeli a módszer érzékenységét, vagyis a két mutató kombinációja pontosabban azonosítja a bűnös résztvevőket. Az eredmények arra utalnak, hogy a szemmozgás mintázatai nemcsak a figyelmi folyamatokat tükrözik, hanem a kognitív terhelést és a válaszkonfliktusokat is, amelyek az emlékek feldolgozásával kapcsolatosak. Ez a megközelítés különösen ígéretes, mert nehezen manipulálható, így a módszer ellenállóbb lehet a szándékos torzításokkal szemben, mint a pusztán reakcióidő-alapú tesztek. Összességében a tanulmány azt bizonyítja, hogy az implicit mérési módszerek és a szemmozgás-elemzés kombinációja új lehetőségeket kínál a rejtett emlékek detektálására, különösen olyan területeken, mint a kriminalisztika vagy a klinikai pszichológia. A szerzők szerint a jövőben érdemes tovább vizsgálni, hogyan integrálható ez a technológia más viselkedési és neurofiziológiai mutatókkal, hogy még pontosabb és megbízhatóbb eszközök álljanak rendelkezésre az igazságügyi és kutatási gyakorlatban.

Nilsson és munkatársai (2025) kutatásának középpontjában az implicit motívumok álltak – olyan tudattalan szükségletek, mint a hatalom, a teljesítmény és az affiliáció iránti vágy, amelyek alapvetően befolyásolják viselkedésünket és érzelmeinket. Ezeket a motívumokat hagyományosan a *Picture Story Exercise* (PSE) módszerrel mérik, ahol a résztvevők rövid történeteket írnak kétértelmű képekről. A probléma az, hogy az ilyen történetek kódolása rendkívül időigényes és szakértői munkát igényel, ami évtizedek óta korlátozza az implicit motívumkutatás fejlődését. Nilssonék ezt a kihívást szerették volna megoldani azzal, hogy gépi tanulást és nagy nyelvi modelleket (LLM-eket) alkalmaztak a kódolási folyamat automatizálására. A kutatócsoport több mint 85 000 mondatból álló adatbázison tanította a modellt, amely képes volt azonosítani a három fő motívumot: teljesítmény, hatalom és affiliáció. Az eredmények lenyűgözőek voltak: az automatikus kódolás legalább olyan pontosnak bizonyult, mint az emberi szakértők munkája, sőt bizonyos esetekben még megbízhatóbbnak. A korrelációs együtthatók (ICC) 0,85 és 0,89 között mozogtak, ami nagyon erős egyezést jelez a hagyományos kódolással. A kutatók nem álltak meg a pontosság vizsgálatánál: két klasszikus kísérletet is megismételtek, amelyekben implicit motívumokat aktiváltak, és az automatizált

kódolás sikeresen reprodukálta az eredeti hatásokat. Ez azt mutatja, hogy a módszer nemcsak technikailag pontos, hanem pszichológiailag érvényes is. Érdekes eredmény volt, hogy amikor az algoritmus és az eredeti emberi kódolók között nagy eltérés mutatkozott, három független szakértő újrakódolta a mondatokat – és az esetek 85%-ában az algoritmus értékelésével értettek egyet. Ez erős bizonyíték arra, hogy a modell nemcsak gyors, hanem megbízható is. A sebesség tekintetében az előny elképesztő: az automatizált kódolás 99%-kal gyorsabb, mint az emberi munka. Ez azt jelenti, hogy ami korábban hetekig vagy hónapokig tartott, most percek alatt elvégezhető. A kutatók ráadásul egy ingyenesen elérhető keretrendszert is biztosítottak az R nyelvben, amelyhez részletes útmutató tartozik, így a módszer könnyen alkalmazható más kutatásokban is. A tanulmány jelentős, ami alapján egyértelmű, hogy az automatizált kódolás nemcsak időt és pénzt takarít meg, hanem demokratizálja az implicit motívumkutatást, lehetővé téve, hogy sokkal több kutató és intézmény végezzen ilyen vizsgálatokat. Ugyanakkor a szerzők hangsúlyozzák, hogy bár a technológia ígéretes, továbbra is fontos az emberi ellenőrzés és az etikai megfontolások, különösen az adatvédelem és a torzítások kezelése. Összességében a tanulmány azt üzeni, hogy a mesterséges intelligencia nemcsak kiegészítő eszköz, hanem forradalmi megoldás lehet a pszichológiai kutatásban, amely új lendületet adhat az implicit motívumok vizsgálatának.

Vargas és munkatársai (2024) azt kutatták, hogy virtuális valóság (VR) és gépi tanulás (ML) segítségével mennyire lehet megbízhatóan mérni a személyiségvonásokat egy szervezeti környezetben. A személyiség a munkahelyi viselkedés egyik legfontosabb meghatározója, és a Big Five modell (extraverzió, barátságosság, lelkiismeretesség, nyitottság, érzelmi stabilitás) régóta használatos a pszichológiai kutatásban. A hagyományos önbeszámoló kérdőívek azonban sokszor torzulhatnak, mert az emberek nem mindig őszinték a válaszaikban. Ezért a szerzők azt vizsgálták, hogy implicit mutatók – például szemmozgás és döntési mintázatok – alapján lehet-e előre jelezni a személyiségdimenziókat. A kutatásban résztvevők egy immerszív VR-környezetben vettek részt, amely különböző munkahelyi szituációkat szimulált. A rendszer rögzítette a résztvevők szemmozgását (fixációk, saccadok) és döntéseit, majd ezeket az adatokat gépi tanulási algoritmusokkal elemezték. A személyiségvonások „valódi” értékeit a NEO-FFI kérdőív alapján határozták meg, így lehetőség nyílt az ML-modellek pontosságának összehasonlítására. Az eredmények ígéretesek, mivel a random forest algoritmus 83%-os pontossággal jósolta meg a barátságosságot. A k-nearest neighbor (k-NN) modell 75–77%-os pontosságot ért el a nyitottság, neuroticizmus és lelkiismeretesség esetében, a support vector machine (SVM) pedig 85%-os pontossággal azonosította az extraverziót. Érdekes megfigyelés, hogy a szemmozgási adatok nagyobb prediktív erővel bírtak, mint a döntési mintázatok. Ez arra

utal, hogy az emberek vizuális figyelmi stratégiái sokat elárulnak a személyiségükről, még akkor is, ha nem tudatosan irányítják ezeket. A tanulmány hangsúlyozza, hogy bár az eredmények biztatóak, a minta viszonylag kicsi volt, ezért a jövőben nagyobb és diverzebb mintákra van szükség a módszer általánosíthatóságának igazolásához. Ha ez sikerül, a VR és ML kombinációja forradalmasíthatja a személyiségmérést, különösen a munkahelyi kiválasztás és tréning területén, ahol az implicit mutatók csökkenthetik a torzításokat és növelhetik az objektivitást.

Arnold és munkatársai (2025) szisztematikus irodalmi áttekintést mutatnak be arról, hogyan használható a szemmozgás-elemzés és a gépi tanulás az olvasási képességek és a produktivitás javítására. Az olvasás nemcsak alapvető készség, hanem kulcsfontosságú tényező a tanulásban és a munkahelyi teljesítményben. A hagyományos módszerek – például a szövegértési tesztek – sokszor nem képesek feltárni a finom figyelmi mintázatokat, amelyek az olvasási nehézségek mögött állnak. Ezért a kutatók azt vizsgálták, hogyan lehet szemkövetéses technológiát és gépi tanulási algoritmusokat integrálni a folyamatba. Az áttekintés több mint 100 releváns tanulmányt elemzett, amelyek különböző szemmozgási mutatókat vizsgáltak, például fixációk számát, saccadok hosszát, regressziókat és pupillaátmérőt. Ezek az adatok rendkívül informatívak, mert megmutatják, hogyan oszlik meg a figyelem olvasás közben, és milyen stratégiákat alkalmaznak az emberek a szöveg feldolgozására. A gépi tanulási modellek – például random forest, support vector machines (SVM) és neurális hálózatok – képesek voltak ezekből az adatokból előre jelezni az olvasási sebességet, a szövegértést és a kognitív terhelést. Az egyik legígéretesebb alkalmazás az olvasási zavarok korai felismerése volt. A tanulmány szerint az algoritmusok akár 90%-os pontossággal tudták azonosítani a diszlexiára utaló mintázatokat, ami óriási előrelépés a diagnosztikában. Emellett a gépi tanulás segíthet személyre szabott oktatási programok kialakításában: például az algoritmusok képesek megjósolni, mely résztvevők profitálnak leginkább a vizuális segédeszközökből vagy a szövegformázás változtatásából. A kutatók kiemelik, hogy a szemmozgás és gépi tanulás kombinációja nemcsak az oktatásban, hanem a munkahelyi produktivitás növelésében is hasznos lehet. Például a figyelmi mintázatok elemzése alapján az algoritmusok képesek felismerni a mentális fáradtság jeleit, és javaslatot tehetnek mikroszünetekre vagy munkaszervezési változtatásokra. Ez különösen fontos olyan környezetekben, ahol a hosszú ideig tartó olvasás és információfeldolgozás elengedhetetlen.

Nagy adatbázisok elemzése (Big Data a pszichológiában)

A Big Data kifejezés olyan hatalmas, komplex és sokféle adatforrásból származó információhalmazt jelöl, amelyet hagyományos módszerekkel nem lehet hatékonyan feldolgozni. A pszichológiában ez a fogalom az utóbbi években került előtérbe, mivel a digitális technológiák, okoseszközök, közösségi média és online platformok révén soha nem látott mennyiségű viselkedési adat áll rendelkezésre (Woo, Tay, & Proctor, 2020). Ezek az adatok lehetővé teszik, hogy a kutatók valós idejű, természetes környezetben gyűjtött információk alapján vizsgálják az emberi gondolkodást, érzelmeket és viselkedést, így átlépve a laboratóriumi vizsgálatok korlátait. A Big Data három fő jellemzője: a Volume – hatalmas mennyiségű adat (pl. milliós nagyságrendű közösségi média posztok); Velocity – az adatok gyors keletkezése és feldolgozása (pl. valós idejű szenzoradatok); Variety – sokféle adatforrás (szöveg, kép, hang, biometrikus adatok).

A big data világában nem egyetlen technológia viszi a hátán az adatkezelést, hanem egy összetett ökoszisztéma, amelyben minden elemnek megvan a maga szerepe. Ahogy az a 3. táblázatban látható, az elosztott tárolási rendszerek és a felhőplatformok biztosítják az alapot a hatalmas adatmennyiségek kezeléséhez, míg a valós idejű feldolgozást a stream processing és az edge computing teszi lehetővé. A NoSQL adatbázisok rugalmasságot adnak, az ETL eszközök pedig gondoskodnak arról, hogy az adatok megfelelő formában kerüljenek elemzésre. A prediktív analitika segít előre látni a trendeket, a vizualizációs megoldások pedig érthetővé teszik az összetett információkat. Mindezt a data governance és a modern adatarchitektúrák keretezik, hogy az adatok ne csak hasznosak, hanem biztonságosak és átláthatóak is legyenek (Enterprise World, n.d.).

Az utóbbi években a Big Data és a gépi tanulás integrációja új kutatási irányokat nyitott meg: prediktív modellek készítése mentális állapotokra, személyre szabott intervenciók, valamint a pszichológiai elméletek újraértelmezése nagyléptékű adatok alapján (Liu, Kuang, & Schweighofer, 2025). Ugyanakkor komoly kihívások is felmerülnek: adatvédelem, algoritmikus torzítás, és az adatok kontextusának hiánya, ami félrevezető következtetésekhez vezethet (Carvalho & Castro, 2025).

Technológia	Fő funkció
1. Elosztott tárolórendszerek	Nagy mennyiségű adat tárolása több gépen, magas hibatűréssel (pl. Hadoop HDFS, Amazon S3).
2. Felhőalapú platformok	Skálázható erőforrások biztosítása interneten keresztül, rugalmas adattárolás és feldolgozás.
3. Valós idejű analitika	Az adatok azonnali feldolgozása és elemzése döntéstámogatás céljából.
4. Adattavak (Data Lakes)	Strukturált és strukturálatlan adatok tárolása egy központi, rugalmas adattárban.
5. Gépi tanulás és AI	Mintázatok felismerése, prediktív modellek és automatizált döntéshozatal.
6. Stream feldolgozás	Folyamatosan érkező adatok (pl. szenzoradatok, közösségi média) valós idejű kezelése.
7. Adatintegrációs eszközök	Különböző forrásokból származó adatok összekapcsolása és tisztítása.
8. Adatvizualizációs platformok	Grafikonok, dashboardok és interaktív megjelenítések a könnyebb értelmezéshez.
9. Adatbiztonsági megoldások	Titkosítás, hozzáférés-kezelés és adatvédelmi protokollok a biztonság érdekében.
10. Skálázható adatbázisok	Nagy teljesítményű, elosztott adatbázisok (pl. NoSQL) a gyors lekérdezésekhez.

3. táblázat A Big Data 10 kulcsfontosságú technológiája (Enterprise World, n.d.)

Wang és munkatársainak (2024) célja az volt, hogy feltárják az érzelmi mintázatok napi ritmusát a közösségi médiában, és megvizsgálják, mennyire hasonlóak ezek a mintázatok különböző kultúrákban. A szerzők több mint 36 millió Twitter-bejegyzést elemeztek az Egyesült Királyságból és Olaszországból, a COVID-19 lezárások idején. Az érzelmi tartalmat a LIWC2015 pszicholingvisztikai eszközzel mérték, amely képes azonosítani a szövegekben megjelenő érzelmi és kognitív kategóriákat. A kutatók Fourier-analízist és idősorteknikákat alkalmaztak, hogy feltérképezzék az érzelmi kifejezések napi ciklusait. Az eredmények azt mutatták, hogy az érzelmi állapotok cirkadián ritmusai mindkét országban hasonló mintázatot követtek: a pozitív érzelmek reggel és délelőtt voltak a legintenzívebbek, míg a negatív érzelmek délután és este

erősödtek. Ez a mintázat kulturális különbségek ellenére is konzisztens volt, ami arra utal, hogy az emberi érzelmi ritmusok univerzális biológiai és társadalmi tényezők hatására alakulnak. A kutatás különlegessége, hogy Big Data megközelítést alkalmazott: hatalmas mennyiségű természetes nyelvi adatot elemzett valós időben, így sokkal pontosabb képet adott a kollektív pszichológiai reakciókról, mint a hagyományos kérdőíves módszerek. A szerzők hangsúlyozták, hogy az ilyen elemzések nemcsak tudományos szempontból értékesek, hanem gyakorlati jelentőségük is van: például segíthetnek a mentális egészségügyi intervenciók időzítésében, vagy a közösségi kommunikáció optimalizálásában. A tanulmány rávilágít arra, hogy a közösségi média nem csupán információforrás, hanem pszichológiai indikátor, amelyből gépi tanulási és statisztikai módszerekkel értékes mintázatok nyerhetők.

Cao és munkatársainak (2024) az volt a céljuk, hogy feltárják, milyen szerepet játszik az olvasási elköteleződés a diákok tudományos műveltségének alakulásában, és hogyan lehet ezt pontosan előre jelezni gépi tanulási módszerekkel. A szerzők a 2018-as PISA-adatbázist használták, amely több ezer tanuló teljesítményét és háttérváltozóit tartalmazza. A hagyományos statisztikai módszerekkel szemben itt az XGBoost algoritmust alkalmazták, amely egy fejlett gépi tanulási technika, különösen hatékony nagy és komplex adatstruktúrák kezelésében. Az elemzés során 36 különböző változót vizsgáltak, amelyek az olvasási szokásokhoz, motivációhoz és tanulási környezethez kapcsolódtak. Az XGBoost modell nemcsak pontos előrejelzést adott a tudományos műveltség szintjére, hanem a SHAP (Shapley Additive Explanations) módszer segítségével értelmezhetővé tette az eredményeket. Ez azért fontos, mert a gépi tanulási modellek gyakran „fekete doboz” jellegűek, és a SHAP lehetővé teszi, hogy lássuk, mely tényezők járultak hozzá leginkább az előrejelzéshez. Az eredmények szerint az olvasási elköteleződés kiemelkedő prediktor volt: azok a diákok, akik rendszeresen olvasnak és élvezik az olvasást, lényegesen jobb teljesítményt nyújtottak a tudományos műveltség terén. Emellett a tanulási környezet és a szülői támogatás is jelentős szerepet játszott. A gépi tanulási modell rugalmasabbnak és pontosabbnak bizonyult, mint a hagyományos regressziós módszerek, különösen a nemlineáris összefüggések feltárásában. A tanulmány gyakorlati jelentősége, hogy meggyőzően alátámasztja, hogy az ilyen prediktív modellek segíthetnek az oktatáspolitikában és az iskolai intervenciók tervezésében. Például azonosíthatók azok a diákok, akiknél alacsony az olvasási elköteleződés, és célzott programokkal lehet támogatni őket.

Az Adolescent Brain Cognitive Development (ABCD) Study az Egyesült Államok eddigi legnagyobb longitudinális kutatása, amely a gyermekek és serdülők fejlődését vizsgálja. A projekt célja, hogy feltárja, hogyan hatnak a genetikai, környezeti és társadalmi tényezők az agy fejlődésére, a kognitív képességekre és a mentális egészségre. A kutatás különlegessége, hogy Big Data megközelítést alkalmaz: több ezer résztvevőtől gyűjt

adatokat, és ezeket integráltan elemzi. Az ABCD Study többféle adatforrást kombinál: pl. agyi képalkotó eljárások (MRI, fMRI) segítségével vizsgálja az idegrendszeri struktúrákat és funkciókat; önbeszámoló kérdőívek révén feltérképezi a pszichológiai állapotokat, életmódot és szociális tényezőket; viselkedési mutatók és kognitív tesztek alapján értékeli a teljesítményt és a fejlődési pályákat; digitális lábnyomok és környezeti adatok (pl. iskolai teljesítmény, családi háttér) is bekerülnek az elemzésbe. A Big Data elemzés itt lehetővé teszi, hogy a kutatók összekapcsolják a genetikai információkat, az agyi struktúrákat és a pszichoszociális tényezőket, így komplex képet kapnak a fejlődésről. Az egyik legfontosabb cél a mentális egészség kockázati tényezőinek korai azonosítása, például a depresszió, szorongás vagy szerhasználat előrejelzése. Az ilyen nagyléptékű adatbázisok segítségével a kutatók képesek prediktív modelleket építeni, amelyek segíthetnek a megelőzésben és a személyre szabott intervenciók kidolgozásában. DeAngelis (2022) tanulmányában hangsúlyozza, hogy az ABCD Study nemcsak tudományos szempontból jelentős, hanem társadalmi hatása is fontos, hiszen az eredmények befolyásolhatják az oktatáspolitikát, az egészségügyi ellátást és a gyermekvédelmi stratégiákat. Ugyanakkor az adatvédelem és az etikai kérdések kiemelt figyelmet kapnak, hiszen érzékeny, személyes és biológiai adatok kezeléséről van szó.

Több kutatás is jelzi, hogy a digitális lábnyomok – például okostelefonok, viselhető eszközök és közösségi média adatai – a mentális egészség fontos előrejelzői lehetnek. Carvalho és Castro (2025) kutatásai rámutatnak, hogy a modern technológia révén hatalmas mennyiségű viselkedési adat keletkezik, amely értékes információkat hordoz az egyén pszichológiai állapotáról. A gépi tanulási algoritmusok képesek ezekből az adatokból mintázatokat azonosítani, és korai jeleket felismerni olyan problémákra, mint a depresszió vagy a szorongás. Véleményük szerint az algoritmusok különösen hatékonyak az alvási szokások, az aktivitási szintek és az online viselkedés elemzésében. Például ha valaki kevesebbet mozog, rendszertelenül alszik, vagy drasztikusan megváltozik a közösségi médiás aktivitása, az előre jelezheti a mentális állapot romlását. Ezek az információk lehetővé teszik a proaktív intervenciókat, például személyre szabott figyelmeztetéseket vagy támogató programokat, még mielőtt a probléma súlyossá válna. A szerzők hangsúlyozzák, hogy ez a megközelítés forradalmi lehet a pszichológiai ellátásban, hiszen a hagyományos módszerekkel szemben valós idejű és folyamatos monitorozást kínál. Ugyanakkor komoly etikai és adatvédelmi kérdések merülnek fel, hiszen a digitális lábnyomok rendkívül érzékeny információkat tartalmaznak, ezért elengedhetetlen az anonimizálás, az adatbiztonság és az algoritmusok átláthatósága. A szerzők kiemelik, hogy a prediktív modellek torzításai súlyos következményekkel járhatnak, például téves diagnózis vagy diszkrimináció formájában. Összességében azonban elmondható, hogy a gépi tanulás és a digitális adatok integrációja új korszakot nyithat a mentális egészségügyben.

Adeolu (2025) tanulmányában az AI-alapú prediktív modellek szerepét vizsgálja a mentális egészségügyi krízisek előrejelzésében, különös tekintettel az öngyilkossági kockázatra és a súlyos depressziós epizódokra. A szerző szerint az egészségügyi rendszerek világszerte küzdenek azzal, hogy időben felismerjék a veszélyeztetett személyeket, és ebben az adatalapú megközelítések forradalmi lehetőségeket kínálnak. Az AI-algoritmusok képesek hatalmas mennyiségű adatot feldolgozni, például: elektronikus egészségügyi nyilvántartásokból származó anamnézis és diagnosztikai információk; viselhető okoseszközök által gyűjtött fiziológiai adatok (pl. pulzus, alvási mintázatok); közösségi média aktivitás, amely gyakran tükrözi az érzelmi állapot változásait. A gépi tanulási modellek ezekből az adatokból mintázatokat azonosítanak, és képesek előre jelezni a krízishelyzetek kialakulását. Például ha valakinél hirtelen csökken az alvás minősége, nő a szorongásra utaló nyelvi kifejezések aránya a posztjaiban, és csökken a fizikai aktivitása, az algoritmus figyelmeztetést adhat az ellátórendszernek. A tanulmány kiemeli, hogy az AI-alapú predikciók nemcsak a korai felismerést segítik, hanem proaktív intervenciókat is lehetővé tesznek: személyre szabott támogatás, krízisvonalak automatikus értesítése, vagy akár digitális terápiás eszközök aktiválása. Ugyanakkor a szerzők hangsúlyozzák az etikai és adatvédelmi kihívásokat. Az érzékeny egészségügyi és viselkedési adatok kezelése szigorú protokollokat igényel, és biztosítani kell az algoritmusok átláthatóságát, hogy elkerüljük a torzításokat és a téves riasztásokat. Az Adeolu (2025) által bemutatott áttekintés szerint a jövőben az AI és Big Data integrációja alapjaiban változtathatja meg a mentális egészségügyi ellátást.

Szakirodalom

- Adeolu, E. (2025). Artificial intelligence in predicting mental health crises: Opportunities, challenges, and future directions. MedReport Foundation. <https://www.medreport.foundation/post/artificial-intelligence-in-predicting-mental-health-crises-opportunities-challenges-and-future-di>
- Arnold, L., Aryal, S., Hong, B., Nitharsan, M., Shah, A., Ahmed, W., Lilani, Z., Su, W., & Piaggio, D. (2025). A systematic literature review of eye-tracking and machine learning methods for improving productivity and reading abilities. *Applied Sciences*, 15(6), 3308. <https://doi.org/10.3390/app15063308>
- Bachurina, V., Sushchinskaya, S., Sharaev, M., Burnaev, E., & Arsalidou, M. (2022). A machine learning investigation of factors that contribute to predicting cognitive performance: Difficulty level, reaction time and eye-movements. *Decision Support Systems*, 155, 113713. <https://doi.org/10.1016/j.dss.2021.113713>

- Cao, C., Zhang, T., & Xin, T. (2024). The effect of reading engagement on scientific literacy—an analysis based on the XGBoost method. *Frontiers in Psychology*, 15, 1329724. <https://doi.org/10.3389/fpsyg.2024.1329724>
- Carvalho, R. G., & Castro, D. (2025). Digital footprints and machine learning in psychological assessment: Challenges and ethical implications. *European Psychologist*. Advance online publication. <https://doi.org/10.1027/1016-9040/a000549> [psycnet.apa.org]
- Carvalho, R. G., & Castro, D. (2025). Digital footprints and machine learning in psychological assessment: Challenges and ethical implications. *European Psychologist*. <https://doi.org/10.1027/1016-9040/a000549>
- DeAngelis, T. (2022). Big data ups its reach. *Monitor on Psychology*, 53(1). <https://www.apa.org/monitor/2022/01/special-big-data>
- El Msayer, M., Aoula, E. S., & Bouihi, B. (2024, May). Artificial intelligence in computerized adaptive testing to assess the cognitive performance of students: A Systematic Review. In 2024 International Conference on Intelligent Systems and Computer Vision (ISCV) (pp. 1-8). IEEE.
- The Enterprise World. (n.d.). Big data technologies and importance. The Enterprise World. <https://theenterpriseworld.com/big-data-technologies-and-importance/>
- Gawronski, B., & Hahn, A. (2019). Implicit measures: Procedures, use, and interpretation. In H. Blanton, J. M. LaCroix, & G. D. Webster (Eds.), *Measurement in social psychology* (pp. 29–55). Routledge/Taylor & Francis Group. <https://doi.org/10.4324/9780429452925-2>
- Ho, J. (2024). An investigation of automatic item generation using a large language model for assessing Big Five personality traits (Master's thesis, Bowling Green State University). OhioLINK Electronic Theses and Dissertations Center.
- Li, C.-J., Zhang, J., Tang, Y., & Li, J. (2024). Automatic Item Generation for Personality Situational Judgment Tests with Large Language Models. arXiv. <https://arxiv.org/abs/2412.12144>
- Lievens, F., Peeters, H., & Schollaert, E. (2008). Situational judgment tests: A review of recent research. *Personnel Review*, 37(4), 426–441. <https://doi.org/10.1108/00483480810877598>
- Liu, J., Kuang, X., & Schweighofer, S. (2025). Big data in human behavior research: A contextual turn. *Journal of Big Data*, 12, Article 98. <https://doi.org/10.1186/s40537-025-01162-1> [journalofb...eropen.com]
- Nilsson, A. H., Runge, J. M., Ganesan, A. V., Lövenstjerne, C. V. N., Soni, N., & Kjell, O. N. (2025). Automatic implicit motive codings are at least as accurate as humans'

- and 99% faster. *Journal of Personality and Social Psychology*.
<https://doi.org/10.1037/pspp0000544>
- Oeljeklaus, L., Höft, S., & Danner, D. (2025). Comparing psychometric properties of expert-developed and AI-generated personality scales: A proof-of-concept study. *Psychological Test Adaptation and Development*, 6, 29–43.
<https://doi.org/10.1027/2698-1866/a000095>
- Orrù, G., Monaro, M., Conversano, C., Gemignani, A., & Sartori, G. (2020). Machine learning in psychometrics and psychological research. *Frontiers in Psychology*, 10, Article 2970. <https://doi.org/10.3389/fpsyg.2019.02970>
- Pillet, J. C., Larsen, K., Dobolyi, D., Queiroz, M., Handler, A., Arnulf, K., Sharma, R. (2025). AI-Augmented Content Validation in Behavioral Research: Development and Evaluation of the RATER System. *MIS Quarterly*, Forthcoming.
<https://doi.org/10.25300/MISQ/2025/18946>
- Russell-Lasalandra, L. L., Christensen, A. P., & Golino, H. (2024). Generative psychometrics via AI-GENIE: Automatic item generation and validation via network-integrated evaluation. *PsyArXiv Preprints*.
- Terry, J., Strait, G., Alsarraf, S., Weinmann, E., & Waychoff, A. (2025). Artificial intelligence in scale development: Evaluating AI-generated survey items against gold standard measures. *Current Psychology*, 44, 16339–16350.
<https://doi.org/10.1007/s12144-025-08240-w>
- Ustianovych, J., & Krpan, D. (2025). The Potential of Synthetic Twin Agents for Personalized Behavioural Interventions at Scale. *OSF Preprints*.
<https://osf.io/download/vs2mk>
- Vargas, E. P., Carrasco-Ribelles, L. A., Marin-Morales, J., Molina, C. A., & Raya, M. A. (2024). Feasibility of virtual reality and machine learning to assess personality traits in an organizational environment. *Frontiers in Psychology*, 15, 1342018.
<https://doi.org/10.3389/fpsyg.2024.1342018>
- Wang, S., Lightman, S., & Cristianini, N. (2024). Diurnal patterns in Twitter sentiment in Italy and United Kingdom are correlated. *Frontiers in Psychology*, 14, 1276285.
<https://doi.org/10.3389/fpsyg.2023.1276285>
- Woo, S. E., Tay, L., & Proctor, R. W. (2020). Big data in psychological research. *American Psychological Association*. <https://doi.org/10.1037/0000193-000>
[psycnet.apa.org]
- Zangrossi, A., Gatto, L. C., Lanfranchi, V., Scarpazza, C., Celli, M., & Sartori, G. (2024). Autobiographical implicit association test and eye movements: fixations topography enables detection of autobiographical memories. *Frontiers in Psychology*, 15, 1268256. <https://doi.org/10.3389/fpsyg.2024.1268256>

BIG DATA A PSZICHOLÓGIÁBAN *

A nagyméretű adatokban rejlő lehetőségek jelentősek a pszichológia számára. A nagy adatokra való törekvés azonban továbbra is bizonytalan és kockázatos vállalkozás az átlagos pszichológiai kutató számára. Ebben a cikkben ennek a bizonytalanságnak egy részét kezeljük azáltal, hogy megvitatjuk a nagy adatok lehetséges hatását a pszichológiai kutatás számára rendelkezésre álló adatok típusára, foglalkozunk az ezekből az adatokból származó előnyökkel és a legjelentősebb kihívásokkal, és megszervezzük a pszichológia számára a különböző kutatási lehetőségeket. Cikkünk két központi felismerést eredményez. Először is, kiemeljük, hogy a nagyadat-kutatási erőfeszítések könnyebben hozzáférhetők, mint sok kutató felismeri, különösen a nyílt forráskódú kutatási eszközök, digitális platformok és műszerek megjelenésével. Másodszor, azt állítjuk, hogy a nagy adatkutatási lehetőségek változatosak, és különböznek mind a különböző kutatási célokhoz való illeszkedésükben, mind pedig az általuk okozott kihívásokban. Végül, a kilátásaink a pszichológiai kutatók számára, akik a nagy adatokat használják és kihasználják a nagy adatokból származó előnyöket, óvatosan optimisták. Bár nem minden big data erőfeszítés alkalmas minden kutató vagy a pszichológia minden területe számára, a big data kutatási kilátások változatosak, bővülnek és ígéretesek a pszichológia és a kapcsolódó tudományágak számára.

Kulcsszavak: nagy adatok, adattudomány, gépi tanulás, műszeres mérés

Ma már léteznek vagy gyűjthetők olyan nagy és dinamikus adathalmazok, amelyek egy adott időpontban és hosszmetriában egyének ezreinek, sőt egyes esetekben millióinak szemcsés és változatos jellemzőit rögzítik. Ezeket az adatokat elsősorban nagy digitális platformok használatával nyerik, fontos kérdések felvetésére alkalmasak, és a kereskedelmi környezetben (Chen, Chiang, & Storey, 2012), valamint egyes tudományos területeken, különösen az informatikában (pl. Chen et al., 2004; Somanchi, Adhikari, Lin, Eneva, & Ghani, 2015) a "nagy adatok" felhasználásával végzett munkát táplálták. Az elmúlt néhány évben a pszichológia területén a tudósok egyre inkább érdeklődtek és elköteleződtek a digitális platformokból származó nagy adatokban rejlő lehetőségek feltárása iránt, hogy tájékoztassák a terület fontos kérdéseit (Jaffe, 2014). Néhány közelmúltbeli és kiemelt kutatási törekvés illusztrálja a népszerű digitális platformok által generált nagy adatok által lehetővé tett pszichológiai meglátások avancitását. Youyou, Kosinski és Stillwell (2015) például 90 000 vizsgálati résztvevő Facebook "tetszik" adatait használta fel, hogy előrejelző modelleket hozzon létre az egyéni személyiségjellemzők kikövetkeztetésére. Muchnik, Aral és Taylor (2013) randomizált terepkísérletet alkalmazott egy népszerű hírportálon, hogy megpróbálja

* Adjerid, I., & Kelley, K. (2018). Big data in psychology: A framework for research advancement. *American Psychologist*, 73(7), 899. Fordította: Szabó Dominik.

megérteni a társadalmi befolyás hatását a hírek értékelésére. Kétségtelen, hogy ezek az interaktív digitális platformok által generált nagy adatgyűjtési erőfeszítések olyan módot biztosítanak a pszichológiai struktúrák és folyamatok megértésére, amely egészen a közelmúltig nem volt praktikus, ha nem is lehetetlen (Jaffe, 2014).

Ez az ígéret a pszichológia számára, hogy a nagy adatok felhasználásával előrelépést érjen el, miközben izgalmas, jelentős kérdéseket és aggodalmakat vet fel a kutatók számára, különösen azok számára, akiknek kevés vagy semmilyen tapasztalata van a nagy adatok gyűjtésével, előkészítésével és ana-lyzingjával kapcsolatban, és a közelmúltban végzett munka azt sugallja, hogy ez a helyzet a pszichológiai kutatók többsége számára jelenleg (Metzler, Kim, Allum, & Denman, 2016). Tapasztalataink szerint a pszichológia kutatói gyakran bizonytalanok abban, hogy a "nagy adat-korszak" pontosan hogyan változtatja meg a kutatáshoz rendelkezésre álló adatok szerkezetét, és ezeknek a változásoknak a következményeit a konkrét érdeklődési kérdéseikre és a választott módszerekre (pl. Milyen mértékben fogják a nagy adatok a pszichológiában a kutatás fókuszát a prediktív vagy feltáró erőfeszítésekre áthelyezni). Ezenkívül a kutatóknak jelentős kérdései vannak azzal kapcsolatban, hogy a big data kutatás elérhető-e számukra a szélesedő "digitális szakadék" miatt, ahol az elit intézmények néhány kiválasztott kutatója "Big Data gazdag", de a kutatók többsége "Big Data szegény" (Boyd & Crawford, 2012, 674. o.). Ráadásul a tanulmányokban felhasználható nagy adatok gyűjtéséhez és rendszerezéséhez szükséges technikai szakértelem jelenleg inkább az informatikához igazodik képzéssel, mint a hagyományos pszichológiai képzéssel. Ha nem foglalkoznak ezekkel a kérdésekkel, akkor ezek a kérdések jelentős akadályokként jelentkezhetnek a nagyadat-kutatás folytatásában a pszichológia kutatóinak szélesebb közösségében. Ebben a cikkben számos kérdés és aggály felvetésével és kezelésével megpróbálunk lebontani néhány ilyen akadályt. Ezáltal reméljük, hogy támpontot nyújtunk az "átlagos" pszichológiai kutatók számára, akik részt kívánnak venni a nagy adathalmazok kutatásában, amely véleményünk szerint ígéretes, de összetett tájkép.

Azzal kezdjük, hogy leegyszerűsítjük, hogyan változtatja meg a "big data korszak" a kutatáshoz rendelkezésre álló adatok szerkezetét, és azzal érvelünk, hogy a nagymértékben műszerezett digitális platformok drámai hatással lesznek a tanulmányozásra rendelkezésre álló "személyek" nagyságrendjére (a vizsgálati csoport mérete, n), az e személyekről rendelkezésre álló változók (változók, v) újszerűségére és sokszínűségére, valamint arra, hogy e változók változásait sokkal több alkalommal (idő, t) lehet megfigyelni. Ugyanakkor a digitális platformok általában válogatás nélkül gyűjtnek adatokat, gyakran anélkül, hogy kutatási kérdéseket tartanának szem előtt. Így a kapott adatok gyakran rendkívül strukturálatlanok és változatosak, és bizonytalan értékkel bírhatnak a pszichológiai kutatási kérdések feltárása szempontjából. Ezt a valóságot szem előtt tartva tárgyaljuk azokat az előnyöket, amelyeket az elérhető adatokban bekövetkezett változások a pszichológiai kutatók számára jelentenek, valamint a megfelelő összetettséget és kihívásokat, és rámutatunk néhány útra a kutatók számára, hogy leküzdjék ezeket a kihívásokat. Ezt a vitát a pszichológia számára a nagy mintaméret (nagy n), az egyénekre és/vagy csoportokra vonatkozó változók

gazdag készlete (nagy v), valamint az időbeli granuláris és folyamatos adatgyűjtés (nagy t) által lehetővé tett árnyalt és változatos kutatási lehetőségek lebontásával követjük. Ezt a bontást számos példával egészítjük ki a kortárs keresési erőfeszítések különböző területeken, hogy kézzelfoghatóbbá tegyék a pszichológiai kutatók által folytatható potenciális nagy adatgyűjtési erőfeszítéseket. A pszichológiában végzett nagyadat-kutatással kapcsolatos etikai és adatvédelmi megfontolások megvitatásával zárjuk, és néhány végső gondolatot adunk az ilyen kutatások irányáról ezen a területen.

Számos fontos felismerést nyújtunk, amelyek reményeink szerint tisztázzák a pszichológiában a nagy adatgyűjtési kutatást fontolgató kutatók néhány legsürgetőbb kérdését. Először is, kiemeljük, hogy a nagy adatkutatói erőfeszítések sokkal inkább elérhetőek, mint sok kutató felismeri. Konkrétan azt állítjuk, hogy a nagy adatkutatás jóval túlmutat a résztvevők számán (azaz a minta méretén), amelyet időnként elsődleges tényezőnek tekintettek, amikor azt vizsgálták, hogy mi teszi az adatokat "nagy". Ezenkívül rámutatunk a kutatókra olyan munkákra, amelyek kezdik szűkíteni a pszichológia hagyományos módszertani kompetenciái és a nagy adattérképen való navigáláshoz szükséges szakadékot. Végül kiemeljük, hogy a nagy adatokhoz való kutatási célú hozzáféréshez különböző utak állnak rendelkezésre (adatok lekaparása, harmadik féltől származó szállítók vagy tömeges beszállítói platformok). Fontos, hogy ezen utak közül sok nem igényli a platformok tulajdonosainak együttműködési kötelezettségvállalását, amelyet nehéz lehet megszerezni. A nagy adatok még inkább hozzáférhetőek, ha az újrakutatók felismerik, hogy saját kutatási beállításokat készíthetnek, amelyek az egyénekre vonatkozó gazdag és részletes adatok rögzítésére szolgálnak.

Másodszor, kiemeljük, hogy a nagy adatok újbóli kutatásának lehetőségei különböző formákat ölthetnek, és hogy ezek a különböző formák különböznek a különböző kutatási erőfeszítésekhez és célokhoz való illeszkedésükben. Például a kutatók, akiknek célzott kérdései vannak olyan kapcsolatokra vonatkozó kérdésekkel, amelyek az érdeklődő populációban nagyon heterogének lehetnek, előnyös lehet a nagy, változatos minták valós viselkedésének megfigyelése, de csak néhány változót igényelhetnek ezekről az egyénekről. Másrészt a pszichometria és a mérés iránt érdeklődő kutatók azt szeretnék feltárni, hogy a pszichológia számára régóta érdekes konstrukciók (a személyiség dimenziói, a megismerés iránti igény, a motiváció stb.) hogyan mutatkoznak meg az e platformok felhasználói által hagyott különböző adatokban (néha "adatmorzsáknak" nevezik). A tágabb értelemben vett pont az, hogy a nagy adatszolgáltatási erőfeszítések sokszínűek, és úgy véljük, hogy a pszichológia legtöbb kutatója profitálhat a nagy adatszolgáltatási lehetőségekből. Ugyanakkor nem minden big data erőfeszítés illik minden kutatási kontextushoz vagy egyéni kutatóhoz, és a big data nem helyettesítheti a gondos kutatási tervezést és a kutatási kérdések megfelelő mérlegelését.

Big Data és annak hatása a "kutatásra, ahogyan mi ismerjük"

Ahhoz, hogy a big data kutatást perspektívába helyezzük, hasznos röviden tárgyalni a pszichológiai kutatás jelenlegi helyzetét. A hagyományos pszichológiai kutatásban a vizsgálat egyetlen eredményváltozóra összpontosít, viszonylag kevés magyarázó változóval. Ha ezeket a változókat idővel mérik, akkor általában erősen strukturált és diszkrét alkalmakkor mérik őket, amelyeket gyakran a priori meghatároznak (pl. 5 héten keresztül minden héten egy laboratóriumi utazás). A pszichológiában és a kapcsolódó tudományágakban a kutatás tervezésére vonatkozó szakirodalom nagy része ezen a foratókönyvön alapul, amely szerint csak néhány változót (v), keresztmetszetben vagy erősen strukturált alkalmakkor (t), (viszonylag) kevés résztvevő (n) számára végzett kutatásokról van szó. Valójában a kutatástervezési szakirodalom nagy része arra törekszik, hogy olyan kis mintaméretet (n) találjon, amely ésszerű az adott kérdés megválaszolásához (pl. teljesítményelemzéssel, amely azt a minimálisan szükséges mintaméretet keresi, amely legalább 80%-os teljesítményt biztosít egy valóban közepes vagy nagyobb hatás kimutatásához). Sok tekintetben a kevés változó és a kis mintaméret kombinációja az elmúlt évszázadban jellemző volt a pszichológia empirikus kutatásaira. Az ilyen hagyományos újrakutatási erőfeszítések által megválaszolt kérdések célzottan és szükségszerűen korlátozottak, gyakran a variancia felosztására és az egyes változók közötti hatások becslésére összpontosítanak. Nem meglepő, hogy a hagyományos pszichológiai kutatásokban alkalmazott számos kutatási módszer jól ismert és jól bevált (pl. t-tesztek, varianciaanalízis [ANOVA], többszörös regresszió, chi-négyzet illeszkedés, pszichometria).

Idővel az ilyen típusú kutatások néhány fontos és figyelemre méltó korlátja alakult ki, amelyek a nagy adatkutatás szempontjából relevánsak. Például több mint 50 évvel ezelőtt kezdett nyilvánvalóvá válni, hogy a kutatók gyakran túl kicsi mintát használtak a hatékony kutatáshoz (pl. Cohen, 1962). Ráadásul a hagyományos kutatások gyakran használnak "konve-niens" mintákat, hogy teszteljék és megkíséreljék validálni a pszichológiai-elméleteket, annak ellenére, hogy ezek a minták nem reprezentálják azt a populációt, amelyre a kutatók gyakran remélik, hogy általánosíthatják eredményeiket (Henrich, Heine, & Norenzayan, 2010). Emellett a pszichológiában az erősen dinamikus konstruktumok (pl. hangulat, érzelem) mérése gyakran túl durva, és e konstruktumok hasznos variációját gyakran nem mérik pontosan, ami az intenzív longitudinális módszerek kifejlesztéséhez vezetett (Csikszentmihalyi & Larson, 2014). Végezetül, lelepleződtek a valószínűleg ritka, de jelentős kutatási csalások (pl. Simonsohn, 2013), valamint az adatmanipuláció potenciálisan elterjedtebb gyakorlatai, mint például a "p-hacking" (azaz csak a "működött" feltételekről való beszámolás és a post hoc elméletalkotás; John, Loewenstein, & Prelec, 2012; Simmons, Nelson, & Simonsohn, 2011). Hozzáadva a mintaméretnek használatához, amelyek gyakran még mindig túl kicsik a robusztus és megismételhető eredményekhez, ezek a problémák jelentősen hozzájárulnak az úgynevezett "replikációs válsághoz" a pszichológiában (Maxwell, Lau, & Howard, 2015).

Azt állítjuk, hogy a nagy digitális adatokból származó nagyméretű adatok forrásokból származó nagyméretű adatok a következő évtizedben és azon túl is kiegészítik és bővítik

a hagyományos pszichológiai kutatásokat. Különösen úgy véljük, hogy változás következik be a kutatásban alkalmazott módszerek, az adatkorlátozások jellege és az etikai megfontolások (pl. a magánélet védelme) tekintetében. Mielőtt azonban belemerülnénk ezekbe a megfontolásokba, először leegyszerűsítjük, hogy a "nagy adatkorszak" hogyan változtatja meg a kutatáshoz rendelkezésre álló adatok szerkezetét a kutatási módszerek két alapvető művének lencséjén keresztül. Az első Cattell "adatdobozá" (Cattell, 1946, 93. o.; lásd még Cattell, 1966), amelyben az adatok szerkezete alapján osztályozza a módszereket, és legegyszerűbb formájában három dimenzió mentén szervezi az adatokat: per-szonok, változók és alkalmak. Cattell adatdobozának kontextusában a műszerekkel felszerelt világ és az általa generált nagy mennyiségű adat drámai hatással lesz e dimenziók mindegyikére, mivel nő a tanulmányozásra rendelkezésre álló "személyek" száma (minta mérete, n), az e személyekről rendelkezésre álló változók (változók, v) újszerűsége és sokfélesége, valamint az a képesség, hogy e változók változását sokkal több alkalommal (idő, t) figyelhetjük meg. A nagy adatok Cattell adatdobozát használó koncepciónk, bár nem azonos, párhuzamba állítható a nagy adatok más kortárs nézeteivel, amelyek azt állítják, hogy a nagy adatokat három V -vel lehet jellemezni: az adatok mennyisége, változatossága és sebessége (Borgman, 2015).

A második munka Coombs (1964) Theory of Data című munkája, amelyben megjegyzi, hogy a formális statisztikai módszerek a betekintés keresése során olyan megfigyeléseket használnak fel, amelyeket a potenciális megfigyelések univerzumából választanak ki, és statisztikai modellekben felhasználható információkká elemeznek (1. fejezet). Coombs keretrendszerében ezek a (nyers) megfigyelések választási lehetőségeket biztosítanak arra vonatkozóan, hogy mely adatokat kell értelmes változókra bontani, és hogyan kell ezeket a változókat a kutatásban felhasználni, ami a nagy adatokkal egyre összetettebbé válik. Ráadásul az e digitális platformokról származó adatok gyakran gazdagok, de válogatás nélkül gyűjtöttek, gyakran anélkül, hogy kutatási kérdéseket határoztak volna meg, szem előtt tartva. Ez a probléma nemcsak rendkívül strukturálatlan és változatos adatokat eredményezhet, hanem olyan adatokat is, amelyek értéke bizonytalan a pszichológiai kutatási kérdések feltárása szempontjából. Cattell és Coombs perspektíváit ötvözve azzal érvelünk, hogy a nagy adatmennyiségű kutatás sokkal több potenciális résztvevőt és sokkal több róluk szóló információt fog magában foglalni. Ugyanakkor ezek az adatok kevésbé strukturáltak és kevésbé könnyen integrálhatók a meglévő kutatási erőfeszítésekbe. A következőkben megvizsgáljuk a pszichológiai kutatásokra gyakorolt néhány jelentős hatást, ahogy az adatok n , v vagy t mentén "nagygyá" válnak.

Nagy "n"

Az egyes nagy adatgyűjtési erőfeszítések alapjául szolgáló digitális platformok több tízezer, egyes esetekben több millió személyhez biztosíthatnak hozzáférést a kutatáshoz. A hagyományosabb adatforrásokkal és adatgyűjtési módszerekkel (pl. diákpopulációk, személyes interjúk, laboratóriumi tanulmányok stb.) ellentétben a nagyméretű digitális platformok nagyszámú egyén valós viselkedésére vonatkozó adatok gyűjtésére alkalmasak. Ezen túlmenően egyes ilyen platformok nem csak az egyének megfigyelésére, hanem a beavatkozások bevezetésére vagy a velük való kommunikációra is lehetőséget nyújtanak költséghatékonyan és olyan mértékben, amire a közelmúltig nem volt példa az egyénekkel foglalkozó kutatók számára. Ha ezeket a képességeket azzal a ténnyel párosítjuk, hogy számos ilyen platform nagy arányú elfogadottságot és használatot élvez, akkor a digitális platformok potenciálisan hozzáférést biztosítanak a (online) népesség nagy részéhez, megragadják a pszichológia számára érdekes valós eredményeket és viselkedéseket, és mechanizmust biztosítanak az egyénekkel való interakcióra, valamint a döntési környezetük megváltoztatására. Ezek a nagyobb mintanagyságú, változatosabb egyénekre kiterjedő minták lehetővé teszik a specifikus hatások nagyfokú pontossággal történő kimutatását, és általában véve lehetővé teszik az összetett statisztikai modellek becslését. Ezen túlmenően az online populáció széles rétegeihez való hozzáférés olyan kutatási mintákat is elősegíthet, amelyek lényegesen reprezentatívabbak a célpopulációjukra nézve (Kosinski, Matz, Gosling, Popov, & Stillwell, 2015; Shannon, Andrew, & Duggan, 2016; Ramo & Prochaska, 2012), bár egyes csoportok még az egyének összességében változatosabb halmazában is megfoghatatlanok maradnak. Természetesen a kutatóknak még mindig figyelembe kell venniük a minta kiválasztásával kapcsolatos aggályokat, hogy milyen típusú egyének reagálnak a toborzási erőfeszítésekre ezeken a digitális platformokon.

Nagy "v"

A nagyméretű adatok megjelenésének háttérében álló nagy digitális platformok szintén jelentős hatással lesznek a kutatáshoz rendelkezésre álló változók sokféleségére. Míg a nagy mintanagyságot a digitális platformok és eszközök széles körű elterjedtsége és részvétele hajtja, addig a kutatáshoz rendelkezésre álló változók sokféleségének növekedését a gazdag az interakciók jellege ezeken a platformokon, valamint e platformok képessége arra, hogy ezt a viselkedést granuláris szinten mérjék. Az online egyének képeket tölthetnek fel, írhatnak, szerkeszthetnek és törölhetnek bejegyzéseket a közösségi hálózatokon, szavazhatnak történetekre, megoszthatnak és fogyaszthatnak különböző tartalmakat (cikket, videókat, filmeket stb.), kereshetnek bizonyos dolgokat, és különböző termékeket nézegethetnek, majd dönthetnek a vásárlásról (vagy nem). Mindezek a viselkedések valamilyen szinten megfigyelhetőek ezeken a platformokon, így a platformok felhasználoiról sokféle változót lehet levezetni. Az a képesség, hogy az összes ilyen interakciót rögzíteni tudjuk, még a nem eseményeket is ugyanolyan érdekessé teszi (pl. hogy egy felhasználó mire nem

kattintott). Végző soron a nagy "v" eredményeképpen az egyéni viselkedés sokkal több potenciális intézkedés áll rendelkezésre a kutatók számára, és potenciálisan bevonható a kutatási erőfeszítéseikbe. A megválaszolható célzott kérdések univerzumának bővítése mellett a kutatáshoz egyre inkább rendelkezésre álló gazdag változóhalmaz megkönnyítheti a feltáróbb erőfeszítéseket, a különbségek értékelését, az adatokból való tanulást és az előrejelzést. Fontos azonban szem előtt tartani, hogy ezeket a változókat sokkal kevésbé strukturált módon és gyakran a kutatási erőfeszítések szem előtt tartása nélkül rögzítik (az ezzel kapcsolatos kihívásokat egy későbbi szakaszban tárgyaljuk).

Nagy "t"

Végül, a nagy digitális platformok és eszközök "mindig figyelő" jellege drámai változásokat eredményez az egyének és viselkedésük megfigyelésének képességében hosszú időn keresztül és nagyon részletes szinten. Akár ma, akár holnap vagy egy hónap múlva történik a platformmal való foglalkozás, az adatgyűjtés folyamatos jellege lehetővé teszi, hogy a hagyományos adatgyűjtési módszerekhez képest viszonylag alacsony költséggel rögzítsük ezt a foglalkozást (bár a platform létrehozásának induló költségei magasak lehetnek). Sőt, ha az egyének részt vesznek a platformon, a platform nagyon kis időintervallumokban (közel folyamatos időben) rögzíti a viselkedésükben bekövetkező változásokat. Tekintsük példaként a népszerű egészségügyi viselhető eszközök (pl. Fitbit karpántok) által generált adatokat, amelyek jellemzően percről percre rögzítik a lépések számának megfigyelését, amikor viselik (hiányzó adatokat eredményeznek, amikor feltöltik vagy nem viselik, ami önmagában izgalmas módszertani kérdéseket vet fel, amelyeket a kutatók különböző módon kezelhetnek). Az a képesség, hogy ezeken a platformokon a viselkedést hosszabb időn keresztül félig folyamatos módon megfigyeljék, lehetővé teszi a kutatók számára, hogy pontosan megragadják, amikor az érdekes események és viselkedések bekövetkeztek, ezeket a viselkedéseket hosszú időn keresztül alacsony költséggel nézzék meg (azaz hosszú távú hatások tanulmányozása), és ezeknek a viselkedéseknek a finom változásait ezeken az időszakokon keresztül. A változók gazdag halmazának viszonylag folyamatos rögzítésének képessége megkönnyítheti a folyamatra összpontosító tanulmányokat, valamint az egyetlen egyénre vonatkozó "mély merüléseket" - emlékeztetve arra, amivel a kvalitatív kutatók érvelnek.

Általános kihívások és (néhány) megoldás

Bár úgy véljük, hogy a kutatáshoz rendelkezésre álló adatokban bekövetkezett változások jelentős előnyökkel járnak, jelentős és újszerű kihívásokkal is járnak. Ebben a szakaszban ezeket a kihívásokat és néhány lehetséges megoldásukat mutatjuk be. Mivel ezek a kihívások a nagy adatmennyiségű újrakutatási erőfeszítésekre

vonatkoznak, ebben a szakaszban általános értelemben mutatjuk be őket. Amikor a következő szakaszban a pszichológia konkrét lehetőségeit tárgyaljuk, elmélyedünk e kihívások instanciáiban és abban, hogy ezek a kihívások a különböző típusú nagyadat-kutatási erőfeszítések esetében eltérő módon merülhetnek fel.

A hozzáférés megszerzése

Az n , v vagy t tekintetében "nagy" adatokat létrehozó platformok sokfélék és egyre nagyobbak (pl. Amazon, Facebook, Twitter, Fitbit, Khan Academy). E platformok közül sok a (online) népesség nagy részét érinti, miközben a pszichológia számára érdekes eredményeket is rögzít. Természetesen a platformokhoz való hozzáférés megszerzése és az általuk generált adatok nehéz lehet, ha egyáltalán lehetséges a vállalatokon kívüli kutatók számára. Sok akadémiai kutató számára ez leküzdhetetlen akadállyal tűnhet, és jó okkal. A platformtulajdonosoktól több okból is nagyon nehéz lehet kötelezettségvállalásokat szerezni. Az ilyen kötelezettségvállalások költségesek lehetnek a platformtulajdonosok számára; például a platformtulajdonosoknak erőforrásokat kell fordítaniuk arra, hogy a kutatók hozzáférjenek a felhasználókhoz és technológiai platformjaikhoz (pl. a személyzet ideje). E közvetlen költségeken túlmenően a kutatási együttműködések a szervezetet a negatív sajtó, a verseny szempontjából releváns meglátások nyilvánosságra hozatala, az ügyfelek magánéletének megsértése és a platform szolgáltatási feltételeinek tényleges (vagy néha vélt) megsértése kockázatának tehetik ki. Bár a nagy kereskedelmi adatokhoz való hozzáférés gyakran nem elérhető az akadémiai kutatók számára, azt állítjuk, hogy ez nem olyan jelentős korlátozás, mint amilyennek néha tekintik, és hogy a nagy adatok egyre inkább elérhetőek a pszichológiai kutatók számára. Ez azért van így, mert a platformtulajdonosokkal való partnerség csak akkor lehet szükséges, ha a kutatási erőfeszítések megkövetelik, hogy a platform felhasználóinak nagy részének (azaz a nagy n -nek) a módosításait (pl. Randomizált kezelés bevezetése) és/vagy ha a platformok nem nyilvános interakcióira vonatkozó adatokat igényelnek (például a felhasználói naplók vagy a felhasználók közötti privát interakciók). Ha a kutatási erőfeszítések nem támasztanak ilyen követelményeket, az adatok megszerzésére gyakran vannak alternatívák a közvetlen partnerség helyett. Például a kutatók hozzáférhetnek ezen adatok egy részéhez olyan automatizált eljárásokkal, amelyek nyilvános oldalakról "kaparnak" adatokat (pl. Reddit, egy hírszervezet kommentjei, bizonyos Facebook-oldalak stb.), vagy harmadik féltől vásárolnak adatokat (pl. több milliányi felhasználói tweetek több szállítótól is megvásárolhatók). Ha a kutatási erőfeszítések nem igényelnek nagy n -t, e digitális platformok (pl. Facebook, Fitbit) felhasználói közvetlenül toborozhatók kutatási tanulmányokhoz, amelyek után engedélyt adhatnak a kutatóknak arra, hogy hozzáférjenek a gazdag adatokhoz, amelyeket ezek a platformok gyűjtenek róluk. Ezekhez az adatokhoz ezután a platformok alkalmazásprogram-interfészéhez (API) intézett szabványos adatkérésekkel lehet hozzáférni.⁽¹⁾ Ismét fontos megjegyezni, hogy ezeknek a megközelítéseknek még mindig megvannak a maguk

akadályai. Például a felhasználók közvetlen toborzása ezekről a platformokról megfizethetetlenül költségessé válhat, ha a kutatási célok nagyszámú (pl. több tízezer) felhasználóra vonatkozó adatokat igényelnek, és ezek a megközelítések technikai szaktudást igényelnek (ezeket a kihívásokat alább részletesebben tárgyaljuk).

Lehetőség van arra is, hogy a saját digitális platformokat teljesen megkerüljük, miközben a digitális platformok által kínált adatokhoz hasonló adatokhoz jutunk. Például a kutatók növelhetik a minta méretét (nagy n) a digitális tömeges beszerzési platformok kihasználásával, hogy résztvevőket kérjenek a kutatáshoz. Ezeket a platformokat a kutatók egyre gyakrabban használják arra, hogy hatékonyan és olcsón toborozzanak résztvevőket a maguk a kutatók által tervezett és lefuttatott vizsgálatokhoz (pl. online felmérések vagy kísérletek). A tömeges forrásbevonással összefüggésben széles körben használt megvalósítás az Amazon Mechanical Turk (AMT), amelyet "az internet rejtett tudományos gyáráként" (Marder, 2015, 1. o.) jellemeztek; más hasonló platformok egyre nagyobb lendületet vesznek, és hasonló adatminőséget és hatékonyságot kínálnak (Peer, Samat, Brandimarte, & Acquisti, 2015). Bár hatalmas (pl. több százezres nagyságrendű) minták gyűjtése ezeken a platformokon keresztül még nem megvalósítható, a skálázható számítási architektúrán keresztül könnyen kiterjeszthető a mintanagyság több ezer egyedre. A pszichológia valójában már előrehaladást ért el ebben az összefüggésben, az AMT-minták validálásának úttörő munkájával (pl. Buhrm-ester, Kwang és Gosling, 2011). A tömeges mintáknak vannak potenciális korlátai is. Például a tömeges forráskihelyezési platformok szenvedhetnek a hatalmi felhasználók megjelenésétől, ami azt eredményezi, hogy a felhasználók egy kis része a tevékenység aránytalanul nagy részét teszi ki (Paolacci & Chan-dler, 2014).

Az egyéni viselkedésre vonatkozó különféle változók (big v), amelyeket idővel (big t) granulárisan mérnek, szintén lehetségesek lehetnek e saját digitális platformokhoz való közvetlen hozzáférés nélkül is. Különösen a széles körben elérhető kutatási eszközök nyújthatnak gazdag adatgyűjtési lehetőségeket a kutatók számára (azaz olyan kontextusokban, amelyek műszerekkel vannak vagy lehetnek felszerelve). Például a hagyományos felmérési eszközök, amelyeket általában kérdőívek készítésére használnak, egyre inkább életképes eszközökké válnak a gazdag adatgyűjtési környezetek kialakítására. A Qualtrics felmérési eszköz például beépített kérdésekkel rendelkezik, amelyek lehetővé teszik az egyéni résztvevők a felmérés információinak áramlását, hasonlóan ahhoz, ahogyan a felhasználók egy online weboldalon közlekednének. E kérdések mellett a Qualtrics olyan funkciókat is tartalmaz, amelyek lehetővé teszik a kutatók számára, hogy adatokat gyűjtsenek a válaszadók viselkedéséről ezekben a környezetekben. Például a Qualtrics lehetővé teszi a kutatók számára, hogy mérjék, mennyi ideig tart a kérdések megválaszolása, rögzítsék a kattintások számát és az oldalon töltött időt, és hőtérféket készítsenek az oldalakon, hogy a résztvevők könnyen jelezhessék, hogy az oldal mely részei a leginkább kiemelkedőek számukra (a képernyő egyes pixeleire).

Az egyénekre vonatkozó adatok gyűjtésének lehetősége kibővül, ha egyéni szkripteket és kódot használ, amely rögzíti az érdeklődésre számot tartó eredményeket.

A Qualtrics például támogatja az egyéni JavaScriptet, amely felhasználható a Qualtrics felmérési eszközön az egérmozgás részletes adatainak rögzítésére, tárolására és elemzésére, valamint az egér adott időpontban a képernyőn elfoglalt pozíciójának rögzítésére. Boas és Hidalgo (2013) integrálja a Qualtrics-et az rApache-csal (az R egy Apache webservereken futó változata), így dinamikusan generálhat tartalmat külső forrásokból (pl. online adatbázisokból), és valós időben végezhet elemzést a felmérésen. Bizonyos értelemben félreérthetővé vált, hogy az ilyen eszközöket "felmérési" eszközöknek nevezzük, holott valójában olyan eszközök, amelyekkel olyan interaktív online környezetet lehet létrehozni, amelyet mi interaktív online környezetként írunk le, és amely műszeres módon biztosít gazdag adatgyűjtést a válaszadókról és azok tevékenységéről. Érdekes, hogy a sok résztvevő adatgyűjtésének terhe a kódolás befejezése után könnyen skálázható, ellentétben sok olyan vizsgálattal, amelyben egy vagy több kutató egy-egy adatgyűjtési erőfeszítésben vesz részt (pl. A laboratórium látogatásai).

A felmérési eszközök fejlődésének lehetőségei mellett a felmérési eszközök megkönnyítik egy interaktív online környezet kialakítását, amely lehetővé teszi a gazdagabb adatgyűjtést, a kutatók elkezdtek olyan egyedi csomagokat fejleszteni, amelyek lehetővé teszik a kutatók számára, hogy kidolgozott, természetes és műszeres webes kísérleteket végezzenek. Például de Leeuw (2015) egy nyílt forráskódú javascript könyvtárat (jsPsych) biztosít, amely egy weboldalba integrálható, hogy gazdag adatgyűjtési lehetőségeket biztosítson. Garaizar és Reips (2014) egy nyílt forráskódú webes rendszert fejlesztett ki, amely szimulál egy közösségi hálózati környezetet, és adatokat rögzít arról, hogy a résztvevők hogyan navigálnak és kommunikálnak a platformon. Ezek a keretrendszerek, amelyek nyíltan, a nagy platformtulajdonosok partnersége nélkül is elérhetőek, számos olyan adatgyűjtési lehetőséget kínálnak, amelyeket eddig nem használtak a pszichológiában, de amelyek gazdag betekintést nyújthatnak a legkülönbözőbb kontextusokban.

Ezeket a változatos és jól hozzáférhető lehetőségeket összekapcsolva, az a könnyen elképzelhető egy olyan tanulmány, amelyben a kutatók néhány nap alatt több ezer résztvevőt kérnek fel kísérletek vagy megfigyelési tanulmányok elvégzésére, gyorsan fejleszthető, granuláris adatgyűjtésre, valamint fejlett logikára és funkcionalitásra képes, naturalisztikus kutatási környezetek segítségével. Bár ezek az adatok nem rendelkeznek a saját digitális platformon gyűjtött adatok bizonyos aspektusaival (pl. a döntési kontextus realizmusa), az előnye, hogy az adatgyűjtés hozzáférhető és a kutató közvetlen ellenőrzése alatt áll, és gyakran ésszerűen alacsony költséggel végezhető.

Műszaki Kihívások

Még a nagy adatokhoz való hozzáférés megszerzése után is a kutatók valószínűleg azt fogják találni, hogy a gazdag változóhalmaz, amelyet ezek a platformok idővel granulárisan rögzítenek, gyakran jelentős feldolgozást és tisztítást igényel, mielőtt hasznos lenne az újbóli kutatási erőfeszítésekhez; ez visszautal a Coombs (1964) és a

gyűjtött megfigyelések értelmes adatokra történő elemzésének fontosságára. Ezek a kihívások elsősorban azért merülnek fel, mert az e digitális platformok által rögzített változók gazdag halmaza (big v) nem áll rendelkezésre olyan rendezett formátumban, amelyet könnyen be lehetne építeni a kutatási erőfeszítésekbe. Ráadásul az ezekről a platformokról idővel gyűjtött adatok a mérési alkalomtól függően teljesen eltérőek lehetnek; ráadásul az ilyen adatokat különböző részletességgel lehet mérni, nem feltétlenül ugyanabból a forrásból származnak, és valójában nyílt válaszok is lehetnek. A megfigyelések típusainak ilyen sokfélesége a megfigyelések felhasználás előtti adatelemzésének nehézségéről árulkodik. Valójában a tudósok megjegyezték, hogy a nagy adatelemzéssel összefüggésben az idő 80% -át az adatok előkészítésével töltik, és csak 20% -át az elemzéssel (pl. Wickhan, 2014; lásd még Dasu & Johnson, 2003), és hogy "abszolút mítosz, hogy egy algoritmust küldhetsz a nyers adatokra, és a felismerések felbukkannak" (Lohr, 2014, 2. o.). A digitális platformokon szükséges egyedi típusú zaj és adattisztítás illusztrálására gondoljunk arra, hogy egy nemrégiben készült tanulmány szerint közel 40 millió Twitter-fiók valójában automatizált botok, amelyeket arra terveztek, hogy online utánozzák a felhasználók viselkedését, ez a tanulmány egy osztályozási keretet is kínál ezen hamis fiókok azonosítására és számbavételére (Varol, Ferrara, Davis, Menczer, & Flammini, 2017). Ez alátámasztja azt az általánosabb pontot, hogy az ilyen adatokkal végzett kutatások nem triviális mértékű technikai szakértelmet igényelhetnek az adatok egyszerű adminisztrálásához, kezeléséhez, valamint az adatok "birkózásához" és "rendezéséhez"; a szükséges technikai szakértelem még inkább pro-nounced lehet, ha az erőfeszítés véletlenszerű manipulációkat és adatgyűjtést foglal magában élő és dinamikus platformokról. Ezeket az aggodalmakat súlyosítja az egyének nagyságrendje (nagy n) és a sebesség, amellyel a rájuk vonatkozó adatok felhalmozódnak (nagy t), mivel az adattisztítás bármilyen kézi megközelítése (pl. újrakutatási asszisztensek vagy kézi kódolók) gyorsan lehetetlenné válik, ami szükségessé teszi az automatizált szkriptek és kódolás használatát a rendelkezésre álló adatok tisztításához és feldolgozásához.

A pszichológia és a kapcsolódó területek tudósainak közelmúltbeli erőfeszítései kezdik kezelni a nagy adatok elérésének és feldolgozásának technikai kihívásait. Chen és Wojcik (2016) például gyakorlati útmutatót kínál a kutatáshoz szükséges nagy adatforrások azonosításához, az adatgyűjtés megközelítéseihez, valamint az adatok feldolgozásának és elemzésének módszereihez. Landers, Brusso, Cavanaugh és Collmus (2016) útmutatót nyújtanak a következőkhöz: online adatok automatizált kinyerése webkaparással. Vannak speciális szoftvercsomagok is, amelyek bizonyos digitális platformokra irányulnak: a TwitteR (Gentry, Gentry, SQLite, & Artistic, 2016) és a RedditExtractoR (Rivera, 2015) eszközkészleteket kínál a Twitter és a Reddit adatainak kinyerésére. Deghani et al. (2016) létrehozta a Text Analysis, Crawling, and Interpretation Tool (TACIT) nyílt és bővíthető eszközpárosító képességeket, amelyek lehetővé teszik a nagyméretű szöveges adatok gyűjtését és elemzését. A meglévő szoftvercsomagokra való támaszkodás fontos módja lehet a hagyományos kutatók számára, hogy kihasználják az ismert készségeket, miközben a nagy adatkutatás egyéb technikai és statisztikai kihívásaival is foglalkoznak. Chen és Wojcik (2016) megjegyzi,

hogy "bár a nagy adathalmazok kutatásához számítástechnikai készségek szükségesek, szakértői szintű képességek általában nem szükségesek, részben a fejlett technikákat megvalósító, már meglévő szoftverkönyvtárak elérhetősége miatt" (459. o.).

A nagyméretű adatok értelmezése

Pusztán azért, mert egy digitális platform hozzáférést biztosít nagyszámú vizsgálati résztvevőhöz és a róluk szóló gazdag és változatos adatokhoz, nem jelenti azt, hogy ezek a rendelkezésre álló adatok azonnal hasznosak a pszichológia számára érdekes témák tanulmányozásához, vagy hogy bővítik a szakirodalmat. Míg a tudósok (Jaffe, 2014) azt állították, hogy a kattintási adatokon keresztül online hagyott "adatmorzsák" alapvető egyéni jellemzőket (pl. személyiség, kognitív stílus, érzelmek) tárhatnak fel, ezeknek az "adatmorzsáknak" (amelyeket nem a kutatás céljából gyűjtöttek) a pszichológia számára érdekes szerkezetekké és eredményekké történő tényleges lefordítása nem triviális, és fontos kihívásokat jelent a pszichológiai kutatók számára. Különösen a pszichológiai jellemzőket és konstrukciókat (pl. érzelmek, személyiség, intellektuális képességek stb.) mérő, jól hitelesített felmérési eszközöket ritkán alkalmazzák e nagy digitális platformok felhasználóinál, ami komoly fejtörést okoz a kutatók számára. Ismét úgy találjuk, hogy ezt a kihívást súlyosbítja az egyedi egyének (big n) nagyságrendje, amely ezeken a platformokon tanulmányozható, mert ez gyakran kizárja a kutatókat a hagyományos módszerek (pl. a pszichometriai módszerek) használatából a konstrukciók mérésére és a konstrukciók közötti kapcsolatok értékelésére.

Míg az alkalmazott konkrét módszerek eltérőek lesznek, azt javasoljuk, hogy a probléma koncepcionálisan hasonló a tesztek összekapcsolásához vagy egyenértékűvé tételéhez, ami az oktatási mérési kontextusokban széles körben használt elképzelés (pl. Dorans, Pommerich és Holland, 2007). Az összekapcsolási és egyenlőségi ötletek nagy adat kutatási környezetre való kiterjesztése azt sugallja, hogy a nagy adatok "értelmének" egyik módja az, hogy megpróbáljuk összekapcsolni vagy egyenlővé tenni a változók két csoportját: a magasan validált mérőeszköz (hagyományos) és a nyers adatok, amelyeket ezek a műszeres platformok rögzítenek. Ennek egyik gyakorlati megközelítése az, hogy az érdeklődésre számot tartó konstrukciókat (hagyományos módszerekkel) mérjük a felhasználók egy részhalmazára az érdeklődésre számot tartó platformon, majd kihasználjuk mindkét struktúra elérhetőségét.

A felhasználók ezen részhalmazára esetében olyan modellek kialakításának megkezdése érdekében, amelyek segítenek megfeleltetni ezeket a nyers adatokat az érdeklődésre számot tartó konstrukcióknak. Ez lehet egy tervezett miss-ingness design alkalmazása, bár egy szélsőségesebb változat (pl. Rhemtulla & Little, 2012; Silvia, Kwapil, Walsh, & Myin-Germeys, 2014), ahol intenzív intézkedéseket adnak be egy nagyobb adathalmaz kis almintájára.

Nehéz túlbecsülni azoknak az erőfeszítéseknek a fontosságát, amelyek segítenek lefordítani a nagy adatplatformokon rendelkezésre álló változókat a pszichológia számára érdekes konstrukciókba és intézkedésekbe. Először is, a változók gazdag

halmazának (big v), amelyek az idő múlásával (big t) nagymértékben felhalmozódnak, összekapcsolása a pszichológia számára érdekes konstrukciókkal feltárhatja maguknak a konstrukcióknak a fontos jellemzőit, valamint azt, hogy ezek a konstrukciók hogyan fejlődnek az idő múlásával. Másodsor, és talán még fontosabb, hogy az egyének egy részhalmazából modelleket építve elkezdhetjük megkülönböztetni a pszichológiai konstrukciókat a megfigyelt adatokból, amelyek sokkal több egyén számára állnak rendelkezésre, és remélhetőleg elkezdhetjük értékelni az e konstrukciók és a viselkedés közötti kapcsolatot az egyének skáláján, amelyet ezek a nagy adatplatformok biztosítanak. Vegyük példaként, hogy a Cambridge-i Pszichometriai Központ nemrégiben létrehozott egy API-t (amely a kutatók számára ingyenesen hozzáférhető), amely a Facebook-adatok és a pszichológiai konstrukciók összekapcsolásából származó modellek segítségével a személyiség, a boldogság, az intelligencia stb. előzetes előrejelzéseit hozza létre a Facebook kedvelései és üzenetei alapján. Az ilyen eszközök a kutatási kérdések széles körét nyitják meg a kutatók széles köre számára, mivel lehetővé teszik bármely, Facebook-adatokkal rendelkező kutató számára, hogy olyan konstrukciókkal kapcsolatos kérdéseket vizsgáljon meg, amelyek esetében nem tudják elvégezni a mérésükhöz általában használt felméréseket.

Statisztikai Kihívások

Az egyének nagyságrendje, a változók széles köre és az adatok gyűjtésének granularitása azt a kihívást is jelenti, hogy a statisztikai elemzés hagyományos megközelítései és az eredmények értelmezése már nem biztos, hogy jól illeszkednek. Más kihívásokhoz hasonlóan a nagyméretű adatok különböző dimenziói is különböző típusú statisztikai kihívásokat vezetnek be.

A megnövekedett mintaméret vagy "nagy n" esetén az adatokban lévő kapcsolatok általában statisztikailag szignifikánsak lesznek, ami szükségessé teszi a hatások nagyságának és fontosságának megvitatását. A populációs hatásokra vonatkozó konfidenciaintervallumok például szűkek lehetnek, és nem tartalmazhatják a nullát (azaz statisztikailag szignifikánsak lehetnek), de olyan méretű értékeket zárhatnak be, amelyek kis értéket képviselnek. Vagyis a konfidenciaintervallumokban szereplő értékek teljes halmaza nem lehet túl az "elég jó tartományon" ahhoz, hogy elméleti jelentőségűnek tekintsük őket (azaz a valódi hatás nagysága legfeljebb elég közel van a nulla értékhez ahhoz, hogy elméletileg ne legyen érdekes; pl. Serlin & Lapsley, 1993. Ha az adatok az egyénekre vonatkozó változók gazdag készletét is tartalmazzák (nagy v), a hamis korreláció lehetősége a p-értékek bármilyen értelmezését pl. a többszöröségi problémák korrekciójának megkísérlése, amikor sok hipotézist tesztelnek, folyamatos téma a viselkedésgenetikában, ahol sok genetikai variánst értékelnek a potenciális magyarázó érték szempontjából (Troendle & Mills, 2011).

A tényezők e kombinációja azt sugallja, hogy ezekkel az adatokkal alternatívaként a nagy előrejelzési érvényesség elérésére lehet összpontosítani gazdag statisztikai modellekkel és keresztellenőrzéssel párosított keresztellenőrzéssel, hogy biztosítsák a

jó mintán kívüli előrejelzést (Domin-gos, 2012). Ezzel kapcsolatban azonban az a kihívás, hogy a pszichológiában (és sok más területen) gyakran használt statisztikai megközelítések közül sokan csak korlátozottan képesek kezelni a nagyszámú prediktort tartalmazó összetett modelleket (pl. Hastie, Tibshirani, Friedman, & Franklin, 2005). A hagyományos módszerek korlátai a változók egyre gazdagabb halmazának kezelésére a statisztika és az informatika metszéspontjában kifejlesztett módszereket, például a gépi tanulást eredményezték, amely különösen a nagy vagy gazdag adathalmazok szituációiban alkalmazható (pl. Domingos, 2012). A gépi tanulási megközelítések történelmileg inkább adatközpontúak voltak, lazán az elmélet által vezérelve, ha egyáltalán használtak elméletet, és az osztályozásra, mintafelismerésre és predikcióra összpontosítottak. A gépi tanulási megközelítések egyre szélesebb körű alkalmazásával azonban egyre több az elméletvezéreltebb módon használható módszer. Például a témamodellezés módszereinek fejlődése lehetővé teszi a kutatók számára, hogy a strukturálatlan adatokban meghatározott témákra vagy érdeklődési területekre összpontosítsanak (Andrzejewski, Zhu, & Craven, 2009; Wang & Blei, 2011). Brandmaier, Prindle, McArdle és Linden-berger (2016) olyan módszert javasol, amely egyesíti a strukturális egyenletmodellezést és a döntési fákat, hogy lehetővé tegye az olyan változók automatikus kiválasztását, amelyek előre jelzik az egyes elméleti modellekben az egyes személyek közötti különbségeket. Más megközelítések a heterogén kezelési hatások azonosítására összpontosítanak a másodlagos és kísérleti adatokban (pl. McFowland, Speakman, & Neill, 2013), és valószínűleg nagymértékben elősegítik az elméletépítést és az elméletgenerálást.

Ugyanakkor néhány jól ismert statisztikai kérdés a következő (a hagyományos erőfeszítésekhez képest) súlyosbítja a nagy adatokkal együtt alkalmazott gépi tanulást. Például a túlillesztés és a "dimenzió átka" problémája az ilyen megközelítésekkel kapcsolatos legégetőbb aggályok közé tartozik (Domingos, 2012). Ez különösen akkor lehet igaz, ha az adatok sok változót tartalmaznak, amelyeket viszonylag kevés egyedről gyűjtöttek, ami például a legkisebb négyzetek modellillesztésének mesterséges növekedését eredményezi (James, Witten, Hastie és Tibshirani, 2013). Ezenkívül további kihívások merülnek fel, ha a változókat közel folyamatos időben (nagy t) gyűjtik, mivel az ilyen változókat valószínűleg nem mérik szépen strukturált alkalmakkor, előfordulhatnak hibás vagy "nem alkalmazható" adatok, és a szinkronitás gyakran nem érvényesül. Ezekben az esetekben a kutatóknak nem csak olyan modelleket kell fontolóra venniük, amelyek képesek kezelni a kutatáshoz rendelkezésre álló változók gazdag készletét, hanem olyanokat is, amelyek képesek befogadni az idősoros adatok gyors létrehozása és elemzésekbe való bevonása (Ding, Trajcevski, Scheuermann, Wang és Keogh, 2008; Xi, Keogh, Shelton, Wei és Ratanamahatana, 2006). Ismét, a legújabb erőfeszítések kezdik segíteni a pszichológia tudósait az ilyen típusú adatok elemzésével kapcsolatos kihívások leküzdésében. Például Stanton (2013) gyakorlati bevezetést kínál a pszichológiában az adatbányászati erőfeszítésekhez, de-tails a nyers adatok (használható) feldolgozott adatokká történő átalakításához szükséges lépésekkel, hogy statisztikai modelleket és elemzéseket lehessen végrehajtani és értelmezni. Más munkák bevezetést nyújtanak a gépi tanulási módszerekbe, a pszichológiában és a

kapcsolódó területeken történő alkalmazásokra összpontosítva (Oswald & Putka, 2015).

Elméleti és kutatási érték

A nagymértékben strukturálatlan és változatos adatok a pszichológia számára érdekes, egyértelmű adatok nélkül, valamint a gyakran ateoretikusnak tekintett statisztikai megközelítések alkalmazásával párosulva azt a kihívást jelentik, hogy a nagy adatok által lehetővé tett erőfeszítések hasznosak lehetnek az alkalmazott problémákban, de korlátozott értéket képviselhetnek a mögöttes jelenségek pszichológiai elméletének kidolgozásában, tájékoztatásában vagy értékelésében (pl. Mert az egyéni prediktorok értelmezése nem áll a középpontban). Ez az aggodalom újjáéleszti azt a valójában régóta fennálló diskurzust, amely a feltáró vagy előrejelző erőfeszítések szerepéről szól az ex-planációs erőfeszítésekhez képest (pl. lásd Pedhazur, 1997).

Azt állítjuk, hogy ezek az aggodalmak csak egy pontig lehetnek indokoltak; a lehetőségek, amelyek kihasználják ezeket a gazdag adatokat, számos formát ölthetnek, amelyek közül sokan közvetlen és jelentős ígéretet adhatnak az elmélet tájékoztatására (bár talán induktív módon). Különösen részben tévhit, hogy a nagy adatok kutatását ateo-retorikus módon kell folytatni; amint azt a következő szakaszban látni fogjuk, a nagy adatok különböző formáit hasznosító újbóli kutatási erőfeszítések elméletvezérelt megközelítéseket alkalmaznak. Ez magában foglalja az olyan kutatásokat, amelyeket a szakirodalom egyértelmű elméleti feszültségei vezérelnek, amelyek az adatokat az ex ante motivált és kinyilvánított hipotézisek tesztelésének kifejezett céljával gyűjtik és aggregálják, majd tesztelik ezeket a kapcsolatokat. Ennek ellenére ezeknek a tanulmányoknak gyakran újszerű statisztikai megközelítéseket kell alkalmazniuk ezekre az adatokra, amelyek lehetővé teszik számukra, hogy az őket érdeklő elméleti keretek és kérdések szempontjából releváns konstrukciókat és intézkedéseket vonjanak ki.

Ezen túlmenően a pontos előrejelzések és a feltáró elemzések jelentős kutatási értéket képviselhetnek, ha lehetővé teszik a viselkedés jobb megértését és esetleges megváltoztatását. Ez egyértelműen kapcsolódik a pozitív kimenetelű viselkedésváltozások ösztönzésére irányuló erőfeszítésekhez, ami a pszichológia számos területét mélyen foglalkoztatja. A különböző viselkedések ösztönzésére irányuló beavatkozásokat akár személyre is szabhatjuk annak alapján, hogy a résztvevő adatai mit árulnak el pszichológiai jellemzőiről vagy hajlamairól. Ezek az elképzelések a pszichológiai eredményekre vonatkozó személyre szabott orvosláshoz hasonlítanak. Ezen túlmenően, az előrejelző vagy feltáró erőfeszítéseknek megvan a potenciális lehetősége, hogy olyan változókat tárjanak fel, amelyek nem feltétlenül tűnnek elméletileg megalapozottnak az adott jelenségekben. Például a pszichológiai konstruktumok strukturálatlan adatokból történő megismerése fontos árnyalatokat tárhat fel magukról a konstruktumokról, amelyek további elméleti fejlesztést és értékelést irányíthatnak. Más szóval, ami kezdetben nem tűnik elméletileg

megalapozottnak, lehet, hogy egyszerűen még nem épül be egy elméletbe, és az elméleteket a feltáró vagy előrejelző nagy adatkutatás megállapításai alapján lehet kidolgozni. Talán éppen a műszeres világ az, amire szükség van a pszichológiai elméletek szigorúbb teszteléséhez és validálásához, valamint a kutatási eredmények gyakorlati értéké alakításához. Ehhez azonban szükség lehet arra, hogy a terület nyitottabbá váljon a kevésbé merev elméleti kiindulópontokból származó felismerésekre.

Árnyalt és változatos lehetőségek a pszichológia számára

Az előző két szakasz metszéspontja, amelyben a nagy adatokkal kapcsolatos különböző előnyöket és kihívásokat tárgyaljuk, árnyalt és változatos kutatási lehetőségeket eredményez a pszichológia számára. Ezeket a lehetőségeket először csak a nagy adatok egyetlen dimenziója tekintetében lehet megvizsgálni. Például a kutatók bővíthetik vizsgálati mintájukat (nagy n), de megtarthatják a fókuszt kis számú változóra (kis v), keresztmetszetben mérve (kis t). Ez a megközelítés lehetőséget kínál arra, hogy a pszichológiában az alulméretezett tanulmányokat kezeljék, és ha a minták reprezentatívabbak, csökkentsék azokat az aggodalmakat, hogy az eredmények nem általánosíthatók az érdeklődésre számot tartó populációra. Hasonlóképpen, az elemzéshez gazdagabb változókészlet összegyűjtésének lehetősége lehetőséget biztosít a célzottabb kapcsolatok és a potenciálisan érdekes kapcsolatok kölcsönhatásainak (moderátorainak) értékelésére. Az a képesség, hogy ezeket a változókat idővel részletesebben lehet gyűjteni, enyhítheti a dinamikus konstrukciókkal kapcsolatos aggodalmakat, amelyeket korábban túl durván mértek (pl. csak a reggeli és esti vércukorszintek, míg a vércukorszinteket ma már szinte folyamatosan lehet mérni pl. a hangulat vagy a figyelemelterelhetőség értékelésénél). Bár ezek a lehetőségek nem triviálisak, nem biztos, hogy teljes mértékben kihasználják a nagy adatok által nyújtott előnyöket. Például a statisztikailag szignifikáns hatásoknak nem kell azt jelenteniük, hogy a hatások gyakorlati jelentőséggel bírnak (Kirk, 1996; Kelley & Preacher, 2012), és a statisztikai teljesítmény és a becslési pontosság növekedése a néhány paraméter becsléséhez kevésbé releváns, ahogy a minta mérete egy bizonyos ponton túl növekszik; a gyakorlati jelentőségű hatásméreteket tipikusan nem igényelnek több százezer egyént, hogy pontosan azonosítani lehessen (pl. szűk konfidenciaintervallumot kapjanak). Hasonlóképpen, amint azt már megjegyeztük, a hagyományos kutatási erőfeszítéseknél a változók gazdag készletének használata (azaz erősen célzott) súlyosbíthatja a hamis korrelációval és a szignifikáns hatások szelektív jelentésével kapcsolatos aggodalmakat az adatokban.

Azt állítjuk tehát, hogy a pszichológia nagy adatkutatásának fontos lehetőségei a növekedés metszéspontjában merülnek fel az adatok e különböző dimenzióiban; ennek oka, hogy a nagy n , v és t előnyei nagymértékben kiegészítik egymást. Vegyük például, hogy az adatok hosszabb időn keresztül történő gyűjtésének képessége (nagy t) kritikus lehet ahhoz, hogy az ezeken a platformokon elérhető nagyszámú egyént teljes

mértékben ki lehessen használni a kutatásban (nagy n). Ez azért van így, mert e platformok nagymértékű elfogadása nem egyenlő a platformok felhasználóinak folyamatos használatával és aktivitásával. Egyes források szerint például a Twitter felhasználóinak mindössze 44%-a küldött valaha is tweetet (Koh, 2014). Így a megfigyelés hosszabb (történelmileg és bizonyos esetekben prospektív) ablakai kritikusak ahhoz, hogy ténylegesen rendelkezünk adatokkal a felhasználók széles köréről ezekről a platformokról (rövid időszakokban sok ilyen felhasználóról gyér vagy semmilyen adat nem állna rendelkezésre). Ilyen esetekben nem arról van szó, hogy az adatok feltétlenül hiányoznak, hanem egyszerűen arról, hogy az egyének nem vették igénybe a szolgáltatást, és így nem állnak rendelkezésre adatok. Ezen túlmenően a feltáró vagy előrejelző erőfeszítések, amelyek teljes mértékben kihasználják a változók gazdag készletét (azaz a big v), jelentős variációt igényelnek ezekben a változóknak, ha megvalósíthatóak akarnak lenni. Ez azt sugallja, hogy a változók gazdag készletét (big v) nagy mintával (big n) vagy hosszmetsetben gazdag méréssel (big t) kell párosítani ahhoz, hogy teljes potenciáljukat kiaknázzák. C. R. Rao azt javasolja, hogy a nagy minták új típusú kutatási erőfeszítéseket tesznek lehetővé, mivel "az elméleti modellek bizonyos a-sumptions lazíthatók, elkerülhető a prediktív modellek túlzott illeszkedése a képzési adatokhoz, a zajos adatok hatékonyan kezelhetők, és a modellek bőséges tesztadatokkal validálhatók" (Nielsen, 2016, 4. o.). Ezenkívül Oswald és Putka (2015) kiemelik, hogy bár "azt gondolhatnánk, hogy az olyan adatkészletek, amelyeket nagynak nevezhetünk", enyhítenék az alulméretezett vizsgálatokkal kapcsolatos aggodalmakat, "a nagy adatmodellek képesek összetett összefüggések illesztésére, ahol léteznek, és ezért ők is nagyon éhesek az adatokra" (45. o.). Ehhez kapcsolódóan a nagy adatokban a nagy adatokat övező izgalom közepette gyakran elvész az a tény, hogy a változók különböző kombinációi esetében a megfigyelések száma (pl. egy részecske "cellában" vagy a változók kombinációiban) nagyon ritka lehet.

A szakasz további részében a pszichológia kutatási lehetőségeinek rendszerezését kínáljuk aszerint, hogy hogyan használják ki a nagy mintaméret (nagy n), az egyénekre vonatkozó változók gazdag készlete (nagy v) és a granuláris és folyamatos adatgyűjtés időbeli kombinációját (nagy t). Olyan munkákat idézünk, amelyeknek meg kellett küzdeniük a nehézségekkel, nem feltétlenül azért, mert ideális módon vagy rossz megközelítéssel tették ezt; egyszerűen csak példaként szolgálnak.

Big n , Little v , Big t : Or, Traditional Research Expanded

Először is megvizsgáljuk a célzott kérdésekre (azaz kevés változóra) összpontosító kutatási erőfeszítéseket, miközben a nagy n és a nagy t kombinációját használjuk fel a kölcsönhatások valós környezetben és sok egyén esetében történő megragadására. A big data kutatásnak ez a változata alkalmas arra, hogy tájékoztassa a következő kérdéseket a változók egy meghatározott csoportját és azok egymáshoz való viszonyát, miközben a valós világban a tényleges viselkedést is megfigyelik. Ezek az erőfeszítések rendkívül hatékonyak lehetnek olyan kutatási területeken, ahol az elméletek

megalapozottak, de tartós feszültségek vannak; különösen akkor, ha ezek a feszültségek alulméretezett vizsgálatokból, a minta torzításából vagy a kutatási kontextusok realizmusával kapcsolatos aggodalmakból erednek.

Néhány nemrégiben készült tanulmány jól példázza a nagy adatok e formáját. Muchnik et al. (2013) például 5 hónapon keresztül randomizált terepkísérletet végzett, és bizonyítékot talált a társadalmi befolyás okozta torzításra egy népszerű közösségi híroldalon. Az oldal nagy felhasználói bázisát (nagy n) kihasználva, kombinálva az oldal azon képességével, hogy folyamatosan gyűjti az adatokat az idő múlásával (nagy t), 101 281 kommentet manipuláltak, amelyeket aztán több mint 10 milliószor néztek meg és 308 515 alkalommal értékelték az 5 hónapos vizsgálati időszak alatt. Mivel képesek voltak hosszabb időszakon keresztül megfigyelni a viselkedést, azt is meg tudták figyelni, hogy a pozitív társadalmi befolyásnak halmozódó csordahatása volt, amely idővel növelte a hatását. Egy másik példa Bapna, Ramaprasad, Shmueli és Umyarov (2016) munkája, akik 3 hónapon keresztül nagyszabású terepkísérletet végeztek egy népszerű online társskereső weboldalon. Manipulálták, hogy ezen a társskereső oldalon 100 000 felhasználónak biztosítottak-e egy népszerű adatvédelmi funkciót, amely lehetővé teszi számukra, hogy elrejtsek mások profiljának átnézését; azt találták, hogy a nők jelentősen kevesebb romantikus interakciót kaptak a weboldalon, ha biztosították ezt az adatvédelmi funkciót. Feltételezték, hogy az adatvédelmi funkciók csökkentik a romantikus interakciókat a nők esetében, mivel a nők a romantikus érdeklődés jelzésére szolgáló közvetett mechanizmusból profitálnak. Hasonlóan Muchnik et al. (2013), a nagy felhasználói bázis kombinációja a platformon és az adatgyűjtés lehetősége az idő múlásával kulcsfontosságú volt ahhoz, hogy képesek legyenek az eredményeik érvényesítésére és számszerűsítésére (pl. Képesek voltak megfigyelni a kezelés előtti trendeket, valamint a kezelés utáni hatásokat). Hasonlóképpen, Kramer, Guillory és Hancock (2014) feltárta az érzelmi fertőzés ok-okozati bizonyítékait azáltal, hogy egy héten keresztül közel 700 000 Facebook-felhasználó tartalmát különböző érzelmi valenciájú ($n = 689\,003$) tartalmakkal ($n = 689\,003$) mutatta be. Az idő szerepét szemléltetve csak azokat vonták be a vizsgálatba, akik a kísérlet hetében posztoltak státuszt ($n \sim 465\,000$).

Az ilyen típusú erőfeszítések esetében a hozzáféréssel kapcsolatos kihívások jelentősek. Például a nagy digitális platformon végzett véletlenszerű helyszíni kísérletek valószínűleg jelentős és nehezen biztosítható kötelezettségvállalásokat igényelnek a platformok tulajdonosaitól (ami funkcionálisan gyakran elérhetlenné teszi őket a kutatók számára). Az ebben a szakaszban tárgyalt tanulmányok mindegyike kihasználta a platformtulajdonosokkal való valamilyen típusú kapcsolatot, mivel szükségük volt arra, hogy nagyszámú felhasználó számára kontrollált és randomizált manipulációkat vezessenek be ezekben a környezetekben. Sőt, az egyéni viselkedésről szóló részletes adatok gyűjtésének képessége gyakran kulcsfontosságú volt a kutatási kérdések szempontjából. Például Bapna et al. (2016) azonosította az alapvető ki-

Bapna és Bapna, illetve Bapna és Bapna a platform felhasználói között küldött, egyébként privát üzenetek értékelésével határozta meg az érdeklődési körét. Sőt, a

nemek közötti aszimmetriára vonatkozó érdekes meglátásuk a társkereső folyamat kezdeti lépéseiben a mikroszintű adatokra támaszkodik, amelyeket idővel granulárisan rögzítettek (azaz adatok arról, hogy ki nézte meg valaki profilját, és hogy az üzenetek követték-e ezeket a nézeteket vagy sem). Természetesen az ilyen típusú kutatási erőfeszítéseknek nem kell randomizált terepkísérleteknek lenniük (pl. A másodlagos adatkészletek is kevés eredményváltozót és kevés magyarázó változót használhatnak fel). A másodlagos nagy adatok felhasználása a célzott kérdések értékelésére azonban a hagyományosabb erőfeszítéseket érintő korlátozásokhoz hasonló korlátozásoktól szenved, beleértve a potenciális kihagyott változó torzításával és a mérési hibával kapcsolatos korlátozásokat.

Egy másik szempont az ilyen típusú nagy adatgyűjtési erőfeszítésekkel kapcsolatban az, hogy az érintett egyének nagyságrendje gyakran kizárja a kutatók további adatgyűjtését, ami olyan adatokat eredményez, amelyek megközelíthetik az eredményeket vagy az inter-est változókat. Például Kramer et al. (2014) elemezte a Facebook-bejegyzéseket az érzelmi valencia szempontjából, és a bejegyzéseket "pozitív vagy negatív kategóriába sorolta, ha legalább egy pozitív vagy negatív szót tartalmazott" (8789. o.). Ezenkívül Bapna és munkatársai (2016) három üzenetváltást használtak fel annak helyettesítőjeként, hogy történt-e egyezés a platformon, de nem tudták megfigyelni, hogy az egyének ténylegesen elmentek-e randevúra, a randevú minőségét, vagy hogy a résztvevők egyezései kapcsolathoz vezettek-e. A kutatásban részt vevők nem tudták megfigyelni, hogy az egyének valóban elmentek-e randevúra, vagy hogy a randevú minősége milyen volt. Sőt, e tanulmányok adminisztrációjával kapcsolatban technikai kihívások merültek fel. Például Kramer et al. (2014) kellett módosítaniuk egy olyan szoftvert, amely a szöveget elemzi a pozitív versus negatív szavakra vonatkozóan, hogy a Hadoop-on (egy olyan szoftver keretrendszer, amelyet olyan alkalmazásokhoz terveztek, amelyek hatalmas mennyiségű adatot tudnak feldolgozni) és a résztvevők Facebook hírfolyamában fusson. Végül, vannak kísérleti tervezési megfontolások, amelyek az ilyen platformokon végzett kutatáshoz kapcsolódnak, például a manipulációk bevezetése a platformon való természetes előfordulásukkal megegyező arányban. Ezen aggályok miatt a Muchnik et al. (2013) által végzett kísérletben szereplő 101 281 hozzászólásból csak 4049-et kezeltek pozitívan (felfelé szavazást kaptak) és csak 1942-et negatívan (lefelé szavazást kaptak). Hasonlóképpen, Kramer et al. (2014) két külön kontrollkörülmenyt futtatott a pozitív és negatív valenciájú kezelésekre, mivel a pozitív valenciájú hozzászólások gyakoribbak voltak a Facebook valencián.

Másrészt, néhány kihívás, amely felmerülhet a nagy adatkutatás kevésbé lehet hangsúlyos. Először is, az ilyen tanulmányok statisztikai elemzése ésszerű egyenes lehet, mivel az ilyen tanulmányok gyakran használnak standard becslési eljárásokat. Bapna et al. (2016) elsősorban az átlagok közötti különbségek értékelésére és a t-tesztekre támaszkodik, Kramer et al. (2014) Poisson-regressziót és súlyozott lineáris regressziót használ, Muchnik et al. (2013) pedig összetettebb (de még mindig jól ismert) regressziós modelleket használ, amelyek véletlen hatásokat tartalmaznak az ugyanazon értékelőtől származó ismételt megfigyelések figyelembevételére. Ez azt jelenti, hogy a nagy mintanagyság miatt az e tanulmányok által azonosított hatások általában

statisztikailag szignifikánsak, ami szükségessé teszi a megvitatását, hogy az azonosított hatások elméleti vagy gyakorlati jelentőséggel bírnak-e. Másodszor, ezek a tanulmányok általában erősen fókuszáltak, és könnyebben pozícionálhatók a teoretikus értékük és a kutatás szempontjából; valójában az ebben az alfejezetben szereplő összes tanulmányt a korábbi munkák meglehetősen konkrét korlátai motiválják (pl. külső érvényesség vagy a korábbi eredmények oksági értelmezése). A meglévő statisztikai megközelítések alkalmazhatósága és e tanulmányok elméletalapúságának lehetősége így lehetővé teszi, hogy az ilyen típusú adatok és kutatások könnyen integrálhatók legyenek a meglévő kutatási keretekbe. Ugyanakkor az ilyen erőfeszítések képletesen "lábujjhegyre mártásnak" is tekinthetők abban a nagy rendszerben, amit a nagy adatok lehetővé tesznek.

Kis n, nagy v, nagy t: Or, Small Sample Big Data Research

A nagy adatkutatás egy másik formája a kutatók számára rendelkezésre álló változók növekedését, valamint ezeknek a változóknak az időbeli változását használja ki, ahelyett, hogy a mintaméretre (n) összpontosítana, önmagában. Ez a fajta big data kutatás a legkevesebb figyelmet kapta a big data szemszögéből, és mégis, véleményünk szerint, néhányat kínál a leginkább megvalósítható potenciálból, hogy azonnali és kézzelfogható hozzájárulást nyújtson a pszichológiai kutatók számára, hogy hozzájáruljanak a szakirodalomhoz. Ezek az erőfeszítések fontos folyamatorientált meglátásokat eredményezhetnek, és olyan feltáró vagy előrejelző kutatásokat is magukban foglalhatnak, amelyek a hagyományos pszichológiai konstrukciókat a nagy adatplatformok által jellemzően generált változók típusaihoz kívánják kapcsolni. Számos tanulmány példázta, hogy mi lehetséges a kis mintájú nagyadat-kutatással. Különösen ígéretesek azok a kutatási erőfeszítések, amelyek a pszichológia hagyományos érdekességeit és az egyének viselkedésére vonatkozó gazdag granuláris adatokat kombinálják. Wang és munkatársai (2014) egy 10 hetes tavaszi félév során 48 diákról gyűjtöttek adatokat, amelyek 53 GB érzékelési adatot tartalmaztak az okostelefonjaikról (pl. helymeghatározási információk, alvás, aktivitási információk, a személyes beszélgetések időtartama és gyakorisága stb.), 32 000 napi önjelentést, amelyek olyan változókat fedtek le, mint az érzelmek, a stressz, a testmozgás, a hangulat és a magány, az érdeklődésre számot tartó pszichológiai konstrukciókat (személyiség, depresszió stb.) mérő előzetes és utólagos felméréseket, valamint a tanulmányi teljesítmény mérését (pl. GPA). Ezen adatok felhasználásával Wang, Harari, Hao, Zhou és Campbell (2015) a GPA-t a jelentett jegyek +/-0,179-es pontossággal tudták megjósolni, és az akadémiai teljesítmény számos fontos meghatározó tényezőjét azonosították. Ugyanezen minta felhasználásával kimutatták, hogy az okostelefonok által általánosan rögzített adatok erősen korrelálhatnak a napi stresszszint, a depresszió és a magányosság változásával (Ben-Zeev, Scherer, Wang, Xie, & Campbell, 2015). Purta és munkatársai (2016) 500 egyetemi hallgató gazdag Fitbit-adatait (pl. lépések, elégetett kalóriák, alvás stb.) és mobiltelefon-adatokat (érezékelőadatok, telefonnaplók

stb.) rögzítettek egy 2 éves időszak alatt. Ezzel párhuzamosan rendszeresen rögzítettek kérdőíves adatokat a személyiségről, az önbecsülésről, az önhatékonyságról, a mentális egészségről, az általános egészségről, az alvási szokásokról, a fizikai tevékenységekről, az edzés és hovatartozás. Mark, Iqbal, Czerwinski, Johns és Sano (2016) 12 munkanapon keresztül minden munkaidőben automatikusan naplózták a munkahelyi számítógépes tevékenységet. Emellett egy általános felmérést is beadtak, amely a Big 5 személyiségjegyet, valamint az impulzivitást, a stresszt és más változókat mérte. Ezeket az adatokat arra használták fel, hogy jobban megértsék a munkahelyi figyelemelterelést, összpontosítást és termelékenységet; például azt találták, hogy a neuroticizmus összefüggött a rövidebb online összpontosítás időtartamával, és hogy egyes személyek másoknál fogékonyabbak voltak az online figyelemváltásra a munkahelyen. Hibbeln, Jenkins, Schneider, Valacich és Weinmann (2017) három kis mintájú vizsgálatot (n = 65, 126 és 80) és az egérmozgások granuláris rögzítésével egyesített kísérleti megközelítést használtak fel az egérkurzor mozgása és a negatív érzelmek közötti kapcsolat értékelésére. A három vizsgálatban azt találták, hogy a kurzor távolsága és sebessége szignifikáns előrejelzője volt a negatív érzelmeknek (az egyik vizsgálatban 82%-os pontossággal tudták azonosítani azokat a csoportokat, amelyek a negatív érzelmi kezelést kapták). Mindegyik kutatásban az adathalmazok "nagyok" és változatosak voltak, de viszonylag kis számú egyénnel foglalkoztak.

Az ilyen típusú kutatási erőfeszítéseknél néhány kihívás a legjelentősebb. Először is, gyakran jelentős szükség van a nyers adatok előfeldolgozására, majd elemzésére, hogy olyan változókat hozzanak létre, amelyek hasznosak az adott munka számára. Wang és munkatársai (2014) például szkripteket hoztak létre az okostelefon gyorsulásmérőjéből, fényérzékelőjéből, mikrofonjából és gps/Bluetooth-jából származó adatgyűjtés automatizálására, majd különböző osztályozókat alkalmaztak, hogy ezeket a nyers adatokat az érdeklődésre számot tartó változókká alakítsák. Különösen az előre feldolgozott gyorsulásmérő adatokból vontak ki jellemzőket, és egy döntési fa osztályozót alkalmaztak a fizikai aktivitásra való következtetéshez, külön osztályozókat használtak az emberi hang és a beszélgetés következtetésére a mikrofonadatokból, és egy olyan osztályozót építettek, amely a telefon fényérzékelőjének és mikrofonjának adatait is felhasználja egy olyan osztályozó létrehozásához, amely megkülönbözteti, hogy a résztvevők valószínűleg mikor alszanak. Hasonlóképpen, Wang et al. (2015) létrehozta a társadalmi versus akadémiai viselkedés közelítő intézkedéseit a helyadatok (könyvtárban vagy testvériségben vannak), a környezeti zaj szintje, mennyi ideig maradnak egy adott helyen, és így tovább. Azonban a kutatóknak nem mindig kell ilyen típusú elemzést végezniük maguknak; például Purta et al. (2016) kihasználta a Fitbit algoritmusait, hogy közelítse a résztvevők fizikai aktivitásának szintjét, alvási mintákat és így tovább. Természetesen, ha mások saját algoritmusokat hajtottak volna végre, a válaszok másképp alakulhattak volna. Az ilyen jellegű mérési problémák, amelyeket a pszichológusok már régóta figyelembe vesznek (megbízhatóság és érvényesség), véleményünk szerint jobban előtérbe kellene kerülniük a nagy adatgyűjtési kutatásokban.

A második jelentős kihívás, amely ezekkel az erőfeszítésekkel kapcsolatban felmerült a viszonylag kevés egyedi egyénre vonatkozóan longitudinálisan gyűjtött gazdag változóhalmaz statisztikai elemzése körül forog. Wang és munkatársai (2015) megjegyzik, hogy a mintájukban szereplő egyedi résztvevők kis száma túlillesztést vezetett be, aggodalmak és korlátozták a kifinomult prediktív modellek használatának lehetőségét. Ben-Zeev et al. (2015) hasonló korlátozásokkal szembesültek, és büntetett funkcionális regressziót (Gold-smith, Bobb, Crainiceanu, Crainiceanu, Caffo, & Reich, 2011) használtak annak érdekében, hogy "intenzív ismétlődő mérési változókat használjanak prediktorként, és azokat, mint egész, egyéni szintű kimeneti mérésekhez kapcsolják" (6. o.). Ben-Zeev et al. (2015) ezekben a mintákban az adatok gazdag longitudinális jellegét is figyelembe vették a vegyes hatású lineáris modellek alkalmazásával. A harmadik kihívás a résztvevők folyamatos megfelelésével kapcsolatos, különösen a hosszabb időszakokon átívelő vizsgálatok esetében. Különösen a digitális eszközökről (például okostelefonokról vagy Fitbitről) gyűjtött adatok megkövetelik, hogy ezeket az eszközöket feltöltsék, hogy a résztvevők maguknál hordják vagy viseljék őket, és hogy bizonyos funkciókat (pl. Bluetooth) következetesen bekapcsolva tartsanak. Ez megköveteli, hogy a kutatók folyamatos ösztönző rendszereket alkalmazzanak, hogy a résztvevők a vizsgálati időszak alatt folyamatosan magas szintű megfelelést biztosítsanak. Például Wang et al. (2014) a vizsgálati időszak során a magas megfelelési arányú résztvevők számára díjakat sorsoltak ki, Purta et al. (2016) pedig havi pénzbeli ösztöndíjat biztosított a résztvevők számára, amely a megfelelési arányuktól függött.

A big data kutatással kapcsolatos további kihívások a következők

Kevésbé hangsúlyosak azokkal az erőfeszítésekkel kapcsolatban, amelyeket ebben a szakaszban vizsgálunk. Először is, a hozzáférés kisebb kihívást jelenthet, mivel ezek az erőfeszítések nem foglalnak magukban kereskedelmi érdekeltségeket vagy platformokat; az ebben a szakaszban tárgyalt tanulmányok mindegyike a technológiai platformok tulajdonosaival való együttműködés nélkül készült, és a kutatók elsődleges adatgyűjtési erőfeszítései. Hibbeln et al. (2017) bemutatja, hogy ezek az erőfeszítések csak hagyományos minták, nyílt forráskódú eszközök és a kutatók saját kísérleti környezetének felhasználásával végezhetők. Konkrétan az Amazon Mechanical Turk-től származó egy mintát és két diákmintát használnak a saját maguk által kifejlesztett digitális környezetekkel együtt, amelyek granulárisan rögzítik a felhasználók egérmozgásait. Egy nyilvánosan elérhető JavaScript könyvtár (jQuery) segítségével képesek voltak olyan weboldalt fejleszteni, amelyek milliszekundumos pontossággal rögzítik az egérkurzor pozícióját és időbélyegét. Ezzel a megközelítéssel képesek voltak randomizált manipulációkat bevezetni ezekbe a környezetekbe, és hatékonyan vizsgálhatták hipotéziseiket különböző döntési beállítások között. A nagy adatkutatás ezen formájának hozzáférhetősége és könnyű replikálhatósága ellensúlyozhatja a kis mintákhoz kapcsolódó szelekciós és általánosíthatósági aggályok egy részét. Ez azért

van, mert más kutatók könnyebben megismételhetik ezeket a tanulmányokat, hogy validálják, kiegészítsék, cáfolják, vagy megtalálják és értékeljék a moderátorokat vagy közvetítőket az előzetes eredményekhez. Másodszor, az elméleti és kutatási hozzájárulással kapcsolatos kihívások kevésbé hangsúlyosak lehetnek, mivel a kutatóknak közvetlenebb kontrolljuk van az adatgyűjtés és a kutatási eljárás felett. Ez olyan kutatási erőfeszítésekhez járulhat hozzá, amelyek a digitális platformok gazdag adatait használják az előre megtervezett és elméletileg vezérelt hipotézisek tesztelésére. Például az egyének digitális tevékenységére vonatkozó granuláris és gazdag adatok gyűjtésekor Mark et al. (2016) konkrét hipotéziseket alkottak és teszteltek arról, hogy ez a digitális viselkedés hogyan kapcsolódik a pszichológiai konstrukciókhoz. Ehhez kapcsolódóan a kis minta lehetővé teszi a kutatók számára, hogy hagyományos megközelítéseket alkalmazzanak a pszichológia szempontjából közvetlenül releváns konstrukciók mérésére (pl. felmérési megközelítések). Valójában az ilyen típusú erőfeszítések kritikusak lehetnek a pszichológia számára a nagy adatok "értelmezéséhez" azáltal, hogy a hagyományos pszichológiai konstrukciókat összekapcsolják az e platformok által generált strukturálatlan, de gazdag változókkal.

Nagy n, nagy v, kis t: Vagy, kis pillanatképek Nagy adatok kutatás

A pszichológiai kutatás számára ígéretesek azok a nagy adatomennyiségű kutatási erőfeszítések is, amelyek nagy mintákkal együtt gazdag változókészletet használnak fel, miközben nem feltétlenül támaszkodnak kritikusan a változók mérésére és az időbeli megfigyelésre. Ezekben a vizsgálatokban a nagy minták kulcsfontosságúak lehetnek a változók gazdag halmazában rejlő teljes potenciál felszabadításában a pszichológia számára érdekes kérdések megismerése, valamint a feltáró és előrejelző erőfeszítések megkönnyítése érdekében.

Az egyik terület, ahol az ilyen típusú kutatási erőfeszítések relevánsak, és újszerű feltáró és előrejelző eredményekkel szolgálhatnak, a viselkedésgenetika. E kutatások nagy részében sok egynukleotid-polimorfizmust (SNP) rögzítenek (big v); sőt, gyakran sokkal több SNP van egy egyénen belül, amelyek potenciálisan érdekesek a kutatók számára, mint ahány egyén van ezekben a vizsgálatokban. Így a sok egyén megfigyelésének képessége (nagy n) kulcsfontosságú az ilyen genetikai információk és az érdeklődésre számot tartó eredmények közötti szilárd kapcsolatok feltárásához, különösen azért, mert a gének nem változnak, bár a génexpresszió (azaz az epigenetika) és az érdeklődésre számot tartó eredmények változhatnak. Például Hu és munkatársai (2016) 89 283 egyén adatait használták fel, hogy azonosítsák a "reggeli ember" önbevallásával kapcsolatos genetikai variánsokat, és azt, hogy a reggeli ember hogyan kapcsolódik a különböző pszichológiai kimenetekhez, beleértve az álmatlanságot és a depressziót. Egy másik példa a nagy adatkutatásra, amely nem igényel granuláris variációt hosszabb időn keresztül, a modern szövegelemzés, amelyben a rövid idő alatt rögzített gazdag szöveg rövid idő alatt számos változót és jellemzőt generálhat, és nagyszámú egyénre vonatkozóan állhat rendelkezésre. Deghani et al. (2016) például

731 332 tweetet gyűjtöttek össze 220 251 felhasználótól (ebből 188 467 esetben tudtak hálózati struktúrát gyűjteni), hogy felmérjék, hogyan jelzik előre az erkölcs dimenziói az online társadalmi távolságot; feltételezik és megerősítő bizonyítékokat találnak arra, hogy az "erkölcsi tisztaság" meghaladja az erkölcs más dimenzióit a társadalmi távolság magyarázata szempontjából.

Az ilyen típusú erőfeszítéseket fontolgató kutatóknak ismét tisztában kell lenniük néhány kiemelkedő kihívással. Például a változógazdagság és a nagy mintanagyság kombinációja jelentős aggodalmakat vet fel a hamis korreláció és a statisztikailag szignifikáns, de gyakorlatilag (vagy klinikailag) nem szignifikáns hatásméretetek miatt. Ezek az aggályok egyértelműek a viselkedésgenetika kontextusában, ahol a genom-széles körű asszociáció a tanulmányok SNP-k milliói és néha kevés kimenetel közötti kapcsolatot értékelik. Emiatt az aggodalom miatt a kutatási erőfeszítések a statisztikai szignifikancia felülvizsgált normáira támaszkodnak, a $p < 5,0 \times 10^{-8}$ értékhasználat elfogadható küszöbértékként a statisztikailag érdekes összefüggésnek tekintett összefüggésekhez (Hu et al., 2016). Ezenkívül az ezekben a tanulmányokban részt vevők skálája megnehezíti a pszichológia szempontjából közvetlenül releváns konstrukciókra vonatkozó adatok gyűjtését. Egyes tanulmányok megkerülik ezt a problémát azáltal, hogy olyan saját adatokat használnak fel, amelyek gazdag változókészletet kapcsolnak össze a pszichológia számára érdekes eredményekkel. Hu és munkatársai (2016) például a "23 and Me" (egy nagyszabású, de szabadalmaztatott digitális platform, amely olcsó genetikai feltérképező készleteket árul) által gyűjtött önbevallásos felmérési adatok felhasználásával tudták elvégezni a reggeli személyiség genetikai mutatóit (valamint a kapcsolódó eredményeket, például a depressziót) vizsgáló tanulmányukat. Ezekkel a kutatási erőfeszítésekkel azonban gyakrabban fordul elő, hogy az érdeklődésre számot tartó konstrukciók a rendelkezésre álló adatokban nem figyelhetők meg közvetlenül (különösen, ha az egyének léptéke nagy). Deghani et al. (2016) például az erkölcsnek a társadalmi távolságtartásra gyakorolt hatása iránt érdeklődött, de nem tudott hagyományos felmérési intézkedéseket használni az erkölcsi beállítottság megragadására a mintájukban. Ehelyett "az erkölcsiséget közvetettebb módon, a társadalmi diskurzus szövegeiben hátrahagyott, természetesen előforduló "erkölcsi maradványok" megfigyelésével ragadják meg" (2. o.). Ezt úgy teszik, hogy szinguláris érték dekompozíciót használnak, hogy a tweeteket olyan vektorokká redukálják, amelyek összehasonlíthatók egy adott erkölcsi aggályhoz kapcsolódó kifejezésekhez való távolságuk szempontjából; ez lehetővé teszi számukra, hogy értékeljék, hogyan kapcsolódnak a különböző erkölcsi aggályok az online társadalmi távolsághoz. A megfigyelt adatokat a pszichológia számára érdekes konstrukciókkal összekötő erőfeszítések fontosságát szemléltetve a Deghani et al. (2016) által kifejlesztett megközelítést más kutatók is felhasználhatják az erkölcsi hajlammal kapcsolatos sokféle más kérdés értékelésére a potenciálisan nagy kiterjedésűek számára.

Az ilyen jellegű erőfeszítések iránt érdeklődő kutatók végső szempontja az, hogy míg a másodlagos és nagyméretű adatok felhasználása érdekes betekintést nyújthat, a kutatói ellenőrzés hiánya, amelyet bevezetnek, valamint az érdeklődésre vonatkozó

konstrukciók közelítésének szükségessége megnehezítheti a robusztus oksági következtetések levonását. Hu et al. (2016) ezt a kérdést a Mendel-féle randomizációs elemzéssel kezelte, és valójában azt találta, hogy a reggeli személyiség és a pszichológiai eredmények (pl. Depresszió) közötti kezdetben erős korrelációk nem voltak robusztusak a szigorúbb oksági elemzéssel szemben. Dehghani és munkatársai (2016) ugyanezt a kérdést úgy kezelték, hogy nagyszabású megfigyelési tanulmányukat két laboratóriumi kísérlettel egészítették ki, amelyekben az erkölcsi aggodalom hagyományos intézkedéseit, valamint véletlenszerű hozzárendelést alkalmaztak, hogy megerősítsék eredményeiket.

A nagy minták és a gazdag adatok kombinációja a az egyénnel kapcsolatos adatokkal e mintákban értékes lehet a pszichológia számos kutatási törekvése számára. Különösen ezek az erőfeszítések jelentős potenciállal rendelkeznek a következő kérdések megismerésében amelyek a pszichológia számára olyan változókra összpontosítanak, amelyek nem változnak jelentősen a vizsgált időszak alatt, valamint olyanok, amelyekben sok egyén kis pillanatfelvételei elegendő adatgazdagságot biztosítanak az érdeklődésre számot tartó kutatási kérdések megválaszolásához.

Big n, Big v, Big t: Vagy: Idealizált nagy adatok kutatás

Most olyan kutatási törekvéseket vizsgálunk meg, amelyek a nagy adatok mindhárom dimenzióját metszik, nagy mintákkal és gazdag változóhalmazzal, amelyeket hosszú időn keresztül granulárisan rögzítenek. Az ilyen típusú tanulmányok képviselik a nagy adatok néhány átalakító potenciálját a pszichológiai újrakutatásban. Más tudományágokban az ilyen adatok olyan kutatási erőfeszítéseket tettek lehetővé, amelyek jelentős közérdeklődésre tartottak számot.

Aral és Walker (2012) először alkalmazott egy nagyszabású digitális kísérletet (1,3 millió Facebook-felhasználó egy 44 napos időszak alatt), hogy megértse azokat a tényezőket, amelyek az egyént fogékonyá teszik a társadalmi befolyásolásra, ami egyértelműen egy olyan konstrukció, amely sok pszichológust érdekel. Érdekes módon a tanulmány egy mobilalkalmazás mindössze ~8 000 egyedi felhasználójának társadalmi hálózatát használta fel az 1,3 millió Facebook-felhasználón végzett kísérlet lefuttatásához; ez rávilágít mind a hálózatos alkalmazások erejére a nagyszabású vizsgálatok lehetővé tételében, mind pedig az általuk kiváltott etikai aggályokra (amelyeket az alábbiakban részletesebben tárgyalunk). A szerzők ezután kísérleti eredményeiket egy nagyobb másodlagos adathalmazra (12 millió felhasználó 85 millió kapcsolattal) extrapolálják, és megállapítják, hogy a befolyásos egyének kevésbé fogékonyak a befolyásolásra, mint a nem befolyásos egyének, és hogy a befolyásolók hajlamosak a hálózatok csoportosítására, míg a befolyásolásra fogékonyak nem.

Kosinski, Stillwell és Graepel (2013) 58 000 önkéntesről származó történelmi Facebook-adatok (pl. "kedvelések", részletes de-mográfiai profilok stb.) és több pszichometriai teszt eredményeinek kombinációját használta fel olyan prediktív modellek létrehozására, amelyek képesek egyes érzékeny tulajdonságokra (pl. szexuális

orientáció, faji vagy politikai beállítottság) következtetni az egyénekről. Youyou és munkatársai (2015) hasonló adatokat használtak (90 000 résztvevőtől) annak értékelésére, hogy a Facebookon a felhasználók "kedveléseire" vonatkozó adatokkal összekapcsolt számítógépes modellek képesek-e megjósolni az egyéni személyiségjellemzők eltéréseit. Azt találták, hogy az adatvezérelt modellek pontosabbak voltak a személyiségmérések előrejelzésében, mint a résztvevők Facebook-ismerősei, és hogy a számítógépes személyiségmegítélések magas külső érvényességgel rendelkeztek az olyan életkilátások előrejelzésekor, mint a kábítószerrel való visszaélés, a politikai attitűdök és a fizikai egészség. Más erőfeszítések évszázados szöveges adatokat használnak fel a változó pszichológiai állapotok és konstrukciók értékelésére hosszabb időn keresztül. Iliev, Hoover, Dehghani és Axelrod (2016) például két évszázadnyi szöveget elemzett az amerikai angol nyelv történeti korpuszaiból - a Google Books és a New York Times -, hogy megmutassa, hogy a jól dokumentált linguista pozitív torzítás lineáris időbeli tendenciát mutat az idő múlásával, és hogy ez a hatás érzékeny a gazdasági, társadalmi és pszichológiai tényezők változásaira. Iliev és Smirnova (2016) hasonló erőfeszítésre vállalkoztak, és történelmi korpuszokat értékelték annak a hipotézisnek az igazolása érdekében, hogy az oksági megismerés (ahogyan azt az oksági nyelvezet időbeli változásai mutatják) idővel egyre nagyobb szerepet játszik a nyugati társadalomban.

Ezek az erőfeszítések izgalmas munkát jelentenek a nagy adatok és a pszichológia metszéspontjában. Nem meglepő azonban, hogy ezek az erőfeszítések is szembesülnek a korábban tárgyalt kihívások teljes skálájával, és így a legmesszebb kerülhetnek a tipikus pszichológiai kutatók komfortzónájától. Az ilyen típusú erőfeszítések elemzése bonyolult lehet, és megköveteli a fejlett statisztikai módszerek kihasználását mind a rendelkezésre álló információk feldolgozásához, hogy az elemzéshez felhasználhatóvá váljon, majd elemezze ezeket az adatokat. Például Iliev és Smirnova (2016) és Iliev et al. (2016) mindketten fejlett szövegelemzési met-ódusokat használtak a pszichológia számára érdekes intézkedések (a pozitív torzítás és az alkalmi megismerés mértéke) kivonására. Kosinski, Stillwell és Graepel (2013) először az egyének Facebook-kedveléseire vonatkozó adatok dimenzió-szerűségét csökkentették szinguláris értékű dekompozícióval. Ezután a top-100 SVD-összetevőket használták keresztellenőrzött lineáris és logisztikus regressziós modellekkel kombinálva, hogy megjósolják az adatok különböző, érdeklődésre számot tartó kimeneteleit. Youyou et al. (2015) hasonló adatokat használt, de a résztvevők tetszéseit reprezentáló mátrix redukálása helyett ezeket az adatokat LASSO regresszióval kombinálták (egy olyan becslési megközelítés, amely alkalmasabb a gazdag adatok kezelésére az előrejelzéshez, különösen akkor, ha egyes együtthatók közel vannak a nullához, és úgy gondolják, hogy funkcionálisan figyelmen kívül hagyhatók). Más munkákhoz hasonlóan a modellek túlillesztésének elkerülése érdekében ők is keresztellenőrzést alkalmaztak, és többször képezték a modelleket az adatok különböző részhalmazain, hogy a teljes mintájukra vonatkozó előrejelzéseket hozzanak létre.

Az idő is jelentősebb szerepet játszik az elemzésben és az adatgyűjtésben, mind a teoretikai újdonság és érték, mind a módszertani megközelítések és kihívások

tekintetében. Iliev és Smir-nova (2016) és Iliev et al. (2016) például explicit hipotéziseket javasoltak és teszteltek az írott szövegek időbeli változékonyságával kapcsolatban, valamint azzal, hogy ezek a szövegek hogyan változnak a történelmi események és a társadalmi változások hatására, szintén az idő múlásával. Más esetekben az időbeli változékonyság módszertani kihívások elé állítja az ilyen törekvéseket. Kosinski, Stillwell és Graepel (2013) például viszonylag alacsony előrejelzési pontosságot ért el olyan, erősen időbeli jellegű mérések esetében, mint az önbevalláson alapuló "életelegedettség" és a kapcsolati státusz. Megjegyzik, hogy ez az alacsony előrejelzési pontosság azért lehet, mert a Facebook-kedvelések hosszabb idő alatt gyűlnek össze, és így a legjobban alkalmasak lehetnek a hosszú távú és stabilabb mea-sures előrejelzésére. Bár az ilyen típusú erőfeszítések számos, a nagy adatokkal kapcsolatos kihívással szembesülhetnek, fontos megjegyezni, hogy a kutatási célok szempontjából rendkívül rugalmasak lehetnek. Például, bár ezek az erőfeszítések mindegyike a nagy adatok mindhárom dimenziója mentén gazdag adatokat használ fel, a nagy adatok mindhárom dimenziója mentén gazdag adatokat használnak fel.

Az előzetes elméleti fejlesztés és tesztelés szintje szempontjából: Iliev és Smirnova (2016) és Iliev et al. (2016) konkrét hipotéziseket motiválnak és tesztelnek, míg Aral és Walker (2012) egy célzott kísérlettel kezdenek, majd kiterjesztik a feltáróbb elemzésre, Kosinski, Stillwell és Graepel (2013) és Youyou et al. (2015) pedig az egyes jellemzők előrejelzésére összpontosító feltáró megközelítéseket alkalmaznak.

Ezek az erőfeszítések lehetnek a legértékesebbek, legalábbis rövid távon, azokon a területeken, ahol az előrejelzési erőfeszítések klinikai értéket kínálnak, vagy ahol a feltáró erőfeszítések potenciálisan felfedezhetik a pszichológiai konstrukciók és a megfigyelt viselkedés kapcsolatának megismerését. Hosszú távon ezek az erőfeszítések olyan területeken lehetnek értékesek, ahol az elmélet fejletlen, vagy ahol a meglévő elmélet nem képes megjósolni vagy megmagyarázni a robusztus empirikus jelenségeket. Mint ilyenek, rendkívül hasznosak lehetnek az új elméleti irányok feltárásában és azonosításában.

Különböző kutatások párosítása erőfeszítések

A kutatóknak nem kell egyetlen kutatási formára korlátozódniuk, mivel sok esetben egyetlen újrakutatási cikket lehet erősíteni a kutatás különböző formáinak (mind a hagyományos, mind a nagy adatok felhasználásával) egyidejű folytatásával. A legegyszerűbb, de talán a legerőteljesebb a big data kutatás és a pszichológiában alkalmazott hagyományos megközelítések párosítása. Azokban az esetekben, amikor a tudósok érdekes összefüggéseket vagy potenciális felismeréseket azonosítanak, de az eredményeket szigorúbb ok-okozati elemzéssel vagy célzottabb vizsgálattal kell megszilárdítaniuk, a hagyományos megközelítések megfelelő kiegészítést jelenthetnek. Ezenkívül a kutatók alkalmazhatták az érdeklődésre számot tartó konstrukció közelítéseit, és előnyös lehet az eredmények validálása kis mintákkal és az ugyanazon konstrukció mérésére szolgáló hagyományos módszerekkel (pl. felmérési eszközök).

Ezenkívül a kis mintájú nagy adatgyűjtésű kutatások (kis n, nagy v, nagy t), amelyek megpróbálják megbecsülni, hogy a gazdag, de strukturálatlan változók hogyan korrelálnak a hagyományosabb pszichológiai konstrukciókkal, segíthetnek a nagyobb léptékű tanulmányoknak (pl. nagy n, nagy v és nagy t), hogy "értelmet adjanak" az adataiknak, és összpontosítsák feltáró vagy előrejelző erőfeszítéseiket. Hasonlóképpen, ezek a nagyszabású feltáró erőfeszítések olyan eredményeket hozhatnak, amelyek olyan alapvetőbb összefüggésekre utalnak, amelyek megérdemlik a célzottabb feltárást. Ebben a tekintetben az ugyanazon a platformon végzett randomizált kísérletek (pl. nagy n, kis v, nagy t erőfeszítések révén) hasznos kiegészítői lehetnek ezeknek az erőfeszítéseknek, mivel tisztábban megragadhatják és szétválaszthatják az előre meghatározott változók közötti kapcsolatokat, és mindezt ugyanabban a környezetben tehetik, mint a kezdeti értékelés. Végső soron a hagyományos és a big data-kutatás párosításának módja a közelmúltban folytatott vita kérdése a területen (Baumeister, 2016; Sakaluk, 2016). Azt állítjuk, hogy ez a döntés a gyakorlatban számos tényezőtől függ, beleértve azt is, hogy mit mutatott az előzetes szakirodalom, a szakirodalommal való konkrét kapcsolat megerősítésének fontossága, a többféle kutatási forma folytatásának költségei stb.

Etikai és adatvédelmi megfontolások

Az etikus kutatás normái és a megfelelő protokollok a népszerűsített nagy adatgyűjtési erőfeszítésekkel összefüggésben még mindig fejlődnek, és egyes kutatások jelentős vitát generálnak a kutatási etikával és a résztvevők beleegyezésével (vagy annak hiányával) kapcsolatban. Goel (2014) azt javasolta, hogy a nagyszabású kísérletek bevezetik a "olyan embereken végzett kutatások lehetőségét, akik talán soha nem is tudják, hogy a vizsgálat alanyai, nem is beszélve a kifejezett hozzájárulásról" (1. o.). Ennek a feszültségnek a szemléletes példája az a felháborodás, amelyet az OKCupid társkereső oldal közel 70 000 felhasználójának adataiból a kutatók által lekapart, majd közzétett adatok okoztak. Bár az adatokat egy nyilvános oldalról kaparták le, jelentős vita övezte az azonosítható adatok hozzájárulás nélküli, kutatási célú közzétételét (Leetaru, 2016). Még akkor is, ha a kutatók kérik a résztvevők hozzájárulását, a big data korszak összekapcsolt és gazdag adatai további kihívásokat hozhatnak. Például a Facebook-adatok megszerzése a résztvevőktől (még azoktól is, akik beleegyezésüket adták) elkerülhetetlenül azt eredményezi, hogy adatokat gyűjtenek a kutatásban résztvevők barátairól, akik nem járultak hozzá ahhoz, hogy a vizsgálat részesei legyenek (hasonló aggályok merülnek fel a Twitter, Fitbit stb. esetében). Nem kellene ezeket az adatokat tiltottá tenni? Ha nem, milyen feltételek mellett engedélyezhető a felhasználásuk? Nyitott etikai kérdések övezik a kutatási résztvevők AMT-n és más crowd-sourcing platformokon történő felhasználását és kérését is. Egyesek az AMT-t és a tágabb értelemben vett crowd-sourcing irányzatot "digitális izzasztóüzemnek" nevezték, ahol az egyéneknek a minimálbérnél kevesebbet fizetnek a feladatok

elvégzéséért, mindenféle jog vagy fizetési garancia nélkül, ha például a kérvényező nem elégedett a munkavállalók teljesítményével (Cushing, 2013).

A kutatáshoz rendelkezésre álló adatok változó jellege az elfogadható kutatási gyakorlatra is hatással van. Például megvitattuk, hogy a nagy adatszolgáltatási erőfeszítések révén rendelkezésre álló változók gazdag készlete hogyan súlyosbíthatja az eredmények szelektív jelentésével kapcsolatos aggodalmakat. Különösen a változók kiterjedt és gazdag készletével a poszt hoc hipotézisekkel és a hamis korrelációval kapcsolatos aggályok még inkább pro-nemlegesek lehetnek. A nagy adatszolgáltatási erőfeszítések felé való elmozdulás azonban csökkentheti ezeket az aggodalmakat. Különösen a vizsgálati résztvevők bősége csökkenti az alulméretezett vizsgálatokkal kapcsolatos aggodalmakat, és valójában segíthet abban, hogy a hangsúlyt a statisztikai szignifikanciáról a gyakorlati szignifikanciára és a hatásméret nagyságának becslésére helyezték át. Sőt, a hatásmentesség állítása (azaz a nullhipotézis alátámasztása) nagyobb minták esetén (pl. egyenértékűségi vizsgálatokban) jobban védhető lehet. Ezenkívül a több száz változót és a gépi tanulási módszereket hasznosító előrejelző vagy feltáró erőfeszítések nem különösebben kedveznek az alábbiak specifikus hatásának elkülönítéséhez egy változónak a kimenetelre gyakorolt hatását. Valójában számos ilyen módszer "fekete doboz"-nak tekinthető, mivel nem generálnak értelmes együttthatóbecsléseket a bennük szereplő egyes változókra vonatkozóan.

Ehhez kapcsolódó kihívás, hogy a rendkívül dinamikus digitális platformok adatait használó kutatási erőfeszítések, ahol az adatokat félig folyamatosan generálják, olyan hatásokat vehetnek fel, amelyek nagyon specifikusak az adatok egy adott pillanatfelvételére. Bár ez nem feltétlenül jelenti azt, hogy az ilyen tanulmányok eredményei helytelenek vagy spu-riózusak, ez a nagy adattanulmányokban megfigyelt jelenségek általánosíthatóságáról szólhat. Az általunk tárgyalt tanulmányok némelyike az ilyen típusú aggályokat úgy kezeli, hogy megállapításait több, különböző időpontban gyűjtött mintán és néhányszor különböző beállításokból is megismétli. Például Jones, Wojcik, Sweeting és Silver (2016) a Twitter-felhasználók három kis részmintáját (~ 1000 felhasználó) használta fel a negatív érzelmekben bekövetkezett változások elemzésére a főiskolai kampuszokon elkövetett három különálló erőszakos bűncselekményt követő három különböző incidenst követően. Hasonlóképpen, Hibbeln et al. (2017) megismételték eredményeiket három különböző mintán és kísérleti kontextusban. Emellett Iliev és munkatársai (2016) két független, időbélyegzővel ellátott szövegtörzset (Google Books és a New York Times) tesztelték hipotéziseiket.

A pszichológiai nagyadat-kutatás szintén jelentős adatvédelmi aggályokat vethet fel. Az eddig ismertett tanulmányok közül számos olyan tanulmányt tartalmaz, amely az egyének millióiról, ha nem százmillióiról széles körben elérhető nyilvános adatokat összekapcsolja ezen egyének nagyon intim pszichológiai dimenzióival (személyiség, öngyilkossági hajlam stb.). Az ilyen jellegű előrejelzéseknek kétértelmű (és néha káros) hatásai lehetnek az egyénekre, ha kevésbé jó szándékú szervezetek képesek lennének tanulni ezekből a kutatásokból, és ugyanilyen típusú előrejelzéseket tenni. A Crystal Platform például azt állítja magáról, hogy a világ legnagyobb "személyiségplatformja", és a róluk szóló "nyilvános adatok" elemzése alapján személyiségprofilokat árul (teszt

nélkül) egyének számára. Bizonyos bizonyítékok arra utalnak, hogy a személyiséget a közösségi média adataiból előrejelző kereskedelmi szolgáltatások kiemelkedő hatással voltak a 2016-os amerikai választásokra és az Egyesült Királyság "Brexit" szavazására (Grassegger & Krogerus, 2017). A Facebook például nemrégiben megtiltotta egy nagy brit gépjármű-biztosítónak, hogy az ügyfelek közösségi médiaadatait átkutassa, hogy megismerje ügyfelei személyiségjegyeit; a biztosító azt remélte, hogy e meglátások alapján különböző díjakat számíthat fel a biztosítási díjakra (Rudgard, 2016). Ez nehéz kérdéseket vet fel azzal kapcsolatban, hogy milyen ellenőrzésekre van szükség a kutatási alanyok védelme és a kutatás etikus elvégzése érdekében. Ezeket az aggodalmakat súlyosbítják a közelmúltban megjelent munkák, amelyek kiemelik a fogyasztók korlátozott képességét az összetett adatvédelmi kompromisszumok online navigálására (Adjerid, Peer, & Acquisti, 2017; Adjerid, Acquisti, Brandimarte, & Loewenstein, 2013). Bár e cikk keretein kívül esik e kérdések kezelésének részletes tárgyalása, más munkák hosszasan tárgyalták ezeket a kérdéseket (lásd pl. Wienberg & Gordon, 2015; Boyd & Crawford, 2012).

Megbeszélés és Következtetések

Összességében azt állítjuk, hogy a pszichológia jól helyezkedik el - valójában jobban, mint sok más terület -, hogy kihasználja a nagy adatok korszakát a kutatás előmozdítására. Ez részben azért van így, mert a nagy adatok kontextusában gyűjtött adatok nagy része személyeket és gyakran viselkedéseket (pl. Vásárlási döntés, online tevékenységek, e-mailekre adott válaszok vagy reakciók, különböző vállalatoknak vagy okoknak adott "kedvelések", állapotfrissítések, írásos válaszok / megjegyzések) és ezért emberi folyamatok. Ugyanakkor a big data-kutatás számos alapvető kérdést vet fel a terület számára és számára.

Először is, a különböző technológiai és statisztikai korlátozások következetes kihívást jelentenek a pszichológiai, valamint más területeken végzett nagyadat-kutatási erőfeszítések számára. Különösen, míg az informatika és a statisztika metszéspontjában bekövetkezett fejlesztések (pl. A gépi tanulás) olyan kutatási lehetőségeket nyitottak meg, amelyek a pszichológia számára releváns kérdésekkel foglalkoznak a nagy adatok felhasználásával, ezeknek a módszereknek a pszichológia számára érdekes kérdésekre történő felhasználása és testre szabása nem triviális. Azt állítjuk azonban, hogy a pszichológia jól felkészült arra, hogy megbirkózzon ezekkel a kihívásokkal, és sok tekintetben már rendelkezik tapasztalatokkal a nagyméretű adatokkal kapcsolatban, a nagyszabású tesztekkel kezdve a nyilvántartásokon át az oktatási hatékonysági értékelésekig. Valójában a statisztika és a pszichológia területeinek gazdag közös múltja van, amely még mindig tart. Ahogy Stigler (1999) ékesszólóan megfogalmazza, "a statisztika és a pszichológia régóta szorosan kapcsolatot ápol ... összekapcsolódnak" (189. o.). Ez magában foglalja olyan módszerek kifejlesztését, amelyek széles körű vonzerőre és népszerűsége tettek szert, mivel számos problémára általánosíthatóak. Valójában Gelman egyszer egy előadásában megjegyezte: "Azt

hiszem, ismerünk egy régóta fennálló elvet a statisztikában, amelyet néhányan itt újra felfedeztek, nevezetesen azt, hogy bármilyen ötletet, ami az embernek van, már körülbelül 50 évvel ezelőtt megcsinálták a pszichometriában."²Nyilvánvalóan van némi túlzás Gelman kijelentésében, de a lényeg az, hogy a pszichológia és a statisztika történelmi egymásrataltsága azt eredményezi, hogy a pszichológia kutatói rendkívül sokoldalú empirikusok, akik készen állnak és képesek a nagy adatok által támasztott kihívások kezelésére és az általuk biztosított előnyök kihasználására. Valójában úgy gondoljuk, hogy a pszichológia kutatóinak több módszertani technikát kellene fejleszteniük a pszichológia egyedi kihívásainak kezelésére ezen a téren (pl. például a *Psychological Methods* nemrégiben megjelent "Big Data in Psychology" különszámában, 2016. decemberi számában).

Bár van egy út a nagy adatokat használó pszichológiai újrakutatók számára, a kihívások továbbra is fennállnak. Jelenleg attól tartunk, hogy a pszichológia jelenlegi módszertani képzése és a nagyadat-kutatáshoz olykor szükséges dolgok között szakadék lehet. Így a pszichológia alap- és mesterképzési programjai, különösen a kvantitatív fókuszúak, fontolóra vehetik módszertani kínálatuk bővítését, esetleg más tudományágakkal való partnerség révén, mint például informatika, informatikai menedzsment és üzleti analitika, hogy olyan módszertani eszközök átfogóbb csomagját nyújtsák, amelyek könnyebben kezelik a nyers műszeres adatok megszerzését, szervezését és átalakítását használható viselkedési adatokká. Hasonlóan az 1990-es években (Aiken et al., 1990) és a 2000-es évek első évtizedében (Aiken, West, & Millsap, 2008) mindkettő ebben a folyóiratban végzett felülvizsgálathoz, itt lehet az ideje, hogy a pszichológia mint terület felülvizsgálja a módszertani képzést a műszeres adatok, az online generált adatok, a fejlett felmérési módszerek stb. szem előtt tartásával. Úgy látjuk, hogy ki kell egészíteni, nem pedig kizorítani a jelenleg tanítottakat, az adatkezelési technikákra (pl. webes kaparás, Hadoop az elosztott számítástechnikához), valamint az adatok elemzésének megközelítéseire (pl. gépi tanulás, hálózatelemzés, sőt mesterséges intelligencia) összpontosító ajánlatokkal. Tapasztalataink szerint az üzleti iskolák doktoranduszai számára már régóta gyakori, hogy a pszichológia tanszékek módszertani kurzusait veszik fel. Talán itt az ideje, hogy a pszichológushallgatók is hasonlóan járjanak el, és az üzleti iskolák, különösen az informatikai menedzsment és az üzleti analitika programok, valamint a számítástechnikai tudományok tanszékeinek műszeres adatokkal foglalkozó kurzusait keressék fel.

Ehhez kapcsolódóan felmerül a kérdés, hogy a big data keresési erőfeszítések ugyanolyan értéket fognak nyújtani, mint a pszichológiában történelmileg lezajlott módszertani fejlesztések? Különösen az a sokféle mód, ahogyan a nagy mennyiségű adat elemezhető, új mérési kérdéseket vet fel, és rávilágít arra, hogy a klasszikus kérdéseket új kontextusban kell felülvizsgálni. Ez magában foglalja a különböző típusú validitások, különösen a diszkriminanciális és konvergens validitás felülvizsgálatát. A Cronbach és Meehl (1955) klasszikus munkájában a konstruktum érvényességéről felvetett kérdések közül sok még mindig nagyon fontos, de úgy tűnik, hogy a nagy adatok kontextusában nem gyakran veszik figyelembe (lásd még Messick, 1995, ez a folyóirat). A mérési invariancia (pl. Millsap, 2011) például új megfontolásokat kap a

különböző platformok miatt, amelyeken a digitális környezetben interakcióba léphetünk (pl. "platform-invariancia"). Természetesen, csak azért, mert nagy mennyiségű adatot lehet gyűjteni, nem feltétlenül minőségi adatokról van szó, vagy arról, hogy az értékek egy értelmes pszichológiai változóhoz kapcsolódnak. Ahogy az Amerikai Statisztikai Egyesület elnöke nemrégiben újra megjegyezte, és amivel egyetértünk, "a mi szakterületünkön a Big Data korában aggódom, hogy a mennyiség javára elvesztettük a minőséggel kapcsolatos fogást" (Nussbaum, 2017). Ahhoz, hogy tartósan hozzájáruljunk, fontosak a megalapozott kutatási tervezési és elemzési megfontolások, függetlenül az adathalmaz méretétől. Szeretnénk arra is rámutatni, hogy a "kis adatok" is nagy értékkel bírhatnak; nem követelmény, hogy az érték az adathalmaz méretéhez legyen kötve.

Végezetül fontos kérdések maradnak, hogy a nagy adatok meglátásai alkalmazott vagy elméleti értékkel bírnak-e? Ezek a kérdések még inkább relevánsak a feltáró nagy adatgyűjtési erőfeszítések összefüggésében, amelyekben a kutatók arra törekszenek, hogy "megértsék, mit mondanak az adatok", ahelyett, hogy poszt hoc hipotéziseket fejlesztenének, hogy megmagyarázzák, miért. Korábban azt állítottuk, hogy a nagy adatok által nyújtott számtalan lehetőség azt sugallja, hogy a nagy adatok kutatása szimbiózisban lesz a hagyományos pszichológiai kutatással (lásd a "Elméleti és kutatási érték" című szakaszt). Ebben a tekintetben a folyóiratok és a bírálók megfontolhatják, hogy nyitottabbak legyenek az adatvezérelt eredményekre, ahelyett, hogy egyesek azt követelnék, hogy az elmélet diktálja, hogy mit kell vizsgálni. Nesselroade (2006) egyszer a fejlődéslélektannal összefüggésben, bár a gondolatok sokkal általánosabbak, azt fejtegette, hogy a módszer és az elmélet olyan, mint egy tánc. Megjegyezte, hogy "az elmélet sokáig vezette a táncot, talán elég sokáig ahhoz, hogy itt az ideje a változásnak [hogy a módszer vezessen]". Ugyanakkor a kutatóknak nem szabad feltételezniük, hogy pusztán azért, mert az adataik "nagyok", hogy az általuk generált meglátások érdekes és publikálhatóak.

Bár egyértelmű, hogy a nagy adatmennyiségű kutatási erőfeszítések egyedi kihívásokkal és kockázatokkal járnak, amelyek gondos mérlegelést igényelnek, a nagy adatok és a nagy adatmennyiségű megközelítések felhasználásával sok mindent nyerhetünk a pszichológiai kutatások előmozdítása érdekében. Valóban, míg ezek az erőfeszítések úgy gondolták, hogy túl vannak néhány kutató, reméljük, hogy megmutattuk, hogy néhány alkalmazás elérhető, és reméljük, hogy a kutatók *con-sider*, ha a munkájuk hasznára válna a wading ezen a területen, és reméljük, hogy inspirálja néhány kutatót, hogy ezt tegye. A kihívásoknak való megfelelés nem lesz könnyű, de úgy gondoljuk, hogy fontos lépéseket kínálhat a pszichológia és a kapcsolódó területek fejlődéséhez.

Szakirodalom

- Adjerid, I., Acquisti, A., Brandimarte, L., & Loewenstein, G. (2013). Sleights of privacy: Framing, disclosures, and the limits of transparency. In Proceedings of the ninth symposium on usable privacy and security (p. 9). New York, NY: ACM.
- Adjerid, I., Peer, E., & Acquisti, A. (2017). Beyond the privacy paradox: Objective versus relative risk in privacy decision making. *Management and Information Systems Quarterly*. Retrieved from https://papers.ssrn.com/sol3/papers.cfm?abstract_id2765097
- Aiken, L. S., West, S. G. S., & Millsap, R. E. (2008). Doctoral training in statistics, measurement, and methodology in psychology: Replication and extension of Aiken, West, Sechrest, and Reno's (1990) survey of PhD programs in North America. *American Psychologist*, 63, 32–50. <http://dx.doi.org/10.1037/0003-066X.63.1.32>
- Aiken, L. S., West, S. G., Sechrest, L., Reno, R. R., Roediger, H. L., Scarr, S., . . . Sherman, S. J. (1990). Graduate training in statistics, methodology, and measurement in psychology: A survey of PhD programs in North America. *American Psychologist*, 45, 721–734. <http://dx.doi.org/10.1037/0003-066X.45.6.721>
- Andrzejewski, D., Zhu, X., & Craven, M. (2009, June). Incorporating domain knowledge into topic modeling via Dirichlet forest priors. In Proceedings of the 26th Annual International Conference on Machine Learning (pp. 25–32). New York, NY: ACM.
- Aral, S., & Walker, D. (2012). Identifying influential and susceptible members of social networks. *Science*, 337, 337–341. <http://dx.doi.org/10.1126/science.1215842>
- Bapna, R., Ramaprasad, J., Shmueli, G., & Umyarov, A. (2016). One-way mirrors in online dating: A randomized field experiment. *Management Science*, 62, 3100–3122.
- Baumeister, R. F. (2016). Charting the future of social psychology on stormy seas: Winners, losers, and recommendations. *Journal of Experimental Social Psychology*, 66, 153–158. <http://dx.doi.org/10.1016/j.jesp.2016.02.003>
- Ben-Zeev, D., Scherer, E. A., Wang, R., Xie, H., & Campbell, A. T. (2015). Next-generation psychiatric assessment: Using smartphone sensors to monitor behavior and mental health. *Psychiatric Rehabilitation Journal*, 38, 218–226. <http://dx.doi.org/10.1037/prj0000130>
- Boas, T. C., & Hidalgo, F. D. (2013). Fielding complex online surveys using rApache and Qualtrics. *The Political Methodologist*, 20, 21–26.
- Borgman, C. L. (2015). *Big data, little data, no data: Scholarship in the networked world*. Cambridge, MA: MIT Press.
- Boyd, D., & Crawford, K. (2012). Critical questions for big data: Provocations for a cultural, technological, and scholarly phenomenon. *Information Communication and Society*, 15, 662–679. <http://dx.doi.org/10.1080/1369118X.2012.678878>
- Brandmaier, A. M., Prindle, J. J., McArdle, J. J., & Lindenberger, U. (2016). Theory-guided exploration with structural equation model forests. *Psychological Methods*, 21, 566–582. <http://dx.doi.org/10.1037/met0000090>
- Buhrmester, M., Kwang, T., & Gosling, S. D. (2011). Amazon's Mechanical Turk: A new source of inexpensive, yet high-quality, data? *Perspectives on Psychological Science*, 6, 3–5. <http://dx.doi.org/10.1177/1745691610393980>

- Cattell, R. B. (1946). Personality structure and measurement; the operational determination of trait unities. *British Journal of Psychology*, 36, 88–103. <http://dx.doi.org/10.1111/j.2044-8295.1946.tb01110.x>
- Cattell, R. B. (1966). The data box: Its ordering of total resources in terms of possible relational systems. In R. B. Cattell (Ed.), *Handbook of multivariate experimental psychology* (pp. 67–128). Chicago, IL: Rand-McNally.
- Chen, E. E., & Wojcik, S. P. (2016). A practical guide to big data research in psychology. *Psychological Methods*, 21, 458–474. <http://dx.doi.org/10.1037/met0000111>
- Chen, H., Chiang, R. H., & Storey, V. C. (2012). Business intelligence and analytics: From big data to big impact. *Management Information Systems Quarterly*, 37, 50–56.
- Chen, H., Chung, W., Xu, J. J., Wang, G., Qin, Y., & Chau, M. (2004). Crime data mining: A general framework and some examples. *Computer*, 37, 50–56. <http://dx.doi.org/10.1109/MC.2004.1297301>
- Cohen, J. (1962). The statistical power of abnormal-social psychological research: A review. *The Journal of Abnormal and Social Psychology*, 65, 145–153. <http://dx.doi.org/10.1037/h0045186>
- Coombs, C. H. (1964). *A theory of data*. New York, NY: Wiley.
- Cronbach, L. J., & Meehl, P. E. (1955). Construct validity in psychological tests. *Psychological Bulletin*, 52, 281–302. <http://dx.doi.org/10.1037/h0040957>
- Csikszentmihalyi, M., & Larson, R. (2014). Validity and reliability of the experience-sampling method. In *Flow and the foundations of positive psychology* (pp. 35–54). Rotterdam, the Netherlands: Springer. http://dx.doi.org/10.1007/978-94-017-9088-8_3
- Cushing, E. (2013). Amazon Mechanical Turk: The digital sweatshop. UTNE. Retrieved from <http://www.utne.com/science-and-technology/amazon-mechanical-turk-zm0z13jfzlin.aspx>
- Dasu, T., & Johnson, T. (2003). *Exploratory data mining and data cleaning*. Hoboken, NJ: Wiley. <http://dx.doi.org/10.1002/0471448354>
- Dehghani, M., Johnson, K. M., Garten, J., Boghrati, R., Hoover, J., Balasubramanian, V., . . . Parmar, N. J. (2016). TACIT: An open-source text analysis, crawling, and interpretation tool. *Behavior Research Methods*, 49, 538–547.
- Dehghani, M., Johnson, K., Hoover, J., Sagi, E., Garten, J., Parmar, N. J., . . . Graham, J. (2016). Purity homophily in social networks. *Journal of Experimental Psychology: General*, 145, 366–375. <http://dx.doi.org/10.1037/xge0000139>
- de Leeuw, J. R. (2015). jsPsych: A JavaScript library for creating behavioral experiments in a Web browser. *Behavior Research Methods*, 47, 1–12. <http://dx.doi.org/10.3758/s13428-014-0458-y>
- Ding, H., Trajcevski, G., Scheuermann, P., Wang, X., & Keogh, E. (2008). Querying and mining of time series data: Experimental comparison of representations and distance measures. *Proceedings of the VLDB Endowment International Conference on Very Large Data Bases*, 1, 1542–1552. <http://dx.doi.org/10.14778/1454159.1454226>
- Domingos, P. (2012). A few useful things to know about machine learning. *Communications of the ACM*, 55, 78–87. <http://dx.doi.org/10.1145/2347736.2347755>

- Dorans, N. J., Pommerich, M., & Holland, P. W. (Eds.). (2007). Linking and aligning scores and scales. New York, NY: Springer Science & Business Media. <http://dx.doi.org/10.1007/978-0-387-49771-6>
- Garaizar, P., & Reips, U. D. (2014). Build your own social network laboratory with Social Lab: A tool for research in social media. *Behavior Research Methods*, 46, 430–438. <http://dx.doi.org/10.3758/s13428-013-0385-3>
- Gentry, J., Gentry, M. J., RSQLite, S., & Artistic, R. L. (2016). Package ‘twitterR’. Retrieved from <https://cran.r-project.org/web/packages/twitterR/twitterR.pdf>
- Goel, V. (2014). As data overflows online, researchers grapple with ethics. *The New York Times*. Retrieved from <http://www.nytimes.com/2014/08/13/technology/the-boon-of-online-data-puts-social-science-in-aquandary.html>
- Goldsmith, J., Bobb, J., Crainiceanu, C. M., Caffo, B., & Reich, D. (2011). Penalized functional regression. *Journal of Computational and Graphical Statistics*, 20, 830–851. <http://dx.doi.org/10.1198/jcgs.2010.10007>
- Grassegger, H., & Krogerus, M. (2017). The data that turned the world upside down. *Motherboard*. Retrieved from https://motherboard.vice.com/en_us/article/how-our-likes-helped-trump-win
- Hastie, T., Tibshirani, R., Friedman, J., & Franklin, J. (2005). The elements of statistical learning: Data mining, inference and prediction. *The Mathematical Intelligencer*, 27, 83–85. <http://dx.doi.org/10.1007/BF02985802>
- Henrich, J., Heine, S. J., & Norenzayan, A. (2010). The weirdest people in the world? *Behavioral and Brain Sciences*, 33, 61–83. <http://dx.doi.org/10.1017/S0140525X0999152X>
- Hibbeln, M., Jenkins, J. L., Schneider, C., Valacich, J. S., & Weinmann, M. (2017). How is your user feeling? Inferring emotion through humancomputer interaction devices. *Management Information Systems Quarterly*, 41, 1–21.
- Hu, Y., Shmygelska, A., Tran, D., Eriksson, N., Tung, J. Y., & Hinds, D. A. (2016). GWAS of 89,283 individuals identifies genetic variants associated with self-reporting of being a morning person. *Nature Communications*, 7, 10448. <http://dx.doi.org/10.1038/ncomms10448>
- Iliev, R., Hoover, J., Deghani, M., & Axelrod, R. (2016). Linguistic positivity in historical texts reflects dynamic environmental and psychological factors. *Proceedings of the National Academy of Sciences of the United States of America*, 113, E7871–E7879. <http://dx.doi.org/10.1073/pnas.1612058113>
- Iliev, R., & Smirnova, A. (2016). Revealing word order: Using serial position in binomials to predict properties of the speaker. *Journal of Psycholinguistic Research*, 45, 205–235. <http://dx.doi.org/10.1007/s10936-014-9341-3>
- Jaffe, E. (2014). What big data means for psychological science. *Observer*, 27. Retrieved from <https://www.psychologicalscience.org/observer/what-big-data-means-for-psychological-science>
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). An introduction to statistical learning (Vol. 6). New York, NY: Springer.

- John, L. K., Loewenstein, G., & Prelec, D. (2012). Measuring the prevalence of questionable research practices with incentives for truth telling. *Psychological Science*, 23, 524–532.
- Jones, N. M., Wojcik, S. P., Sweeting, J., & Silver, R. C. (2016). Tweeting negative emotion: An investigation of Twitter data in the aftermath of violence on college campuses. *Psychological Methods*, 21, 526–541. <http://dx.doi.org/10.1037/met0000099>
- Kelley, K., & Preacher, K. J. (2012). On effect size. *Psychological Methods*, 17, 137–152. <http://dx.doi.org/10.1037/a0028086>
- Kirk, R. (1996). Practical significance: A concept whose time has come. *Educational and Psychological Measurement*, 56, 746–759. <http://dx.doi.org/10.1177/0013164496056005002>
- Koh, Y. (2014). Report: 44% of Twitter accounts have never sent a tweet. *Wall Street Journal*, 11.
- Kosinski, M., Matz, S. C., Gosling, S. D., Popov, V., & Stillwell, D. (2015). Facebook as a research tool for the social sciences: Opportunities, challenges, ethical considerations, and practical guidelines. *American Psychologist*, 70, 543–556. <http://dx.doi.org/10.1037/a0039210>
- Kosinski, M., Stillwell, D., & Graepel, T. (2013). Private traits and attributes are predictable from digital records of human behavior. *Proceedings of the National Academy of Sciences of the United States of America*, 110, 5802–5805. <http://dx.doi.org/10.1073/pnas.1218772110>
- Kramer, A. D., Guillory, J. E., & Hancock, J. T. (2014). Experimental evidence of massive-scale emotional contagion through social networks. *Proceedings of the National Academy of Sciences of the United States of America*, 111, 8788–8790. <http://dx.doi.org/10.1073/pnas.1320040111>
- Landers, R. N., Brusso, R. C., Cavanaugh, K. J., & Collmus, A. B. (2016). A primer on theory-driven web scraping: Automatic extraction of big data from the Internet for use in psychological research. *Psychological Methods*, 21, 475–492. <http://dx.doi.org/10.1037/met0000081>
- Leetaru, K. (2016). Are research ethics obsolete in the era of big data? *Forbes*. Retrieved from <https://www.forbes.com/sites/kalevleetaru/2016/06/17/are-research-ethics-obsolete-in-the-era-of-big-data/#2353d8897aa3>
- Lohr, S. (2014). For big-data scientists, “janitor work” is key hurdle to insights. *The New York Times*. Retrieved from <https://www.nytimes.com/2014/08/18/technology/for-big-data-scientists-hurdle-to-insights-isjanitor-work.html>
- Marder, J. (2015). The Internet’s hidden science factory. *PBS News Hour*. Retrieved from <http://www.pbs.org/newshour/updates/inside-amazonshidden-science-factory/>
- Mark, G., Iqbal, S. T., Czerwinski, M., Johns, P., & Sano, A. (2016, May). Neurotics can’t focus: An in situ study of online multitasking in the workplace. In *Proceedings of the 2016 CHI conference on human factors in computing systems* (pp. 1739–1744). New York, NY: ACM.

- Maxwell, S. E., Lau, M. Y., & Howard, G. S. (2015). Is psychology suffering from a replication crisis? What does “failure to replicate” really mean? *American Psychologist*, 70, 487–498. <http://dx.doi.org/10.1037/a0039400>
- McFowland, E., III, Speakman, S., & Neill, D. (2013). Fast generalized subset scan for anomalous pattern detection. *Journal of Machine Learning Research*, 14, 1533–1561.
- Messick, S. (1995). Validity of psychological assessment: Validation of inferences from persons’ responses and performances as scientific inquiry into score meaning. *American Psychologist*, 50, 741–749. <http://dx.doi.org/10.1037/0003-066X.50.9.741>
- Metzler, K., Kim, D. A., Allum, N., & Denman, A. (2016). Who is doing computational social science? Trends in big data research (Whitepaper). London, England: SAGE Publishing. <http://dx.doi.org/10.4135/wp160926>
- Millsap, R. E. (2011). *Statistical approaches to measurement invariance*. New York, NY: Routledge.
- Muchnik, L., Aral, S., & Taylor, S. J. (2013). Social influence bias: A randomized experiment. *Science*, 341, 647–651. <http://dx.doi.org/10.1126/science.1240466>
- Nesselrode, J. R. (2006). Quantitative modeling in adult development and aging: Reflections and projections. In C. S. Bergeman & S. M. Boker (Eds.), *Methodological issues in aging research: Notre Dame series on quantitative methods* (pp. 1–18). New York, NY: Erlbaum Associations.
- Nielsen, F. (2016). Interview with Professor Calyampudi Radhakrishna Rao. *Amstatnews*. Retrieved from http://magazine.amstat.org/blog/2016/12/01/raointerview/?utm_sourceandec16&utm_mediumemail&utm_campaignamstatnews
- Nussbaum, B. (2017). President’s Corner: Reflecting on Quality vs. Quantity. *Amstat News*. Boston, MA: American Statistical Association. Retrieved from <http://magazine.amstat.org/blog/2017/06/01/reflecting-onquality-vs-quantity/>
- Oswald, F. L., & Putka, D. J. (2015). Statistical methods for big data: A scenic tour. In *Big data at work. Data science revolution and organizational psychology* (pp. 1907–2800). New York, NY: Routledge.
- Paolacci, G., & Chandler, J. (2014). Inside the Turk: Understanding Mechanical Turk as a participant pool. *Current Directions in Psychological Science*, 23, 184–188. <http://dx.doi.org/10.1177/0963721414531598>
- Pedhazur, E. J. (1997). *Multiple regression in behavioral research* (3rd ed.). New York, NY: Harcourt Brace.
- Peer, E., Samat, S., Brandimarte, L., & Acquisti, A. (2015). Beyond the Turk. Retrieved from <http://ssrn.com/abstract2594183> or <http://dx.doi.org/10.2139/ssrn.2594183>
- Purta, R., Mattingly, S., Song, L., Lizardo, O., Hachen, D., Poellabauer, C., & Striegel, A. (2016, September). Experiences measuring sleep and physical activity patterns across a large college cohort with Fitbits. In *Proceedings of the 2016 ACM international symposium on wearable computers* (pp. 28–35). New York, NY: ACM.
- Ramo, D. E., & Prochaska, J. J. (2012). Broad reach and targeted recruitment using Facebook for an online survey of young adult substance use. *Journal of Medical Internet Research*, 14, e28. <http://dx.doi.org/10.2196/jmir.1878>

- Rhemtulla, M., & Little, T. (2012). Planned missing data designs for research in cognitive development. *Journal of Cognition and Development*, 13, 425–438. <http://dx.doi.org/10.1080/15248372.2012.717340>
- Rivera, I. (2015). Package: 'RedditExtractoR.' Retrieved from <https://cran.r-project.org/web/packages/RedditExtractoR/RedditExtractoR.pdf>
- Rudgard, O. (2016). Admiral to use Facebook profile to determine insurance premium. *The Telegraph*. Retrieved from <http://www.telegraph.co.uk/insurance/car/insurer-trawls-your-facebook-profile-to-see-howwell-you-drive/>
- Sakaluk, J. K. (2016). Exploring small, confirming big: An alternative system to the new statistics for advancing cumulative and replicable psychological research. *Journal of Experimental Social Psychology*, 66, 47–54. <http://dx.doi.org/10.1016/j.jesp.2015.09.013>
- Serlin, R. C., & Lapsley, D. K. (1993). Rational appraisal of psychological research and the good-enough principle. *A handbook for data analysis in the behavioral sciences: Methodological issues* (pp. 199–228). Mahwah, NJ: Scientific Research.
- Shannon, G., Andrew, P., & Duggan, M. (2016). *Social media update 2016*. Washington, DC: Pew Research Center.
- Silvia, P. J., Kwapil, T. R., Walsh, M. A., & Myin-Germeys, I. (2014). Planned missing-data designs in experience-sampling research: Monte Carlo simulations of efficient designs for assessing within-person constructs. *Behavior Research Methods*, 46, 41–54. <http://dx.doi.org/10.3758/s13428-013-0353-y>
- Simmons, J. P., Nelson, L. D., & Simonsohn, U. (2011). False-positive psychology: Undisclosed flexibility in data collection and analysis allows presenting anything as significant. *Psychological Science*, 22, 1359–1366. <http://dx.doi.org/10.1177/0956797611417632>
- Simonsohn, U. (2013). Just post it: The lesson from two cases of fabricated data detected by statistics alone. *Psychological Science*, 24, 1875–1888. <http://dx.doi.org/10.1177/0956797613480366>
- Somanchi, S., Adhikari, S., Lin, A., Eneva, E., & Ghani, R. (2015, August). Early prediction of cardiac arrest (code blue) using electronic medical records. In *Proceedings of the 21th ACM SIGKDD international conference on knowledge discovery and data mining* (pp. 2119–2126). New York, NY: ACM.
- Stanton, J. M. (2013). *Data mining: A practical introduction for organizational researchers. In modern research methods for the study of behavior in organizations* (pp. 199–230). London, United Kingdom: Taylor and Francis. <http://dx.doi.org/10.4324/9780203585146>
- Stigler, S. M. (1999). *Statistics on the table: The history of statistical concepts and methods*. Cambridge, MA: Harvard University Press.
- Troendle, J. F., & Mills, J. L. (2011). Correction for multiplicity in genetic association studies of triads: The permutational TDT. *Annals of Human Genetics*, 75, 284–291.
- Varol, O., Ferrara, E., Davis, C. A., Menczer, F., & Flammini, A. (2017). Online human-bot interactions: Detection, estimation, and characterization. Retrieved from <https://arxiv.org/abs/1703.03107>

- Wang, C., & Blei, D. M. (2011, August). Collaborative topic modeling for recommending scientific articles. In Proceedings of the 17th ACM SIGKDD international conference on Knowledge discovery and data mining (pp. 448–456). New York, NY: ACM.
- Wang, R., Chen, F., Chen, Z., Li, T., Harari, G., Tignor, S., . . . Campbell, A. T. (2014). StudentLife: Assessing mental health, academic performance and behavioral trends of college students using smartphones. In Proceedings of the 2014 ACM international joint conference on pervasive and ubiquitous computing (pp. 3–14). New York, NY: ACM.
- Wang, R., Harari, G., Hao, P., Zhou, X., & Campbell, A. T. (2015, September). SmartGPA: How smartphones can assess and predict academic performance of college students. In Proceedings of the 2015 ACM international joint conference on pervasive and ubiquitous computing (pp. 295–306). New York, NY: ACM.
- Wickhan, H. (2014). Tidy data. *Journal of Statistical Software*, 59, 1–23. Wienberg, C., & Gordon, A. S. (2015, June). Insights on privacy and ethics from the web’s most prolific storytellers. In Proceedings of the ACM web science conference (p. 22). New York, NY: ACM.
- Xi, X., Keogh, E., Shelton, C., Wei, L., & Ratanamahatana, C. A. (2006). Fast time series classification using numerosity reduction. In Proceedings of the 23rd international conference on Machine learning (pp. 1033–1040). New York, NY: ACM.
- Youyou, W., Kosinski, M., & Stillwell, D. (2015). Computer-based personality judgments are more accurate than those made by humans. *Proceedings of the National Academy of Sciences of the United States of America*, 112, 1036–1040. <http://dx.doi.org/10.1073/pnas.1418680112>

4. Kutatásmódszertan és adatelemzés

A társadalomtudományokban, ahol az adatok sokszor bonyolult, összetett emberi jelenségeket tükröznek korábban egy-egy elemzés hónapokig tartó kódolást, statisztikai előkészítést vagy kvalitatív értelmezést igényelt, ma már azonban olyan eszközök állnak a kutatók rendelkezésére, amelyek nemcsak felgyorsítják, hanem alapjaiban megváltoztatják az empirikus kutatás logikáját. A prediktív modellek, a gépi tanulás, a természetes nyelv feldolgozása (NLP) vagy az automatizált meta-analízis nem csupán technikai megoldások: ezek újfajta tudományos gondolkodást, új kérdésvetéseket és másfajta értelmezési horizontokat is jelentenek (Vaccaro et al., 2024; Short et al., 2018).

A mesterséges intelligencia bevonása a kutatási folyamat különböző szakaszaiban történhet. A legtöbb esetben a gépi tanulás pusztán csak az adatok rendezésében, strukturálásában, például szövegek automatikus kódolásánál vagy változók közötti összefüggések keresésénél segít. Komplexebb szinten azonban már olyan rendszerekről van szó, amelyek képesek, kutatási kérdéseket, hipotéziseket és különböző predikciókat felállítani, mintázatokat azonosítani vagy előre jelezni a vizsgált pszichológiai jelenségek alakulását (Ahn & Picard, 2023). Ezek a mesterséges intelligencia alapú feldolgozási eszközök különösen hasznosak lehetnek nagy vizsgálati minták, bonyolult összefüggések vagy interakciós hatások esetén, amelyeket a hagyományos statisztikai modellek, többváltozós elemzések nagyon nehezen tudnak megragadni.

A kutatásmódszertanban megjelenő innovatív mesterséges intelligencia alapú megoldások azonban nemcsak a kvantitatív területet érintik, hanem a kvalitatív irány feldolgozását is alapvetően meghatározzák. A természetes nyelv feldolgozása és a szövegbányászat lehetővé teszi, hogy interjúk, naplófeljegyzések vagy éppen közösségi média posztok alapján átfogó képet kapjunk a vizsgált populáció belső világáról – akár pszichológiai jellemzőkről, érzelmekről, attitűdökről. Ezek az automatizált szövegelemző rendszerek, mint például NVivo vagy GPT-alapú szövegelemzők, nemcsak a kvalitatív kutatásokat teszik gyorsabbá, de segíthetnek abban is, hogy a kutatók személyes torzításai jóval kisebb szerepet játsszanak az értelmezésben, mint eddig (Short et al., 2018).

További, egyre fontosabb terület a tudományos validálás új módjainak megjelenése. Az MI-alapú meta-analízisek és replikációs eljárások révén könnyebben azonosíthatók a publikációs torzítások, az alacsony megbízhatóságú eredmények vagy éppen a kontextusfüggő hatások. A mesterséges intelligencia nemcsak a számításokat gyorsítja fel, hanem segíthet az eredmények szintetizálásában is, különösen akkor, ha különböző nyelvű, eltérő módszertanú kutatások összevetéséről van szó (Vaccaro et al., 2024).

Az alábbiakban négy olyan meghatározó területet mutatunk be, ahol a mesterséges intelligencia különösen fontos szerepet tölt be a pszichológiai kutatómódszertan fejlődésében. Ezek a prediktív modellezés és gépi tanulás a pszichológiai kutatásokban, a szövegbányászat és természetes nyelvfeldolgozás kvalitatív adatok elemzésére, az automatizált statisztikai elemzés és vizualizáció, és végül a replikáció és meta-analízis MI-támogatással. Ezeken a területeken keresztül elsősorban azt igyekszünk bemutatni, hogy a mesterséges intelligencia nem csupán egy eszköz, hanem új kutatási megközelítések és módszertani paradigmák motorja.

Prediktív modellezés és gépi tanulás pszichológiai kutatásban

A pszichológia nagyon hosszú ideig elsősorban leíró tudomány volt, melynek segítségével azt próbáltuk megérteni, hogy miért viselkednek úgy az emberek, ahogy. Az elmúlt évtizedekben azonban egyre erőteljesebben megjelent egy másik irányzat is, mégpedig az ami felveti annak kérdését, hogyan tudnánk megbízhatóan előrejelezni a viselkedést, miként lehet megjósolni például egy páciens terápiára adott választát, egy tanuló tanulmányi sikerességét, vagy épp egy alkalmazott kiegészi kockázatát? Ebben a paradigmaváltásban úgy tűnik, hogy a mesterséges intelligencia, különösen a gépi tanulás, kulcsszereplővé vált.

A prediktív modellezés alapvető célja az, hogy a meglévő adatokból előrejelezzünk egy jövőbeli kimeneti állapotot, legyen szó akár viselkedésről, döntésről, érzelmekről vagy éppen egy összetett pszichológiai állapotról. A gépi tanulás (machine learning) ebben az értelemben nem csupán egy újfajta számítástechnikai módszer, hanem olyan tanulórendszer, amely képes felismerni rejtett mintázatokat, a nem-lineáris összefüggéseket és olyan kapcsolódásokat is, amelyeket hagyományos statisztikai eszközökkel gyakran meglehetősen nehéz kimutatni (Bzdok et al., 2021). A pszichológiai kutatásokban ez óriási előnyt jelent, hiszen az emberi viselkedés ritkán írható le egyszerű, lineáris egyenletekkel.

Egy 2023-as tanulmányban Koul et al. depressziós tünetek előrejelzésére használtak gépi tanulást: különböző önkitaltós kérdőívekből és viselkedési adatmintákból (pl. az alvás ritmusa, aktivitás szintje) tanítottak meg egy pszichológiai modellt, amely 85%-os pontossággal tudta előre jelezni, hogy a következő hónapban romlik-e a személy pszichés állapota (Koul et al., 2023). Fontos, hogy a fentiekben nemcsak az előrejelzés volt megbízható, hanem az is kiderült, hogy a modell képes volt prediktív mintákra (pl. szociális visszahúzóds vagy alvászavarok) is érzékenyen reagálni, előrejelezni, ami mindenbizonnyal új utakat nyithat a megelőzés és a személyre szabott intervenció terén.

Más kutatók, mint például Eichstaedt és munkatársai (2021), közösségi média posztokból próbáltak következtetni személyiségjegyekre és mentális állapotra. Egy érdekes kutatásban, mélytanulási (deep learning) modellt alkalmazva, Twitter-bejegyzések alapján sikerült előre jelezni a posztoló személyek depressziójának mértékét és kockázatát. A kutatás egyik különlegessége az volt, hogy nem kulcsszavakra építettek a kutatást végző szakemberek, hanem a nyelvhasználat finom stílusjegyeire, mint például fokozott énfókusz, negatív érzelemkifejezések, múltidő preferencia, és ezek alapján állították fel az előrejelzést. Ez a megközelítés nemcsak a pszichológiai predikció új dimenzióját nyitja meg, hanem fontos etikai kérdéseket is felvetnek.

Különösen érdekes és értékes megközelítésnek ígérkezik az agyi képalkotó adatokkal végzett predikció. Finn et al. (2015) egy fMRI-adatokon alapuló gépi tanulási modellt építettek, amely képes volt megkülönböztetni a résztvevőket egymástól pusztán az agyi aktivitásmintáik alapján. Ez a „neurális ujjlenyomat” elméletében lehetővé teszi a személyre szabott neuropszichológiai beavatkozások tervezését, és segíthet azonosítani azokat a mintázatokat, amelyek pszichiátriai zavarok korai előjelei lehetnek.

A fenti példák jól mutatják, hogy a gépi tanulás a pszichológiai kutatásban nem csupán egy új módszertani lehetőség, hanem egy olyan eszköz, amely képes újrafogalmazni a „miért?” kérdést „mi lesz, ha...?” típusú kérdésekké. Láthatjuk, hogy a predikció tehát nem a megértés helyett áll, hanem annak kiegészítőjeként jelenik meg. A jövőbeli viselkedés előrejelzése mindenbizonnyal új hipotéziseket szülhet, és lehetővé teszi, hogy jobban megcélazzuk az intervenciós pontokat, legyen szó prevencióról, diagnózisról vagy fejlesztésről.

Szövegbányászat (data mining) és természetes nyelvfeldolgozás a pszichológiai kutatásban

A pszichológiai kutatásokban gyakran olyan adatok keletkeznek, amelyek nem számokban, hanem szavakban öltenek testet. Ilyenek lehetnek például a vizsgálati személlyel vagy egy pácienssel végzett interjúk, a nyílt végű kérdések, a terápiás jegyzetek vagy naplófeljegyzések, amelyek nagymennyiségű szövegek és mind értékes információt rejtenek az emberi gondolkodásról és viselkedésről. Mindezekig ezen anyagok feldolgozása rendkívül időigényes, meglehetősen szubjektív és gyakran nehezen reprodukálható volt. Az utóbbi években azonban a szövegbányászat (text mining) és a természetes nyelvfeldolgozás (NLP) eszköztára olyan hatalmas fejlődésen ment keresztül, ami nagyban forradalmasította a területet.

A szövegbányászat célja, hogy strukturálatlan szövegekből nyerjen ki releváns mintázatokat, kulcsszavakat, érzelmi tónusokat vagy épp tematikus szerkezeteket. Az

NLP ehhez biztosítja az algoritmikus hátteret: lemmatizálás, szófaji elemzés, entitásfelismerés, vagy épp érzelemelemzés segítségével képesek vagyunk tömeges szövegtörzseket automatikusan elemezni. Ezek az eljárások egyre fejlettebbek: míg korábban főként szótár alapú rendszereket (pl. LIWC) alkalmaztak, ma már BERT, RoBERTa vagy GPT-alapú modellek segítik a kontextusfüggő jelentésértelmezést is (Rasche et al., 2021).

A pszichológiai alkalmazások köre meglepően széles. Egy 2023-as kutatásban például Hoang és munkatársai tanulmányozták, hogyan lehet tanulói esszéket automatikusan kielemezni érzelmi terheltség vagy motivációs jelek alapján. A BERT-modell által végzett kódolás és klaszterezés során kirajzolódott, hogy az alacsony motivációjú hallgatók más típusú nyelvi szerkezeteket, több negatív érzelmet és kevesebb jövőre utaló kifejezést használnak (Hoang et al., 2023). Ez a módszer lehetőséget kínál arra, hogy az oktatók korai visszajelzést kapjanak a tanulók mentális állapotáról.

De nemcsak az oktatás, hanem a klinikai pszichológia is profitál ezekből az eszközökből. Guntuku és munkatársai (2022) például közösségi média posztok elemzésével próbálták előre jelezni a depresszió és a szorongás kockázatát. A modell nemcsak az érzelemkifejezések gyakoriságát, hanem azok nyelvtani mintázatait is figyelembe vette. Az eredmények azt mutatták, hogy a magas szorongású egyének több első személyű névmást, múlt időt és negatív érzelmi szavakat használnak – ami összhangban van a klasszikus klinikai jellemzőkkel.

A kvalitatív kutatásokban gyakran használt interjúk és naplók automatizált elemzése szintén új utakat nyit a feldolgozásban és az adatokértelmezésben. A GPT-alapú elemzőrendszerek képesek nemcsak tartalmi kategóriákat azonosítani, hanem akár narratív szerkezeteket, jelentésrétegeket vagy implicit attitűdöket is felismerni. Ez különösen hasznos lehet például a traumafeldolgozás, az életút-interjúk vagy a közérzeti- és önreflektív naplók vizsgálatakor, ahol az apró nyelvi kifejezések kiemelten fontosak.

Természetesen nem lehet szó nélkül elmenni az etikai kérdések mellett sem, mivel az NLP-alapú elemzés képes érzékeny, személyes információkat feltárni olyan szövegekből is, amelyek nem erre a célra születtek. Ez különösen fontos akkor, ha például közösségi média adatokkal dolgozunk. A kutatóknak ezért kiemelten kell ügyelniük a transzparenciára, adatvédelemre és a résztvevők tájékozott beleegyezésére (Chancellor et al., 2019).

Összességében elmondható, hogy a szövegbányászat és a természetes nyelvfeldolgozás olyan lehetőségeket kínál a pszichológiai kutatásokban, amelyek korábban elképzelhetetlenek lettek volna, annak ellenére, hogy ezek az eszközök nem helyettesítik a kutatói érzékenységet vagy a kvalitatív elemzés mélységét, de újfajta

mintázatokra, kérdésekre és összefüggésekre hívják fel a figyelmet olyan dolgokra, amelyek talán eddig rejtve maradtak a szemünk előtt.

Automatizált statisztikai elemzés és vizualizáció

A pszichológiai kutatás hagyományosan számottevő statisztikai felkészültséget igényel. Az adattisztítás, modellépítés, hibaszámítás és a vizualizáció mind-mind olyan lépések, amelyek időigényesek és hibalehetőségekkel terheltek. Az utóbbi években azonban az automatizált statisztikai elemzés, különösen a mesterséges intelligenciával támogatott rendszerek, érezhetően átalakították a kutatási gyakorlatokat.

Az automatizált elemzőeszközök egyik legnagyobb előnye, hogy képesek az adatok előfeldolgozásától kezdve a statisztikai modell lefuttatásán át az értelmezhető eredmények vizualizálásáig a teljes analitikai folyamatot felölelni. Ilyen rendszerek például a JASP, az AutoStat, vagy a Google által fejlesztett AutoML Tables, amelyek már nem igényelnek programozói tudást, mégis komplex modelleket képesek futtatni, legyen szó lineáris regresszióról, faktoranalízisről vagy akár gépi tanulási algoritmusokról (Van Doorn et al., 2021).

Különösen izgalmas terület az automatizált vizualizáció. Míg korábban a kutatóknak külön időt kellett szánniuk a diagramok, scatterplotok vagy hő térképek megtervezésére, ma már léteznek olyan intelligens rendszerek – például a DataWrapper vagy a Tableau AI Assistant –, amelyek a változók típusától és eloszlásától függően automatikusan javaslatot tesznek a legértelmezhetőbb grafikonokra. Ez különösen hasznos lehet pszichológus hallgatók számára, akik még nem jártasak az adatábrázolásban, de fontos, hogy gyorsan vizuálisan is értelmezni tudják az eredményeket.

Egy 2022-es tanulmányban, amelyet Liu és munkatársai publikáltak, egy automatizált rendszer pszichológiai kérdőíves adatokon futtatott klaszteranalízist, majd önállóan vizualizálta az eredményeket egy többdimenziós térben. Az így azonosított klaszterek jól megfeleltek a kutatók által korábban kézzel definiált szegmenseknek, és az AI által létrehozott grafikus ábrázolások jobban támogatták az adatok kommunikálhatóságát is (Liu et al., 2022).

Természetesen a teljes automatizáció nem mentes a veszélyektől. Az egyik kihívás az „értelmezés nélküli” számolás, vagyis amikor a kutató vakon elfogadja a rendszer által generált modelleket anélkül, hogy értené azok elméleti megalapozottságát vagy korlátait. Ez különösen veszélyes lehet pszichológiai kontextusban, ahol a statisztikai modell mögött gyakran komplex emberi viselkedések és pszichés folyamatok húzódnak meg. Ezért fontos, hogy az automatizált statisztikai elemzés eszközeit a kutatók inkább támogatásként, semmint helyettesítésként kezeljék.

Összességében azonban ezek az új eszközök lehetővé teszik, hogy a pszichológiai kutatók – még azok is, akik nem statisztikai szakértők – gyorsabban, hatékonyabban és

gyakran pontosabban juthassanak el az eredményekhez. Az automatizált statisztika nemcsak a kutatás gyorsítását szolgálja, hanem hozzájárulhat ahhoz is, hogy az elemzés színvonala kiegyenlítettebbé váljon különböző intézmények és kutatói szintek között.

Replikáció és metaelemzés AI-támogatással

A tudományos kutatás egyik alapvető elve, hogy az eredményeknek újra előállíthatónak kell lenniük. Ez a replikáció elve, amely különösen fontos szerepet játszik a pszichológiában – nemcsak a múltbéli eredmények megerősítése, hanem a tudományterület megbízhatóságának megőrzése szempontjából is. Az utóbbi években azonban több kutatás is rámutatott arra, hogy a pszichológiai tanulmányok jelentős része nem replikálható az eredeti formájában. Ezt a „replikációs válságként” emlegetett problémát a mesterséges intelligencia ma új eszközökkel segíti orvosolni.

A replikáció nem csupán azt jelenti, hogy megismétlünk egy kutatást. Sokkal inkább egy rendszerszintű értékelést jelent, amelyhez elengedhetetlen a korábbi eredmények átfogó elemzése és összehasonlítása. Ezen a pontos jelenik meg a metaelemzés, az a módszer, amely statisztikai módszerekkel, szorgos kutatók munkájával integrálja a megjelent tanulmányok eredményeit. A mesterséges intelligencia ebben a folyamatban több ponton is segíthet, például úgy, hogy automatizálja a releváns cikkek kiválogatásának a folyamatát, lehetővé teszi az adatok kinyerést, az elemzések futtatását, sőt a torzítások feltérképezésében is szerepet játszhat.

Példaként említhetünk egy friss tanulmányt, amelyben Wang és munkatársai (2023) egy LLM-alapú (large language model) rendszert fejlesztettek, ami képes volt automatikusan kiszűrni és kategorizálni a pszichológiai metaanalízisekhez szükséges tanulmányokat. A rendszer a kulcsszavak mellett figyelembe vette a módszertani leírásokat, a mintavételi jellemzőket és az alapvető statisztikai mutatókat is. Ennek eredményeként jelentősen csökkent az elemzéseket és a feldolgozást végző szakemberek munkaterhelése, miközben nem csökkent a kiválasztott cikkek adekvátsága és relevanciája. A kutatás azt is kimutatta, hogy az LLM-eken alapuló keresés pontosabbnak bizonyult, mint a korábbiakban alkalmazott klasszikus szűrési technikák (Wang et al., 2023).

Másik izgalmas tudományos fejlesztés a replicability.ai platform, amely nemcsak az eredmények újraelemzését, hanem azok prediktív újrafuttatását is lehetővé teszi. A rendszer gépi tanulás segítségével képes megbecsülni, hogy egy adott tanulmány milyen eséllyel replikálható sikeresen. Az algoritmus képes a statisztikai erő (power), a mintaelemszám, a módszertani robusztusság és a publikálási torzítások alapján kalkulálni az előrejelzést (Yang et al., 2022). Ez különösen értékes módszer lehet például

olyan esetben, ha kutatási pályázatokról kell eldönteni azt, hogy érdemes-e megismételni egy korábbi vizsgálatot.

A mesterséges intelligencia támogatásával végzett meta-analízisek tehát nem csupán gyorsabbak, hanem pontosabbak is lehetnek, ugyanakkor nem szabad elfelejtenünk, hogy ezek az eszközök sem csodafegyverek. Fontos, hogy a kutatók ne csak az automatizmusokra bizzák az értelmezést, hiszen a tanulmányok közötti különbségek, a kulturális kontextus, vagy az alkalmazott mérőeszközök finom eltérései mind olyan tényezők, amelyeket csak egy tapasztalt kutató tud megfelelően értékelni.

Összegzésként elmondható, hogy az MI-vel támogatott meta-analízis és replikációs vizsgálatok új szintre emelik a pszichológiai kutatás megbízhatóságát. Nem váltják le a kutatót, de új partnert kínálnak számára – egy olyan intelligens rendszert, amely képes strukturáltan és hatékonyan átlátni a növekvő tudományos ismeretanyagot.

Szakirodalom

- Ahn, J., & Picard, R. W. (2023). AI methods in psychological science: From data to insight. *Current Directions in Psychological Science*, 32(2), 101–108. <https://doi.org/10.1177/09637214221142693>
- Bzdok, D., Krzywinski, M., & Altman, N. (2021). Points of Significance: Machine learning: a primer. *Nature Methods*, 18(3), 275–276. <https://doi.org/10.1038/s41592-021-01020-3>
- Chancellor, S., Kalantidis, Y., Pater, J. A., De Choudhury, M., & Shamma, D. A. (2019). Multimodal classification of moderated online pro-eating disorder content. *Proceedings of the ACM on Human-Computer Interaction*, 3(CSCW), 1–21. <https://doi.org/10.1145/3359183>
- Eichstaedt, J. C., Smith, R. J., Merchant, R. M., Ungar, L. H., Crutchley, P., Preoțiu-Pietro, D., ... & Schwartz, H. A. (2021). Facebook language predicts depression in medical records. *PNAS*, 115(44), 11203–11208. <https://doi.org/10.1073/pnas.1802331115>
- Finn, E. S., Shen, X., Scheinost, D., Rosenberg, M. D., Huang, J., Chun, M. M., ... & Constable, R. T. (2015). Functional connectome fingerprinting: identifying individuals using patterns of brain connectivity. *Nature Neuroscience*, 18(11), 1664–1671. <https://doi.org/10.1038/nn.4135>
- Guntuku, S. C., Yaden, D. B., Kern, M. L., Ungar, L. H., & Eichstaedt, J. C. (2022). Detecting depression and mental illness on social media: An integrative review. *Current Opinion in Behavioral Sciences*, 38, 43–49. <https://doi.org/10.1016/j.cobeha.2021.11.005>

- Hoang, L. T., Nguyen, T. D., & Phan, D. H. (2023). Deep learning for automatic essay emotion analysis in educational settings. *International Journal of Artificial Intelligence in Education*, 33(2), 259–276. <https://doi.org/10.1007/s40593-022-00284-1>
- Koul, A., D’Mello, A. M., & Kumar, D. (2023). Predicting depressive symptomatology from behavior and digital biomarkers: A machine learning approach. *Journal of Affective Disorders*, 336, 234–243. <https://doi.org/10.1016/j.jad.2023.01.081>
- Liu, M., Zhou, Y., & Chen, W. (2022). Automated clustering and visualization in psychological survey analysis using AI-based dimensionality reduction. *Journal of Computational Psychology*, 29(3), 214–229. <https://doi.org/10.1016/j.jcps.2022.03.007>
- Rasche, S., Schlögl, S., & Leimeister, J. M. (2021). Text mining in psychology: A systematic review. *Frontiers in Psychology*, 12, 672595. <https://doi.org/10.3389/fpsyg.2021.672595>
- Short, J. C., McKenny, A. F., & Reid, S. W. (2018). More than words? Computer-aided text analysis in organizational behavior and psychology research. *Annual Review of Organizational Psychology and Organizational Behavior*, 5, 415–435. <https://doi.org/10.1146/annurev-orgpsych-032117-104622>
- Vaccaro, M., Almaatouq, A., & Malone, T. (2024). When combinations of humans and AI are useful: A systematic review and meta-analysis. *Nature Human Behaviour*, 8(12), 2293–2303. <https://doi.org/10.1038/s41562-024-02024-1>
- Van Doorn, J., Ly, A., Marsman, M., & Wagenmakers, E. J. (2021). The JASP guidelines for conducting and reporting a Bayesian analysis. *Psychonomic Bulletin & Review*, 28, 813–826. <https://doi.org/10.3758/s13423-020-01798-5>
- Wang, Z., Liu, H., & Roberts, B. (2023). Automating meta-analytic review: A language-model-assisted framework for identifying and extracting psychological studies. *Behavior Research Methods*, 55(2), 465–480. <https://doi.org/10.3758/s13428-023-02118-z>
- Yang, J., Evans, N. J., & Wager, T. D. (2022). Predicting replicability of psychological studies using machine learning. *Nature Human Behaviour*, 6(1), 28–37. <https://doi.org/10.1038/s41562-021-01101-3>

A TERMÉSZETES NYELV AUTOMATIZÁLT ELEMZÉSE A PSZICHOLÓGIAI KUTATÁSOKBAN*

A pszichológiai kutatások gyakran támaszkodnak a természetes nyelv kvalitatív és kvantitatív értékelésére annak érdekében, hogy jobban azonosítsák és megértsék az összetett kognitív feladatok mögött meghúzódó mechanizmusokat (Dowell et al., 2019; Graesser & McNamara, 2011; Johns & Jamieson, 2018; Magliano & Graesser, 2012; Pennebaker et al., 2007; Yan et al., 2020). Az esszék, a nyílt végű kérdések, a hangos gondolkodási jegyzőkönyvek és az interjúk gyakran a legmegbízhatóbb módszerek az egyének gondolatainak részletes megismerésére. Gyakran gyűjtik őket a pszichológiai területeken, beleértve az alkalmazott kutatási területeket is, mint például az oktatás, a diskurzusfolyamatok, a kognitív tudomány, a szociál- és személyiségpszichológia, a törvényszéki orvostudomány, és a klinikai pszichológia. A gazdagság ellenére, hogy ezekből a válaszokból rengeteg információ nyerhető, az elemzések gyakran időigényes jegyzetelésre és pontozásra támaszkodnak az emberi szakértő értékelők részéről, ami akadályozhatja az előrehaladást és visszatarthatja a kutatókat attól, hogy összegyűjtsék ezeket a forrásokat.

Ezekre a módszertani kihívásokra válaszul a kutatók és oktatók az informatika és a tanulásanalitika kiegészítő területeihez fordultak, amelyek jelentős előrelépést értek el a természetes adatok elemzésének automatizálásában.

A nyelv természetes nyelvi feldolgozás (NLP; Clark et al., 2013; Hirschberg & Manning, 2015; Jurafsky & Martin, 2008), valamint a big data megközelítések szélesebb körű kihasználása (Griffiths, 2015; Jones, 2017). Ez az interdiszciplináris munka mérföldkőnek számító előrelépésekhez vezetett a nyelvtanulás (Kyle, 2021; Kyle & Crossley, 2018), az oktatás (Dowell et al., 2020; Litman, 2016; McNamara et al., 2017), a diskurzusfolyamatok (McNamara et al., 2014) és a diskurzus kohéziójának automatizált elemzése (Dascalu et al., 2018; Graesser & McNamara, 2011) terén. A kutatóknak ma már széleskörű lehetőségük van az automatizált szövegelemzések megvalósítására, kihasználva a népszerű programozási nyelvek fejlesztőcsomagjainak előnyeit (pl. spaCy Python és R nyelven; NLTK Pythonban; tidytext R-ben), valamint olyan szabadon elérhető NLP-szoftvereszközök, amelyek szükségtelenné teszik a kiteljesedett programozási ismereteket (pl. Crossley, Kyle, et al., 2019; Kyle et al., 2018; McNamara et al., 2014).

Ez a fejezet áttekintést nyújt az NLP jelenlegi megközelítéseiről, és arról, hogyan alkalmazták azokat a pszichológiai területen végzett kutatásokban. Először áttekintést nyújtunk arról, hogy az NLP-technológiákat hogyan használják a természetes nyelvi válaszok pontozásának segítésére. Másodszor, leírjuk, hogy ugyanezek a technikák

* Allen, L. K., Graesser, A. C., & McNamara, D. S. (2023). Automated analyses of natural language in psychological research. In: Cooper, H. E., Coutanche, M. N., McMullen, L. M., Panter, A. T., Rindskopf, D. E., & Sher, K. J. (2023). APA handbook of research methods in psychology: Foundations, planning, measures, and psychometrics, Vol. 1. Fordította: Arató Judit.

felhasználhatók arra, hogy az írásbeli válaszokból pszicho-logikai tulajdonságokra következtessünk, például az egyéni különbségekre és a tanulási folyamatokra.

Harmadszor, azt tárgyaljuk, hogy a természetes nyelvi válaszok elemzését hogyan építették be az intelligens oktatórendszerekbe (ITS), amelyek adaptív oktatást nyújtanak a tanuló felhasználóknak. Végül a közelmúltban kifejlesztett eszközök és megközelítések rövid ismertetésével zárjuk, amelyek a nyelvi elemzés multimodális megközelítéseit vizsgálják, az időzítéssel, az érzelmi állapotokkal és a csoportdinamikával kapcsolatos információk bevonásával.

Természetes nyelvi feldolgozás mint a válaszok pontozásának módszere

Az NLP leggyakoribb kutatási alkalmazása az írott nyelv automatizált pontozásában történt. A pszichológiai területeken számos feladat a résztvevőkre támaszkodik, hogy írásos nyelvi válaszokat hozzanak létre, a rövid válaszoktól kezdve a hosszabb esszéig. Az NLP-technikák felhasználhatók az ilyen írásbeli válaszok pontozására a nyelv több dimenziójában számított jellemzők segítségével. Az NLP-technikák például elemezhetik a szavak, mondatok és teljes szövegek jellemzőit, beleértve a konstruktumok széles skálájához kapcsolódó jellemzőket, beleértve a nyelv ismertségét, összetettségét, kohézióját és szemantikáját. Ezek a számítási megközelítések számos előnnyel rendelkeznek az emberi kódolással szemben, amely költséges és időigényes lehet.

Összehasonlítva az emberek által végzett diskurzuselemzéssel szemben a számítógépes megközelítések azonnali visszajelzést tudnak adni, nem fáradnak el, megbízhatóak, és több dimenzióra vonatkozóan nagyobb részletességgel képesek (Hirschberg & Manning, 2015; McNamara et al., 2014). A következő szakaszokban példákat mutatunk be arra, hogyan használták az NLP-t két különböző kontextusban: rövid válaszok olvasás közbeni felkérésekre és hosszabb írásformák (pl. érvelő esszék).

Rövid természetes nyelvi válaszok automatizált elemzései

A rövid természetes nyelvi válaszokat gyakran gyűjtik a pszichológiai kutatások során. Ezek a válaszok lehetnek nyílt végű kérdésekre adott válaszok, párbeszédekben vagy többoldalú beszélgetésekben való közreműködések, illetve komplex feladatok, például olvasás vagy problémamegoldás során adott hangos gondolkodásra adott válaszok. Számítógépes megközelítéseket alkalmaztak e válaszok elemzésére számos dimenzió mentén, mint például pontosság, relevancia, stílus, szóbeliség és koherencia. A pontozási feladat jellegétől függően e szóbeli jegyzőkönyvek értékelése lehet egyszerűbb (pl. a tanulók válaszainak pontosságának értékelése egy rövid válaszokat tartalmazó tesztben) vagy összetettebb (pl. a tanulók stratégiáinak használata egy hangos gondolkodási feladatban).

A szövegekre adott konstruált válaszokat általában azért gyűjtötték, hogy megvizsgálják az olyan összetett feladatok alapjául szolgáló kognitív folyamatokat, mint

például az olvasás vagy a szövegek olvasása, vagy problémamegoldás (Coté & Goldman, 1999; Denton et al., 2015; Magliano & Graesser, 2012; Magliano et al., 2011). Jelentős bizonyíték van arra, hogy az ilyen konstruált válaszok érzékenyek az új információk megértésében és megtanulásában szerepet játszó folyamatokra (Magliano et al., 1999; Ozuru et al., 2004). Például a nyílt végű hangos gondolkodási jegyzőkönyvek feltételezhetően megragadnak a tanuló gondolatait és tapasztalatait az anyag megértése és a problémamegoldás során (K. A. Ericsson & Simon, 1984), míg a konstruált válaszok célzottabb formái (pl. önmagyarázat, kérdésmegoldás) olyan utasításokat tartalmaznak, amelyek célja a megértés és a tanulás módosítása (Magliano & Graesser, 2012; McNamara, 2004).

Bár ezek a válaszok jelentős értékkel bírnak a megértés és a tanulás tanulmányozásában, felhasználásukat jelentősen korlátozza a protokollelemzés munkaigényes jellege (Magliano & Graesser, 2012). Így az elmúlt 2 évtizedben jelentős előrelépés történt az alkalmazásban NLP-technikák alkalmazását a konstruált válaszok elemzésének támogatására (Allen et al., 2015; Landauer et al., 2007). Ezek az előrelépések az olvasásértés során a magyarázatok és a hangos gondolkodási jegyzőkönyvek számítógépes értékelésével (Gilliam et al., 2007; Magliano et al., 2011), a rövid válaszokat tartalmazó kérdések osztályozásával (Leacock & Chodorow, 2003) és az ITS-ekkel összefüggésben történtek, amelyek a diákoktól konstruált válaszok előállítását követelik meg (Graesser, 2016; Graesser et al., 2020; McCarthy et al., 2020).

Ezek az automatizált rendszerek különböző NLP-eszközöket és algoritmusokat építenek be a válaszok értékeléséhez, és következtetéseket vonnak le a tanulói megértésre, tanulásra és problémamegoldásra vonatkozóan. Magliano és munkatársai például kidolgozták az olvasási stratégiát értékelő eszközt (RSAT; Magliano et al., 2011), amely arra kéri a tanulókat, hogy nyílt végű válaszokat adjanak olyan felkérésekre, amelyek célja, hogy hangosan gondolkodó választ vagy választ adjanak olyan kérdésekre, amelyek célja a szövegértési szintek megismerése (pl. a nemrég olvasott mondathoz kapcsolódó miért és hogyan kérdések).

Az RSAT egyszerű számítógépes algoritmusokat használ a válaszok elemzésére a szövegértési folyamatok, például a parafrázálás, a következtetések áthidalása és a részletes következtetések kimutatására. Az RSAT-ra vonatkozó értékelések (Magliano et al., 2011; Millis & Magliano, 2012) arról számolnak be, hogy az RSAT megfelelő munkát végez az objektív szövegértési pontszámok előrejelzésében és a szövegértési stratégiák megkülönböztetésében.

A Magliano et al. (2011) által végzett vizsgálatban a főiskolai hallgatók egy sor szöveget olvastak el, és közvetlen és közvetett kérdésekre válaszoltak, miközben interakcióba léptek az RSAT-tal. Ezután többféle szövegértési mérést végeztek, beleértve a Gates-MacGinitie olvasási tesztet és a kísérletező által generált, nyílt végű szövegértési értékeléseket. A kutatók először az RSAT szövegértés általános mérése és a résztvevőknek a két szövegértési mérésen nyújtott teljesítménye közötti összefüggéseket vizsgálták. Az RSAT pontszámai korreláltak mind a Gates-MacGinitie olvasási teszten ($r = 0,52$), mind a nyílt végű szövegértési értékeléseken ($r = 0,45$) elért

teljesítménnyel, ami arra utal, hogy az RSAT sikeresen észlelte a résztvevők válaszai alapján a szövegértési folyamatokat.

A korrelációk ezen RSAT-stratégia pontszámok (pl. parafrazálás, áthidalás, kifejtés) és a szakértő emberi értékelők által az ilyen stratégiák azonosítása között 0,46 és 0,70 között változott, ami azt jelzi, hogy az RSAT sikeresen észlelte a szövegértési stratégiákat a konstruált válaszok alapján. A tanulók RSAT-stratégiai pontszámai a nyílt végű szövegértési teszten nyújtott teljesítmény varianciájának körülbelül 21%-át tették ki.

Konkréten, a magasabb a szövegértés pozitívan kapcsolódott a hidak és a kifejtések létrehozásához, de negatívan a parafrazáláshoz. Összességében ez a munka azt sugallja, hogy az NLP felhasználható az olvasás során alkalmazott stratégiák azonosítására, és hogy ezek a stratégiák előre jelzik az egyének szövegből való tanulási képességét.

Esszéi válaszok automatizált elemzése A rövid, konstruált válaszok pontozásán túlmenően az NLP-technikákat alkalmazták esszék automatizált pontozására is. Az automatizált esszéértékelés (AES) mára elérte azt a szintet, hogy számos esszéosztály pontozása olyan pontos, mint a szakértő emberi értékelőké (Attali & Burstein, 2006; McNamara et al., 2015; Shermis et al., 2010; Yan et al., 2020). Az AES-rendszereket általában olyan esszék korpuszán képzik ki, amelyeket szakértő emberi értékelők egy rubrika alapján értékelték. A korpuszt két esszéhalmozra osztják: egy gyakorlóhalmozra (amelyet az esszék képzéséhez használnak modell) és egy tesztkészlet (amely azt vizsgálja, hogy a modell milyen mértékben általánosítható az új esszékre). A gépi tanulási algoritmusokat alkalmazzuk a képzési halmazban lévő esszék optimális illesztésére.

A kifejlesztett modellt ezután a tesztkészlet esszéire alkalmazzuk, és ezeket a pontszámokat összehasonlítjuk az emberi értékelők pontszámaival. Az AES-modell akkor tekinthető sikeresnek, ha a számítógép és az emberek pontszámai hasonlóan egyeznek az emberek közötti pontszámokhoz.

Shermis et al. (2010) áttekintette a három legsikeresebb AES-rendszer teljesítményét (Attali & Burstein, 2006; Burstein, 2003), a Pearson Knowledge Technologies által kifejlesztett Intelligent Essay Assessor (Landauer et al., 2003) és a Vantage Learning által kifejlesztett IntelliMetric (Elliot, 2003; Rudner et al., 2006). Ezek a rendszerek a 80-as évek közepéig terjedő pontos egyezéstről, a 90-es évek közepéig terjedő szomszédos egyezésekről és a 80-as évek közepéig terjedő korrelációkról számoltak be. Ugyanilyen lenyűgöző, hogy ezek a teljesítménymutatók valamivel magasabbak, mint a képzett emberi értékelők közötti egyetértés.

Az AES-rendszerek teljesítménye kellően lenyűgöző ahhoz, hogy a következő rendszerekben való felhasználásukhoz méretezzék őket. Ezeket a rendszereket olyan magas szintű tesztek pontozási folyamatában használták, mint például a mint a GMAT (Graduate Management Admission Test) analitikus írásbeli felmérése. A GMAT két 30 perces írásbeli feladatot tartalmaz a kritikai gondolkodással és az ötletek közlésével kapcsolatos képességek felmérésére. Az egyik feladat egy téma elemzését tartalmazza: A vizsgázók kapnak egy kérdést vagy véleményt, és azt az utasítást kapják, hogy magyarázzák meg álláspontjukat a vonatkozó indokok vagy bizonyítékok idézésével.

A második feladat egy érvelés elemzése: A vizsgázók elolvasnak egy rövid érvelést, elemzik a mögötte álló érvelést, és bírálják az érvelést. Az AES-eket elektronikus portfóliórendszerekben is használják, hogy segítsék a tanulókat az íráskészségük javításában azáltal, hogy visszajelzést adnak az esszéik több jellemzőjére vonatkozóan, hasonlóan a Criterion (Attali & Burstein, 2006) és a MY Access (Elliot, 2003) rendszerhez.

Bár az AES-ek gyakorlati haszna tagadhatatlan, a kritikusok olyan kérdéseket vetnek fel, amelyek megkérdőjelezzik e rendszerek mindenütt jelenlévő használatát némi emberi szakértelem nélkül. Néhány kritikus aggályokat fogalmaz meg az írás olyan aspektusai miatt, amelyeket az AES rendszerek nem valószínű, hogy megragadják, a számítógépek és nem a tanárok írástanításának etikai kérdései, valamint az emberek és a számítógépek által az esszéik osztályozásához használt kritériumok közötti különbségek (Calfee, 2000; P. F. Ericsson & Haswell, 2006). Van egy tartós harmadik változó is, amely robusztusan előrejelzi az esszé pontszámokat, nevezetesen az esszé szavainak száma. A számítási algoritmusok által a szavak számán túlmutató növekményről gyakran nem számolnak be, vagy azokban az értékelésekben, amelyek a szavak számát ellenőrizték, nem látványos. E kihívás leküzdésének egyik akadály, hogy az emberi értékelők gyakran a szavak számát veszik alapul értékelésük bizonyos szempontjai alapján, és a több szó több tartalmat jelent, ami jobb esszét eredményez.

E fejezet keretein túlmutat az AES-ekben alkalmazott számítási algoritmusok pontos leírása, különösen azért, mert némelyik szabadalmaztatott, vagy a közzétett jelentések nem tükrözik a jelenlegi rendszereket. Shermis és Burstein (2003) szerkesztett kötete számos korai rendszer részletes leírását tartalmazza, olyan mértékben, amennyire a vállalatok szívesen megosztották. Az e-rater AES (Attali & Burstein, 2006) az emberi pontozási szempontokhoz igazodó hat elemzési területen pontozta az esszét: nyelvtani hibák, szóhasználati hibák, mechanikai hibák, stílus, szervezési szegmensek beillesztése (pl. tézis vagy néhány bizonyíték beillesztése) és szókincsbeli tartalom. Az IntelliMetric AES (Elliot, 2003; Rudner et al., 2006) a szavakat egy több mint 500 000 egyedi szót tartalmazó szókincshez illesztette, több mint 500, a szövegben előforduló nyelvi és nyelvtani jellemzőt azonosított, és ezt a tartalmat egy szófogalom-háló segítségével elemezte, amely a szavak közötti hasonlóságokat vizsgálja, hogy meghatározza szemantikai jelentésüket. Ezeket a szövegjellemzőket ezután a gyakorló korpusz minden egyes pontozási rubrikaszintjén szereplő esszékhöz társítottuk, hogy felfedezzük, mely esszéjellemzők a legerősebben diagnosztizálják az egyes szinteket.

Az intelligens esszéértékelő AES (Landauer et al., 2003) az esszé szavait látens szemantikai elemzés (LSA; Landauer, 2003) segítségével elemezte. Az LSA fontos módszer a szavak, mondatok, bekezdések vagy esszék közötti fogalmi hasonlóság kiszámítására, mivel figyelembe veszi az implicit tudást. Az LSA egy matematikai, statisztikai technika a szavakkal és a világgal kapcsolatos tudás reprezentálására egy nagy szövegtörzs alapján, amely megpróbálja megragadni egy tipikus vizsgázó tudását.

Az LSA központi intuíciója az, hogy egy szó, W jelentése tükröződik a szót körülvevő többi szó társaságában a naturalisztikus dokumentumokban (képzeljünk el 40 000 szöveget vagy 11 millió szót). Két szó annyiban hasonló jelentésű, amennyiben hasonló szavakkal vannak körülvéve. Például az "üveg" szóhoz nagymértékben társulnak az azonos funkcionális környezetbe tartozó szavak, mint például a pohár, folyadék, öntsük ki, törjük össze és átlátszó. Ezek nem szinonimák vagy antonimák, amelyek egy szótárban előfordulnának, hanem inkább olyan szavak, amelyek valószínűleg ugyanabban a dokumentumban fordulnak elő, mint az üveg szó. Az LSA statisztikai technikát használ az úgynevezett szinguláris érték dekompozíciót (SVD), amellyel egy nagyon nagy szövegtárost 100-500 statisztikai dimenzióra sűrítjük (Landauer et al., 2007).

Az utóbbi időben számítási módszereket fejlesztettek ki a szavak kontextusának jobb megragadására, azzal a feltételezéssel, hogy a szavak a környező szavak által meghatározott kontextusba ágyazódnak. Az LSA-hoz hasonlóan a Word2Vec is vektorokként reprezentálja a szavakat, de kétrétegű neurális hálózatokat használ (SVD helyett) a modellek képzéséhez (Mikolov et al., 2013). A Bidirectional Encoder Representations from Transformers (BERT) kibővíti a szavak kontextuális beágyazásainak ablakát azáltal, hogy mélytanulással több kontextuális reprezentációt generál minden szóhoz (Devlin et al., 2018). Az ilyen szemantikai modellek általában a szövegrészek (pl. szó, tétel, mondat, esszé) közötti fogalmi hasonlóságot a szövegrészek értékei és súlyozott dimenziói közötti geometriai koszinusként (azaz 0-1) számítják ki.

Az esszére adott holisztikus osztályzatnak van némi értéke az író számára, mint az írás minőségének általános mutatója. Az írás különböző jellemzőire vonatkozó konkrét visszajelzés azonban hasznosabb információt nyújt a hallgató és az oktató számára. Van-e probléma a helyesírással, a szókinccsel, a szintaktikával, a mondanivaló kohéziója, hiányzó tartalom, stíluselemek és így tovább? Az e-rater AES 12 jellemzőre vonatkozóan adott ilyen visszajelzést a Criterion, a hallgatók írásainak elektronikus portfóliója támogatására.

Az írásmintákat tartalmazó portfólió idővel összegyűjthető, hogy a diákok vagy az oktatók nyomon követhessék a fejlődést. Hasonlóképpen, az Intelligens esszéértékelő LSA moduljait egy Summary Street (Franzke et al., 2005) nevű rendszerben is felhasználták, amely visszajelzést ad a diákoknak a szöveg összefoglalóinak minőségéről. A Summary Street azonosítja azokat a mondatokat, amelyek alacsony LSA-relevancia pontszámot kaptak a szöveg más mondataival, és alacsony pontszámot kaptak a szöveg mögöttes tartalmi rubrikájának különböző tartalmi kategóriáiban elvárt információkkal. Az ideális összefoglaló lefedné az elvárt tartalmat, és olyan mondatokat tartalmazna, amelyek fogalmilag kapcsolódnak egymáshoz (lásd Botarleanu et al., 2021, és Crossley, Kim, et al., 2019, a legújabb összefoglaló algoritmusokról).

Burstein és munkatársai (2003) a Criterion rendszerhez egy automatizált pontozási technológiát fejlesztettek ki a következő helyen Educational Testing Service (ETS), amely meghatározza, hogy egy esszé milyen mértékben tartalmazza az esszé egyes összetevőit. Az esszé célzott kategóriái közé tartozik a cím, a bevezető anyag, a tézis

megfogalmazása, a tézishez kapcsolódó fő gondolatok, a támogató gondolatok, a következtetések és a lényegtelen részek. Képzett emberi bírálók körülbelül 0,80-as kappa egyezőségi pontszámmal (három különböző esszéfeladatnál 0,86 és 0,95 között) képesek azonosítani ezeket a részeket. A kappa pontszámok korrigálják a találgatásokat, korrigálják a döntések eloszlását, és 0 (véletlen) és 1,0 (tökéletes egyezés) között változnak. A Kappa pontszámok előnyben vannak a korrelációkkal szemben, de a gyakorlatban a teljesítménymérők azonos következtetésekhez vezetnek ebben a kutatási irányban. A számítógépes algoritmusok és az emberi értékelők közötti kappa pontszámok tekintélyesek, jellemzően .70 feletti.

A kappa és a korrelációkon kívül a kutatók rutinszerűen gyűjtik a visszahívási, pontossági és F-mérési pontszámokat az adott megfigyelésekre vonatkozó számítógépes döntés és az emberi bíráló döntése között (vagy alternatívaként egy bíráló és egy másik bíráló között). A számítógépes rendszer visszahívási pontszáma a számítógépes döntések azon aránya, amelyek ugyanazt a döntést kapják, mint egy ember egy adott nyelvi/beszédmódbeli jellemző előfordulása egy megfigyelésben. A pontossági pontszám a számítógép azon döntéseinek aránya, amelyek megegyeznek az emberével. Az F-mérték $2 p \text{ recall } p \text{ precision} / (\text{recall} + \text{precision})$, lényegében a recall és precision pontszámok átlaga. Burstein és munkatársai (2003) arról számoltak be, hogy a számítógép és az ember közötti pontszámok megközelítőleg azonosak voltak e három mérőszám esetében, és átlagosan 0,76-ot tettek ki, a különböző paraméterektől és kritériumoktól függően. Az emberi bíráló párok közötti egyezés átlagosan .91 volt. Bár nem tökéletesek, ezek az automatizált rendszerek egyértelműen jelentős előrelépést tesznek az esszék összetevőinek azonosításában. Ezeket a kategóriákat fontos azonosítani, hogy informatív útmutatást adhassunk a tanulóknak az íráskészségük javításához.

Az AES-rendszerek részletesebb visszajelzései felé való elmozdulás egybeesett az automatikus írásbeli értékelő rendszerek (AWE) fejlesztésével, amelyek célja, hogy túllépjenek az egyszerű írásbeli értékelésen.

A diákok esszéinek pontozása

Az AWE-rendszerek célja, hogy lehetőséget biztosítsanak a tanulók számára az írásgyakorlatok gyakorlására, valamint arra, hogy összefoglaló és formatív visszajelzést kapjanak az írásaikról (Allen & Perret, 2016). Ezeket a rendszereket sikeresen integrálták számos osztálytermi környezetbe, és gyakran használják őket a magas szintű írásértékelésekben (Dikli, 2006).

Bár az e területen végzett kutatások jelentős része még mindig az automatizált pontszámok pontosságának értékelésére összpontosít (Warschauer & Ware, 2006; Yan et al., 2020), az újabb kutatások az írás egyéb aspektusait is vizsgálják, például hogy a diákok képesek-e javítani esszéik minőségét, miután a rendszer visszajelzést adott (Roscoe et al., 2015), vagy hogy pontosabban tudják-e ellenőrizni saját teljesítményüket (Allen et al., 2015). A számítógépes íráskészség-ellenőrző rendszerek

elsődleges célja tehát nem csupán az kell, hogy legyen, hogy pontos pontszámokat adjanak a tanulók teljesítményéről, hanem az is, hogy olyan oktatást és visszajelzést nyújtsanak, amely segíthet a tanulóknak saját munkájuk pontosabb értékelésében.

Kihívások az automatizált írásértékelésben

Számos módszertani kihívásra kell odafigyelniük azoknak, akik az íráskészség időbeli nyomon követésére és javítására tervezett oktatórendszereket fejlesztenek. Az egyik probléma az, hogy kevés olyan szabványosított írásbeli teljesítményt mérő teszt létezik, amelynek normái lehetővé teszik az időbeli fejlődés mérését. A másik probléma az, hogy a rendelkezésre álló, normákra hivatkozó standardizált tesztek, mint például a Woodcock-Johnson vagy a Wechsler Individual Achievement Test, kevés íráskészséget és műfajt fednek le. A harmadik probléma az, hogy az írás folyamatát számos tényező befolyásolja: a pragmatikus írási kontextushoz kapcsolódó tényezők, a célközönség, az írási ösztönzők, az írásra szánt idő, az írás módja (kézírás vs. billentyűzet), az íráshoz választott témák és az író jellemzői (Graham & Perin, 2007).

Az írásbeli esszék pontozásának időigényes jellege hagyományosan korlátozta a tanárokat abban, hogy nagyszámú írásbeli feladatot adjanak. Ez a korlátozás természetesen megkerülhető az AES és az AWE rendszerek segítségével. A számítógépek használatán kívül más módszerek is léteznek. Például az, hogy a tanulók saját írói teljesítményüket és fejlődésüket értékelik, javítja az íráskészséget (Andrade & Boulay, 2003; Graham & Perin, 2007; Ross et al., 1999). A tanárok azt is elérhetik, hogy a diákok egymás írását értékeljék. Ha a tanulókat megtanítják arra, hogyan értékeljék és adjanak visszajelzést társaiknak, akkor mind a saját, mind a társaik írása javul (Cho et al., 2006; Graham & Perin, 2007).

Az NLP-értékelés áttekintése

Összességében ez a szakasz azt mutatja be, hogy az NLP-technikák milyen módon használhatók a természetes nyelv automatizált értékelésére az alábbi területeken különböző pszichológiai és oktatási kontextusokban. E megközelítések megvalósíthatóságának illusztrálására tekintsünk két diákot, akiknek az a feladatuk, hogy alakítsanak ki véleményt arról, hogy az iskolákban meg kellene-e követelni az egyenruha viselését. Ebben a hipotetikus feladatban a diákokat arra kérnék, hogy olvassanak el több olyan szöveget, amelyek információt nyújtanak a témáról, és rendszeresen felkérnék őket arra, hogy önmagyarázatot készítsenek az éppen olvasottakról. Ezután arra kérnék őket, hogy röviden foglalják össze a kérdéssel kapcsolatos véleményüket.

Ebben a példában két elsődleges forrásunk van a természetes nyelvnek, amelyet az NLP segítségével értékelhetünk: az önmagyarázatok és az összefoglalók. Ezután

bemutatunk néhány módszert, amellyel megközelíthetjük a következőket az önmagyarázatok NLP-alapú elemzését.

Tekintsük a következő részleteket a két diák által készített önmagyarázatokból:

Diák 1: Soha nem szeretném, ha bárki megmondaná, hogyan öltözzek az iskolában; ez a szabadságom megsértésének tűnik, és én szeretem, ha kreatívan kifejezhetem magam.

Diák 2: Szerintem ez az első rész arra próbál utalni, hogy az egyenruha egyik előnye, hogy csökkentheti az egyenlőtlenségek érzékelését. Kíváncsi vagyok, hogy a többi szövegrészlet is foglalkozik-e a következményekkel.

Ebben a két részletben láthatjuk, hogy a tanulók különböző típusú szövegfeldolgozásban vesznek részt; az 1. tanuló úgy tűnik, hogy saját személyes tapasztalataira támaszkodik, amikor a következőkről beszél. Míg a 2. tanuló az első szöveg célját parafrázálja, és metakognitív feldolgozásba kezd, amikor a többi szöveg tartalmát előre jelzi. E feldolgozási különbségek értékeléséhez több dimenzió mentén is jellemezhetjük ezeket az önmagyarázatokot. A 17.1. táblázat példát mutat néhány kiszámítható mérőszámra (ehhez az elemzéshez a tanulók által készített összes önmagyarázatot használtuk, nem csak a fent megadott részleteket) két kategóriában. A 17.1. táblázatból láthatjuk, hogy az NLP-elemzések lehetővé teszik számunkra, hogy az önmagyarázatokot több dimenzió mentén értékeljük.

A leíró mutatók azt mutatják, hogy az 1. tanuló összességében több szót alkotott az önmagyarázataiban, de a 2. tanuló átlagosan hosszabb szavakat írt. Ez némi alapvető információt nyújt számunkra a feladat során a szóbeliségükről, valamint a tanulók lexikai kifinomultságáról. Az RSAT-indexek Magliano et al. (2011) nyomán következnek, és árnyaltabb információt nyújtanak arról, hogy a tanulók milyen konkrét stratégiákat alkalmaztak az olvasás során. Itt láthatjuk, hogy az 1. tanuló a szöveg sekélyesebb feldolgozását végezte, mint a 2. tanuló, mivel túlnyomórészt parafrázálással foglalkoztak a hídképzéssel vagy elaborációval szemben. Fontos, hogy az itt bemutatott indexek csak egy kis részhalmazát képezik azoknak az indexeknek, amelyeket ezekhez az önmagyarázatokhoz ki lehetne számítani, de a céljuk az, hogy bemutassák az NLP erejét a tanulók természetes nyelvhasználatának többdimenziós szemszögből történő értékelésében, szemben a szokásos holisztikus pontszámokkal.

17.1. táblázat Példák a természetes nyelvi feldolgozás (NLP) indexeire az önmagyarázatok értékeléséhez

Típusa			
NLP változó	változó	Diák 1	Diák 2
Szavak száma	Leíró	453	236
Átlagos betű/szó	Leíró	3.90	5.23
Parafrázisok száma	Stratégia használata	6	3
A hidak száma	Stratégia használata	4	5
Kidolgozások száma	Stratégia használata	2	5

Pszichológiai jellemzők és folyamatok kikövetkeztetése természetes nyelvből

Eddig olyan kutatásokra összpontosítottunk, amelyek a számítógépes rendszerek pontosságát vizsgálják az egyének konstruált válaszainak pontozásában. Azonban egyre több olyan munka van, amely azt vizsgálja, hogy az NLP-technikák hogyan használhatók az egyes írók és viselkedésük aspektusainak modellezésére. Az ilyen megközelítések segítségével árnyaltabb információkat lehet nyújtani a következőkről a diskurzusfeldolgozást és -produkción befolyásoló kontextuális tényezők. A kutatások megkezdtek annak vizsgálatát, hogy az NLP-technikák felhasználhatók-e az egyéni különbségek modellezésére az egyének által előállított diskurzusok (pl. konstruált válaszok, esszék) nyelvi jellemzői alapján. A legújabb munkák például azt sugallják, hogy az egyének olvasás közbeni konstruált válaszainak (pl. önmagyarázatok, hangosan gondolkodó válaszok) kohéziója jelzi az egyének mentális reprezentációjának koherenciáját (Allen et al., 2016a). Allen és munkatársai (2016) például arról számoltak be, hogy a konstruált válaszok kohéziója magasabb volt, amikor az olvasókat önmagyarázatra kérték, mint parafrázisra, és hogy a diákok konstruált válaszainak kohéziója nőtt az önmagyarázati oktatás és gyakorlás során. Így a tanulók konstruált válaszaik kohéziójának automatizált elemzése ablakot nyújt az olvasók mentális reprezentációjának koherenciájára. Ezáltal pedig megjósolhatjuk, hogy az egyén jobb olvasó lesz, ha koherens és lexikailag kifinomult nyelvet produkál (Allen et al., 2016a).

Ezt a munkát kiterjesztették több dokumentum megértési kontextusára is. Allen és munkatársai (2021) arra kérték a résztvevőket, hogy több dokumentum olvasása közben konstruált válaszokat hozzanak létre, majd írjanak egy esszét a dokumentumok közötti integráció értékelésére. A konstruált válaszok kohéziója az egyes

dokumentumokon belül negatív kapcsolatban állt az esszé minőségével. Ezzel szemben a konstruált válaszok kohéziója a dokumentumok között pozitív kapcsolatban állt az esszé minőségével. Továbbá, a hangosan gondolkodáshoz képest a stratégiai utasítások az önmagyarázatra vagy a források értékelésére, a dokumentumok közötti fokozott integrációra. Mint ilyen, a tanulók konstruált válaszainak kohéziójára vonatkozó NLP-elemzések elméleti és gyakorlati betekintést nyújtottak a sikeres megértési és tanulási folyamatokba, és, különösen a szöveg koherensebb mentális reprezentációjához vezető stratégiai szövegértési folyamatokat.

Az egyéni különbségeken túlmenően az érzelmek és más pszicho-logikai állapotok vizsgálatára is végeztek munkát az írásbeli válaszokból. Az egyik eszköz, amely jelentős előrelépést hozott az e területen végzett munkában, a Pennebaker és munkatársai (2007) által kifejlesztett Linguistic Inquiry and Word Count (LIWC) eszköz. A LIWC-t a pszichológia és az oktatás jelenségeinek széles körének elemzésére használták, sokkal többre, mint bármely más, automatizált rendszerekkel végzett erőfeszítést. A LIWC egy adott szövegben a nyelvtani (pl. "cikkek", "névmások", "prepozíciók"), pszichológiai (pl. "érzelmek", "kognitív mechanizmusok", "szociális") vagy tartalmi kategóriáknak (pl. "otthon", "foglalkozás", "vallás") szentelt szavak százalékos arányát jelenti. Például a "sírás" és a "bánat" a szomorú kategóriába tartozó szavak, míg a "szerelem" és a "szép" a pozitív érzelem kategóriába sorolt szavak. A szavak és a szókategóriák közötti leképezés nem zárja ki egymást, mivel egy szó több kategóriába is tartozhat. A LIWC nagyjából 80 szókategóriát ad meg, de ezeket a szókategóriákat tágabb dimenziókba is csoportosítja, mint például pszichológiai konstrukciók (pl. okok, szomorúság) és személyes konstrukciók (pl. munka, vallás). A LIWC úgy működik, hogy elemzi a diskurzus átíratát, és megszámlolja az egyes kategóriákhoz tartozó szavak számát. Ezután minden egyes kategóriára vonatkozóan kiszámítjuk az arányszámot úgy, hogy a diskurzusban az adott kategóriába tartozó szavak számát elosztjuk a szavak teljes számával.

A LIWC-kategóriák érvényesnek bizonyultak és megbízható jelzői számos pszichológiailag jelentős konstrukciónak (Chung & Pennebaker, 2007; Pennebaker et al., 2003). A pszichológiai szavak relatív gyakorisága nyilvánvalóan leképezné a releváns pszichológiai konstrukciókat, és ezek a hivatkozások áttekintik az ilyen tendenciákat. Mindazonáltal, a Pennebaker és munkatársai által dokumentált, inkább ellenkező értelmű megállapítás a szavak nyelvi jellemzőinek szerepe. A LIWC olyan nyelvi jellemzőket ad meg, amelyek a funkciósavakat, a névmások különböző típusait, a közös és segédigéket, a különböző időhatározókat, a határozószókat, a kötőszavakat, a tagadószavakat, a kvantorokat, a számokat és a káromkodó szavakat foglalják magukban. Némileg meglepő módon a funkciósavakat, nem pedig a tartalmi szavakat számos pszichológiai állapotot diagnosztizálnak (Pennebaker, 2011). A funkciósavakat az emberek nehezen tudják tudatosan kontrollálni, ezért a szövegben való használatuk vizsgálata nem reaktív módon számos szociális és személyiségbeli folyamat feltárását teszi lehetővé.

A funkciósavak használatát egyéni különbségek széles körével hozták összefüggésbe. A funkciószóhasználat a nem, az életkor és a társadalmi osztály

függvényében változhat (Pennebaker, 2011). Például a névmásokat olyan pszichológiai állapotokhoz kapcsolták, mint például a depresszió és az öngyilkosság esszéiben, természetes beszélgetésekben és versekben (Rude et al., 2004; Stirman & Pennebaker, 2001). Ez a munka ösztönözte a nyelvi stílus kutatását (Pennebaker et al., 2003), amelyet a funkciószavak használata képvisel a különböző kontextusokban. A nyelvi stílust számos tényezővel, például a személyiséggel (Pennebaker, 2011) és érzelmi állapotokkal (Tausczik & Pennebaker, 2010) hozták összefüggésbe. Újabban a kutatók azt vizsgálják, hogy a nyelvi stílusok hogyan változnak dinamikusan a beszélgetések során. Müller-Frommeyer és munkatársai (2020) például arról számoltak be, hogy a monológokban a nyelvi stílusok jelentősen eltérnek a beszélgetésekhez képest, és hogy ez a változás nagyobb volt a konfliktusos beszélgetések esetében a baráti beszélgetésekhez képest. Az NLP-elemzések tehát potenciálisan képesek feltárni az interakciók jellegét a közös társalgási kontextusokban.

Érzelmeik kikövetkeztetése

A LIWC és más hasonló eszközök egyik fontos alkalmazási területe az érzelmi állapotok előrejelzése az egyének nyelvezete alapján. Számos különböző megközelítés létezik a szövegminták érzelmi tartalmának elemzésére. Az egyik egyszerű megközelítés az érzelemlifejezések alapjául szolgáló kisszámú dimenzió azonosítása (Samsonovich & Ascoli, 2006). E kutatás úttörője volt évtizedekkel ezelőtt Osgood és munkatársai, akik azt elemezték, hogy a különböző kultúrákban élő emberek hogyan értékelték a különböző érzelelmszavak hasonlóságát (Osgood et al., 1975). Elemzései az értékelés (azaz jó vagy rossz), a potencia (azaz erős vagy gyenge) és az aktivitás (azaz aktív vagy passzív) mint kritikus dimenziók tekintetében konvergáltak. Ezek a dimenziók összhangban vannak a valenciával és az arousalral, amelyeket az affektív élmény alapvető dimenzióinak tartanak (Barrett et al., 2007; Russell, 2003).

A második megközelítés a szöveg részletesebb lexikai elemzése annak érdekében, hogy azonosítani lehessen azokat a szavakat, amelyek az írók vagy a beszélők konkrét affektív állapotát jelzik előre (Cohn et al., 2004; Crossley et al., 2017; Pennebaker et al., 2003). Más kutatók olyan lexikai adatbázisokat fejlesztettek ki, amelyek affektív információkat szolgáltatnak a gyakori szavakhoz. A WordNet-Affect (Strapparava & Valitutti, 2004) például a WordNet kiterjesztése az affektív tartalomra. Mások a szavakon túl a szöveg szemantikai elemzésére is kiterjedtek.

Gill és munkatársai (2008) például blogokat elemezték, és arról számoltak be, hogy az emberek által félelmet és örömet kifejezőnek ítélt szövegek szemantikailag hasonlóak voltak az érzelmi fogalmi szavakhoz (pl. "fóbia" és "terror" a "félelem" esetében, de "öröm" és "boldogság" az "öröm" esetében). A szövegek és az érzelmi kulcsszavak (pl. "félelem", "öröm") közötti szemantikai hasonlóság automatikus kiszámításához LSA-t (Landauer et al., 2007) és a nyelvi modell hipertér-analógiáját (Burgess et al., 1998) használták. Bár a szövegek és az érzelmi fogalomszavak szemantikai összehangolásának ez a módszere a félelem és az öröm szövegek esetében

ígéretesnek bizonyult, más érzelmeket, például haragot és szomorúságot közvetítő szövegek esetében kudarcot vallott.

D'Mello és munkatársai (2008, 2010) a tanulói érzelmeket a nyelv és a diskurzus alapján jósolták meg az AutoTutor oktatói dialógusokban. Azt találták, hogy a visszajelzések, a beszédaktuskategóriák (pl. közvetett utalások), a kohézió, a tagadások és más nyelvi jellemzők sikeresen jósolták meg a tanulói affektusállapotokat, amelyek gyakoriak a korrepetálás során, mint például az unalom, a frusztráció, a zavarodottság és az elkötelezettség.

A szövegalapú affektusérzékelés negyedik és legkifinomultabb megközelítése olyan rendszereket foglal magában, amelyek a világ ismereteinek nagyszámú korpuszából affektív modelleket építenek fel, és ezeket a modelleket alkalmazzák a szövegek affektív hangnemének azonosítására (Crossley et al., 2017; Pang & Lee, 2008; Wiebe et al., 2005). Például a "baleset" szó tipikusan egy nemkívánatos eseményhez kapcsolódik, így a "baleset" jelenléte növeli a "feltartottak egy baleset miatt az autópályán" mondat negatív valenciáját. Ezt a megközelítést néha hangulatelemzésnek, vélemény-kivonatolásnak vagy szubjektivitáselemzésnek is nevezik, mivel a szövegminta valenciájára összpontosít, nem pedig a szöveg egy adott érzelmi kategóriába (pl. dühös, szomorú) való besorolására.

Az NLP mint a pszichológiai folyamatok modellezésének eszköze áttekintése

Összességében ez a szakasz kibővíti az értékelésről szóló szakaszt, hogy feltárja, hogyan lehet az NLP segítségével pszichológiai és érzelmi állapotokra következtetni a természetes nyelvből. Ezeket a megközelítéseket az előző szakaszban szereplő Student 1 és Student 2 újragondolásával szemléltethetjük. A fentiekben kifejezetten a tanulók által alkalmazott stratégiák minőségének és típusainak értékelésére összpontosítottunk. Az NLP-t azonban arra is használhatjuk, hogy következtetni tudjunk azokra a konkrét folyamattípusokra, amelyekben részt vesznek, valamint az olvasás közbeni érzelmi állapotukra.

Amint a 17.2. táblázatban látható, a két tanuló önmagyarázatának kohéziója meglehetősen eltérő volt. Ezek az indexek azt jelezték, hogy a 2. tanuló által generált önmagyarázatok koherensebbek voltak, mint az 1. tanuló által írtak, ami arra utal, hogy

17.2. táblázat Példa a természetes nyelvi feldolgozás (NLP) indexeire a pszichológiai folyamatok és állapotok önmagyarázatokból való következtetéséhez

NLP változó	változó	Diák 1	Diák 2
A kötőszavak száma	Kohézió	10.00	15.00
Szemantikai átfedés (LSA)	Kohézió	0.36	0.53
Pozitív szavak aránya	Érzelem	0.53	0.21
Negatív szavak aránya	Érzelem	0.42	0.33

Megjegyzés. LSA = látens szemantikai elemzés.

A 2. tanuló potenciálisan több integratív folyamatot folytatott az olvasás során, ami a szöveges információk jobb megértéséhez kapcsolódik. Másrészt úgy tűnt, hogy az 1. tanuló a szöveg érzelmi feldolgozásában jobban részt vett, ami azzal függhetett össze, hogy a saját élettapasztalataival kapcsolatban állt. Így, bár ez a tanuló kevésbé tudott összefüggéseket kialakítani a szövegek között, mégis érzelmesebb volt, ami arra utalhat, hogy motiváltabb vagy elkötelezettebb volt a feladat során. Összességében ez a példa azt jelzi, hogy az NLP technikák felhasználhatók a természetes nyelv standardizált értékelésén túlmutatóan is és olyan kontextust biztosítanak, amely fontos a tanulási folyamat teljesebb megértéséhez.

Az nlp technikák alkalmazása intelligens oktatórendszerekben

A fent leírt munka egyik gyakori alkalmazási területe a személyre szabás és a visszajelzés fokozása az oktatási technológiákban, például az ITS-ekben. Az ITS-ek személyre szabott tanulást biztosítanak a tanulók modellezésével, amely magában foglalja a felhasználók területi tudását, stratégiáit és egyéb pszichológiai állapotait nyomon követő számítógépes elemzéseket (Chrysafiadi & Virvou, 2013; Woolf, 2009). Az ITS-ek adaptívan reagálnak a felhasználókra azáltal, hogy olyan tevékenységeket és visszajelzéseket nyújtanak, amelyek érzékenyek ezekre az állapotokra, és amelyek előmozdítják az oktatási menetrendeket. Az ITS és a felhasználók közötti interakció nagyszámú, ha nem végtelen számú alternatív pályát követ, amelyek megpróbálnak alkalmazkodni mind a tanuló, mind az oktatási célok korlátaihoz. Ezért a tanulói válaszok értékelése minden ITS-ben alapvető fontosságú. Az ilyen értékelések egyszerűek, ha a válaszok az alternatívák rögzített halmazából való kiválasztás, mint például a feleletválasztós kérdések, igaz-hamis kérdések, értékelések vagy a váltogatott válaszok esetében.

Kihívások merülnek fel azonban, amikor a tanulót természetes nyelvi bevitelre kéri az ITS-en belül. Ilyenkor NLP-technikákra van szükség ahhoz, hogy a felhasználóknak pontszámokat és automatikus visszajelzést adjanak a válaszaikról.

Számos olyan ITS-t fejlesztettek ki, amelyek természetes nyelvet használó tanulóknak feldolgozzák és válaszolnak nekik. Ilyen például az ITSPOKE (Litman et al., 2006), a beszélt társalgási számítógép (Pon-Barry et al., 2004), a taktikai nyelvi és a culture training system (L. W. Johnson & Valente, 2008) és a Why-Atlas (VanLehn et al., 2007).

A következő szakaszban három nyelvi alapú ITS-t ismertetünk, hogy kiemeljük az e területen végzett munkát: (Graesser, 2016; Graesser, Lu et al., 2004), iSTART (McCarthy et al., 2020; McNamara et al., 2004) és a Writing Pal (Roscoe & McNamara, 2013).

AutoTutor

Az AutoTutor egy olyan ITS, amely a tanulóknak számítógépes írástudást, fizikát, oktat, kritikai gondolkodási készségeket és más technikai témákat természetes nyelven folytatott beszélgetések révén (Graesser, 2016; Graesser et al., 2020; Graesser, Lu et al., 2004; Nye et al., 2014). Az AutoTutor 0,3 szigma (szórásegység) és 0,8 szigma közötti tanulási nyereséget mutat (Graesser, Jeon, & Dufty, 2008) az előzetes tesztekhez vagy egy olyan feltételhez képest, amelyben a diákok ugyanennyi ideig tankönyvet olvasnak. Az oktatói párbeszédnek olyan nehéz kérdések és problémák köré szerveződnek, amelyek a válaszokban érvelést és magyarázatot igényelnek.

Az AutoTutor például megkérdezheti: "Ha egy könnyű személygépkocsi és egy masszív teherautó frontálisan ütközik, melyik járműre nagyobb az ütközés ereje? Melyik jármű mozgása változik meg nagyobb mértékben, és miért?" Az ilyen kérdésekhez a tanulóknak körülbelül három-hét mondatot kell felépítenie, és a válaszokban érvelést mutassanak be.

Amikor a diákok kérdést tesznek fel nekik, az első beszélgetés során jellemzően rövid, néhány szótól néhány mondatig terjedő válaszokat adnak. Egy beszélgetésre van szükség ahhoz, hogy jobb betekintést nyerjünk abba, hogy mit tud a tanuló, még akkor is, ha a tanuló megfelelő tárgyi tudással rendelkezik. Egy ilyen kihívást jelentő kérdéshez tartozó párbeszéd körülbelül 20-100 beszélgetési fordulóból áll az AutoTutor és a tanuló között. AutoTutor visszajelzést ad a tanuló beírása alapján (pozitív vagy semleges vs. negatív visszajelzés), további információért pumpálja a tanulót ("Mi van még?"), felszólítja a tanulót a hiányzó szavak kitöltésére, tippeket ad a tanulóknak, állításokkal pótolja a hiányzó információkat, kijavítja a hibás gondolatokat és téves elképzeléseket, válaszol a tanuló kérdéseire, és összefoglalja a válaszokat. Ezek a válaszok az AutoTutor fontos párbeszéd lépései, és a párbeszéd során végül a kérdésre adott teljes válasz felépítéséhez vezetnek.

Az AutoTutor teljesítményének pontozására többféle módszer létezik (Graesser et al., 2007, 2020; Jackson & Graesser, 2006; VanLehn et al., 2007). Az egyik módszer annak pontozása, hogy a tanulók szóbeli hozzászólásai mennyire felelnek meg a kérdésre adott jó válaszoknak (az úgynevezett elvárásoknak) a rossz válaszokkal (az úgynevezett téves elképzelésekkel) szemben.

A tanulók annál magasabb pontszámot kapnak, minél több elvárást és kevesebb téves elképzelést fejeznek ki az oktatói párbeszédben. Az elvárások és a téves

elképzelések lefedettségére vonatkozó pontszámokat az első tanulói forduló során vagy a párbeszéd befejezése után lehet kiszámítani. A tanulók ritkán artikulálják tökéletesen az elvárásokat, mert a természetes nyelv túlságosan pontatlan, töredékes, homályos, nem grammatikus és elliptikus. Ezért az AutoTutor számos szemantikai megfeleltetési algoritmust használt annak értékelésére, hogy a diákok szóbeli válaszai mennyire felelnek meg egy adott elvárásnak (Graesser et al., 2020).

Egy másik módszer a tanulói teljesítmény értékelésére az AutoTutorban az AutoTutor által kiválasztott azon párbeszédlépések számának és típusának elemzése, amelyeket a válasz fejlődése során a tanulóból való információszerezésre választottak ki.

A rendszer a dialógus során időszakosan azonosít egy hiányzó elvárást, és kiírja az elvárás lefedésének célját. Amikor egy elvárás kiírásra kerül, az AutoTutor megpróbálja rávenni a tanulót annak artikulálására olyan utalások és kérések generálásával, amelyek a tanulót a szavak és mondatok kitöltésére ösztönzik. Olyan konkrét felszólítások és tippek generálódnak, amelyek maximalizálják, hogy a tanuló kitöltse ezt a tartalmat, és a megfelelési pontszámot a küszöbérték fölé emeljék.

A tanuló AutoTutorban nyújtott teljesítménye mérhető az AutoTutor pumpák, tippek és felszólítások számának kiszámításával, amelyek szükségesek ahhoz, hogy a tanuló választ adjon egy kérdésre. Ezt négy olyan párbeszédmozgás-kategória elemzésével vizsgálták, amelyek megpróbálják lefedni az egyes elvárások tartalmát: pumpák, tippek, sűgők és állítások (Jackson & Graesser, 2006). Az e kategóriákba tartozó párbeszéd lépések arányának érzékenynek kell lennie a tanulók fizikával kapcsolatos ismereteire (amit egy fizika előteszttel mértünk a Force Concept Inventoryhoz hasonló feleletválasztós kérdésekkel; Hestenes et al., 1992). Van egy kontinuum a tanuló által szolgáltatott információtól a tutor által szolgáltatott információig, ahogyan a szivattyúktól az utalásokon át a felszólításokig haladunk.

A tanulók tudásával való korrelációk tökéletesen tükrözték ezt a kontinuumot, a korrelációk .49, .24, -.19 és -.40 voltak. A fizikából többet tudó tanulók esetében az AutoTutor meg tud boldogulni a szivattyúkkal és a célzásokkal, ezáltal ösztönözve a tanulót az elvárások megfogalmazására. A fizikában kevésbé jártas tanulók esetében az AutoTutornak olyan felkéréseket kell generálnia, amelyek konkrét szavakat kérdeznek ki, vagy a helyes információ megerősítésére, ezáltal a tudást darabonként vonja ki, vagy csupán a helyes információt mondja meg a tanulónak.

A tanulók AutoTutoron keresztül adott szóbeli válaszainak ezen elemzései számos állítást alátámasztanak. Először is, számos olyan automatizált algoritmus létezik, amely képes pontozni, hogy bizonyos mondatokra kiterjednek-e a szóbeli válaszok, amelyek fejlődnek a beszélgetés során a társalgási fordulatokban. Másodszor, a mondat tartalmi egyezésekre vonatkozó számítógépes pontszámok mérsékelten de nem látványos pontossági szintje, legalábbis a hosszú esszék pontozásához képest. Egy mondatban kevesebb tartalom van, mint egy esszében, így ez a második következtetés teljesen várható.

Másrészt a szóbeli válaszok pontszáma rendkívül magas, ha a várakozási egység egyetlen szó, közepes, ha egy mondat, és magas, ha egy esszé. Harmadszor, a szóbeli válaszok AutoTutorral történő pontozása megköveteli az elvárt tartalom elemzését és

annak értékelését, hogy a szóbeli válaszok mennyire felelnek meg az alábbiaknak az elvárt tartalomnak. Az AutoTutor hatáskörén kívül esik az olyan tartalmak elemzése, amelyek nem szerepelnek az elvárások radarján.

iSTART (Interaktív stratégiai tréner) for Automated Reading and Thinking)

Az iSTART (Levinstein et al., 2007; McNamara et al., 2004) egy olyan ITS, amely segít a középiskolás, főiskolás és felnőtt írástudó diákoknak a szövegértési stratégiák elsajátításában és gyakorlásában, hogy javítsák a kihívást jelentő kifejtő szövegek megértését.

Az iSTART bizonyítottan javítja az önmagyarázat minőségét, a szövegértési stratégiák használatát és az olvasásértést a középiskolásoktól a felnőttkorig terjedő olvasók esetében (Magliano et al., 2005; McCarthy et al., 2018; McNamara et al., 2007). Az iSTART különösen hatékonyan segíti az alacsony tudású és kevésbé képzett olvasókat abban, hogy jobban megértsék a kihívást jelentő szövegeket.

Az iSTART olyan modulokat tartalmaz, amelyek segítségével a tanulók három makrostratégiát tanulhatnak meg: önmagyarázat (McNamara et al., 2017), kérdésfeltevés (Ruseti et al., 2018) és összegzés (Botarleanu et al., 2021; Crossley et al., 2019). Minden modul rövid leckéket tartalmaz, amelyek a tanulók számára információt nyújtanak a stratégiák használatáról, valamint mikrostratégiákat, amelyek megkönnyítik a tanulók számára a stratégiák alkalmazását. A tanulók a stratégiákat természetes nyelvi válaszok, például önmagyarázatok vagy összefoglalók készítésével gyakorolják.

Az iSTART hatékonyságának döntő szempontja az a visszajelzés, amelyet egy pedagógiai ügynök ad a tanulóknak, amikor a szövegértési stratégiák segítségével beírják a szövegre adott válaszaikat. Az automatizált NLP algo-ritmusok érzékelik a válaszok minőségét, így adaptív visszajelzést adhatnak a diáknak. Az iSTART kétféle játékalapú gyakorlatot is tartalmaz (Jackson & McNamara, 2013).

A generatív játékokban a tanulók pontokat kapnak a jó minőségű válaszok, például magyarázatok vagy összefoglalók készítéséért. Az azonosító játékokban a tanulók példaválaszokat olvasnak egy szövegre, és pontokat szereznek azzal, ha helyesen azonosítják, hogy a példákban milyen szövegértési stratégiákat használtak. A diákok a pontjaikat arra használják, hogy testreszabási funkciókat vásároljanak a diákok avatarjaihoz vagy új játékok feloldására. Ezek a "metajáték" elemek a tanulók motivációjának további fokozását célozták (Jackson & McNamara, 2013). Az iSTART lényege, hogy az önképzésre összpontosít. A kihívást jelentő szövegek magyarázata öt empirikusan igazolt szövegértési stratégia segítségével: a szövegértés megfigyelése, parafrázálás, előrejelzés, áthidalás és kifejtés. A szövegértés-figyelés az olvasó azon képessége, hogy olvasás közben értékelje a szöveg megértését. A parafrázálás a szövegnek az olvasó saját szavaival történő újrafogalmazása. Az előrejelzés az, amikor az olvasó előre jelzi a szövegben megjelenő információkat, vagy úgy, hogy megalapozott feltételezéseket tesz, vagy olyan információkat jegyez fel, amelyek, ha jelen vannak,

segítik egy korábbi fogalom megértését. Az áthidalás az aktuális mondat és a szövegben található korábbi információk közötti kapcsolat megteremtése. Kidolgozás a szövegben szereplő fogalmak kibővítéséhez az általános vagy szakterület-specifikus előzetes tudás vagy a logika felhasználása.

Az iSTART értékelő algoritmus több változatát fejlesztették ki és értékelték (McNamara et al., 2007). A végső cél egy olyan algoritmus kifejlesztése volt, amely teljesen automatizált, és nem támaszkodik semmilyen emberi vagy kézzel kódolt számításokra. Az így létrejött algoritmus a szóalapú megközelítések és a szemantikai algoritmusok, például az LSA (Landauer et al., 2007) kombinációját használja. A szóalapú megközelítések tartalmazznak egy hosszkritériumot, amelyben a tanuló magyarázatának meg kell haladnia a szövegben található tartalmi szavak meghatározott számát.

Az LSA-alapú megközelítés a célszövegből származó viszonyítási pontok halmazára támaszkodik, beleértve a szöveg címét, a célmondatban szereplő szavakat és az előző két mondatban szereplő szavakat. A szóalapú algoritmusok visszajelzést adnak a sekélyes magyarázatokról (vagyis azokról, amelyek irrelevánsak vagy amelyek megismétlik a célmondatot). Az LSA a szóalapú algoritmusokat mélyebb, minőségi értékeléssel egészíti ki.

A hosszabb, relevánsabb magyarázatokra több pozitív visszajelzést adnak, míg a rövidebb, kevésbé releváns magyarázatokra fokozott interakciókat és támogatást nyújtanak.

A tanulók önmagyarázatait egy sor NLP-algoritmus segítségével értékelik. Először is, a válasz metakognitív és befagyasztott kifejezések szűrése (pl. "Nem értem, mit mondanak itt", "Unatkozom"). Ha a magyarázatban a befagyasztott kifejezések dominálnak, és kevés egyéb tartalmat tartalmaz, akkor a pedagógiai ágens közvetlenül ezekre a kijelentésekre válaszol egy véletlenszerűen kiválasztott válaszkészlet segítségével: "Kérem, próbálja meg kitalálni, hogy mi ez a mit jelent" vagy "Megpróbálná használni az olvasási stratégiák egyikét? Talán az segítene a megértésben". Miután a befagyasztott állításokat eltávolítottuk a magyarázatból, a magyarázat fennmaradó részét szóalapú és LSA-alapú módszerekkel elemezzük (McNamara et al., 2007).

Ha a magyarázat hossza nem ér el egy bizonyos küszöbértéket, T-t, a célszöveg hosszához képest, akkor a tanulót arra kérjük, hogy egészítse ki a magyarázatot. Az ügynök ekkor azt mondhatja: "Tudnál még valamit hozzátenni a magyarázatodhoz? Próbáld meg elmagyarázni, hogyan kapcsolódik valamihez, amit már tudsz". Ha a magyarázat szavakban vagy szemantikailag nem mutat kellő átfedést a célszöveggel és a környező szöveggel, akkor irrelevánsnak értékelik.

A magyarázatot a továbbiakban a célszöveghez való hasonlóság szempontjából értékelik. Ha túlságosan közel áll a célszöveghez a szavak teljes száma és az átfedő tartalmi szavak száma tekintetében, mint az alábbi példában, akkor ismétlésnek minősül. Egy ismétlésről olyan visszajelzést kaphat, mint például: "Próbálgon meg több olyan információt hozzáadni, amely megmagyarázza, hogy mit jelent a mondat". A cél az, hogy a tanulót arra készítssük, hogy a mondaton túlmutasson.

A parafrázálás kiváló és optimális módja a magyarázat elkezdésének, de a cél általában az, hogy a tanulót arra készítsük, hogy a parafrázison túlmutatva korábbi szöveg vagy külső ismeretek bevonásával magyarázza a magyarázatot. Ebben az esetben a tanuló olyan visszajelzést kapna, mint például: "Úgy tűnik, átfogalmaztad a mondatot. Most meg tudod magyarázni úgy, hogy gondolkodsz azon, hogy mit tudsz még?". Amint a magyarázat átlépi a hossza, relevanciára és hasonlóságra vonatkozó küszöbértékeket, visszajelzést kapunk a minőségéről. A tanulók minőségi visszajelzést kapnak, például: "Ez elég jó" a közepes minőségű magyarázat esetén, és "Nagyszerű munkát végeztél!" a magasabb minőségű magyarázat esetén.

A gyengébb minőségű magyarázatok csak a küszöbértéket érik el, és kevés olyan tartalommal rendelkeznek, amely túlmutat a célszövegen. A szövegértési stratégiák használatához felkéréseket és tippeket kapnak.

Az iSTART a tanulók által olvasott szövegek nehézségét is képes az iSTART-ban nyújtott teljesítményük alapján módosítani. Ha a tanulók önmagyarázatának minősége magas, a következő szövegek nagyobb kihívást jelentenek, és fordítva, ha az önmagyarázat minősége magas, a következő szövegek nagyobb kihívást jelentenek.

Az iSTART-ban a tananyagoknak a tanulók képességszintjéhez való igazítása a tanulás érzetének növekedéséhez vezet (Watanabe et al., 2019), és pozitív tanulási eredményekhez vezet, különösen a kevésbé képzett olvasók esetében (McCarthy et al., 2018, 2020). Az iSTART értékelő algoritmusainak pontosságát a diszkriminatív elemzésen alapuló lineáris egyenletek kiszámításával értékeltük. Egy adatkészletre, és kiszámították annak képességét az emberi értékelések előrejelzésére különböző adatkészletek esetében (Boonthum et al., 2007; Jackson et al., 2010; McNamara et al., 2007; Millis et al., 2004). Számos értékelés során az iSTART algoritmusok jól megfeleltek az emberi értékelésnek. McNamara et al. (2007) arról számoltak be, hogy az algoritmusok nagymértékben megfeleltek az emberi értékeléseknek az iSTART kezdeti gyakorlómoduljának két szövegére vonatkozó önmagyarázatokkal kapcsolatban; az algoritmus és az emberi értékelések között 62-64%-os volt az egyetértés ($r = .64 - .71$; $d' = 1,54 - 1,79$). Az algoritmusok sikeresen átvitték a különböző természettudományos témájú szövegeket is, amelyeket egy osztálytermi vizsgálatban használtak, amelyben 549 középiskolás diák vett részt, akik egy tanéven keresztül az iSTART segítségével hosszabb gyakorlásban vettek részt (Jackson et al., 2010). Ez a tanulmány $r = .66$ -os korrelációt mutatott az emberi értékelések és az iSTART algoritmusai között. Ez figyelemre méltó, tekintve a tanulók által ebben a vizsgálatban önmaga által magyarázott szövegek sokféleségét. Bár ez a teljesítmény látszólag magasabbnak tűnik, mint az AutoTutoré, figyelembe kell venni, hogy a két rendszer egészen más információkat céloz meg. Az iSTART a tanuló önmagyarázó stratégiáinak minőségét értékeli, míg az AutoTutor a várható érdemi tartalom minőségét, mélységét és pontosságát.

Az ebben a szakaszban szereplő elemzések alátámasztják azt az állítást, hogy az automatizált elemzések mérsékelten sikeresek a rövid szóbeli válaszok minőségének értékelésében. Különböző algoritmusokat használtak a tanulók szóbeli válaszai és a mondatelvárások közötti szemantikai egyezések kiszámítására. Ezen algoritmusok

többsége a tartalmi szavak és a következtetési tartalom átfedésén alapul az LSA-n keresztül, de néhányan figyelembe veszik a szavak kifejezésének sorrendjét, sőt mély szimbolikus elemzéseket is végeznek a természetes nyelvre vonatkozóan. Ezeknek a számítógépes elemzéseknek a teljesítménye mérsékelten sikeres, de nem olyan lenyűgöző, mint az esszék automatikus pontozása. Arra számítunk, hogy a jövőbeni erőfeszítések a tartalom mélyebb elemzését fogják végezni kifinomultabb NLP-vel.

Writing Pal

Az olyan ITS-ek, mint az AutoTutor és az iSTART a rövid, konstruált válaszokra összpontosítanak. A Writing Pal egy olyan ITS, amelyet az AWE rendszerek kiterjesztéseként fejlesztettek ki, és amely a tanulóknak visszajelzést ad az írásukról. Konkrétan a Writing Pal-t úgy tervezték, hogy explicit stratégiai oktatás, tudatos gyakorlás és automatikus visszajelzés révén javítsa a középiskolás és főiskolás diákok íráskészségét (Roscoe et al., 2014; Roscoe & McNamara, 2013). A számítógép-alapú írásrendszerek többségével ellentétben (áttekintésért lásd Allen et al., 2016b), a Writing Pal erősen összpontosít az írási stratégiák használatára vonatkozó oktatásra és gyakorlásra, amellett, hogy lehetőséget biztosít az esszéírásra személyre szabott visszajelzéssel.

A Writing Pal rendszerben a stratégiaoktatás az írás folyamatának három elsődleges fázisát öleli fel: az írás előtti írást, a fogalmazást és az átdolgozást. A rendszerben ezeket a stratégiákat az egyes oktatási modulok keretében tanítják, amelyek közé tartozik a szabad írás és tervezés; a bevezetés felépítése, a szöveg felépítése és a következtetés felépítése; valamint az átfogalmazás, a kohézióépítés és az átdolgozás. Az oktatási modulok mindegyike több leckevideót tartalmaz, amelyeket egy-egy animált pedagógiai ágens narrál. Ezekben a videóknak az ügynök leírja és példákat mutat be az egyes írási stratégiákra. Miután a tanulók megtekintették a leckevideókat, minijátékokat oldhatnak fel, amelyek lehetőséget biztosítanak számukra, hogy az írásbeli stratégiákat elszigetelten gyakorolják, mielőtt egy teljes esszé kontextusában alkalmaznák azokat. Az Írás Palban a tanulók a stratégiákat azonosító minijátékokkal gyakorolhatják, amelyekben arra kéri őket, hogy válasszák ki a legjobb választ egy adott kérdésre, vagy generatív minijátékokkal, amelyekben természetes nyelvű (gépelt) válaszokat adnak a gyakorolt stratégiákhoz kapcsolódóan.

A Writing Pal rendszer fontos eleme az AWE komponens (azaz az esszé gyakorló komponens). A Writing Pal ezen része egy szövegszerkesztőt tartalmaz, amelyben a tanulók esszéket írhatnak a Scholastic Aptitude Test (SAT) típusú felkérések alapján. Ezen kívül a tanároknak lehetőségük van arra is, hogy a rendszerhez saját felkéréseket adjanak hozzá. Miután a tanuló elkészítette az esszét, az elküldhető a Writing Pal rendszerbe értékelésre. Más AES és AWE eszközökhöz hasonlóan a Writing Pal is az NLP és a gépi tanulási technikákat ötvözi az automatikus visszajelzőrendszer és az adaptivitás működtetéséhez (Allen et al., 2016; McNamara et al., 2015). Az NLP-

technikákat a diákok esszéinek értékelésére használják különböző nyelvi dimenziók, például a lexikai kifinomultság vagy az esszé szervezése tekintetében.

A kivonatolás után ezeket az információkat az esszéértékelő algoritmusok vezérlésére használják, amelyek a SAT rubrikákhoz hasonló, 6 pontos skálán adnak összefoglaló pontszámokat a gyengétől a nagyszerűig terjedő skálán (Roscoe et al., 2014). A formatív visszajelzés másrészt információt nyújt a stratégiákról, amelyeket a diákok az esszéik minőségének javítására használhatnak. A formatív visszajelzés az írásfejlesztés fontos összetevője, mivel ismereteket nyújt a jó minőségű írás összetevőiről, valamint a javításra vonatkozó, megvalósítható ajánlásokat. A Writing Palban található formatív visszajelzéseket ennek figyelembevételével fejlesztettük ki és többféle írási stratégiára vonatkozó ajánlásokat tartalmaz. Miután elolvasták a visszajelzést, a diákok átdolgozhatják esszéiket.

A Writing Pal-t használó diákok jelentős javulást mutatnak az íráskészségben, az esszék általános pontszámaiban és az írásstratégiai ismeretekben (Allen et al., 2015; Roscoe & McNamara, 2013). Az explicit írásstratégiai oktatásban való részesülés segít a diákoknak abban, hogy figyelemmel kísérjék saját stratégiájuk használatát és írásuk pontosságát, ami akkor előnyös, ha a diákoknak személyre szabott írásbeli visszajelzésre van szükségük, és oktatójuk nem elérhető (Allen et al., 2015). Az Writing Pal sikere hangsúlyozza az egyéni visszajelzés fontosságát a holisztikus írásminőség javításában.

Az automatizált nyelvi elemzések jövője

Ez a fejezet áttekintette azt a rengeteg munkát, amelyet a nyelvi elemzések automatizálásával kapcsolatban végeztek a pszichológiai területen. Tudjuk, hogy a nyelv fontos konstrukció a pszichológiai és viselkedési konstrukciók széles körének megértésében; ugyanakkor rendkívül összetett, multimodális és többdimenziós (Allen et al., 2022; McNamara, 2021). Így az automatizált nyelvi elemzések jövője olyan modellek kifejlesztésében rejlik, amelyek a nyelv komplexitását vizsgálják, a nyelvet több skála segítségével figyelembe véve, amelyek a szavak jellemzőinek vizsgálatától (pl. hogy mennyire ismerős, érzelmi vagy absztrakt) magának a diskurzusnak a szerveződéséig terjednek.

Az ilyen többdimenziós elemzések képesek árnyaltabb információkat nyújtani a nyelv és a pszicho-logikai folyamatok közötti kapcsolatokról. Például a nyelvek szó-, mondat- és diskurzusszinten történő vizsgálata árnyaltabb információkat nyújthat arról, hogy bizonyos kísérleti manipulációk vagy egyéni különbségek hogyan befolyásolják a diskurzusprodukción és a megértést. Az emberi viselkedés megértéséhez és előrejelzéséhez továbbá a különböző modalitásokból származó többféle információforrás, például a gesztusok, a szemmozgás, a billentyűleütéses viselkedés és az érzelmi reakciók integrálására van szükség. Ezért a jövőbeli kutatásoknak nemcsak a pszichológiai feladatok során előállított nyelvet kell figyelembe venniük, hanem más, esetleg kiegészítő adatforrásokat is. A legújabb kutatások például olyan modelleket vizsgáltak, amelyek kombinálják a billentyűleütést a nyelvi adatokkal (Allen et al., 2016),

szemmozgásokkal (Chukharev-Hudilainen et al., 2019) és click-stream adatokkal (Crossley et al., 2020). A multimodális munka valószínűleg sokkal árnyaltabb és szilárdabb megértést nyújt a diskurzusfolyamatokról, a megismerésről és az emberi viselkedésről tágabb értelemben.

Összességében jelentős előrelépés történt a természetes nyelv és a diskurzus automatizált értékelésének képességében. Ezt a fejlődést a számítási teljesítmény, a statisztikai technikák, az NLP-eszközök és a diskurzusfolyamatok elméleti megértése terén elért előrelépések táplálták. Ezek a fejlesztések alapozták meg az esszék pontozására, a különböző típusú írások jellemzőinek elemzésére, a szövegek nehézségének értékelésére szolgáló technikákat, a tanulói hozzájárulások pontosságának, minőségének és típusának értékelése a korrepetáló rendszerekben, a beszélők és írók pszicho-logikai jellemzőinek következtetése, valamint a diskurzusban megjelenő affektív dimenziók felismerése.

Arra számítunk, hogy a szövegek és diskurzusok automatizált elemzése a jövőben tovább fog terjedni és bővülni. Ebben a fejezetben csak a számítógépes modellezés és a pszichológia metszéspontjain folyó kutatásoknak csak egy kis szeletét fedeztük fel.

Néhány kolléga továbbra is egészséges szkepticizmussal fog viszonyulni a nyelv és a diskurzus automatizált elemzéseihez. Mások azonban továbbra is felfedezni, hogy a pszichológiai mechanizmusok különböző aspektusai hogyan ragadhatók meg a szöveg és a diskurzus automatizált elemzésével. Mindkét gondolkodásmódra szükség van ahhoz, hogy olyan automatizált értékelésekhez jussunk, amelyek a leghatékonyabban és legmegfelelőbben mozdítják elő a pszichológia területét.

Szakirodalom

- Allen, L. K., Creer, S. D., & Öncel, P. (2022). Natural language processing as a tool for learning analytics: Towards a multi-dimensional view of the learning process. In C. Lang, G. Siemens, A. F. Wise, D. Gašević, & A. Merceron (Eds.), *Handbook of learning analytics* (2nd ed., pp. 46–53). Society for Learning Analytics Research.
- Allen, L. K., Jacovina, M. E., & McNamara, D. S. (2016a). Cohesive features of deep text comprehension processes. In J. Trueswell, A. Papafragou, D. Grodner, & D. Mirman (Eds.), *Proceedings of the 38th Annual Meeting of the Cognitive Science Society in Philadelphia, PA* (pp. 2681–2686).
- Allen, L. K., Jacovina, M. E., & McNamara, D. S. (2016b). Computer-based writing instruction. In C. A. MacArthur, S. Graham, & J. Fitzgerald (Eds.), *Handbook of writing research* (2nd ed., pp. 316–329). Guilford Press.
- Allen, L. K., Magliano, J. P., McCarthy, K. S., Sonia, A., Creer, S., & McNamara, D. S. (2021). In T. Fitch, C. Lamm, H. Leder, & K. Tessmar (Eds.), *Proceedings of the 43rd Annual Conference of the Cognitive Science Society* (pp. 931–937).
- Allen, L. K., Mills, C., Jacovina, M. E., Crossley, S., D’Mello, S., & McNamara, D. S. (2016). Investigating boredom and engagement during writing using multiple sources of information: The essay, the writer, and keystrokes. *Proceedings of the 6th International Learning Analytics & Knowledge Conference* (pp. 114–123). ACM.

- Allen, L. K., & Perret, C. A. (2016). Commercialized writing systems. In D. S. McNamara & S. A. Crossley (Eds.), *Adaptive educational technologies for literacy instruction* (pp. 145–162). Taylor & Francis, Routledge. <https://doi.org/10.4324/9781315647500-11>
- Allen, L. K., Snow, E. L., & McNamara, D. S. (2015). Are you reading my mind? Modeling students' reading comprehension skills with Natural Language Processing techniques. *Proceedings of the International Learning Analytics & Knowledge Conference* (pp. 246–254). ACM.
- Andrade, H. G., & Boulay, B. A. (2003). Role of Rubric-Referenced Self-Assessment in Learning to Write. *The Journal of Educational Research*, 97(1), 21–34. <https://doi.org/10.1080/00220670309596625>
- Attali, Y., & Burstein, J. (2006). Automated essay scoring with e-rater R V.2. *The Journal of Technology, Learning, and Assessment*, 4(3), 1–30.
- Barrett, L. F., Mesquita, B., Ochsner, K. N., & Gross, J. J. (2007). The experience of emotion. *Annual Review of Psychology*, 58(1), 373–403. <https://doi.org/10.1146/annurev.psych.58.110405.085709>
- Boonthum, C., Levinstein, I., & McNamara, D. S. (2007). Evaluating self-explanations in iSTART: Word matching, latent semantic analysis, and topic models. In A. Kao & S. Poteet (Eds.), *Natural language processing and text mining* (pp. 91–106). Springer. https://doi.org/10.1007/978-1-84628-754-1_6
- Botarleanu, R.-M., Dascalu, M., Allen, L. K., Crossley, S. A., & McNamara, D. S. (2021). Automated summary scoring with ReaderBench. In *International Conference on Intelligent Tutoring Systems (ITS 2021)*. Springer. Burgess, C., Livesay, K., & Lund, K. (1998). Explorations in context space: Words, sentences, and discourse. *Discourse Processes*, 25(2–3), 211–257. <https://doi.org/10.1080/01638539809545027>
- Burstein, J. (2003). The E-rater scoring engine: Automated essay scoring with natural language processing. In M. D. Shermis & J. C. Burstein (Eds.), *Automated essay scoring: A cross-disciplinary perspective* (pp. 113–121). Erlbaum.
- Burstein, J., Marcu, D., & Knight, K. (2003). Finding the WRITE stuff: Automatic identification of discourse structure in student essays. *IEEE Intelligent Systems*, 18(1), 32–39. <https://doi.org/10.1109/MIS.2003.1179191>
- Calfee, R. (2000). To grade or not to grade. *IEEE Intelligent Systems*, 15, 35–37.
- Cho, K., Schunn, C. D., & Wilson, R. W. (2006). Validity and reliability of scaffolded peer assessment of writing from instructor and student perspectives. *Journal of Educational Psychology*, 98(4), 891–901. <https://doi.org/10.1037/0022-0663.98.4.891>
- Chrysafiadi, K., & Virvou, M. (2013). Student modeling approaches: A literature review for the last decade. *Expert Systems with Applications*, 40(11), 4715–4729. <https://doi.org/10.1016/j.eswa.2013.02.007>
- Chukharev-Hudilainen, E., Saricaoglu, A., Torrance, M., & Feng, H.-H. (2019). Combined deployable keystroke logging and eyetracking for investigating L2 writing fluency. *Studies in Second Language Acquisition*, 41(3), 583–604. <https://doi.org/10.1017/S027226311900007X>
- Chung, C., & Pennebaker, J. (2007). The psychological functions of function words. In K. Fielder (Ed.), *Social communication* (pp. 343–359). Psychology Press.
- Clark, A., Fox, C., & Lappin, S. (Eds.). (2013). *The handbook of computational linguistics and natural language processing*. John Wiley & Sons.

- Cohn, M. A., Mehl, M. R., & Pennebaker, J. W. (2004). Linguistic markers of psychological change surrounding September 11, 2001. *Psychological Science*, 15(10), 687–693. <https://doi.org/10.1111/j.0956-7976.2004.00741.x>
- Coté, N., & Goldman, S. R. (1999). Building representations of informational text: Evidence from children’s think-aloud protocols. In H. van Oostendorp & S. R. Goldman (Eds.), *The construction of mental representations during reading* (pp. 169–193). Lawrence Erlbaum.
- Crossley, S. A., Karumbaiah, S., Ocumpaugh, J., Labrum, M. J., & Baker, R. S. (2020). Predicting math identity through language and click-stream patterns in a blended learning mathematics program for elementary students. *Journal of Learning Analytics*, 7(1), 19–37. <https://doi.org/10.18608/jla.2020.71.3>
- Crossley, S. A., Kim, M., Allen, L. K., & McNamara, D. S. (2019). Automated summarization evaluation (ASE) using natural language processing tools. In *Proceedings of the 20th International Conference of Artificial Intelligence in Education* (pp. 84–95). *Lecture Notes in Computer Science*, Vol. 11625. Springer.
- Crossley, S. A., Kyle, K., & Dascalu, M. (2019). The Tool for the Automatic Analysis of Cohesion 2.0: Integrating semantic similarity and text overlap. *Behavior Research Methods*, 51(1), 14–27. <https://doi.org/10.3758/s13428-018-1142-4>
- Crossley, S. A., Kyle, K., & McNamara, D. S. (2017). Sentiment Analysis and Social Cognition Engine (SEANCE): An automatic tool for sentiment, social cognition, and social-order analysis. *Behavior Research Methods*, 49(3), 803–821. <https://doi.org/10.3758/s13428-016-0743-z>
- Dascalu, M., McNamara, D. S., Trausan-Matu, S., & Allen, L. K. (2018). Cohesion network analysis of CSCL participation. *Behavior Research Methods*, 50(2), 604–619. <https://doi.org/10.3758/s13428-017-0888-4>
- Denton, C. A., Enos, M., York, M. J., Francis, D. J., Barnes, M. A., Kulesz, P. A., Fletcher, J. M., & Carter, S. (2015). Text-processing differences in adolescent adequate and poor comprehenders reading accessible and challenging narrative and informational text. *Reading Research Quarterly*, 50(4), 393–416. <https://doi.org/10.1002/rrq.105>
- Devlin, J., Chang, M.-W., Lee, K., & Toutanova, K. (2018). Bert: Pretraining of deep bidirectional transformers for language understanding. *arXiv*, 1810.04805. <https://doi.org/10.48550/arXiv.1810.04805>
- Dikli, S. (2006). An overview of automated scoring of essays. *The Journal of Technology, Learning, and Assessment*, 5(1), 1–35.
- D’Mello, S. K., Craig, S. D., Witherspoon, A. W., McDaniel, B. T., & Graesser, A. C. (2008). Automatic detection of learner’s affect from conversational cues. *User Modeling and User-Adapted Interaction*, 18(1–2), 45–80. <https://doi.org/10.1007/s11257-007-9037-6>
- D’Mello, S. K., Graesser, A., & King, B. (2010). Toward spoken human-computer tutorial dialogues. *Human-Computer Interaction*, 25(4), 289–323. <https://doi.org/10.1080/07370024.2010.499850>
- Dowell, N. M., Lin, Y., Godfrey, A., & Brooks, C. (2020). Exploring the relationship between emergent sociocognitive roles, collaborative problem-solving skills, and outcomes: A group communication analysis. *Journal of Learning Analytics*, 7(1), 38–57. <https://doi.org/10.18608/jla.2020.71.4>
- Dowell, N. M. M., Nixon, T. M., & Graesser, A. C. (2019). Group communication analysis: A computational linguistics approach for detecting sociocognitive roles in multiparty

- interactions. *Behavior Research Methods*, 51(3), 1007–1041. <https://doi.org/10.3758/s13428-018-1102-z>
- Elliott, S. (2003). IntelliMetric: From here to validity. In M. D. Shermis & J. Burstein (Eds.), *Automated essay scoring: A cross-disciplinary perspective* (pp. 71–86). Erlbaum.
- Ericsson, K. A., & Simon, H. A. (1984). *Protocol analysis: Verbal reports as data*. MIT Press.
- Ericsson, P. F., & Haswell, R. (Eds.). (2006). *Machine scoring of student essays: Truth and consequences*. Utah State University Press. <https://doi.org/10.2307/j.ctt4cgq0p>
- Franzke, M., Kintsch, E., Caccamise, D., Johnson, N., & Dooley, S. (2005). Summary street: Computer support for comprehension and writing. *Journal of Educational Computing Research*, 33(1), 53–80. <https://doi.org/10.2190/DH8F-QJWM-J457-FQVB>
- Gill, A., French, R., Gergle, D., & Oberlander, J. (2008). Identifying emotional characteristics from short blog texts. In B. C. Love, K. McRae & V. M. Sloutsky (Eds.), *Proceedings of the Annual Meeting of the Cognitive Science Society* (pp. 2237–2242).
- Gilliam, S., Magliano, J. P., Millis, K. K., Levinstein, I., & Boonthum, C. (2007). Assessing the format of the presentation of text in developing a Reading Strategy Assessment Tool (R-SAT). *Behavior Research Methods*, 39(2), 199–204. <https://doi.org/10.3758/>
- Graesser, A. C. (2016). Conversations with AutoTutor help students learn. *International Journal of Artificial Intelligence in Education*, 26, 124–132.
- Graesser, A. C., Hu, X., Rus, V., & Cai, Z. (2020). Conversation-based learning and assessment environments. In D. Yan, A. Rupp, & P. Foltz (Eds.), *Handbook of automated scoring: Theory into practice* (pp. 383–402). CRC Press/Taylor and Francis. <https://doi.org/10.1201/9781351264808-21>
- Graesser, A. C., Jeon, M., & Dufty, D. (2008). Agent technologies designed to facilitate interactive knowledge construction. *Discourse Processes*, 45(4–5), 298–322. <https://doi.org/10.1080/01638530802145395>
- Graesser, A. C., Lu, S., Jackson, G. T., Mitchell, H. H., Ventura, M., Olney, A., & Louwerse, M. M. (2004). AutoTutor: A tutor with dialogue in natural language. *Behavior Research Methods, Instruments, & Computers*, 36(2), 180–192. <https://doi.org/10.3758/BF03195563>
- Graesser, A. C., & McNamara, D. S. (2011). Computational analyses of multilevel discourse comprehension. *Topics in Cognitive Science*, 3(2), 371–398. <https://doi.org/10.1111/j.1756-8765.2010.01081.x>
- Hu, X. (2007). Using LSA in AutoTutor: Learning through mixed initiative dialogue in natural language. In T. Landauer, D. McNamara, S. Dennis, & W. Kintsch (Eds.), *Handbook of latent semantic analysis* (pp. 243–262). Erlbaum.
- Graham, S., & Perin, D. (2007). A meta-analysis of writing instruction for adolescent students. *Journal of Educational Psychology*, 99(3), 445–476. <https://doi.org/10.1037/0022-0663.99.3.445>
- Griffiths, T. L. (2015). Manifesto for a new (computational) cognitive revolution. *Cognition*, 135, 21–23. <https://doi.org/10.1016/j.cognition.2014.11.026>
- Hestenes, D., Wells, M., & Swackhamer, G. (1992). Force concept inventory. *The Physics Teacher*, 30(3), 141–158. <https://doi.org/10.1119/1.2343497>
- Hirschberg, J., & Manning, C. D. (2015). Advances in natural language processing. *Science*, 349(6245), 261–266. <https://doi.org/10.1126/science.aaa8685>

- Jackson, G. T., & Graesser, A. C. (2006). Applications of human tutorial dialog in AutoTutor: An intelligent tutoring system. *Revista Signos*, 39, 31–48.
- Jackson, G. T., Guess, R. H., & McNamara, D. S. (2010). Assessing cognitively complex strategy use in an untrained domain. *Topics in Cognitive Science*, 2(1), 127–137. <https://doi.org/10.1111/j.1756-8765.2009.01068.x>
- Jackson, G. T., & McNamara, D. S. (2013). Motivation and performance in a game-based intelligent tutoring system. *Journal of Educational Psychology*, 105(4), 1036–1049. <https://doi.org/10.1037/a0032580>
- Johns, B. T., & Jamieson, R. K. (2018). A large-scale analysis of variance in written language. *Cognitive Science*, 42(4), 1360–1374. <https://doi.org/10.1111/cogs.12583>
- Johnson, A., McCarthy, K. S., Kopp, K., Perret, C. A., & McNamara, D. S. (2017). Adaptive reading and writing instruction in iSTART and W-Pal. In Z. Markov & V. Rus (Eds.), *Proceedings of the 30th Annual Florida Artificial Intelligence Research Society International Conference (FLAIRS)* (pp. 561–566). AAAI Press.
- Johnson, L. W., & Valente, A. (2008). Tactical language and culture training systems: Using artificial intelligence to teach foreign languages and cultures. *Proceedings of the Twentieth Conference on Innovative Applications of Artificial Intelligence*. AAAI Press.
- Jones, M. N. (2017). *Big data in cognitive science*. Psychology Press: Taylor & Francis.
- Jurafsky, D., & Martin, J. H. (2008). *Speech and language processing: An introduction to natural language processing, computational linguistics, and speech recognition*. Prentice-Hall.
- Kyle, K. (2021). Natural language processing for learner corpus research. *International Journal of Learner Corpus Research*, 7(1), 1–16. <https://doi.org/10.1075/ijlcr.00019.int>
- Kyle, K., Crossley, S., & Berger, C. (2018). The tool for the automatic analysis of lexical sophistication (TAALES): Version 2.0. *Behavior Research Methods*, 50(3), 1030–1046. <https://doi.org/10.3758/s13428-017-0924-4>
- Kyle, K., & Crossley, S. A. (2018). Measuring syntactic complexity in L2 writing using fine-grained clausal and phrasal indices. *Modern Language Journal*, 102(2), 333–349. <https://doi.org/10.1111/modl.12468>
- Landauer, T., McNamara, D. S., Dennis, S., & Kintsch, W. (Eds.). (2007). *Handbook of latent semantic analysis*. Erlbaum.
- Landauer, T. K., Laham, D., & Foltz, P. W. (2003). Automatic essay assessment. *Assessment in Education: Principles, Policy & Practice*, 10(3), 295–308. <https://doi.org/10.1080/0969594032000148154>
- Leacock, C., & Chodorow, M. (2003). C-rater: Automated scoring of short-answer questions. *Computers and the Humanities*, 37(4), 389–405. <https://doi.org/10.1023/A:1025779619903>
- Levinstein, I. B., Boonthum, C., Pillarisetti, S. P., Bell, C., & McNamara, D. S. (2007). iSTART 2: Improvements for efficiency and effectiveness. *Behavior Research Methods*, 39(2), 224–232. <https://doi.org/10.3758/BF03193151>
- Litman, D. (2016). Natural language processing for enhancing teaching and learning. *Proceedings of the AAAI Conference on Artificial Intelligence*, 30(1), 4170–4176. <https://doi.org/10.1609/aaai.v30i1.9879>
- Litman, D. J., Rose, C. P., Forbes-Riley, K., VanLehn, K., Bhembe, D., & Silliman, S. (2006). Spoken versus typed human and computer dialogue tutoring. *International Journal of Artificial Intelligence in Education*, 16(2), 145–170.

- Magliano, J. P., & Graesser, A. C. (2012). Computerbased assessment of student-constructed responses. *Behavior Research Methods*, 44(3), 608–621. <https://doi.org/10.3758/s13428-012-0211-3>
- Magliano, J. P., Millis, K. K., The RSAT Development Team, Levinstein, I., & Boonthum, C. (2011). Assessing comprehension during reading with the Reading Strategy Assessment Tool (RSAT). *Metacognition and Learning*, 6, 131–154. <https://doi.org/10.1007/s11409-010-9064-2>
- Magliano, J. P., Todaro, S., Millis, K. K., Wiemer-Hastings, K., Kim, H. J., & McNamara, D. S. (2005). Changes in reading strategies as a function of reading training: A comparison of live and computerized training. *Journal of Educational Psychology*. American Psychological Association. Not for further distribution. Automated Analyses of Natural Language in Psychological Research 379 *Computing Research*, 32(2), 185–208. <https://doi.org/10.2190/1LN8-7BQE-8TN0-M91L>
- Magliano, J. P., Trabasso, T., & Graesser, A. C. (1999). Strategic processing during comprehension. *Journal of Educational Psychology*, 91(4), 615–629. <https://doi.org/10.1037/0022-0663.91.4.615>
- McCarthy, K. S., Likens, A. D., Johnson, A. M., Guerrero, T. A., & McNamara, D. S. (2018). Metacognitive overload! Positive and negative effects of metacognitive prompts in an intelligent tutoring system. *International Journal of Artificial Intelligence in Education*, 28(3), 420–438. <https://doi.org/10.1007/s40593-018-0164-5>
- McCarthy, K. S., Watanabe, M., Dai, J., & McNamara, D. S. (2020). Personalized learning in iSTART: Past modifications and future design. *Journal of Research on Technology in Education*, 52(3), 301–321. <https://doi.org/10.1080/15391523.2020.1716201>
- McNamara, D. S. (2004). SERT: Self-explanation reading training. *Discourse Processes*, 38(1), 1–30. https://doi.org/10.1207/s15326950dp3801_1
- McNamara, D. S. (2017). Self-Explanation and Reading Strategy Training (SERT) Improves low-knowledge students' science course performance. *Discourse Processes*, 54(7), 479–492. <https://doi.org/10.1080/0163853X.2015.1101328>
- McNamara, D. S. (2021). Chasing theory with technology: A quest to understand understanding. *Discourse Processes*, 58(5–6), 422–448. <https://doi.org/10.1080/0163853X.2021.1917914>
- McNamara, D. S., Allen, L. K., Crossley, S. A., Dascalu, M., & Perret, C. A. (2017). Natural language processing and learning analytics. In G. Siemens & C. Lang (Eds.), *Handbook of learning analytics and educational data mining* (pp. 93–104). SOLAR. <https://doi.org/10.18608/hla17.008>
- McNamara, D. S., Boonthum, C., Levinstein, I. B., & Millis, K. (2007). Evaluating self-explanations in iSTART: Comparing word-based and LSA algorithms. In T. Landauer, D. S. McNamara, S. Dennis, & W. Kintsch (Eds.), *Handbook of latent semantic analysis* (pp. 227–241). Erlbaum.
- McNamara, D. S., Crossley, S. A., Roscoe, R. D., Allen, L. K., & Dai, J. (2015). Hierarchical classification approach to automated essay scoring. *Assessing Writing*, 23, 35–59. <https://doi.org/10.1016/j.asw.2014.09.002>
- McNamara, D. S., Graesser, A. C., McCarthy, P., & Cai, Z. (2014). *Automated evaluation of text and discourse with Coh-Metrix*. Cambridge University Press. <https://doi.org/10.1017/CBO9780511894664>

- McNamara, D. S., Levinstein, I. B., & Boonthum, C. (2004). iSTART: Interactive strategy training for active reading and thinking. *Behavior Research Methods, Instruments & Computers*, 36(2), 222–233. <https://doi.org/10.3758/BF03195567>
- McNamara, D. S., O'Reilly, T., Rowe, M., Boonthum, C., & Levinstein, I. B. (2007). iSTART: A web-based tutor that teaches self-explanation and metacognitive reading strategies. In D. S. McNamara (Ed.), *Reading comprehension strategies: Theories, interventions, and technologies* (pp. 397–421). Erlbaum.
- Mikolov, T., Sutskever, I., Chen, K., Corrado, G., & Dean, J. (2013). Distributed representations of words and phrases and their compositionally. In *Advances in Neural Information Processing Systems 26* (pp. 3111–3119). Curran Associates, Inc. Millis, K., Kim, H. J., Todaro, S., Magliano, J. P., Wiemer-Hastings, K., & McNamara, D. S. (2004). Identifying reading strategies using latent semantic analysis: Comparing semantic benchmarks. *Behavior Research Methods, Instruments, & Computers*, 36(2), 213–221. <https://doi.org/10.3758/BF03195566>
- Millis, K., & Magliano, J. (2012). Assessing comprehension processes during reading. In J. Sabatini, T. O'Reilly, & E. Albro (Eds.), *Reaching an understanding: Innovations in how we view reading assessment* (pp. 35–53). Rowman & Littlefield Education.
- Müller-Frommeyer, L. C., Kauffeld, S., & Paxton, A. (2020). Beyond consistency: Contextual dependency of language style in monolog and conversation. *Cognitive Science*, 44(4), e12834. <https://doi.org/10.1111/cogs.12834>
- Nye, B. D., Graesser, A. C., & Hu, X. (2014). AutoTutor and family: A review of 17 years of natural language tutoring. *International Journal of Artificial Intelligence in Education*, 24(4), 427–469. <https://doi.org/10.1007/s40593-014-0029-5>
- Osgood, C. E., May, W. H., & Miron, M. (1975). *Cross-cultural universals of affective meaning*. University of Illinois Press.
- Ozuru, Y., Best, R., & McNamara, D. S. (2004). Contribution of reading skill to learning from expository texts. In K. Forbus, D. Gentner, & T. Regier (Eds.), *Proceedings of the 26th Annual Cognitive Science Society* (pp. 1071–1076). Erlbaum.
- Pang, B., & Lee, L. (2008). Opinion mining and sentiment analysis. *Foundations and Trends in Information Retrieval*, 2(1–2), 1–135. <https://doi.org/10.1561/15000000011>
- Pennebaker, J. W. (2011). *The secret life of pronouns: What our words say about us*. Bloomsbury Press/ Bloomsbury Publishing. [https://doi.org/10.1016/S0262-4079\(11\)62167-2](https://doi.org/10.1016/S0262-4079(11)62167-2)
- Pennebaker, J. W., Booth, R. J., & Francis, M. E. (2007). *Linguistic Inquiry and Word Count: LIWC 2007*. Austin, TX: LIWC.net (<https://www.liwc.net>)
- Pennebaker, J. W., Mehl, M. R., & Niederhoffer, K. G. (2003). Psychological aspects of natural language use: Our words, our selves. *Annual Review of Psychology*, 54(1), 547–577. <https://doi.org/10.1146/annurev.psych.54.101601.145041>
- Pon-Barry, H., Clark, B., Schultz, K., Bratt, E. O., & Peters, S. (2004). Advantages of spoken language interaction in tutorial dialogue systems. In *Proceedings of the 7th International Conference on Intelligent Tutoring Systems* (pp. 390–400). Springer-Verlag.
- Roscoe, R. D., Allen, L. K., Weston, J. L., Crossley, S. A., & McNamara, D. S. (2014). The Writing Pal intelligent tutoring system: Usability testing and development. *Computers and Composition*, 34, 39–59. <https://doi.org/10.1016/j.compcom.2014.09.002>

- Roscoe, R. D., & McNamara, D. S. (2013). Writing Pal: Feasibility of an intelligent writing strategy tutor in the high school classroom. *Journal of Educational Psychology*, 105(4), 1010–1025. <https://doi.org/10.1037/a0032340>
- Roscoe, R. D., Snow, E. L., Allen, L. K., & McNamara, D. S. (2015). Automated detection of essay revising patterns: Application for intelligent feedback in a writing tutor. *Technology, Instruction, Cognition, & Learning*, 10(1), 59–79.
- Ross, J. A., Rolheiser, C., & Hogaboam-Gray, A. (1999). Effects of self-evaluation training on narrative writing. *Assessing Writing*, 6(1), 107–132. [https://doi.org/10.1016/S1075-2935\(99\)00003-3](https://doi.org/10.1016/S1075-2935(99)00003-3)
- Rude, S. S., Gortner, E. M., & Pennebaker, J. W. (2004). Language use of depressed and depressionvulnerable college students. *Cognition and Emotion*, 18(8), 1121–1133. <https://doi.org/10.1080/02699930441000030>
- Rudner, L. M., Garcia, V., & Welch, C. (2006). An evaluation of the IntelliMetric essay scoring system. *The Journal of Technology, Learning, and Assessment*, 4(4), 1–22.
- Ruseti, S., Dascalu, M., Johnson, A. M., McNamara, D. S., Balyan, R., McCarthy, K. S., & Trausan-Matu, S. (2018). Scoring summaries using recurrent neural networks. In R. Nkambou, R. Azevedo, & J. Vassileva, (Eds.), *Proceedings of the 14th International Conference on Intelligent Tutoring Systems (ITS) in Montreal, Canada* (pp. 191–201). Springer.
- Russell, J. A. (2003). Core affect and the psychological construction of emotion. *Psychological Review*, 110(1), 145–172. <https://doi.org/10.1037/0033-295X.110.1.145>
- Samsonovich, A., & Ascoli, G. (2006). Cognitive map dimensions of the human value system extracted from natural language. In B. Goertzel & P. Wang (Eds.), *Advances in artificial general intelligence: Concepts, architectures and algorithms* (pp. 111–124). IOS Press.
- Shermis, M. D., & Burstein, J. (Eds.). (2003). *Automated essay scoring: A cross-disciplinary perspective*. Erlbaum.
- Shermis, M. D., Burstein, J., Higgins, D., & Zechner, K. (2010). Automated essay scoring: Writing assessment and instruction. In E. Baker, B. McGaw, & N. S. Petersen (Eds.), *International encyclopedia of education* (3rd ed.). Elsevier. <https://doi.org/10.1016/B978-0-08-044894-7.00233-5>
- Stirman, S. W., & Pennebaker, J. W. (2001). Word use in the poetry of suicidal and nonsuicidal poets. *Psychosomatic Medicine*, 63(4), 517–522. <https://doi.org/10.1097/00006842-200107000-00001>
- Strapparava, C., & Valitutti, A. (2004). WordNet Affect: An affective extension of WordNet. In *Proceedings of the Fourth International Conference on Language Resources and Evaluation* (pp. 1083–1086). European Language Resources Association.
- Tausczik, Y. R., & Pennebaker, J. W. (2010). The psychological meaning of words: LIWC and computerized text analysis methods. *Journal of Language and Social Psychology*, 29(1), 24–54. <https://doi.org/10.1177/0261927X09351676>
- VanLehn, K., Graesser, A. C., Jackson, G. T., Jordan, P., Olney, A., & Rosé, C. P. (2007). When are tutorial dialogues more effective than reading? *Cognitive Science*, 31(1), 3–62. <https://doi.org/10.1080/03640210709336984>
- Warschauer, M., & Ware, P. (2006). Automated writing evaluation: Defining the classroom research agenda. *Language Teaching Research*, 10(2), 157–180. <https://doi.org/10.1191/1362168806lr190oa>

- Watanabe, M., McCarthy, K., & McNamara, D. S. (2019). Examining the effects of adaptive task selection on students' motivation in an intelligent tutoring system. In Proceedings of the 9th International Conference on Learning Analytics and Knowledge (pp. 161–162). SOLAR.
- Wiebe, J., Wilson, T., & Cardie, C. (2005). Annotating expressions of opinions and emotions in language. *Language Resources and Evaluation*, 39(2–3), 165–210. <https://doi.org/10.1007/s10579-005-7880-9>
- Woolf, B. P. (2009). *Building intelligent interactive tutors*. Morgan Kaufmann Publishers.
- Yan, D., Rupp, A. C., & Foltz, P. W. (Eds.). (2020). *Handbook of automated scoring: Theory into practice*. Chapman and Hall, CRC Press.

Alkalmazott pszichológia és munkerő kiválasztás

Az elmúlt évtizedekben a munka világa látványos átalakuláson ment keresztül. Ez nem csupán a technológiai fejlődés, a munkavállalói elvárások, a szervezeti kultúra és a humán erőforrás menedzsment szempontjai is teljesen új alapokra kerültek. Ebben a dinamikus környezetben a mesterséges intelligencia nemcsak egyszerű támogató eszközként, hanem stratégiai partnerként jelenik meg a pszichológiai alapú döntésekben. Az AI-vezérelt rendszerek ma már képesek viselkedési mintázatokat elemezni, személyiségjegyeket profilozni, sőt előre jelezni a munkahelyi teljesítményt vagy a kiégés kockázatát, és mindezt olyan adatmennyiség és összefüggésrendszer alapján, amit egy emberi szakértő önmagában aligha tudna átlátni.

A pszichológia és a HR területen a mesterséges intelligencia képes új kapukat nyitni, különösen az alkalmazott pszichológia területén válik kézzelfoghatóvá az a potenciál, amely nemcsak a kiválasztási folyamatokat gyorsítja fel, hanem újfajta objektivitást is hozhat a döntésekbe. Ugyanakkor ezek az eszközök komoly kérdéseket is felvetnek, például olyanokat, hogy mennyire megbízható egy algoritmus egy olyan fontos és meghatározó döntésekben, amely az emberek életét, szakmai jövőjét befolyásolják? Milyen kockázatokat hordoz a diszkrimináció vagy az adatvédelmi incidensek szempontjából egy MI-alapú toborzási rendszer?

Ebben a fejezetben azokat a területeket járjuk körbe, ahol a mesterséges intelligencia a legnagyobb hatást gyakorolja a munka világában alkalmazott pszichológiai gyakorlatokra. Először az MI-alapú személyiségprofilozás és kiválasztás kerül fókuszba, majd a munkahelyi jóllét és teljesítmény predikciójának lehetőségeit vizsgáljuk meg. Végül nem kerülhetjük meg az etikai dimenziókat sem, hiszen az AI alkalmazása épp olyan kérdéseket vet fel, mint amennyi problémát megold.

AI-alapú személyiségprofilozás és kiválasztás

A munkaerő-kiválasztás során a személyiség régóta az egyik legfontosabb szempont. Évtizedeken át különféle kérdőívekkel, strukturált interjúkkal és projektív módszerekkel próbálták feltérképezni azt, hogy vajon ki illeszkedik legjobban egy adott munkakörbe, ki a legalkalmasabb egy adott álláshely betöltésére. Az utóbbi években azonban a folyamatot egyre inkább automatizált rendszerek váltják fel, amelyek mesterséges intelligencia (MI) segítségével értelmezik a jelentkezők viselkedését, nyelvhasználatát és válaszstruktúráit.

Az MI-alapú személyiségprofilozás egyik leggyakrabban alkalmazott eszköze a természetes nyelvfeldolgozás (NLP), amely lehetővé teszi, hogy az algoritmusok írásos

szövegek – például önéletrajzok, motivációs levelek vagy interjútranszkriptek – alapján vonjanak le következtetéseket a személyiségvonásokra. Egy példa erre a HireVue platform, amely videóinterjúkat elemez arcmimika, hanghordozás és nyelvhasználat alapján, majd a kapott mintázatokból Big Five dimenziókat becsül (Chamorro-Premuzic et al., 2019).

Ugyancsak figyelemre méltó megközelítés az IBM Watson Personality Insights, amely közösségi média-bejegyzések vagy nyílt szövegek alapján képes meghatározni a személyiségprofilokat, akár olyan részletességgel is, mint a nyitottság, lelkiismeretesség vagy barátságosság szintje (IBM, 2022). A módszer mögött egy mélytanulási rendszer áll, amely több millió nyelvi mintázaton tanult, és képes finoman elkülöníteni a különböző személyiségtípusokat.

Friss kutatások is megerősítik e rendszerek relevanciáját. Li és Zhang (2023) tanulmányukban bemutatták, hogy a GPT-alapú nagy nyelvi modellek képesek olyan munkahelyi szituációkat generálni, amelyek személyiségjellemzőket tesztelnek indirekt módon, például helyzetmegítélési teszteken keresztül (Situational Judgment Tests). Ezek az LLM-ek által írt scenáriók nemcsak tartalmilag hitelesnek bizonyultak, de megbízhatóan prediktálták a résztvevők önértékelésen alapuló személyiségjegyeit is.

Az AI-alapú személyiségértékelés azonban nem csupán kérdőíveket jelent. Egy másik kutatás során Ni et al. (2024) kimutatták, hogy a GPT által generált személyiség-skála tételek pszichometriai jellemzői – például reliabilitás, faktorszerkezet – nem maradnak el az ember által készítettektől. Ezzel lehetővé válik, hogy a kiválasztási rendszerek nagy mennyiségű új itemet állítsanak elő minimális emberi beavatkozással.

Fontos hangsúlyozni, hogy az MI-vezérelt rendszerek hatékonysága és elfogadottsága jelentős részben múlik a felhasználói élményen is. Egy 2025-ös vizsgálatban (Chang & Gierl, 2025) a résztvevők azt jelezték vissza, hogy a mesterséges intelligencia által generált kérdések „természetesebbnek” és kevésbé direktnek hatottak, ami elősegítette az őszinte válaszadást. Ez különösen fontos lehet érzékeny témákban, például stresszkezelés vagy munkahelyi konfliktushelyzetek feltérképezése esetén.

Mindazonáltal az MI-alapú kiválasztás kérdéseket is felvet az átláthatóság, a torzítások és az adatvédelem területén. Az algoritmusok döntéseinek logikája gyakran rejtett, így könnyen előfordulhat, hogy egy jelentkező azért nem jut tovább a kiválasztáson, mert a nyelvhasználata „nem illeszkedik” az algoritmus által megtanult mintához – még ha emberi értékelő számára teljesen elfogadható is lenne. Ezért kulcsfontosságú, hogy ezek a rendszerek csak kiegészítőként, nem kizárólagos döntéshozóként működjenek.

Munkahelyi jóllét és teljesítmény predikciója

A munkahelyi teljesítmény nem egyszerűen az elvégzett feladatok mennyiségén vagy minőségén mérhető. Az, hogy egy dolgozó mennyire elkötelezett, mennyire érzi magát kompetensnek, és mennyire tud mentálisan jelen lenni a munkában, egyre fontosabb mérőszámokká válnak a modern szervezeti pszichológiában. Ezen komplex dimenziók értékelésében és előrejelzésében a mesterséges intelligencia (MI) ma már nem csupán ígéret, hanem egyre inkább működő valóság.

A gépi tanulási algoritmusok például képesek különféle szervezeti adatforrásokat — például teljesítményértékelések, HR-rendszerek, belső kommunikációs csatornák, vagy akár e-mailek és naptárhasználat — alapján előre jelezni, hogy egy munkavállaló milyen valószínűséggel válik kiégés áldozatává, vagy épp mikor érdemes előléptetni (Ravid et al., 2022). Ezek az algoritmusok nemcsak mintázatokat keresnek, hanem folyamatosan tanulnak is, így idővel egyre pontosabb predikciót adhatnak. Ez különösen értékes nagy szervezeteknél, ahol több ezer munkavállaló adatait kellene átlátni emberi erőforrásból szinte lehetetlen módon.

Egy különösen érdekes kutatásban Riemann és munkatársai (2023) azt vizsgálták, hogyan lehet a munkavállalói „digitális lábnyomok”, például e-mail válaszütem, értekezlet-sűrűség, Slack-aktivitás - alapján modellezni a szubjektív jóllétet. A mesterséges intelligencia segítségével nyert predikciók több ponton is korreláltak a klasszikus pszichológiai skálákkal, például a munkával való elégedettség vagy érzelmi kimerültség mértékével. Fontos ugyanakkor megjegyezni, hogy ezek a modellek csak akkor működnek etikusán, ha az adatok kezelése átlátható, és a dolgozók tudnak róla.

A mesterséges intelligencia szerepe nem merül ki az egyének szintjén. Szervezeti szinten is képes kimutatni, hogy mely csapatoknál fordul elő magasabb fluktuáció, csökkenő motiváció vagy épp produktív hullámvölgy. Egy 2024-es tanulmány (Biron et al., 2024) szerint a munkahelyi reziliencia predikciójára is sikerrel alkalmazhatók deep learning modellek. A kutatás szerint az algoritmus képes volt azonosítani azokat a szervezeti egységeket, ahol fokozott támogatásra lenne szükség — még azelőtt, hogy a problémák látványossá váltak volna.

Ugyanakkor, ahogy más HR-alkalmazásoknál, itt is megjelennek az etikai dilemmák. Egy algoritmus, amely képes „előre jelezni” a kiégést, könnyen válhat döntéshozó eszközzé — akár akaratlan diszkrimináció forrásává is. Az emberi tényező, az interjú, a személyes megfigyelés, a munkavállalói tapasztalatok meghallgatása továbbra is nélkülözhetetlen marad. Az MI nem válthatja ki az empátiát, csak támogathatja azt.

Összességében az MI alkalmazása a munkahelyi jóllét és teljesítmény előrejelzésében új lehetőségeket teremt — de csak akkor működik jól, ha technológiai hatékonyságot ötvözünk pszichológiai érzékenységgel és etikai felelősséggel.

Etikai kérdések: diszkrimináció, adatvédelem

Amikor a mesterséges intelligencia belép a munka világába – különösen a kiválasztás, teljesítményértékelés és személyiségprofilozás területére – szinte azonnal felmerülnek az etikai kérdések. Ezek nem csupán elméleti problémák: valós hatással lehetnek emberek életére, lehetőségeikre, sőt, önértékelésükre is.

Az egyik legnagyobb kihívás a mesterséges intelligenciát használó rendszerek torzítása (bias). Bár az algoritmusok gyakran objektívnek tűnnek, valójában tanulási folyamatuk során emberi előítéleteket örökölhetnek meg. Egy MI-modell, amely több ezer önéletrajz alapján tanult, könnyen megtanulhatja, hogy bizonyos nevek, életkorok vagy iskolák preferáltabbak – függetlenül attól, hogy ez valójában mennyire releváns a munkakör szempontjából (Binns et al., 2018). Ez különösen aggasztó lehet például a nemek közti esélyegyenlőség vagy kisebbségi csoportok esélyei szempontjából.

Egy másik kényes terület amit fontos megemlíteni az adatvédelem kérdése. A személyiségprofilozáshoz vagy teljesítménymérésekhez használt algoritmusok gyakran olyan adatokkal dolgoznak, amelyeket a munkavállalók nem tudatosan bocsátottak rendelkezésre, például e-mail mintázatokkal, mozgásadatokkal vagy épp hangfelvételekkel. Bár ezek az adatok technikailag „elérhető”, alapvető kérdés azonban, hogy a felhasználók valóban hozzájárultak-e azok pszichológiai célú feldolgozásához. Az európai GDPR szabályozás éppen ezt a kérdéskört próbálja rendezni, de a gyakorlati alkalmazás még számos nyitott kérdést hagy (Wachter & Mittelstadt, 2019).

Egy friss tanulmányban Raji és munkatársai (2023) azt vizsgálták, hogyan jelennek meg rejtett diszkriminációs mintázatok videóalapú állásinterjú-értékelő rendszerekben. A kutatók rámutattak, hogy bár a rendszer „semlegesnek” tűnt, a valóságban a sötétebb bőrszínű vagy nem amerikai akcentussal beszélő jelölteket gyakrabban értékelte alacsonyabb pontszámra – még azonos válaszminőség mellett is.

Emellett a „black box” probléma is komoly gondot jelent. Sok MI-rendszer döntései nem transzparenssek – azaz még a fejlesztők sem tudják pontosan, milyen mintázatok alapján hozott egy adott döntést a rendszer. Ez nemcsak a visszajelzést nehezíti meg, de azt is, hogy a jelölt jogorvoslatot kérhessen egy elutasítás esetén.

A megoldások keresése már elindult. Egyre több kutatás foglalkozik a „fair AI” fejlesztésével, vagyis olyan algoritmusokkal, amelyek már a tanulás során beépítik az esélyegyenlőségi szempontokat. Emellett megjelennek olyan átláthatósági törekvések is, mint a modelldokumentációk (Model Cards) vagy etikai auditok (Mitchell et al.,

2019), amelyek célja, hogy az MI-rendszerek működését érthetőbbé és elszámoltathatóbbá tegyék.

Végül soron a mesterséges intelligencia nem magától válik etikus vagy etikátlaná – ezt a felhasználás módja határozza meg. A HR-ben alkalmazott MI-rendszerek akkor lehetnek valóban értékes eszközök, ha a technológiai lehetőségek mellé emberi érzékenység, transzparencia és folyamatos etikai kontroll is társul.

Szakirodalom

- Binns, R., Veale, M., Van Kleek, M., & Shadbolt, N. (2018). 'It's Reducing a Human Being to a Percentage': Perceptions of Justice in Algorithmic Decisions. CHI Conference on Human Factors in Computing Systems, 1–14. <https://doi.org/10.1145/3173574.3173951>
- Biron, M., Tziner, A., & Weiss, D. (2024). Predicting Organizational Resilience Through Deep Learning: A Longitudinal Study of Work Units. *Journal of Occupational and Organizational Psychology*, 97(2), 312–329. <https://doi.org/10.1111/joop.12415>
- Chamorro-Premuzic, T., Winsborough, D., Sherman, R. A., & Hogan, R. (2019). New talent signals: Shiny new objects or a brave new world? *Industrial and Organizational Psychology*, 12(3), 252–275. <https://doi.org/10.1017/iop.2019.30>
- IBM. (2022). IBM Watson Personality Insights. Retrieved from <https://www.ibm.com/watson/services/personality-insights/>
- Li, C.-J., & Zhang, J. (2023). Automatic Item Generation for Personality Situational Judgment Tests with Large Language Models. arXiv preprint arXiv:2412.12144. <https://arxiv.org/abs/2412.12144>
- Mitchell, M., Wu, S., Zaldivar, A., Barnes, P., Vasserman, L., Hutchinson, B., ... & Gebru, T. (2019). Model Cards for Model Reporting. Proceedings of the Conference on Fairness, Accountability, and Transparency, 220–229. <https://doi.org/10.1145/3287560.3287596>
- Ni, J., Lin, X., & Huang, L. (2024). Evaluating GPT-based Personality Item Generation in Psychological Assessment. *Journal of AI in Mental Health Research*, 7(1), 55–72.
- Chang, H., & Gierl, M. J. (2025). Naturalistic AI-Generated Questions in Child Psychology Assessments. *Computers in Human Behavior*, 139, 107527. <https://doi.org/10.1016/j.chb.2024.107527>

- Raji, I. D., Smart, A., White, R. N., Mitchell, M., Gebru, T., Hutchinson, B., ... & Barnes, P. (2023). The Disparate Impact of Facial Analysis: Measuring and Mitigating Algorithmic Bias. *ACM Transactions on Computer-Human Interaction*, 30(2), 1–25. <https://doi.org/10.1145/3597617>
- Ravid, D. M., Tomczak, D. L., White, R. P., & Behrend, T. S. (2022). AI in Employee Retention and Burnout Prediction: Ethical Implications and Opportunities. *Personnel Psychology*, 75(1), 55–83. <https://doi.org/10.1111/peps.12439>
- Riemann, R., Fischer, L., & Köhler, T. (2023). Modeling Employee Wellbeing from Digital Communication Traces: An Interdisciplinary Approach. *Computers in Human Behavior*, 141, 107657. <https://doi.org/10.1016/j.chb.2023.107657>
- Wachter, S., & Mittelstadt, B. (2019). A Right to Reasonable Inferences: Re-Thinking Data Protection Law in the Age of Big Data and AI. *Columbia Business Law Review*, 2019(2), 494–620.

Több mint szavak? Számítógépes szövegelemzés a szervezeti viselkedés és pszichológia kutatásában*

A számítógéppel támogatott szövegelemzés (CATA) nagy ígéretet kínál azon tudósok számára, akik arra törekcsenek, hogy megragadják az egyének hiedelmeit, kognícióit és érzelmeit, ahogyan azok narratíváikban és írott szövegekben tükrözödnék. Áttekintjük a CATA szervezeti tanulmányokban való felhasználásának fejlődését, és kiemeljük a CATA használata során a szigor beépítése felé irányuló fokozott momentumot. Áttekintjük a legfontosabb CATA-szoftvereket, és megjegyezzük, hogy a nyelvekből történő jelentéskivonás során a megközelítések lehetőségei mennyire eltéröek. Ezután felvázoljuk e technika lehetőségeit a szervezeti pszichológiát és a szervezeti viselkedést körülvevő tudás építésében. Konkrétan kiemeljük azokat a konkrét kutatási irányokat, amelyek profitálhatnak a CATA használatából, és kiemeljük a kultúrák közötti perspektívákat, amelyek tovább fejleszthetik a technika használatát.

Kulcsszavak: számítógépes szövegelemzés, tartalomelemzés, nyelv, szervezeti magatartás, szervezeti viselkedés

Words are the voice of the heart. - Confucius

I was reading the dictionary. I thought it was a poem about everything. -Stephen Wright

A nyitó idézetek két, egymástól nagyon eltérő nézőpontot mutatnak be a szavak természetéről és használatukról. Kína legnagyobb filozófusa szerint a szavak az egyén gondolatainak, érzéseinek és meggyöződésének lényegét ragadják meg oly módon, hogy potenciálisan betekintést nyújtanak az egyén szívébe. Ezzel szemben Stephen Wright komikus szerint a szavak bemutatása kissé véletlenszerűnek és kaotikusnak tűnhet. A tartalomelemzés olyan technika, amelyet a tudósok számos területen alkalmaznak az egyének által beszédekben, szervezeti narratívákban vagy más kommunikációs médiumokban használt szavak, mondatok és nyelvezet rendszerezésére és értelmezésére. A tartalomelemzés a szavakban vagy elbeszélő szövegekben bemutatott retorikában tükrözödnő megismeréseket, érzelmeket és más jelentéstípusokat ragadja meg. Bár ez a technika alkalmas arra, hogy megragadja az írott és a kimondott szó mély hiedelmeit és gondolatait, ahogyan azt Konfucius javasolta, a tudósoknak óvatosan kell eljárniuk, hogy a tartalomelemzés módja ne eredményezzen olyan gavalléros kísérletet, hogy értelmet származtassanak ott, ahol az nem létezik, ahogyan azt Stephen Wright idézete is példázza.

A tartalomelemzés alkalmazása az érdeklődésre számot tartó jelenségek tanulmányozására gazdag múltra tekint vissza a társadalmi tudományok és

* Short, J. C., McKenny, A. F., & Reid, S. W. (2018). More than words? Computer-aided text analysis in organizational behavior and psychology research. *Annual Review of Organizational Psychology and Organizational Behavior*, 5, 415-435. Fordította: Mészáros Veronika.

bölcsészettudományok több mint egy évszázados múltra visszatekintő kutatásai (pl. Berelson 1952, Holsti 1969, Lasswell 1948, Mathews 1910, Pool 1959). A szervezeti vezetéssel kapcsolatos korai munkák például azt vizsgálták, hogy a termelő szervezetek vezetőinek és feletteseinek interjúleírataiban talált, a vezetői klisékhez kapcsolódó bizonyos témák (pl. csapatmunka, kemény munka, együttműködés) használata és gyakorisága hogyan tájékoztat arról, hogy a szervezeti kontextus hogyan befolyásolja a vezetői orientációt (Rossel 1970). Rossel (1970) azt találta, hogy az, hogy a vezetők mennyire instrumentálisabbak és folyamatorientáltabbak (pl. "Fenn kell tartanom az osztály fegyelmét, ellenőriznem kell, hogy az emberek hatékonysága megfelelő-e", 311-12. o.) vagy mennyire expresszívabbak és kapcsolatközpontúak (pl. "A legnagyobb dolog az emberekkel való kijövésben az, hogy inkább megkérem őket valamire, mint hogy megmondom nekik", 312. o.), attól függött, hogy a szervezetben milyen típusú munkát és milyen szintű munkavállalói elkötelezettséget követel meg. Rossel (1970) munkája jellemző volt a szervezeti tanulmányok korai tartalomelemzési megközelítéseire, amelyek a nyílt végű interjú-átiratok és esettanulmányok kézi kódolására helyezték a hangsúlyt (Jauch et al. 1980).

Egy évtizeddel ezelőtt Duriau és munkatársai (2007) azt mutatták be, hogy a közzétett szervezeti tanulmányok

1980 és 2005 között a tartalomelemzést használták. A vezetői szakfolyóiratokban megjelent 98 tanulmányt vizsgáltak, amelyek különböző kutatási irányzatokat tükröztek, beleértve a szervezeti viselkedést, a vezetői és szervezeti megismerést, az emberi erőforrásokat, valamint az üzletpolitikát és stratégiát. Megállapították, hogy a gazdag adatforrások, például az éves jelentések, a közgyűlési nyilatkozatok és az interjúk átíratainak elérhetősége - az elemzési technikák növekvő kifinomultságával együtt - lehetőséget biztosított a kutatóknak arra, hogy új kontextusban vizsgálják és teszteljék a hipotéziseket, és értékes betekintést nyerjenek, amelyet a hagyományosabb kutatási módszerekkel nehéz volt elérni (Duriau et al. 2007).

A számítógépes szövegelemzés (CATA) megjelenése tovább bővítette a tartalomelemzés alkalmazhatóságát a szervezeti tanulmányokban. A kutatók most már gyorsan és hatékonyan kódolhattak nagy adathalmazokat, miközben csökkentették a kézi kódolás költségeit és idejét (Duriau et al. 2007). Tekintettel ezekre az előnyökre, valamint a CATA által biztosított tökéletes kódolási megbízhatóság lehetőségére, Duriau és munkatársai (2007) meglepődve tapasztalták, hogy mintájukban mindössze 24 tanulmány alkalmazta ezt a technikát. Megjegyezték, hogy a CATA által biztosított jelentős előnyök felülmúlják a korlátokat és azt, hogy ezeket a buktatókat gondosan végrehajtott vizsgálatokkal minimalizálni lehetne. Hangsúlyozták a CATA-technikák fokozott felhasználásának szükségességét a jövőbeli elméletalkotás és hipotézisvizsgálat további javítása érdekében (Duriau et al. 2007). A CATA kiaknázatlan potenciálját tekintve nem meglepő, hogy a módszerekkel foglalkozó tudósok is kiemelték annak ígéretét a szervezeti jelenségek mérésének javítására (Aguinis & Vandenberg 2014).

Szervezés és áttekintés

Először is röviden ismertetjük a CATA elvégzéséhez gyakran használt szoftvercsomagokat, megjegyezve a nyelvből való jelentés kinyerésének különböző megközelítéseit. Ezután felvázoljuk, hogyan használták a CATA-t a menedzsmentkutatásban, arra összpontosítva, hogy a szervezeti tudósok az idők során hogyan fejlődtek és hogyan használták fel a CATA-t az érdeklődésre számot tartó pszichológiai jelenségek feltárására. Ezért kiemelünk 144 empirikus cikket a vezető menedzsment folyóiratokból, amelyek az elmúlt évtizedekben beépítették a CATA elemeit. Különösen a szervezeti viselkedés és a szervezeti pszichológia ismereteinek bővítése szempontjából releváns munkákra összpontosítunk. Végül áttekintésünk rávilágít a szervezeti konstrukciók mérési kérdéseire és a kultúrák közötti összefüggésekre, ahol a CATA mérése kapukat nyithat a nehezen megragadható jelenségek felé. A CATA-kutatás további fejlesztésére való felhívással zárjuk, azt sugallva, hogy a különböző technikák finomítása a CATA-mérés új alkalmazásainak felfedezésével párosulva segíthet jobban megérteni a szavak erejét a szervezeti életben.

E felülvizsgálat céljaira minden olyan cikket kerestünk, amely bármilyen konnotációt említ a CATA-val kapcsolatos kifejezések (pl. "számítógépes szöveg", "számítógépes tartalom"), valamint a CATA szoftverek (pl. "LIWC", "NVivo") említése a következő folyóiratokból: Academy of Management Journal, Administrative Science Quarterly, Journal of Applied Psychology, Journal of International Business Studies, Journal of Management, Journal of Organizational Behavior, Organization Science, Organizational Behavior and Human Decision Processes, Organizational Research Methods, Personnel Psychology és Strategic Management Journal. A nem empirikus cikkeket (pl. áttekintések) vagy a CATA-t a fő elemzés részeként nem használó (pl. lehetséges jövőbeli kutatásként megemlítő) tanulmányokat eltávolítottuk, így végül 144 cikket kaptunk.

A CATA demisztifikálása: kulcsfontosságú megközelítések és szoftvercsomagok

Számos kereskedelmi forgalomban kapható szoftvercsomag létezik, amelyek segítik a tudósokat a különböző CATA-kutatási célok elérésében. A legáltalánosabb megfogalmazásban két kulcsfontosságú megközelítést használtak a CATA erejét kihasználó tudósok. Az egyik megközelítés induktív logikát követ, amelynek során a tudósok vagy kidolgoznak vagy felhasználnak meglévő narratívákat (gyakran félig strukturált interjúk formájában), majd megvizsgálják a tudományos érdeklődésre számot tartó témákat. Az ilyen tanulmányok gyakran a kvalitatív kutatási hagyományokból indulnak ki, amelyek a szervezeti szövegekbe ágyazott átfogó témák gazdag magyarázatát keresik. Ezzel szemben más tudósok a CATA deduktívabb megközelítését használták, amely általában egy kvantitatívabb hagyományt követ. E megközelítés kihasználásakor a tudósok gyakran elméleti konstrukciókhoz kapcsolódó

szótárakat dolgoznak ki, majd ezeket a szótárakat használják a konstrukció szalienciájának mérésére az előzetesen létező elbeszélések mintájában.

A kvalitatív megközelítésen alapuló CATA-t alkalmazó tanulmányra példa de Gama és munkatársai (2012) munkája, akik az erkölcsöt és az etikát vizsgálták kanadai humánerőforrás (HR) szakemberek elbeszéléseiben. Egy folyamatban lévő tanulmány részeként, amely a retorika és a valóság témáit vizsgálta a HR területén, a HR szakemberek két mintájára támaszkodtak, amelyek összesen 40 félig strukturált interjút készítettek. Következésképpen a CATA segítségével elemzett adatok a következő kérdésekre adott válaszokat foglalták magukban a tudósok által a HR-munka természetét körülvevő átfogó kérdések. A kutatók ezután a CATA szoftver segítségével részletes jegyzeteket készítettek, nyomon követték és megszervezték a felmerülő kódolási elemeket, szisztematikusan gyűjtöttek témákat az adatokból, és / vagy a meglévő témák segítségével kapcsolatokat és modelleket állítottak fel. Az ilyen tanulmányok általában az általános témák feljegyzésével haladnak, és gyakran kiemelik a vizsgálati alanyoktól származó konkrét idézeteket. A tudósok például a HR szerepét övező erkölcsi ambivalencia témáját jegyzik meg, miután egy Cindy nevű alany gondolatait vizsgálták (de Gama et al. 2012, 104. o.): Tudod, ha a HR-esekre gondolkodok, két kalapot kell viselniük, igaz? Tehát ha nem a HR-es vagy, és nem örülsz valaminek, akkor megfordulhatsz, és azt mondhatod, hogy tudod, én mint munkavállaló nem örülök ennek. De ha a HR-es vagy, és nem örülsz valaminek, lehet, hogy nem értesz vele egyet, de attól még ki kell menned, és támogatnod kell a döntést, bármi is legyen az. Ezt el kell adnunk az embereknek, akár tetszik, akár nem. Akár úgy gondoljuk, hogy igazságos, akár nem. A marketingben ezt nem kell megtenni. Megfordulhatnak, és azt mondhatják: "Tudod mit, én nem értek ezzel egyet, miért kell ennek így lennie.

Összességében a CATA ezen formája hasznos segítség a tudósok számára a kvalitatív megközelítésben, mivel lehetővé teszi a narratívák szisztematikus kódolását és elemzését azzal a céllal, hogy széleskörű tudományos kérdéseket vizsgáljon nagyrészt induktív módon.

Madera és munkatársai (2009) munkája jól szemlélteti a CATA kvantitatívabb megközelítésében rejlő lehetőségeket. Tanulmányuk részeként a társadalmi szerepelméletet használták fel arra a hipotézisre, hogy "a férfiak nagyobb valószínűséggel írják le az ajánlólevelekben ügynöki kifejezésekkel, mint a nők" (Madera et al. 2009, 1592. o.). Állításukat 624 ajánlólevélből és 194, 8 egyetemi tanári állásra benyújtott pályázatból álló mintán tesztelték, és a LIWC CATA szoftvercsomag kognitív mechanizmusok, mozgás és teljesítmény indexeinek összegzésével létrehozták az ügynöki orientáció mérőszámát. Szótáralapú "szózsákos" megközelítéssel megvizsgálták ezen összetett index szavainak gyakoriságát (beleértve olyan szavakat, mint a "keresni", "szerezni", "tenni", "tudni", "belátni" és "gondolkodni"), és azt találták, hogy a férfiak valóban több ágenciális kifejezést használtak az ajánlólevelekben, mint a nők. Összefoglalva, ez a megközelítés akkor értékes, ha a szótári kifejezések valamilyen kombinációja használható a meglévő adatokból való jelentés kinyerésére. Tekintettel arra, hogy számszerűsíteni lehet, hogy a szótárban szereplő szavak milyen mértékben vannak vagy nem vannak jelen egy szövegben, ezt a

megközelítést gyakran használják az elméleti alapú (kvantitatív) hipotézisek tesztelésének segítésére.

Az 1. táblázat összefoglalja a CATA elvégzéséhez általánosan használt szoftverprogramokat a szervezeti tanulmányok során. Az alábbiakban a leggyakrabban használt csomagokat ismertetjük.

	ATLAS.ti	NVivo	DICTION	LIWC
Elsődleges használat	Induktív; megalapozott elmélet, tematikus elemzés	Induktív; megalapozott elmélet, tematikus elemzés	Deduktív; szótáralapú kódolás	Deduktív; szótáralapú kódolás
Narratív típusok	Éves jelentések, médiacikkek, átirrt interjúk	Éves jelentések, médiacikkek, átirrt interjúk	Éves jelentések, médiacikkek, szervezeti kommunikáció, online tartalom, sajtóközlemények, részvényesi levelek, átiratok (pl. beszédek, híváslisták)	Éves jelentések, médiacikkek, szervezeti kommunikáció, online tartalom, sajtóközlemények, részvényesi levelek, átiratok (pl. beszéd, híváslisták)
Támogatott fájltypusok	Hang (.au, .mp3, .snd), képek (.bmp, .jpg, .tif), PDF, szöveg (.doc, .docx, .rtf, .txt), videó (.mov, .mpg, .qt)	Hang (.au, .m4a, .mp3, .snd, .wav, .wma), képek (.bmp, .jpg, .tif), mobil (.3gp), PDF, táblázatkezelés (.xls), szöveg (.doc, .docx, .rtf, .txt), videó (.avi, .mov, .mpe, .mpeg, .mpg, .mts, .qt, .wmv)	PDF, szöveg (.doc, .docx, .html, .rtf, .txt)	PDF, szöveg (.doc, .docx, .rtf, .txt), táblázatkezelő (.csv, .xls), táblázat (.csv, .xls)
Főbb jellemzők	Támogatja a nyílt kódolást, az automatikus kódolást és a jelöléseket Vizualizálja a kódok közötti kapcsolatokat és hálózatokat. és kódcsoportok között Fájltypusok és adatforrások közötti kódok összekapcsolása Előre definiált kód nélküli szövegszegmensek vagy szavak rögzítése Támogatja a Google	Támogatja a nyílt kódolást, az automatikus kódolást és a jelöléseket Vizualizálja a kódok közötti kapcsolatokat és hálózatokat és kódcsoportok között Lehetővé teszi az adatok egyidejű használatát és megosztását a kutatócsoport tagjai között Importál adatokat a szociális médiaoldalokról (pl. Facebook, Twitter) Több nyelv	Gyorsan kiszámítja a szavak számát és gyakoriságát Tartalmaz 35 előre betöltött szótárat a szóválasztás és a hangnem szempontjainak megragadására. Teljesítményelemzési módot kínál a nagy mennyiségű adat gyors elemzéséhez (>7.000 dokumentumok) Egyéni szótárak létrehozása vagy betöltése	Gyorsan kiszámítja a szavak számát és gyakoriságát Tartalmazza a dimenziók megragadását célzó, előre betöltött szótárakat. a nyelvtan Több mint 50 hitelesített szótárat tartalmaz különböző pszichológiai folyamatokhoz Több nyelven is támogatja Egyéni szótárak létrehozása vagy

Earth és a GEO dokumentumokat Adatok importálása a közösségi médiaoldalak (pl. Facebook, Twitter) Hiperhivatkozások létrehozása dokumentumokon belül és azokon keresztül Exportálás több programokba (Excel, PDF, SPSS, Word)	támogatása Hiperhivatkozások létrehozása a és a dokumentumok között Hivatkozások számítása a bírálók közötti megbízhatósági mutatókra	50 000 korábban elemzett szöveget tartalmazó adatbázist tartalmaz a következőkhöz a megállapítások összehasonlításához	betöltése
--	--	--	-----------

ATLAS.ti és NVivo

Az ATLAS.ti (amelyet a Scientific Software Development GmbH fejlesztett ki) és az NVivo (amelyet a QSR International fejlesztett ki) olyan szoftverek, amelyeket nagy mennyiségű szöveges, grafikus, hang- és videoadatok kvalitatív tartalomelemzésének megkönnyítésére terveztek. Úgy tervezték, hogy a felhasználók számára lehetővé tegyék a megállapítások egyszerű szervezését, megtalálását, kódolását és megjegyzéseit, mindkét programot általában a kézi kódolás segítségével használják, lehetővé téve a kutatók számára, hogy kiválasszák a szövegek passzusait, és könnyen kódolják őket egy új vagy meglévő csomópontba (Krippendorff 2013). A kutatók ezután ezeket a csomópontokat hierarchiákba rendezhetik, modellezhetik a csomópontok közötti kapcsolatokat, és a kézirat kódolása alapján különféle jelentéseket és vizualizációkat hozhatnak létre.

E programok talán legjellemzőbb tulajdonsága az a kódolási rugalmasság, amelyet az elemzés kezdeti fázisaiban biztosítanak. A hagyományos megalapozott elmélet a kódolás több fázisát foglalja magában, hogy a nagy mennyiségű adatot kisszámú fogalomra redukálja, amelyek egy-egy a teljes adathalmazon belül az adott jelenséget (Charmaz 2014). Mind az ATLAS.ti, mind az NVivo lehetővé teszi a szövegszegmensek kódolását, lehetővé téve a felhasználók számára, hogy megjegyezzék a tartalom fontosságát, és a tanulmány szempontjából érdekes jelenségekhez kapcsolják. Ez lehetővé teszi a kutatók számára, hogy jobban megértsék az egyes adatok kontextusát, mielőtt megvizsgálják, hogy milyen főbb témák vagy tendenciák terjednek át egy egész projektre (Maietta 2009). A projektek a szöveg nyílt leltárával kezdődnek, ami lehetővé teszi az adatok kódolását a fő témák és tendenciák alapján, amelyek organikusan keletkeznek, ahelyett, hogy az adatok kódolásának előfeltevései vezetnék őket (Friese 2014). Az ilyen funkciók lehetővé teszik a kutatók számára, hogy hatékonyan kezeljék az adatokból kialakuló, az érdeklődésre számot tartó konstrukció vagy jelenség szempontjából releváns kapcsolatokat egy erőteljesebb és mélyebb elméleti elemzéshez.

1. táblázat Az általánosan használt kereskedelmi CATA szoftverek áttekintése.

	ATLAS.ti	NVivo	DICTION	LIWC
Elsődleges használat	Induktív; megalapozott elmélet, tematikus elemzés	Induktív; megalapozott elmélet, tematikus elemzés	Deduktív; szótáralapú kódolás	Deduktív; szótáralapú kódolás
Narratív típusok	Éves jelentések, médiacikkek, átírt interjúk	Éves jelentések, médiacikkek, átírt interjúk	Éves jelentések, médiacikkek, szervezeti kommunikáció, online tartalom, sajtóközlemények, részvényesi levelek, átiratok (pl. beszédek, híváslisták)	Éves jelentések, médiacikkek, szervezeti kommunikáció, online tartalom, sajtóközlemények, részvényesi levelek, átiratok (pl. beszéd, híváslisták)
Támogatott fájlformátumok	Hang (.au, .mp3, .snd), képek (.bmp, .jpg, .tif), PDF, szöveg (.doc, .docx, .rtf, .txt), videó (.mov, .mpg, .qt)	Hang (.au, .m4a, .mp3, .snd, .wav, .wma), képek (.bmp, .jpg, .tif), mobil (.3gp), PDF, táblázatkezelés (.xls), szöveg (.doc, .docx, .rtf, .txt), videó (.avi, .mov, .mpe, .mpeg, .mpg, .mts, .qt, .wmv)	PDF, szöveg (.doc, .docx, .html, .rtf, .txt)	PDF, szöveg (.doc, .docx, .rtf, .txt), táblázatkezelő (.csv, .xls), táblázat (.csv, .xls)
Főbb jellemzők	Támogatja a nyílt kódolást, az automatikus kódolást és a jelöléseket Vizualizálja a kódok közötti kapcsolatokat és hálózatokat. és kódcsoportok között Fájlformátumok és adatforrások közötti kódok összekapcsolása Előre definiált kód nélküli szövegszegmensek vagy szavak rögzítése Támogatja a Google Earth és a GEO dokumentumokat Adatok importálása a közösségi médiaoldalak (pl. Facebook, Twitter) Hiperhivatkozások létrehozása dokumentumokon	Támogatja a nyílt kódolást, az automatikus kódolást és a jelöléseket Vizualizálja a kódok közötti kapcsolatokat és hálózatokat és kódcsoportok között Lehetővé teszi az adatok egyidejű használatát és megosztását a kutatócsoport tagjai között Importál adatokat a szociális médiaoldalakról (pl. Facebook, Twitter) Több nyelv támogatása Hiperhivatkozások létrehozása a dokumentumok között Hivatkozások számítása a bírálók	Gyorsan kiszámítja a szavak számát és gyakoriságát Tartalmaz 35 előre betöltött szótárat a szóválasztás és a hangnem szempontjainak megmagyarázására. Teljesítményelemzési módot kínál a nagy mennyiségű adat gyors elemzéséhez (>1.000 dokumentumok) Egyéni szótárak létrehozása vagy betöltése 50 000 korábban elemzett szöveget tartalmazó adatbázist tartalmaz a következőkhöz a megállapítások	Gyorsan kiszámítja a szavak számát és gyakoriságát Tartalmazza a dimenziók megmagyarázását célzó, előre betöltött szótárakat. a nyelvtan Több mint 50 hitelesített szótárat tartalmaz különböző pszichológiai folyamatokhoz Több nyelven is támogatja Egyéni szótárak létrehozása vagy betöltése

	belül és azokon keresztül Exportálás több programokba (Excel, PDF, SPSS, Word)	közötti megbízhatósági mutatókra	összehasonlításához	
--	---	----------------------------------	---------------------	--

Bár az ATLAS.ti-t és az NVivo-t jellemzően a kézi kódolásban való segítségnyújtással hozzák összefüggésbe, mindkettő számos olyan funkciót kínál, amelyek a szótáralapú CATA megisméltésére is felhasználhatók. Például a szótárhoz kapcsolódó szavakat keresőkérésekbe lehet beírni, amelyek eredményei az érdeklődésre számot tartó konstrukcióhoz kapcsolódó kódhoz vagy csomópontokhoz menthetők. A kutatók ezután a jelentéstételi funkciók segítségével kivonhatják az egyes szövegekhez kapcsolódó egyes konstrukciókra vonatkozó hivatkozások teljes számát. Az ilyen funkciókat szótáralapú elemzések elvégzésére használó kutatóknak gondosan meg kell vizsgálniuk a projektjeikben használt stop szavak listáját. A stop szavakat a tartalomelemzésben a nyelvben leggyakrabban használt szavak listájának azonosítására használják, amelyek nem jelzik a jelentést, és ezért nem kell figyelembe venni az elemzés részeként (Manning & Schütze 1999). Mivel az ATLAS.ti és az NVivo figyelmen kívül hagyja ezeket a szavakat, ha bármelyik szó megjelenik a szótárban, akár önállóan, akár mondatok részeként, nem tekintik a lekérdezés részének, és hamis pozitív vagy hamis negatív eredményt adhatnak. Például egy egyén időbeli orientációját vizsgáló tudósokat érdekelheti az olyan szavak gyakorisága, mint a "közben" és a "korábban"; ezek a szavak azonban szerepelnek az NVivo alapértelmezett stop szavak listájában, ezért a lekérdezés nem azonosítja őket, és hamis negatív eredményt eredményeznek. Ezzel szemben egy tudós, aki az egyének kudarcával való foglalkozását vizsgálja, a "let down" kifejezést kiemelkedő vizsgálandó kifejezésnek azonosíthatja. Mivel azonban az NVivo a "le" szót stop szóként tekinti, a lekérdezés a "let" szó minden előfordulását úgy adná vissza, mint ami erre a foglalatosságra utal, ami hamis pozitív eredményt eredményezne.

A szótáralapú kódolási funkciók replikációján túlmenően más funkciók is rendelkezésre állnak mindkét program által, amelyek segíthetik a CATA-ra támaszkodó kutatókat. Különösen a két program kvalitatív irányultsága segíthet a CATA egyik kiemelkedő gyengeségének ellensúlyozásában: a hamis pozitív eredmények veszélye, amikor a konstrukttal összefüggésbe hozhatónak vélt szót rendszeresen kontextuson kívül használják a szövegmintában. Az ATLAS.ti és az NVivo többféleképpen segítheti a kutatókat ennek az aggodalomnak az értékelésében és kezelésében. Például a beágyazott kézi kódolási támogatás lehetővé teszi a szövegek egy részmintájának kézi kódolását gyorsabb és egyszerűbb módon, mint a papír- és ceruzás módszerek. Azáltal, hogy a számítógépes elemzés párhuzamos kézi vizsgálatát és a kódolt szavakról szóló jelentést végezhetik, a kutatók azonosíthatják, hogy a szavakat milyen mértékben használják kontextuson kívül, és ennek megfelelően módosíthatják a szótárt (pl. McKenny et al. 2016).

LIWC

A Linguistic Inquiry and Word Count (Pennebaker Konglomerátumok által) eredetileg James Pennebaker és Martha Francis pszichológusok fejlesztették ki 1991-ben, hogy megkönnyítsék az érzelmi megrázkódtatásokat átélt emberek által írt esszék szisztematikus vizsgálatát (Neuendorf 2017, Tausczik & Pennebaker 2010). Ez a szótáralapú CATA-eszköz mára kibővült, és jelenleg közel 90 szótárat tartalmaz, amelyekkel több nyelven, többek között angol, német, spanyol és kínai nyelvű szövegek feldolgozhatók (Pennebaker et al. 2015).

A LIWC számos szótárat tartalmaz, amelyek egy szöveg nyelvtani dimenzióit írják le, például a névmások, cikkek és gyakori melléknevek számát (Pennebaker et al. 2015). Ezek a szótárak fontos betekintést nyújtottak a szöveg szerzőjének pszichológiai aspektusaiba: Például az egyes szám első személyű névmások gyakori használata összefüggésbe hozható a neuroticizmussal (Pennebaker et al. 2003). A LIWC pszichológiai eredetét azonban a pszichológiai folyamatokra vonatkozó több mint 50 belső szótár is feltárja (Pennebaker et al. 2015). A pszichológiai folyamatszótárak az affektív folyamatszótáraktól, például a pozitív és negatív érzelmeket vizsgáló, a szervezetszociológiai és az orga- nizációs viselkedési irodalomban nagymértékben használt affektív folyamatszótáraktól (pl. Bono & Ilies 2006, Brett et al. 2007, Friedman et al. 2004) az ígéretes, de kevésbé használt pszichológiai hajtóerő-szótárakig terjednek, amelyek a hovatartozás, a teljesítmény és a hatalom iránti igényeket vizsgálják (pl. Chen & Latham 2014, Shantz & Latham 2009). A LIWC 2015-ös kiadása több olyan számított változót vezetett be, amelyek más szótárak értékeiből származnak, és nem önálló szótárakat tükröznek: analitikus gondolkodás, befolyásoltság, hitelesség és érzelmi hangvétel (Pennebaker et al. 2015). Sajnos, mivel ezeknek a változóknak a kiszámítása a LIWC szoftver sajátja, a kutatók számára nem átláthatóak (Pennebaker et al. 2015). Mindazonáltal, ha ezek az intézkedések érvényesnek bizonyulnak a szervezeti környezetben, akkor elősegíthetik az új betekintést a szervezeti pszichológia és viselkedéskutatás számos értékes területére. Például a szervezetekben való bizalommal kapcsolatos kutatások megvizsgálhatják a hitelesség mértékét, amelyet a LIWC-ben végzett, a szövegekben a megtévesztés szerepét feltáró kutatások alapján fejlesztettek ki (pl. Newman et al. 2003). Hasonlóképpen, a szervezetekben az érzelmelekkel kapcsolatos kutatások az érzelmi tónus mérőszámot használhatják annak megállapítására, hogy a munkahelyi érzelmi eseményeket követően hogyan változik az attitűd (pl. Cohn et al. 2004).

DICTION

Az eredetileg a politikai beszéd vizsgálatára kifejlesztett DICTION szoftver (amelyet Roderick P. Hart készített és a Digitex, Inc. fejlesztett ki) a szóválasztás és a beszédhangzás szempontjait elemzi (Hart 1984). Ami a szóválasztást illeti, a DICTION szoftvercsomag 31 előre meghatározott szótárat tartalmaz. Ezekből a szótárakból öt fő

változót állítanak össze, amelyekről a szoftver megalkotója, Hart (2001, 45. o.) így érvel: "Ha csak öt kérdést lehetne feltenni egy adott szöveggel kapcsolatban, akkor ez az öt adná a legmegbízhatóbb megértést".

A "bizonyosság" főváltozót egy olyan képlet alapján számítják ki, amely összeadja az állhatatosságot, a kiegyenlítést, a kollektívet és a ragaszkodást jelentő szótárakat, majd levonja a numerikus kifejezéseket, az ambivalenciát, az önreferenciát és a változatosságot jelentő szavakat. Ennek a megközelítésnek a logikája a határozottságot és a magabiztosságot jelző mértékegység létrehozása. Az "optimizmus" főváltozót Barber (1992) tanulmánya inspirálta, amely az optimizmust vizsgálta az elnöki karakter megértésével összefüggésben. Ez a munka a támogatásra utaló nyelvezetet vizsgálja, és a dicséretet, elégedettséget és inspirációt jelző szótárak összegzésével és a hibáztatást, nehézséget és tagadást jelző szótárak levonásával számítják ki. Az "aktivitás" főváltozó a jelentés mérésén alapul (Osgood et al. 1957), és a gondolatok mozgását és a tehetetlenség elkerülését jellemző nyelvezetet vizsgálja. Ez a változó az agresszióra, teljesítményre, kommunikációra és mozgásra utaló szavakat tartalmazó szótárakat kombinálja, míg a kognitív kifejezésekkel, passzivitással és szépítgetéssel kapcsolatos szavakat levonja. A "realizmus" fő változó a nyelvet azzal a céllal vizsgálja, hogy Dewey (1931) pragmatizmusról szóló munkáját megcsapolja. Ez a változó a kézzelfogható, azonnali és felismerhető dolgokat leíró nyelvet vizsgálja azáltal, hogy az ismertséget, a térbeli tudatosságot, az időbeli tudatosságot, a jelenbeli aggodalmakat, az emberi érdeklődést és a konkrétságot jelző szótárakat összegzi, míg a múltbeli aggodalmakat és a komplexitást jelző szótárakat levonja. Az Etzioni (1993) munkájában fellelhető komunitárius koncepciók által inspirált "közös-ality" fő változó a csoport által elfogadott értékekre utaló nyelvezetet vizsgálja. Összeadja a központiséget, az együttműködést és az egyetértést tükröző szótárakat, miközben kivonja a sokféleséget, a kirekesztést és a felszabadultságot tükröző szótárakat.

A DICTION a szóbeli hangszínt illetően egy sor mérőszámot is tartalmaz, amelyek a számított változók. Ezek a változók (amelyek közül néhányat a főváltozók létrehozására használnak) inkább egy adott szövegben található mintákat tükröznek, mint egy adott szótárból származó szavak számolását. Például a "ragozás" változó annak függvénye, hogy milyen gyakran ismétlődnek szavak egy adott szövegben. A DICTION a szavak "változatosságát" is vizsgálja a szövegben található szavak számának és az összes szónak az elosztásával. Végül a DICTION a szavak "összetettségét" is méri azáltal, hogy megvizsgálja az adott szövegben az egy szóra jutó karakterek átlagos számát.

Egyéb szoftvercsomagok

A CAT Scanner (Aaron F. McKenny és Jeremy C. Short tervezte) egy ingyenes CATA eszköz, amely a menedzsment szakirodalomban jelent meg, hogy megkönnyítse a CATA-val kapcsolatos számos folyamatot. Először is, a CAT Scanner segít eltávolítani a speciális karaktereket a szövegfájlokból a CATA-elemzés megkönnyítése érdekében. A különleges karakterek gyakran akkor fordulnak elő, amikor az optikai karakterfelismerő

technológia nem tökéletesen felismert karakterek egy képből vagy PDF-ből rajzolt szövegben. Például az "innovatív" szó "innovatív↑" formában olvasható. Míg e szavak hasonlósága valószínűleg egyértelmű egy emberi kódoló számára, sok CATA-csomag alapértelmezés szerint különálló szavakként azonosítja ezeket. Ennek eredményeképpen a CATA az "innovatív" szót kereső elemzések nem számítanak ezt a szót az elemzés szempontjából relevánsnak, ami hamis negatív megfigyeléshez vezetne. A CAT Scanner számos ilyen karaktert eltávolít a szövegfájlból, így a szövegek és az elemzések tisztábbak lesznek. Másodszor, a CAT Scanner megkönnyíti a CATA szótár létrehozását az induktív szólista-generáló funkciója révén. Short és munkatársai (2010) kiemelik annak fontosságát, hogy a kutató szövegmintájából vett szavakat figyelembe kell venni az új szótárak tartalmi érvényességének biztosítása érdekében. A CAT Scanner megkönnyíti ezt azáltal, hogy a mintában szereplő szövegekben háromszor vagy többször használt szavak listáját generálja. Végül a CAT Scanner képes szótáralapú CATA-elemzéseket végezni. McKenny és munkatársai (2016) például korábban létrehozott szótárakat használnak fel, és a CAT Scanner segítségével mérik a szervezeti ambidexteritást, a vállalkozói orientációt és a piacorientációt a CATA-kutatásban előforduló mérési hibákról szóló tanulmányukban.

Az elemzések jelentős testreszabhatósága miatt a gépi tanulást és a természetes nyelvi programozást alkalmazó új CATA-technikák gyakran megkövetelik a számítógépes programozás (pl. R, Python, Java) ismeretét. Mindazonáltal az ezeket a technikákat használó szervezeti kutatók számára egyre inkább elérhetőek az útmutatók és a mintakódok. Kobayashi és kollégái (2017b) például számos szövegbányászati technikát vázolnak fel, és bemutatják, hogyan alkalmazható a témamodellzés a munkakörök elemzésére, kiegészítésként pedig R-kódjukat adják meg. Hasonlóképpen, Kobayashi és munkatársai (2017a) felvázolják a szövegosztályozás folyamatát R-ben, ismét bemutatva az eljárást humánerőforrás-adatok felhasználásával, és a kódot elérhetővé téve az olvasók számára.

Kutatási trendek és témák

Talán a CATA legfontosabb előnye, és elsődleges megkülönböztetése más elemzési technikáktól az, hogy képes nagy mennyiségű minőségi és szöveges adatot gyorsan kezelni és hatékonyan elemezni a rendelkezésre álló CATA-specifikus szoftvercsomagok bármelyikén keresztül (Short & Palmer 2008). Az ilyen programok használata stabil kódolási sémát, összehasonlítható eredményeket biztosító explicit kódolási szabályokat és tökéletes megbízhatóságot biztosít a tudósok számára, ami lehetővé teszi számukra, hogy jobban összpontosítsanak az érvényességre, az értelmezésre és a magyarázatra (Bligh et al. 2004, Morris 1994). A CATA segítségével a tudósok új adatkészleteket használhatnak fel, és tovább vizsgálhatják az érdeklődésre számot tartó jelenségeket olyan kontextusokban, amelyekről korábban úgy gondolták, hogy hagyományos módszerekkel, például felmérésekkel nem állnak rendelkezésre (Bardi et al. 2008). Ezen

előnyöket figyelembe véve nem meglepő, hogy a CATA népszerűsége az elmúlt évtizedekben egyre nőtt a menedzsmentkutatásban.

Áttekintést nyújtunk a legfontosabb kutatási témákról és tendenciákról, amelyek olyan tanulmányokból származnak, amelyek a CATA-t használják elemzésük egészéhez vagy egy részéhez. A 2. táblázat a CATA-t alkalmazó kutatásokat publikáló folyóiratokat tartalmazza. A 3. táblázat az egyes tanulmányokban használt különböző szövegtípusokat mutatja be, a 4. táblázat pedig az egyes tanulmányok által használt különböző szoftverprogramok bontását tartalmazza.

Bár a CATA-t számos tudós használta a menedzsment területén belül több tudományágban (pl. szervezeti viselkedés, stratégiai menedzsment, vállalkozói tevékenység), mi kifejezetten a szervezeti viselkedéssel és pszichológiával kapcsolatos kutatásokra összpontosítunk.

2. táblázat CATA-t alkalmazó tanulmányok a vezető szervezeti kutatási folyóiratokban

Folyóirat	Tanulmányok száma
<i>Academy of Management Journal</i>	46
<i>Journal of Organizational Behavior</i>	18
<i>Organization Science</i>	17
<i>Stratégiai menedzsment folyóirat</i>	13
<i>Alkalmazott pszichológia folyóirat</i>	12
<i>Menedzsment folyóirat</i>	12
<i>Administrative Science Quarterly</i>	9
<i>Nemzetközi üzleti tanulmányok folyóirat</i>	8
<i>Szervezeti viselkedés és emberi döntési folyamatok</i>	6
<i>Szervezeti kutatási módszerek</i>	3
<i>Személyzeti pszichológia</i>	0

3. táblázat A CATA-vizsgálatokban használt példanarratívák

Minta típusa	Tanulmányok száma	A tanulmányok százalékos aránya
Átírt interjúk	47	33%
Többszörös narratívák	27	19%
Médiacikkek	18	13%
Éves jelentések	12	8%
Részvényesi levelek	10	7%
Kísérleti jegyzőkönyvek	7	5%
Szervezeti narratívák	7	5%
Kérdőívek	4	3%

Helyszíni megfigyelések	3	2%
Online tartalom	3	2%
Átiratok (beszéddek, híváslisták)	3	2%
Egyéb	3	2%

4. táblázat Kereskedelmi CATA szoftverek használata

Szoftvercsomag	Tanulmányok száma	Tanulmányok százalékos aránya
Nvivo	51	35%
LIWC	30	21%
ATLAS.ti	27	19%
Egyéb	13	9%
DICTION	10	7%
Általános kérdező	5	3%
MonoConc Pro	5	3%
VBPro	3	2%

A CATA-t nagy mennyiségű kvalitatív adat kezelésére és elemzésére használták (pl. átírt interjúk), amelyek lehetővé tették a megalapozott elméleti megközelítést alkalmazó tudósok számára, hogy feltárják a felmerülő témákat és megválaszolják az egyének viselkedését és motivációit érintő kérdéseket, például a kreativitást (Sonenshein 2014), a távozási szándékot (Felps et al. 2009), szerénység (Ridge & Ingram 2014), kognitív feldolgozás és döntéshozatal (Basu & Savani 2017), benyomáskezelés (Wilhelmy et al. 2016), munkahelyi stressz (Barley et al. 2011), munka és magánélet egyensúlya (Kreiner et al. 2006, 2009), kulturális különbségek (Caprar 2011, Cerdin et al. 2014, Fisher & Hutchings 2013, Kellogg et al. 2006) és a különböző eredményekre adott reakciók (Savani & King 2015).

A tudósok a validált CATA szólistákat a narratív szövegek más formáira is alkalmazták az egyéni viselkedések és kogníciók további feltárása érdekében. Barclay & Skarlicki (2009) különböző érzelmi és kognitív utalásokat mért egy kísérletben résztvevők írásmintáiban, hogy megmutassák, hogyan enyhíthetik az expresszív írásbeli beavatkozások a munkahelyi igazságtalanság észlelését. A kísérletben résztvevők írásmintáit arra is felhasználták, hogy a motivációs képek célmeghatározásra gyakorolt hatását vizsgálják a mintában használt, a teljesítményhez kapcsolódó szavak számának mérésével (Chen & Latham 2014, Shantz & Latham 2009). Savani & King (2015) az ok-okozati szavak (pl. "mert", "hatás", "ezért"), pozitív szavak és negatív szavak használatát számolták, és azt találták, hogy azok az egyének, akik a korábbi cselekvéseket inkább eseményeknek, mint választásoknak tekintették, kevésbé aggódtak a jövőbeli döntések kimenetele miatt.

Vezetői magatartásformák

A tudósok a CATA-t arra is felhasználták, hogy jelentős mértékben hozzájáruljanak a vezetői jellemzők és a menedzseri viselkedés tanulmányozásához. A tudósok tanulmányozták, hogyan viszonyulnak a vezetők a munkavállalókhoz (Abrahamson & Eisenman 2008), hogyan közelítik meg a vezetők a szervezeti leépítést (Palmer et al. 1997), hogyan befolyásolják a felettesek a munkavállalók hangját (Detert & Treviño 2010), hogyan befolyásolják a vezetői diszpozíciók az innovációt (Heyden et al. 2015), és miért viselkednek egyes vezetők visszaélészerűen (Liang et al. 2016).

A különböző vezetői elbeszélések egyre szélesebb körű elérhetőségének köszönhetően a tudósok képesek voltak a CATA szólistákat nagy adathalmazokra alkalmazni, hogy további betekintést nyerjenek a vezetői kognícióba és viselkedésbe. Fanelli és munkatársai (2009) például újonnan validált szólistákat használtak, hogy megállapítsák, hogy a karizmatikus víziók projekciói egy vezérigazgató részvényeseknek írt éves levelében hajlamosak voltak nagyobb bizalmat kelteni a külső közönségben. A vezérigazgató status quo iránti elkötelezettségét mérő új szólistát használva a részvényeseknek írt levelekből azt is megállapították, hogy a status quo iránti magas szintű elkötelezettség károsan hat a jövőbeli teljesítményre (McClelland et al. 2010). A részvényesi leveleket a vezérigazgatói figyelemhez és fókuszhoz kapcsolódó különböző szólisták segítségével is elemezték, hogy meghatározzák, hogyan befolyásolja a vezérigazgató szintje és fókuszterülete az általános teljesítményt (Gamache et al. 2015, Surroca et al. 2016). A beszédek és konferenciahívások átiratait szószámok és a DICTION dicsérő és önreferencia szótárak segítségével elemezték, hogy mérjék a felsővezetői szerénység szintjét (Ridge & Ingram 2014). Elnöki beszédeket elemezték, hogy lássák, hogyan változnak a vezető retorikájának elemei (pl. optimizmus, hit, agresszió, ambivalencia) a válság utáni környezetben (Bligh et al. 2004).

Csapatok megismerése és teljesítménye

A csapatszintű hatásokat és viselkedést vizsgáló tanulmányok szintén használták a CATA-t. A tudósok a csapatmunka metaforáinak új szólistáit alkalmazták a munkavállalói interjúkhoz, hogy jobban megértsék a csapat szerepével, hatókörével, tagságával és céljaival kapcsolatos elvárások mintáit különböző kulturális kontextusokban (Gibson & Zellmer-Bruhn 2001). A munkacsapatokról szóló felettesek jelentéseit elemezték a következő listák segítségével a kultúrákkal (ember- és versenyorientált), a stratégiákkal (stabilitás-, növekedés- és ügyfélorientált), valamint a humánerőforrás-gyakorlatokkal (sokszínűség- és képzésorientált) kapcsolatos kifejezések, hogy megértsük e munkacsoport-kontextusok moderáló hatását a csoport sokszínűsége és a teljesítményeredmények közötti kapcsolatra (Jehn & Bezrukova 2004). Bezrukova és munkatársai (2012) a csapattagok kérdőíves válaszára egy egyéni szólistát alkalmaztak az eredményorientált kultúra jelenlétével kapcsolatban, hogy mérjék a csoporthibák hatását a csapatteljesítményre. Más tanulmányok éves jelentésekből származó

szöveget használták annak megértéséhez, hogy a globális integrációk hogyan befolyásolták a csapat tanulási képességeit (Zellmer-Bruhn & Gibson 2006), hogy a többnyelvű virtuális csapatok közötti nyelvi akadályok hogyan befolyásolták a csapaton belüli interakciókat (Tenzer & Pudelko 2016), és hogy a nyelvi akadályok hogyan befolyásolták a bizalom kialakulását a multinacionális csapatokban (Tenzer et al. 2014).

A hangszín hatása

A CATA egyik legfontosabb előnye, hogy képes a szöveg mély kontextuális szintjén vizsgálni a szöveg mögöttes témáit és mintáit (Bligh et al. 2004, Kabanoff 1996). Ez különösen hasznos volt azon tudósok számára, akik azt igyekeznek jobban megérteni, hogy az emberek által az egymással való kommunikáció során használt hangnem vagy a szervezetek által a külső közönséggel való kommunikáció során használt hangnem hogyan alakítja a viselkedést és az észleléseket. A tudósok számos validált hangnemszótárat (pl. pozitív, optimista) alkalmaztak a szervezeti narratívákra, hogy további betekintést nyerjenek a konkrét cselekvésekbe és viselkedésekbe. Például több tanulmány is különböző hangnemszótárakat használt annak feltárására, hogy a médiában megjelenő hírek hogyan befolyásolhatják a szervezeti megítélést (Bednar 2012, Shen et al. 2014, Zavyalova et al. 2012), hogyan büntethetik egy vállalat termékének erősen negatív értékelései a többi termékét (Barlow et al. 2016), és hogyan befolyásolhatja a szervezetek ellentmondásos cselekvéseinek keretezése a későbbi részvénytulajdonosi döntéseket (Rhee & Fiss 2014).

A tudósok különösen érdekesnek találták, hogy a hangnem hogyan befolyásolja az interperszonális interakciók eredményeit. Az eBay-vásárlók és -eladók közötti online vitákról kiderült, hogy nagyobb valószínűséggel oldódnak meg pozitív, megerősítő hangnemben, mint negatív, dühös parancsokkal (Brett et al. 2007, Friedman et al. 2004). Hasonlóképpen, az ügyfélszolgálati események elemzése azt találta, hogy az alkalmazottak nagyobb valószínűséggel képesek önszabályozásra és minőségi ügyfélszolgálatra, ha a vevő pozitív hangnemet használ (Walker et al. 2017). Egy másik ügyfélszolgálati tanulmány, amely a vásárlók és az áruházi alkalmazottak közötti interakciók negatív affektív hangnemét vizsgálta, azt találta, hogy az elhízott vásárlók nagyobb valószínűséggel tapasztaltak interperszonális diszkriminációt, ami csökkentette a befejezett értékesítési tranzakció valószínűségét (King et al. 2006). A pozitív érzelmi megnyilvánulásokról kiderült, hogy csökkentik a tárgyalások hosszát és javítják a hasonló személyiségjegyekkel rendelkező felek közötti tárgyalások eredményeit (Wilson et al. 2016). Végül, a tárgyalások során használt azonos hangnem és tenor eltérő eredményeket eredményezett az Egyesült Államokban és Egyiptomban, ami értékes betekintést nyújt abba, hogy a kulturális különbségek hogyan befolyásolják a tárgyalási megállapodásokat (Gelfand et al. 2015).

A CATA jövője a szervezeti pszichológiában és a szervezeti viselkedésben

Duriau és munkatársai (2007) meglepődtek a CATA-t használó kutatások hiányán. Azóta a CATA-t használó szervezetpszichológiai és szervezeti viselkedéskutatások száma jelentősen megnőtt. Azokat a konstruktumokat, amelyeket hagyományosan felmérési és megfigyelési módszerekkel mértek, ma már a nyelvhasználat különböző aspektusainak vizsgálatával lehet mérni. Az egyéb kutatási technikák (pl. a kérdőíves kutatás) fejlődésével párhuzamos módszertani előrelépéseket is vizsgálták a CATA-val kapcsolatban. Short és munkatársai (2010) például meghatározzák, hogyan lehet a CATA-mérések kidolgozásakor a tartalmi, külső, diszkrimináns és prediktív érvényességet maximalizálni.

5. táblázat Jövőbeni kutatási lehetőségek a CATA felhasználásával

Konstrukció	Szöveg	Kutatási kérdés
Hála (Fehr et al. 2017)	Csapatülések jegyzőkönyvei	A hála kifejezései befolyásolják-e a csapat elkötelezettségét a harmadik fél megfigyelők körében?
Pszichológiai felhatalmazás (Spreitzer 1995)	A válaszadó munkájára vonatkozó nyílt végű felmérés válaszai	Hogyan befolyásolja a vezető-tagok közötti cserekapcsolatok minősége a pszichológiai felhatalmazás és a szervezeti állampolgári magatartás közötti kapcsolatot?
Munkahelyi kiközösítés (Ferris et al. 2008)	Kritikus incidens technikával kapcsolatos szövegek	Befolyásolja-e a munkahelyi kiközösítés a közösségi megosztás és az általános kontra kiegyensúlyozott cserekapcsolatok preferenciáit?
Képzési elégedettség és hasznosság (Alliger et al. 1997)	Képzéértékelő szövegek	Befolyásolja-e az elégedettség és a hasznosság észlelése a képzésben résztvevők azon képességét, hogy a képzési tartalmat átültessék a munkahelyi használatba?
Vállalkozói orientáció (Lumpkin & Dess 1996)	Önéletrajzok és kísérőlevelek	A vállalatok úgy gondolják, hogy vállalkozó szellemű munkavállalókat akarnak, de valóban e tulajdonságok alapján hozzák meg a kiválasztási döntéseket?

Hasonlóképpen, McKenny és munkatársai (2016) meghatározzák, hogyan kell értékelni a mérési hibát a CATA intézkedések használata során, és bemutatják a megbízhatóság javításának technikáit. Az ilyen előrelépések ellenére továbbra is jelentős lehetőségek maradnak a CATA kihasználására, hogy hozzájáruljon a területünk kulcsfontosságú kutatási áramlataihoz. Néhány ilyen lehetőséget az 5. táblázat és az 1. ábra mutat be.

Kutatási lehetőségek

A pszichológia pozitív fordulatával párhuzamosan a pozitív konstruktumok kutatása a szervezeti viselkedéskutatásban is jelentős lendületet vett (Luthans & Youssef-Morgan 2017). A pszichológiai tőkét - a pozitív szervezeti viselkedéskutatás egyik kulcskonstrukcióját - már operacionalizálták a CATA szótárak segítségével (pl. McKenny et al. 2013). A pozitív szervezeti kutatásban azonban több konstruktumnak is hasznára válhatna az or-ganizációs szövegekben történő mérés. Például a hála szerepét a szervezetekben vizsgáló kutatások értékes betekintést nyújtottak a pozitív interakciók munkahelyi szerepébe (pl. Ahrens 2016, Fehr et al. 2017, Grant & Wrzesniewski 2010). Mivel a hála gyakran tükröződik az olyan szavak használatában, mint a "köszönöm", "értékelem" és "hálás", a hála mérése a CATA segítségével különösen értékes lehetőség lehet. A jövőbeli kutatások például megvizsgálhatnák, hogy a megfigyelt hála megnyilvánulásai hogyan befolyásolják a hálacserében résztvevők és a harmadik fél csapattagok csapat iránti elkötelezettségét. Itt a kutatók a CATA segítségével elemezhetnék a hálával kapcsolatos nyelvezet gyakoriságát a csapatülések átírataiban, hogy megvizsgálják, hogy e nyelv használata a csapaton belüli vagy a csapat közötti hatásokat eredményez-e a csapat elkötelezettségére.

A pozitív szervezeti ösztöndíjjal foglalkozó kutatókat az is érdekelte, hogy a munkavállalók milyen mértékben egy szervezetben úgy érzik, hogy felhatalmazást kaptak a szerepükben (Dutton & Glynn 2008, Feldman & Khademian 2003). A pszichológiai felhatalmazást úgy határozzák meg, mint "a megnövekedett belső feladatmotivációt, amely négy olyan kognícióban nyilvánul meg, amelyek az egyénnek a munkaszerepével kapcsolatos orientációját tükrözik: jelentés, kompetencia... , az önmeghatározás és a hatás" (Spreitzer 1995, 1443. o.). A CATA gazdag historikával rendelkezik, amely a szövegek szerzőinek kognícióira vonatkozó betekintést nyújt (Pennebaker et al. 2003). Mivel a pszichológiai felhatalmazás középpontjában négy kognitív folyamat áll, a CATA értékes betekintést nyújthat a munkahelyi egyének közvetített pszichológiai felhatalmazására vonatkozóan is. Például amikor az egyének a munkájukról beszélnek, olyan szavakat használhatnak, mint a "képes" vagy a "könnyű", hogy kifejezzék, hogy úgy gondolják, képesek jól végezni a munkájukat, ami összhangban van a kompetencia dimenzióval. Hasonlóképpen használhatnak olyan szavakat, mint az "autonómia" vagy a "mozgástér", hogy érzékelt önrendelkezést közvetítsenek. A CATA alkalmazásával az interjúk átíratai vagy az egyének kérdőíves válaszai alapján beszélnek a munkájukról, a jövőbeli kutatások tesztelhetik, hogy a vezető és a tagok közötti ex-csere kapcsolatok minősége mérsékelheti-e a pszichológiai felhatalmazás és a szervezeti állampolgári magatartás kapcsolatát.


Kiegészítve a pozitív szervezeti ösztöndíj egyre nagyobb hangsúlyát, a kontraproduktív munkamagatartás előzményeinek és következményeinek megértése továbbra is a szervezeti pszichológia és a szervezeti viselkedés kutatásának fontos áramlata (Bennett & Robinson 2000, Marcus et al. 2016). E terület egyik fontos kutatási áramlata a munkahelyi kiközösítés (Ferris et al. 2008, Robinson et al. 2013). A munkahelyi kiközösítés akkor következik be, amikor az egyéneket kizárják a többi

szervezeti taggal való társas interakciókból, és negatív személyes és interperszonális eredményekkel jár (Ferris et al. 2008). Egy olyan szöveggeneráló módszerrel, mint a kritikus incidens technika (pl. Flanagan 1954), a kutatók olyan szavakra összpontosíthatnak, mint a "kirekesztett" vagy a "klikk", hogy megragadják a munkahelyi kiközösítés mértékét a válaszadók tapasztalataiban. Ily módon a jövőbeli kutatások a CATA-t használhatják annak vizsgálatára, hogy a munkahelyi kiközösítés hogyan befolyásolhatja az érintett egyének cserepreferenciáit az idő múlásával. Például a kiközösítésben részt vevő vagy annak célpontjaivá váló egyének a kapcsolati kötelékek megszakadásával a közösségi megosztás és az általános kölcsönösség preferenciáiról az egyéni jogosultságok és a kiegyensúlyozott kölcsönösség preferenciáira térhetnek át.

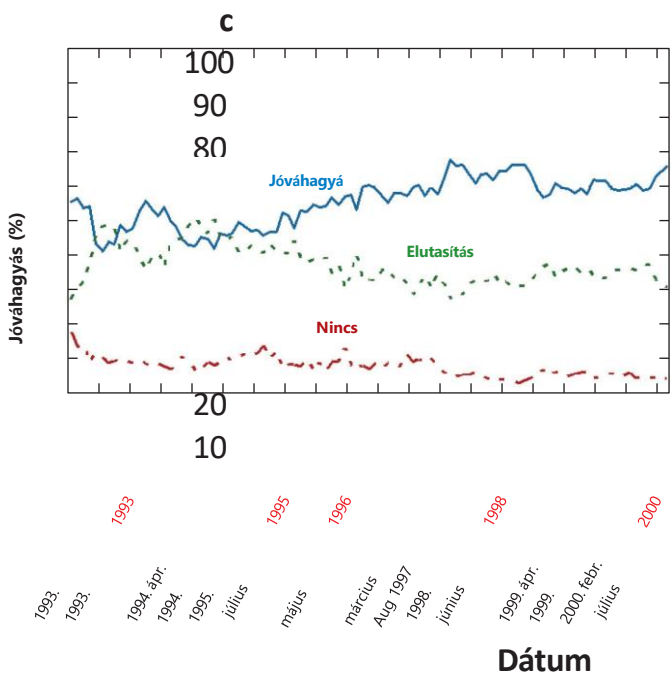
A szervezeti pszichológiai kutatás egyik területe, amely jelentős mértékben profitálhat az alkalmazott a CATA a HR. Számos HR-folyamat szokás szerint szövegek létrehozásával jár. Például az alkalmazottak képzése gyakran a képzési értékelések/visszajelzések bekérésével zárul, amelyek alapján az oktatók értékelhetik a foglalkozások sikerét, és szükség esetén változtatásokat végezhetnek. A meglévő szótárak, mint például a LIWC pozitív és negatív érzelmi szótárai, értékesek lehetnek a képzésben résztvevők képzésükre adott affektív válaszainak vizsgálatához (pl. Pennebaker et al. 2015). A képzésvértékelési kutatások azonban azt jelzik, hogy a képzési visszajelzéseknek számos olyan kiemelkedő dimenziója van, amelyeket nem mértek CATA-val, beleértve az elégedettséget és a hasznosságot (Alliger et al. 1997). Az elégedettségi szótár olyan szavakat kereshet, mint a "csodálatos" és a "szórakoztató", hogy megragadja azt a mértéket, amelyben a képzők úgy érezték, hogy élvezték a foglalkozást. A hasznossági szótár olyan szavakat kereshet, mint a "hasznos" vagy "alkalmazható", annak megállapítására, hogy a képzésben résztvevők úgy vélik-e, hogy a tanfolyam olyan tudást adott számukra, amelyet értékesnek és hasznosnak tartanak. Ezek a szótárak nagy hasznára lehetnek a kutatóknak és a gyakorlati szakembereknek. A kutatók az elégedettségi és hasznossági szótárakat arra használhatnák, hogy megállapítsák, hogy a képzésben résztvevők elégedettségi és hasznossági megítélése befolyásolja-e azt a képességüket, hogy a képzés befejezése után a képzés tartalmát át tudják-e ültetni a munkájuk végzésébe. A gyakorlatban a CATA alkalmazása a képzési visszajelzésekre segíthet a nagyszabású képzési erőfeszítések eredményeinek gyors értékelésében és összegzésében, lehetővé téve a képzők számára, hogy időben változtatásokat hajtsanak végre anélkül, hogy először minden egyes szöveges visszajelzést el kellene olvasniuk.

A szövegeket rutinszerűen használják a HR vonzási és kiválasztási folyamataiban is. Például, a "resume" szűrés intézményesített folyamat a pályázók kiválasztásában (pl. Gatewood & Feild 2001). Jelentős szakirodalom alakult ki, amely a különböző re'sume' jellemzők szerepét vizsgálja a jelöltek értékelésében (pl. Cole et al. 2007, Thoms et al. 1999). Annak ellenére azonban, hogy az önéletrajz szövege fontos szerepet játszik a kiválasztási folyamatban, kevés kutatás vizsgálta a nyelvi jellemzők szerepét az önéletrajzok szűrésében. Úgy tűnik, hogy a munkáltatók egyre inkább olyan jelentkezőket keresnek, akik "vállalkozó szelleműek", "önállóak" és "öntevékenyek"; a vállalkozói jellemzők azonban elriaszthatják a munkáltatókat egyes jelöltek

kiválás
valószínű
szótára
(2016)
jellemz
e kivál



nagyobb
orientációs
enny et al.
ket a kívánt
el kerülnek-



1. ábra

A CATA-t használó potenciális vezetői tanulmányok. (a) Donald Trump elnök fényképe. Az elnöki tweetekben szereplő vezetői retorika vizsgálata felhasználható a pszichológiai tőke vagy a karizmatikus nyelvhasználat és a tőzsdéi reakciók közötti potenciális összefüggések vizsgálatára. A panel a Fehér Ház jóvoltából, közkincs licenc alatt (<https://whitehouse.gov>). (b) Fénykép az 1960-as első elnökválasztási vitáról. Az elnöki viták értékes kontextust kínálnak a vezetésért folytatott versenyek vizsgálatához. Az elnöki viták átírtait vizsgáló jövőbeli kutatások feltárhatják, hogy a tipikusan megtévesztéssel és hitelességgel kapcsolatos nyelvezet hogyan befolyásolja a követők értékelését. (c) Bill Clinton volt elnök népszerűségi mutatói elnöksége alatt, havonta több felmérés átlagát mutatja. Az elnökök elfogadottsági mutatóit beszédátiratokkal lehet párosítani annak feltárására, hogy a vezetők kommunikációjának hangnemtét hogyan befolyásolja a követők aktuális megítélése. Panel c a Roper Center jóvoltából, GNU szabad dokumentációs licenc alatt (<https://commons.wikimedia.org>). (d) Washington Mike Leach állami futball edző a 2012-es szezon egyik mérkőzésén. A tudósok megvizsgálhatják a vezetőedzők által a sajtótájékoztatókon használt kiegészítő nyelvezetet, hogy tanulmányozzák annak hatását a mérkőzések látogatottságára, a csapat teljesítményére, valamint a sportolók fluktuációs és megtartási arányára.

Számos olyan terület is van, ahol a szervezeti pszichológia és a szervezeti viselkedés tudósai előremozdíthatják magát a CATA-módszert. Az általunk áttekintett tanulmányok többsége a CATA-t csak egy változó mérésére használja (pl. Shantz & Latham 2009, Wilson et al. 2016). Mivel azonban több konstruktmorra vonatkozóan szótárak jelennek

meg, és a CATA egyre gyakoribbá válik ebben a szakirodalomban, a kutatók valószínűleg több konstrukció mérésére fogják használni a CATA-t egy tanulmányban. Például egy pozitív affektust és a teljesítmény iránti igényt vizsgáló tanulmány mindkettőt mérhetné a CATA szótárak segítségével. Bár ez általában nem jelenthet problémát, ha két vagy több szótár ugyanazokat a szavakat tartalmazza, akkor ezek ronthatják a statisztikai következtetések érvényességét. Amennyiben a közös szavak a konstrukciók definícióinak elméleti átfedését tükrözik, az átfedő szótárakból származó szisztematikus kovariancia érvényes (pl. McKenny et al. 2013). Ha azonban a szótárak közötti átfedésnek nincs elméleti alapja, a közös szavakból származó szisztematikus kovariancia nem megfelelő, és a dimenzionalitás gyanússá válik. Például a "legyőzött" szó a szó eltérő jelentése miatt valószínűleg megjelenik mind a kiégés, mind a versenyintenzitás szótárában, de ezek a konstrukciók nem kapcsolódnak szorosan egymáshoz. A jövőbeni kutatások megvizsgálhatják, hogyan kezelhetők az olyan átfedő szótárak, amelyekben egy szó több konstrukciót is tükrözhet, de a konstrukciók elméletileg nem rendelkeznek hasonló definíciókkal.

A CATA egy másik problémával is szembesül, ami a több szólista egy vizsgálatban való felhasználását illeti. A kutatás, amely a CATA-t gyakran operacionalizálja a konstrukciókat egypólusú szólisták létrehozásával, amelyekben a szótárból származó szavak jelenléte a konstrukció nagyobb jelentőségét tükrözi (pl. Zachary et al. 2010). Néhány konstrukciónak azonban két elméletileg különböző pólusa van, ami két szótár létrehozását ösztönzi mindkét pólus megragadására (pl. pozitív és negatív affektus, Pennebaker et al. 2015; felfedezés és kizsákmányolás, Uotila et al. 2009). Továbbá lehetnek olyan általánosan használt szavak, amelyeknek még az egypólusú méréseknél is számítaniuk kell. Például, míg a munkával való elégedettség szótára tartalmazhat olyan szavakat, mint az "élvezni" vagy az "élvezetes", az olyan szavak jelenléte, mint az "érdektelen" vagy az "unalmas" értékes ellensúlyt jelenthet a pozitív szavakkal szemben. Sajnos kevés útmutatás van arra vonatkozóan, hogy mikor kell két ellensúlyozó szólistát készíteni, és hogy az e szólisták által generált adatokat össze kell-e vagy hogyan kell-e kombinálni. A jövőbeni kutatások a skálatejesztés legjobb gyakorlataiból meríthetnek és kiterjeszthetők annak felmérésére, hogy a több szólista kombinálása mikor eredményezhet érvényesebb méréseket a szervezeti konstrukciókról.

A CATA-kutatásban egy másik gyakori probléma, hogy az elemzésben felhasznált szövegek hossza jelentősen eltérnek. Ha nem kezeljük ezt az eltérést, akkor a hosszabb szövegek általában magasabb CATA-pontszámot kapnának, mint a rövidebbek. Bár a CATA-adatok nyers mérésekkel történő elemzése indokolt lehet, a kutatók gyakran úgy ellenőrzik a dokumentum hosszát, hogy az egyes CATA-változókat elosztják a szavak teljes számával (pl. Baur et al. 2016). Az információkeresés területén végzett kutatások azonban azt sugallják, hogy a dokumentum hosszának pusztán standardizálása a megfigyelések szavankénti alapra helyezésével nem biztos, hogy elegendő. A nyers vagy szavankénti pontszámok használatával például 10 szó jelenléte egy munkahelyi felhatalmazással kapcsolatos elbeszélésben arra utalna, hogy a szerző 10-szer nagyobb felhatalmazást érez, mint egy olyan egyén, aki csak egy szót használt.

Ez azonban valószínűleg nem így van. Ennek megfelelően a természetes nyelvi feldolgozással kapcsolatos kutatások számos olyan kifejezésgyakorisági transzformációt vezettek be, amelyek fenntartják a szóhasználat és a konstrukció szaliencia közötti pozitív kapcsolatot, de lazítanak azon a feltételezésen, hogy ez lineáris kapcsolat (Manning & Schütze 1999). Például egy gyakori kifejezésgyakorisági súlyozás a logaritmusos normalizálás, amelynek során a megfigyeléseket a következő módon számítják ki $\log(\text{megfigyelés})+1$ minden olyan megfigyelésre, amelyben legalább egy szó található. Ezzel a technikával, az egy szóról 10 szóra történő növekedést nem 900%-os, hanem 100%-os növekedésként jellemezzük a mért konstrukció hangsúlyosságának növekedése. A jövőbeni kutatások megvizsgálhatják, hogy ez és a nyelvészeti mérés egyéb legújabb fejlesztései hogyan alkalmazhatók a CATA-kutatásban az intézkedések érvényességének javítása érdekében.

Számos szótáralapú CATA-eszköz egyik feltételezése az, hogy a szótárban szereplő összes szó egyformán hozzájárul az átfogó konstrukció méréséhez. Például a "tetszik" és a "szeretem" szavak jelenléte egy szövegben egy-egy ponttal növelné az adott szöveg pozitív affektus pontszámát. E két szó manuális kódolója azonban valószínűleg a "love"-t erősebb pozitív affektusnak értékelné, mint a "like"-ot. Ennek megfelelően a szavak egyenlő súlyozása a CATA-szótárban ellentmondhat a szavak hozzájárulásának a mért konstrukció szalienciájához. A jövőbeni kutatások irányt mutathatnak a szótár fejlesztésének és finomításának, ha megmutatják, hogy a szavaknak a konstrukcióhoz való szalienciájuk alapján történő súlyozással való kiegészítése pontosabb méréseket biztosíthat.

A szótáralapú CATA kontextusfüggő jellegének leküzdése érdekében sok tudós a szövegek egy részmintájának kézi kódolását végzi (pl. McKenny et al. 2016, Neuendorf 2017). Konkrétan a kézi tartalomelemzés összehasonlítási pontot biztosít a kutatók számára a CATA-eredményeikhez, lehetővé téve számukra annak meghatározását, hogy a szavak használatának kontextusa milyen mértékben befolyásolja az adataikat. E megbízhatósági ellenőrzés fontossága ellenére továbbra sem világos, hogy hány szöveget kell bevonni ebbe a manuálisan kódolt almintába. A nominális kódolási osztályozásokat használó manuális tartalomelemzésekhez Lacy & Riffe (1996) képleteket ad a megfelelő alminták méretének meghatározásához. Ez az iránymutatás azonban nem könnyen átvihető a CATA-kutatásra, mivel a CATA nem nominális, hanem folyamatos adatokat állít elő. A jövőbeni kutatás kiterjesztheti Lacy & Riffe (1996) útmutatását, hogy a CATA-t használó kutatók számára a részminták megbízhatóságára vonatkozó képleteket biztosítson.

Míg a szótáralapú CATA-módszerek továbbra is a leggyakrabban használt számítógépes tartalomelemzési technika, a számítógépes nyelvészet és az információkeresés fejlődése olyan új CATA-technikákat hoz, amelyek új lehetőségeket kínálnak a szervezeti pszichológia és a szervezeti viselkedés kutatói számára (pl. Champion et al. 2016; Kobayashi et al. 2017a,b). A látens szemantikai elemzés/indexelés (Deerwester et al. 1990) például egy olyan technika, amellyel a szövegek egy mintája közötti kapcsolatokat vizsgálhatjuk azáltal, hogy a dokumentumokban szereplő szavak alapján fogalmakat vagy témákat vonunk ki a dokumentumokból. Ezeket a témákat a

szavak és a témához vélhetően kapcsolódó töltések halmazaként reprezentálják. Például a látens szemantikai elemzés azonosíthat egy témát, amelyhez az "izgatott", "boldog" és "elégedett" szavak kapcsolódnak. Ez azt jelezné, hogy ezek a szavak általában együtt fordulnak elő a szövegek egy részalmazában, és a kutató jelentheti, hogy az ezzel a témával leírt dokumentumok a válaszadó pozitív érzelmeit érintik egy esemény iránt. Más témamodellezési megközelítések közé tartozik a valószínűségi látens szemantikai elemzés (Hofmann 2001) és a látens Dirichlet-kiosztás (Blei et al. 2003), amelyek mindkettő különböző módszereket kínálnak a látens témák feltárására egy szöveghalmazban. A CATA egy utolsó élvonalbeli területe a természetes nyelvfeldolgozással támogatott hangulatelemzés (pl. Pang & Lee 2008, Socher et al. 2013). Ennek a technikának a segítségével a számítógép az érzelmek mérésekor figyelembe veszi azt a kontextust, amelyben az érző szavak hozzájárulnak egy mondatához, például különbséget tesz a "az előadás nem volt túl érdekes" és a "az előadás rendkívül érdekes volt" között.

Következtetés

Jeff Pfeffer egyszer megjegyezte, hogy "a szervezeti viselkedés területén gyakran nagyon kevés az olyan dolog, ami sem szervezeti, sem viselkedéses" (Pfeffer 1981, 415. o.). A CATA megjelenése lehetővé teszi a tudósok számára, hogy jelentést merítsenek a szervezet által készített dokumentumokból, amelyek potenciálisan tartalmazzák a gondolatokat, érzelmeket, véleményeket vagy a munkahelyi élet más aspektusait, amelyeket más kutatási technikákkal lehetetlen természetesen módon megragadni. Bár a CATA használatában jelentős előrelépések történtek, a tudósok számára továbbra is nagy lehetőségek rejlenek az ilyen technikák további finomításában és e módszerek alkalmazásában a szervezeti viselkedés és pszichológia számára érdekes más kérdésekben. Reméljük, hogy munkánk segít az irányt mutatni, ahogy ez a technika tovább növekszik és virágzik.

Szakirodalom

- Abrahamson E, Eisenman M. 2008. Employee-management techniques: transient fads or trending fashions? *Adm. Sci. Q.* 53:719–44
- Aguinis H, Vandenberg RJ. 2014. An ounce of prevention is worth a pound of cure: improving research quality before data collection. *Annu. Rev. Organ. Psychol. Organ. Behav.* 1:569–95
- Ahrens B. 2016. Gratitude, psychological capital, and work stress. PhD Thesis, Bellevue Univ., Bellevue, NE
- Alliger GM, Tannenbaum SI, Bennett W, Traver H, Shotland A. 1997. A meta-analysis of the relations among training criteria. *Pers. Psychol.* 50:341–58

- Barber JD. 1992. *The Presidential Character: Predicting Performance in the White House*. Englewood Cliffs, NJ: Prentice Hall
- Barclay LJ, Skarlicki DP. 2009. Healing the wounds of organizational injustice: examining the benefits of expressive writing. *J. Appl. Psychol.* 94:511–23
- Bardi A, Calogero RM, Mullen B. 2008. A new archival approach to the study of values and value-behavior relations: validation of the value lexicon. *J. Appl. Psychol.* 93:483–97
- Barley SR, Meyerson DE, Grodal S. 2011. E-mail as a source and symbol of stress. *Organ. Sci.* 22:887–906
- Barlow MA, Verhaal JC, Hoskins JD. 2016. Guilty by association: product-level category stigma and audience expectations in the US craft beer industry. *J. Manag.* In press. <https://doi.org/10.1177/0149206316657593>
- Basu S, Savani K. 2017. Choosing one at a time? Presenting options simultaneously helps people make more optimal decisions than presenting options sequentially. *Organ. Behav. Hum. Decis. Process.* 139:76–91
- Baur JE, Ellen BP, BuckleyMR, Ferris GR, Allison TH, et al. 2016. More than one way to articulate a vision: a configurations approach to leader charismatic rhetoric and influence. *Leadersh. Q.* 27:156–71
- Bednar MK. 2012. Watchdog or lapdog? A behavioral view of themedia as a corporate governancemechanism. *Acad. Manag. J.* 55:131–50
- Bennett RJ, Robinson SL. 2000. Development of a measure of workplace deviance. *J. Appl. Psychol.* 85:349–60
- Berelson B. 1952. *Content Analysis in Communication Research*. Glencoe, IL: Free Press
- Bezrukova K, Thatcher S, Jehn KA, Spell CS. 2012. The effects of alignments: examining group faultlines, organizational cultures, and performance. *J. Appl. Psychol.* 97:77–92
- Blei DM, Ng AY, Jordan MI. 2003. Latent Dirichlet allocation. *J. Mach. Learn. Res.* 3:993–1022
- Bligh MC, Kohles JC, Meindl JR. 2004. Charting the language of leadership: a methodological investigation of President Bush and the crisis of 9/11. *J. Appl. Psychol.* 89:562–74
- Bono JE, Ilies R. 2006. Charisma, positive emotions and mood contagion. *Leadersh. Q.* 17:317–34
- Brett JM, OlekalnsM, Friedman R,GoatesN, Anderson C, Lisco CC. 2007. Sticks and stones: language, face, and online dispute resolution. *Acad. Manag. J.* 50:85–99
- Campion MC, Campion MA, Campion ED, Reider MH. 2016. Initial investigation into computer scoring of candidate essays for personnel selection. *J. Appl. Psychol.* 101(7):958–75
- Caprar DV. 2011. Foreign locals: a cautionary tale on the culture of MNC local employees. *J. Int. Bus. Stud.* 42:608–28
- Cerdin J-L, Din´e MA, Brewster C. 2014. Qualified immigrants’ success: exploring the motivation to migrate and to integrate. *J. Int. Bus. Stud.* 45:151–68
- Charmaz K. 2014. *Constructing Grounded Theory*. Thousand Oaks, CA: Sage
- Chen X, Latham GP. 2014. The effect of priming learning versus performance goals on a complex task. *Organ. Behav. Hum. Decis. Process.* 125:88–97

- Cohn MA, Mehl MR, Pennebaker JW. 2004. Linguistic markers of psychological change surrounding September 11, 2001. *Psychol. Sci.* 15:687–93
- Cole MS, Rubin RS, Feild HS, Giles WF. 2007. Recruiters' perceptions and use of applicant r'esum'e information: screening the recent graduate. *Appl. Psychol.* 56:319–43
- De Gama N, McKenna S, Peticca-Harris A. 2012. Ethics and HRM: theoretical and conceptual analysis. *J. Bus. Ethics* 111:97–108
- Deerwester S, Dumais S, Furnas G, Landauer T, Harshman R. 1990. Indexing by latent semantic analysis. *J. Am. Soc. Inf. Sci.* 41:391–407
- Detert JR, Trevi ~ no LK. 2010. Speaking up to higher-ups: how supervisors and skip-level leaders influence employee voice. *Organ. Sci.* 21:249–70
- Dewey J. 1931. *Philosophy and Civilization*. New York: Minton, Blach & Co.
- Duriau VJ, Reger RK, Pfarrer MD. 2007. A content analysis of the content analysis literature in organization studies: research themes, data sources, and methodological refinements. *Organ. Res. Methods* 10:5–34
- Dutton JE, Glynn MA. 2008. Positive organizational scholarship. In *The SAGE Handbook of Organizational Behavior*, ed. J Barling, CL Cooper, pp. 693–712. London: Sage
- Etzioni A. 1993. *The Spirit of Community: Rights, Responsibilities, and the Communitarian Agenda*. New York: Crown
- Fanelli A, Misangyi VF, Tosi HL. 2009. In charisma we trust: the effects of CEO charismatic visions on securities analysts. *Organ. Sci.* 20:1011–33
- Fehr R, Fulmer A, Awtrey E, Miller J. 2017. The grateful workplace: a multilevel model of gratitude in organizations. *Acad. Manag. Rev.* 42(2):361–81
- Feldman MS, Khademian AM. 2003. Empowerment and cascading vitality. In *Positive Organizational Scholarship: Foundations of a New Discipline*, ed. K Cameron, J Dutton, R Quinn, pp. 343–58. San Francisco: Berrett-Koehler Publ.
- Felps W, Mitchell TR, Hekman DR, Lee TW, Holtom BC, Harman WS. 2009. Turnover contagion: how coworkers' job embeddedness and job search behaviors influence quitting. *Acad. Manag. J.* 52:545–61
- Ferris DL, Brown DJ, Berry JW, Lian H. 2008. The development and validation of the workplace ostracism scale. *J. Appl. Psychol.* 93:1348–66
- Fisher K, Hutchings K. 2013. Making sense of cultural distance for military expatriates operating in an extreme context. *J. Organ. Behav.* 34:791–812
- Flanagan JC. 1954. The critical incident technique. *Psychol. Bull.* 51:327–58
- Friedman R, Anderson C, Brett J, Olekalns M, Goates N, Lisco CC. 2004. The positive and negative effects of anger on dispute resolution: evidence from electronically mediated disputes. *J. Appl. Psychol.* 89:369–76
- Friese S. 2014. *Qualitative Data Analysis with ATLAS.ti*. Thousand Oaks, CA: Sage
- Gamache DL, McNamara G, Mannor MJ, Johnson RE. 2015. Motivated to acquire? The impact of CEO regulatory focus on firm acquisitions. *Acad. Manag. J.* 58:1261–82
- Gatewood RD, Feild HS. 2001. *Human Resource Selection*. New York: Harcourt Coll. Publ.
- Gelfand MJ, Severance L, Lee T, Bruss CB, Lun J, et al. 2015. Culture and getting to yes: the linguistic signature of creative agreements in the United States and Egypt. *J. Organ. Behav.* 36:967–89

- Gibson CB, Zellmer-Bruhn ME. 2001. Metaphors and meaning: an intercultural analysis of the concept of teamwork. *Adm. Sci. Q.* 46:274–303
- Grant AM, Wrzesniewski A. 2010. I won't let you down. . . or will I? Core self-evaluations, other-orientation, anticipated guilt and gratitude, and job performance. *J. Appl. Psychol.* 95:108–21
- Hart RP. 1984. Systematic analysis of political discourse: the development of DICTION. In *Political Communication Yearbook*, ed. K Sanders, L Kaid, D Nimmo, pp. 97–134. Carbondale: Southern Ill. Univ. Press
- Hart RP. 2001. Redeveloping DICTION: theoretical considerations. *Prog. Commun. Sci.* 16:43–60
- Heyden ML, Sidhu JS, Volberda HW. 2015. The conjoint influence of top and middle management characteristics on management innovation. *J. Manag.* In press. <https://doi.org/10.1177/0149206315614373>
- Hofmann T. 2001. Unsupervised learning by probabilistic latent semantic analysis. *Mach. Learn.* 42:177–96
- Holsti OR. 1969. *Content Analysis for the Social Sciences and Humanities*. Reading, MA: Addison-Weasley
- Jauch LR, Osborn RN, Martin TN. 1980. Structured content analysis of cases: a complementary method for organizational research. *Acad. Manag. Rev.* 5:517–25
- Jehn KA, Bezrukova K. 2004. A field study of group diversity, workgroup context, and performance. *J. Organ. Behav.* 25:703–29
- Kabanoff B. 1996. Computers can read as well as count: how computer-aided text analysis can benefit organisational research. *J. Organ. Behav.* 18:507–11
- Kellogg KC, OrlikowskiWJ, Yates J. 2006. Life in the trading zone: structuring coordination across boundaries in postbureaucratic organizations. *Organ. Sci.* 17:22–44
- King EB, Shapiro JR, Hebl MR, Singletary SL, Turner S. 2006. The stigma of obesity in customer service: a mechanism for remediation and bottom-line consequences of interpersonal discrimination. *J. Appl. Psychol.* 91:579–93
- Kobayashi VB, Mol ST, Berkers HA, Kismih'ok G, Den Hartog DN. 2017a. Text classification for organizational researchers. *Organ. Res. Methods.* <https://doi.org/10.1177/1094428117719322>
- Kobayashi VB, Mol ST, Berkers HA, Kismih'ok G, Den Hartog DN. 2017b. Text mining in organizational research. *Organ. Res. Methods.* <https://doi.org/10.1177/1094428117722619>
- Kreiner GE, Hollensbe EC, Sheep ML. 2006. Where is the “me” among the “we”? Identity work and the search for optimal balance. *Acad. Manag. J.* 49:1031–57
- Kreiner GE, Hollensbe EC, Sheep ML. 2009. Balancing borders and bridges: negotiating the work-home interface via boundary work tactics. *Acad. Manag. J.* 52:704–30
- Krippendorff K. 2013. *Content Analysis: An Introduction to Its Methodology*. Thousand Oaks, CA: Sage
- Lacy S, Riffe D. 1996. Sampling error and selecting intercoder reliability samples for nominal content categories. *J. Mass Commun. Q.* 73(4):963–73

- Lasswell HD. 1948. The structure and function of communication in society. *Commun. Ideas* 37:215–28
- Liang LH, Lian H, Brown DJ, Ferris DL, Hanig S, Keeping LM. 2016. Why are abusive supervisors abusive? A dual-system self-control model. *Acad. Manag. J.* 59:1385–406
- Lumpkin GT, Dess GG. 1996. Clarifying the entrepreneurial orientation construct and linking it to performance. *Acad. Manag. Rev.* 21:135–72
- Luthans F, Youssef-Morgan CM. 2017. Psychological capital: an evidence-based positive approach. *Annu. Rev. Organ. Psychol. Organ. Behav.* 4:339–66
- Madera JM, Hebl MR, Martin RC. 2009. Gender and letters of recommendation for academia: agentic and communal differences. *J. Appl. Psychol.* 94:1591–99
- Maietta RC. 2009. The life of an ATLAS.ti quotation. ATLAS.ti Library. http://downloads.atlasti.com/library/Maietta_2009-05_6.pdf
- Manning CD, Schütze H. 1999. *Foundations of Statistical Natural Language Processing*. Cambridge, MA: MIT Press
- Marcus B, Taylor OA, Hastings SE, Sturm A, Weigelt O. 2016. The structure of counterproductive work behavior: a review, a structural meta-analysis, and a primary study. *J. Manag.* 42:203–33
- Mathews BC. 1910. A study of a New York daily. *Independent* 68:82–86
- McClelland PL, Liang X, Barker VL III. 2010. CEO commitment to the status quo: replication and extension using content analysis. *J. Manag.* 36:1251–77
- McKenny AF, Aguinis H, Short JC, Anglin AH. 2016. What doesn't get measured does exist: measuring measurement error in computer-aided text analysis. *J. Manag.* In press. <https://doi.org/10.1177/0149206316657594>
- McKenny AF, Short JC, Payne GT. 2013. Using computer-aided text analysis to elevate constructs: an illustration using psychological capital. *Organ. Res. Methods* 16:152–84
- Morris R. 1994. Computerized content analysis in management research: a demonstration of advantages & limitations. *J. Manag.* 20:903–31
- Neuendorf KA. 2017. *The Content Analysis Guidebook*. Thousand Oaks, CA: Sage
- Newman ML, Pennebaker JW, Berry DS, Richards JM. 2003. Lying words: predicting deception from linguistic style. *Personal. Soc. Psychol. Bull.* 29:665–75
- Osgood CE, Suci GJ, Tannenbaum P. 1957. *The Measurement of Meaning*. Urbana-Champaign: Univ. Ill. Press
- Palmer I, Kabanoff B, Dunford R. 1997. Managerial accounts of downsizing. *J. Organ. Behav.* 18:623–39
- Pang B, Lee L. 2008. Opinion mining and sentiment analysis. *Found. Trends Inf. Ret.* 2(1–2):1–135
- Pennebaker JW, Boyd RL, Jordan K, Blackburn K. 2015. *The Development and Psychometric Properties of LIWC2015*. Austin: Univ. Tex. Austin. https://repositories.lib.utexas.edu/bitstream/handle/2152/31333/LIWC2015_LanguageManual.pdf
- Pennebaker JW, Mehl MR, Niederhoffer KG. 2003. Psychological aspects of natural language use: our words, our selves. *Annu. Rev. Psychol.* 54:547–77

- Pfeffer J. 1981. Four laws of organizational research. In *Perspectives on Organizational Design and Behavior*, ed. AH Van de Ven, WF Joyce, pp. 409–18. New York: Wiley
- Pool IDS, ed. 1959. *Trends in Content Analysis*. Urbana-Champaign: Univ. Ill. Press
- Rhee EY, Fiss PC. 2014. Framing controversial actions: regulatory focus, source credibility, and stock market reaction to poison pill adoption. *Acad. Manag. J.* 57:1734–58
- Ridge JW, Ingram A. 2014. Modesty in the top management team: investor reaction and performance implications. *J. Manag.* 43:1283–306
- Robinson SL, O'Reilly J, Wang W. 2013. Invisible at work: an integrated model of workplace ostracism. *J. Manag.* 39:203–31
- Rossel RD. 1970. Instrumental and expressive leadership in complex organizations. *Adm. Sci. Q.* 15:306–16
- Savani K, King D. 2015. Perceiving outcomes as determined by external forces: the role of event construal in attenuating the outcome bias. *Organ. Behav. Hum. Decis. Process.* 130:136–46
- Shantz A, Latham GP. 2009. An exploratory field experiment of the effect of subconscious and conscious goals on employee performance. *Organ. Behav. Hum. Decis. Process.* 109:9–17
- Shen R, Tang Y, Chen G. 2014. When the role fits: how firm status differentials affect corporate takeovers. *Strateg. Manag. J.* 35:2012–30
- Short JC, Broberg JC, Coglisier CC, Brigham K. 2010. Construct validation using computer-aided text analysis (CATA): an illustration using entrepreneurial orientation. *Organ. Res. Methods* 13:320–47
- Short JC, Palmer TB. 2008. The application of DICTION to content analysis research in strategic management. *Organ. Res. Methods* 11:727–52
- Socher R, Perelygin A, Wu JY, Chuang J, Manning CD, et al. 2013. Recursive deep models for semantic compositionality over a sentiment treebank. *Proc. Conf. Empir. Methods Nat. Lang. Process. (EMNLP)*, pp. 1631–42. Stroudsburg, PA: Assoc. Comp. Linguist.
- Sonenshein S. 2014. How organizations foster the creative use of resources. *Acad. Manag. J.* 57:814–48
- Spreitzer G. 1995. Psychological empowerment in the workplace: dimensions, measurement, and validation. *Acad. Manag. J.* 38:1442–65
- Surroca J, Prior D, Tribó Giné JA. 2016. Using panel data DEA to measure CEOs' focus of attention: an application to the study of cognitive group membership and performance. *Strateg. Manag. J.* 37:370–88
- Tausczik YR, Pennebaker JW. 2010. The psychological meaning of words: LIWC and computerized text analysis methods. *J. Lang. Soc. Psychol.* 29:24–54
- Tenzer H, Pudelko M. 2016. Media choice in multilingual virtual teams. *J. Int. Bus. Stud.* 47:427–52
- Tenzer H, Pudelko M, Harzing AW. 2014. The impact of language barriers on trust formation in multinational teams. *J. Int. Bus. Stud.* 45:508–35
- Thoms P, McMasters R, Roberts MR, Dombkowski DA. 1999. Resume characteristics as predictors of an invitation to interview. *J. Bus. Psychol.* 13:339–56
- Uotila J, Maula M, Keil T, Zahra S. 2009. Exploration, exploitation, and financial performance: analysis of S&P 500 corporations. *Strateg. Manag. J.* 30:221–31

- Walker DD, van Jaarsveld DD, Skarlicki DP. 2017. Sticks and stones can break my bones but words can also hurt me. *J. Appl. Psychol.* 102:163–79
- Wilhelmy A, Kleinmann M, König CJ, Melchers KG, Truxillo DM. 2016. How and why do interviewers try to make impressions on applicants? A qualitative study. *J. Appl. Psychol.* 101:313–32
- Wilson KS, DeRue DS, Matta FK, Howe M, Conlon DE. 2016. Personality similarity in negotiations: testing the dyadic effects of similarity in interpersonal traits and the use of emotional displays on negotiation outcomes. *J. Appl. Psychol.* 101:1405–21
- Zachary MA, McKenny AF, Short JC, Payne GT. 2010. Family business and market orientation: construct validation and comparative analysis. *Fam. Bus. Rev.* 24:233–51
- Zavyalova A, Pfarrer MD, Reger RK, Shapiro DL. 2012. Managing the message: the effects of firm actions and industry spillovers on media coverage following wrongdoing. *Acad. Manag. J.* 55:1079–101
- Zellmer-Bruhn M, Gibson C. 2006. Multinational organization context: implications for team learning and performance. *Acad. Manag. J.* 49:501–18

Mesterséges intelligencia az egészségpszichológiában és a prevencióban

Az egészség és a pszichológiai jóllét kérdései ma már nem tekinthetők pusztán orvosi problémának, mivel egyre inkább pszichológiai és technológiai dimenziókat is érintenek. Miközben világszerte nő a krónikus betegségek, a mentális zavarok és a stressz okozta terhek száma, a pszichológia és a digitális technológiák összekapcsolódása új lehetőségeket nyit a megelőzés, a felismerés és a beavatkozás terén. A mesterséges intelligencia (MI) különösen ígéretes ezen a téren: olyan módszereket kínál, amelyek nemcsak szélesebb körben alkalmazhatók, hanem személyre szabottabbá is tehetik az egészségpszichológiai beavatkozásokat (Bailey és mtsai, 2023).

A viselhető eszközök – például okosórák, alvásfigyelő karkötők vagy mobilalkalmazások – ma már nem pusztán adatgyűjtésre szolgálnak. Az MI-algoritmusok révén képesek elemezni az alvásciklusokat, a szívritmust, a mozgásmintázatokat, sőt gyakran felismerik a stressz első jeleit anélkül, hogy a felhasználó észrevenné. Ez a prediktív egészségmonitorozás új szemléletet hozhat: a prevenció fókusza elmozdulhat a reaktív megoldásoktól a proaktív, folyamatos és személyre szabott támogatás felé (Wang és mtsai, 2024).

Kutatások igazolják, hogy megfelelően validált MI-alapú rendszerek pontosabban képesek előre jelezni a depressziós epizódokat, mint a hagyományos kérdőívek (Ramirez és mtsai, 2023). Más vizsgálatok szerint az MI által elemzett viselkedésminták – például az alvászavarok vagy az aktivitás csökkenése – korai jelzői lehetnek olyan állapotoknak, mint a kiégés, a generalizált szorongás vagy a poszttraumás stressz zavar (PTSD).

Ezek a lehetőségek azonban nemcsak technikai, hanem emberi kérdéseket is felvetnek. Nem válik-e kényszeressé az önmegfigyelés? Megőrizhető-e a bizalom, ha MI-rendszerek „véleményt” mondanak az egészségünkről? A pszichológiai prevencióban alkalmazott algoritmusoknak ezért nemcsak pontosnak, hanem etikailag is átgondoltnak kell lenniük. A szakirodalom hangsúlyozza: a technológiai eszközök akkor használhatók jól, ha olyan keretbe illesztjük őket, ahol a pszichológus szerepe nem csökken, hanem erősödik – például az adatok értelmezésében és a folyamat kontrolljában (Bailey és mtsai, 2023; Wang és mtsai, 2024).

A következő fejezetek három kulcsterületet veszünk sorra. Először áttekintjük, milyen lehetőségeket kínál a digitális egészségmonitorozás, és hogyan illeszkednek a viselhető technológiák a pszichológiai prevenció modellekbe. Ezután a stressz- és alvásmintázatok előrejelzését vizsgáljuk, bemutatva, hogy az MI hogyan adhat

figyelmeztető jeleket még a klinikai tünetek megjelenése előtt. Végül a személyre szabott intervenciók kérdését tárgyaljuk: hogyan válhat az MI nemcsak adatgyűjtő eszközzé, hanem pszichológiai „partnerre” a terápiában és az életmód-támogatásban.

Digitális egészségmonitorozás: viselhető eszközök és AI-elemzés

Korábban az egészségi állapotot főként klinikai környezetben, időszakos mérésekkel követték. Ma viszont bárki csuklóján ott lehet egy okosóra vagy gyűrű, amely percenként rögzíti a pulzust, az alvást, a mozgást, sőt a stressz-szintet is. Az Apple Watch, a Fitbit vagy az Oura-gyűrű nemcsak technológiai újdonság, hanem pszichológiai szempontból is új távlatokat nyit. Az MI-alapú algoritmusok képesek értelmezni ezeket az adatokat, és olyan összefüggéseket is felismernek, amelyeket az emberi szem nem venne észre – például a pulzusvariabilitás és a szorongásos epizódok közötti kapcsolatot (Bailey és mtsai, 2023).

A gépi tanulási modellek különösen hasznosak prediktív célokra. Több kutatás kimutatta, hogy az MI korábban képes előre jelezni alvászavarokat vagy stresszreakciókat, mint a hagyományos önbeszámolás kérdőívek. Például Wang és munkatársai (2024) egy mélytanulás-alapú modellt alkalmaztak, amely valós idejű adatokból – testhőmérséklet, bőrellenállás, alvásciklusok – jó pontossággal tudta előre jelezni az akut stressz megjelenését. A rendszer nemcsak figyelmeztetett az érzelmi kimerültségre, hanem javaslatokat is adott a pihenőidő vagy a fizikai aktivitás módosítására.

Egy másik példa: egy MI-alapú rendszer képes volt azonosítani az alvási apnoéa hajlamos személyeket pusztán a légzésszám és a testhelyzet elemzéséből (Ramirez és mtsai, 2023). Az ilyen alkalmazások különösen fontosak a preventív pszichológiai beavatkozásokban, mert lehetővé teszik, hogy az egészségromlás jelei már azelőtt felismerhetők legyenek, hogy a felhasználó észrevenné őket.

Fontos azonban látni, hogy az egészségmonitorozó rendszerek hatékonysága nagymértékben függ az algoritmusok validáltságától, az adatgyűjtés minőségétől és az adatok értelmezésének pontosságától. Az MI-alapú rendszerek még nem mentesek a torzításoktól: egyes adatkészletek túl homogén mintákon alapulnak, vagy a mérési pontosság eltérhet különböző bőrszínek, testalkatok vagy élethelyzetek esetén (Bailey és mtsai, 2023). Emellett etikai kérdések is felmerülnek, különösen az adatok érzékenysége és a felhasználói beleegyezés kapcsán.

Az azonban már világos, hogy a digitális egészségmonitorozás – megfelelő szabályozással és pszichológiai szakértelemmel kiegészítve – kulcsszerepet játszhat a pszichológiai prevenció jövőjében. Nem a terapeuta helyettesítéséről van szó, hanem

egy olyan eszköztárról, amely kiterjeszti az emberi figyelmet, és támogatja a jóllét hosszú távú fenntartását.

Stressz és alvásmintázatok előrejelzése AI segítségével

A stressz és az alvás szorosan összefüggő tényezők, amelyek alapvetően befolyásolják a mentális és fizikai egészséget. A modern életvitel ritmusa, a digitális túlterheltség, a munka és magánélet egyensúlyának felborulása mind hozzájárulnak a krónikus stressz és az alvászavarok terjedéséhez. Ezek a problémák hosszú távon nemcsak a közérzetet rontják, hanem növelik a depresszió, a szorongás, a szív-érrendszeri betegségek és az immunrendszer gyengülésének kockázatát (Palagini és mtsai, 2019). Nem véletlen, hogy a pszichológiai prevenció egyik kiemelt célterülete lett a stressz és az alvás minőségének pontos, lehetőleg előrejelző jellegű vizsgálata – és ebben az MI kulcsszerepet kap.

Az elmúlt években számos kutatás vizsgálta, hogyan képes az MI prediktív modelleket alkotni fiziológiai és viselkedéses adatok alapján. Ezek a modellek sokszor meghaladják a klasszikus önbeszámolókat (pl. PSS vagy PSQI kérdőívek) érzékenységét, mert nem az alany szubjektív értékelésére, hanem objektív, folyamatosan gyűjtött mintázatokra építenek. Például Chen és munkatársai (2023) olyan MI-modellt fejlesztettek, amely viselhető eszközök – szívritmus-variabilitás (HRV), alvási ciklusok, bőrhőmérséklet és aktivitási szint – adatai alapján képes volt azonosítani a krónikus stressz magas kockázatát, még mielőtt az egyén pszichésen észlelte volna a problémát.

Az alvásmintázatok elemzése különösen érzékeny terület, mivel az alvás minősége gyakran tűnik el a szubjektív tapasztalatok és az objektív adatok közötti résben. Az MI azonban képes felfedni azokat a mikro-mintázatokat, amelyek például egy rejtett alvási apnoé, egy fokozatosan kialakuló inszomnia vagy a stresszel összefüggő REM-zavar jelei lehetnek. Egy friss kutatásban Ahmed és kollégái (2024) alvásfigyelő gyűrűk adatait kombinálták önbeszámolókkal, és egy neurális hálózat segítségével képesek voltak prediktálni, hogy a résztvevők mikor számíthatnak rosszabb alvásminőségre – például szorongásos epizódokat megelőző napokon.

Különösen érdekes fejlemény a multimodális MI-rendszerek térnyerése. Ezek a rendszerek egyszerre többféle adatforrást integrálnak – például fiziológiai jeleket, telefonhasználati szokásokat, hangmintákat és mozgásdetektált aktivitást – és ezek alapján komplex predikciókat képesek megfogalmazni. Egy ilyen modell például képes volt megjósolni az akut stresszreakciót egy vizsgaidőszak során, pusztán abból, hogy a hallgatók hogyan változtatták meg az alvásidejüket, milyen gyakran léptek be a közösségi média alkalmazásokba, illetve hogyan alakult a pulzusszámuk a hét napjai

során (Tan et al., 2024). Ezek az eredmények rámutatnak arra, hogy az MI nemcsak passzív mérőeszköz, hanem aktív előrejelző rendszer is lehet, amely akár valós időben képes beavatkozási javaslatokat tenni.

Napjainkban egyre több olyan eszköz jelenik meg a piacon, amely már integrált mesterséges intelligenciával működik, és képes az alvás és stresszadatokat automatikusan elemezni. Az Oura gyűrű, a Whoop karkötő vagy a Fitbit újabb generációi már nemcsak grafikonokat kínálnak a felhasználónak, hanem automatikusan kiértékelt „recovery score”-okat, alvásminőségi jelentéseket vagy éppen stressz-érzékenységi indexeket is, amelyek mögött valós gépi tanulási algoritmusok működnek. Ezek az adatok nemcsak a felhasználó önismeretét növelhetik, hanem orvosok, pszichológusok számára is értékes információval szolgálhatnak, ha megfelelő szakmai keretben történik az értelmezésük.

Mindezek ellenére szükséges a kritikus szemlélet megőrzése is. Több tanulmány figyelmeztet arra, hogy az algoritmusok teljesítménye nagymértékben függ az edzésadatok minőségétől, valamint az egyéni variabilitás figyelembevételétől. Egy-egy alany alvásciklusa, stresszreakciós mintázata ugyanis sokkal inkább idioszinkratikus, mint azt egy „átlagos felhasználói” modell sugallná. Ezért hangsúlyozzák a szakemberek a személyre szabott algoritmusok jelentőségét, valamint a pszichológiai szakértői kontroll szükségességét (Bailey et al., 2023).

Összességében a stressz és alvásmintázatok MI-alapú előrejelzése egyre pontosabb és egyre elérhetőbb. A kihívás már nemcsak technológiai, hanem etikai és pszichológiai is: hogyan tudjuk ezeket az eszközöket úgy beágyazni a mindennapi életbe, hogy azok valóban támogassák a jóllétet – anélkül, hogy túldiagnosztizálnánk vagy túlzottan monitoroznánk magunkat?

Intervenciók személyre szabása AI segítségével

A mentális és fizikai jóllét támogatására szolgáló pszichológiai intervenciók sokáig egy „mindenkire ugyanaz” logikáját követték. Bár az egyéni különbségek fontosságát már a 20. század elején is hangsúlyozták a pszichológiában, a gyakorlatban gyakran generikus tanácsokat, sztenderdizált programokat kaptak a kliensek. Az MI azonban új korszakot nyitott ebben: olyan lehetőségeket kínál, amelyek révén az intervenciók valóban az egyéni szükségletekhez, pszichés állapothoz és viselkedési mintákhoz igazíthatók — még hozzá valós időben.

Az MI-alapú személyre szabás lényege, hogy algoritmusok valós idejű adatokat – például alvásciklus, aktivitási szint, pulzus, telefonhasználat – elemzése alapján képesek meghatározni, mikor és milyen típusú intervenció lehet a leghatékonyabb. Villalobos et

al. (2023) egy mobiltelefonos alkalmazást vizsgáltak, amely a felhasználók hangulati naplózását és fiziológiai adatait elemezte, hogy megfelelő pillanatban javasoljon légzéstechnikákat vagy rövid mindfulness-gyakorlatokat. A rendszer a tanulmányban 74%-os hatékonysággal segítette a stresszérzet csökkentését — különösen azoknál, akik rendszeresen interakcióba léptek az app javaslataival.

Különösen izgalmas az úgynevezett „just-in-time adaptive intervention” (JITAI) modell, amelyet az MI különösen jól támogat. A JITAI koncepciója arra épül, hogy nemcsak a tartalmat, hanem az időzítést is személyre szabja. Az MI ezekhez figyelembe veszi az előző viselkedésmintákat, érzelmi állapotot és környezeti tényezőket is — például azt, hogy valaki mikor szokott reagálni pozitívan egy beavatkozásra. Nahum-Shani és munkatársai (2021) szerint ezek a modellek lehetőséget nyújtanak arra, hogy a segítség „éppen akkor” érkezzon, amikor a legnagyobb szükség van rá — például egy stresszes munkanap után, vagy alvászavar jelentkezésekor.

Az intervenciók személyre szabása különösen fontos a krónikus betegségek esetén is. Egy friss tanulmányban Li et al. (2024) olyan MI-támogatott terápiás modellt írtak le, amely képes volt egyéni pszichológiai profil és digitális viselkedés alapján pszichoszociális támogató tartalmakat javasolni cukorbeteg pácienseknek. A modell nemcsak a vércukorszintre, hanem a stresszre és alvásra is reagált, és képes volt „érzelmi nyelven” visszacsatolást adni, amelyet a páciensek elfogadóbban érztek, mint a hagyományos tanácsokat.

Fontos azonban megemlíteni, hogy a személyre szabás nem csupán technológiai kihívás, hanem etikai kérdés is. Vajon meddig mehet el egy algoritmus az „intimitásban”? Mikor válik a segítség invazívvá? Hogyan biztosítható, hogy a beavatkozás valóban segítő szándékú, és ne manipuláló erejű legyen? Ezekre a kérdésekre még keresik a válaszokat — de az irány világos: a jövő pszichológiai intervenciói már nem csak rólunk szólnak, hanem velünk együtt formálódnak.

Alkalmazási terület	MI-megoldás típusa	Előnyök	Kihívások / Figyelmeztetések	Példák / Források
Digitális egészségmonitorozás	Viselhető eszközök + AI-alapú predikciós modellek	Valós idejű mérés, korai figyelmeztetések, objektív adatok	Pontosság eltérése (pl. bőrtónus, aktivitás), adatvédelem	Wang et al., 2024; Bailey et al., 2023
Stressz- és alvásmintázatok elemzése	Mélytanulási algoritmusok, időalapú predikció	Alvászavarok vagy krónikus stressz előrejelzése, beavatkozás időzítése	Nehézségek az érzelmi állapotok finom detektálásában, túlérzékeny modellek	Ramirez et al., 2023; Paredes et al., 2022
Személyre szabott intervenciók	JITAI-modellek, kontextuális gépi tanulás	Pszichológiai támogatás megfelelő időben, releváns tartalom	Túlintimitás, etikai aggályok, motivációs torzítás	Nahum-Shani et al., 2021; Villalobos et al., 2023
Betegségprevenció és jóllét	Kombinált fiziológiai + pszichológiai adatelemzés	Multimodális predikció, preventív támogatás krónikus betegségekben	Komplex adatkezelés, szükség van hosszú távú validációra	Li et al., 2024

1. táblázat A mesterséges intelligencia (MI) szerepe az egészségpszichológiában és prevencióban

Szakirodalom

- Ahmed, S., Chao, M., & Low, H. M. (2024). Deep learning analysis of sleep patterns for anxiety prediction in young adults. *Sleep and Cognition Research*, 7(1), 112–125. <https://doi.org/10.1016/j.scr.2024.01.008>
- Bailey, A. P., Reavley, N. J., Jorm, A. F., & Rickwood, D. J. (2023). Artificial intelligence in mental health prevention: Opportunities and challenges. *Journal of Mental Health & Prevention*, 29, 200399. <https://doi.org/10.1016/j.jmhp.2023.200399>
- Chen, W., Zhang, Y., & Liu, X. (2023). Machine learning-based detection of chronic stress using wearable sensor data. *Frontiers in Digital Health*, 5, 105822. <https://doi.org/10.3389/fdgth.2023.105822>
- Li, X., Hernandez, K. A., & Smith, M. (2024). AI-assisted psychological coaching for patients with type 2 diabetes: A personalized approach. *Journal of Digital Health Interventions*, 9(1), 48–63. <https://doi.org/10.1016/j.jdhi.2024.01.004>
- Nahum-Shani, I., Smith, S. N., Spring, B. J., Collins, L. M., Witkiewitz, K., Tewari, A., & Murphy, S. A. (2021). Just-in-time adaptive interventions (JITAs) in mobile health: Key components and design principles for ongoing health behavior support. *Annals of Behavioral Medicine*, 52(6), 446–462. <https://doi.org/10.1093/abm/kax004>
- Palagini, L., Biber, K., & Riemann, D. (2019). The role of stress in insomnia: A psychobiological perspective. *Sleep Medicine Reviews*, 43, 101–112. <https://doi.org/10.1016/j.smr.2018.09.003>
- Ramirez, J., Ospina, P., & Patel, V. (2023). Predictive analytics and early detection of depression: A machine learning approach using wearable data. *Digital Mental Health Journal*, 5(1), 45–58. <https://doi.org/10.1016/j.dmhj.2023.02.007>
- Tan, K. M., Lim, R. H., & Goh, W. S. (2024). Multimodal AI for stress prediction in university students: A longitudinal study. *Computers in Human Behavior Reports*, 10, 100298. <https://doi.org/10.1016/j.chbr.2024.100298>
- Villalobos, D., Jansen, K., & Mahoney, K. (2023). Context-aware interventions for mental wellness: A machine learning approach to adaptive stress reduction. *Mobile Mental Health Journal*, 12(3), 141–158. <https://doi.org/10.1016/j.mmhj.2023.141>
- Wang, Y., Liu, H., Zhang, J., & Zhou, X. (2024). Smart health tracking and preventive psychology: Deep learning applications in stress monitoring. *Computers in*

Human Behavior Reports, 9, 100237.

<https://doi.org/10.1016/j.chbr.2024.100237>

Wang, Y., Liu, H., Zhang, J., & Zhou, X. (2024). Smart health tracking and preventive psychology: Deep learning applications in stress monitoring. Computers in

Human Behavior Reports, 9, 100237.

<https://doi.org/10.1016/j.chbr.2024.100237>

III. JÖVŐBELI IRÁNYOK ÉS KIHÍVÁSOK

A mesterséges intelligencia (MI) jelenléte a pszichológia világában ma már nem csupán technológiai érdekesség, hanem mindennapi realitás. Ami egy-két évtizeddel ezelőtt még futurisztikus elképzelésnek tűnt – például gépek által generált terápiás szövegek, automatikus érzelemfelismerés, vagy prediktív diagnosztika –, az ma már nemcsak elérhető, de sok esetben bevett gyakorlattá is vált. Ez a gyors ütemű fejlődés azonban nemcsak lehetőségeket, hanem komoly kihívásokat is rejt – különösen, ha a pszichológia alapvető értékeit, az emberközpontúságot, empátiát és etikus működést is meg akarjuk őrizni.

Az MI jövőbeli szerepének értelmezése kapcsán két ellentétes, mégis egymást kiegészítő tendencia rajzolódik ki. Egyrészt az automatizálás, amely egyre több pszichológiai folyamatot – a diagnózistól a tanácsadásig – képes részben vagy egészben algoritmizálni. Másrészt az emberi tényező iránti újrafelfedezett igény, amely arra emlékeztet bennünket, hogy minden technológia végső célja az emberi jóllét támogatása kell, hogy legyen.

Ebben a fejezetben négy kulcsterületre fókuszálunk, ahol a jövő kihívásai különösen élesen mutatkoznak meg. Elsőként a generatív MI – azaz a szöveget, képet, hangot „alkotó” algoritmusok – pszichológiai alkalmazásait vizsgáljuk, különösen terápiás és oktatási kontextusban. Ezt követően a multimodális adatelemzés lehetőségeit és buktatóit tárgyaljuk: hogyan lehet integrálni a hangot, képet, mozgást és nyelvi adatokat egy közös pszichológiai értelmezési keretbe? A harmadik rész az etikai és jogi dilemmákat tárgyalja – különös tekintettel az adatkezelésre, felelősségvállalásra és döntéshozatali transzparenciára. Végül, de nem utolsósorban, arra keressük a választ, hogyan őrizhető meg az emberi tényező egy olyan világban, ahol egyre több mentális és viselkedési folyamat „leírható” adattá.

A pszichológia nem csupán adatokkal dolgozik – hanem emberekkel. Ahogy Topol (2019) találóan fogalmaz: a technológia akkor szolgálja igazán az emberiséget, ha nem helyettesíti, hanem kiegészíti az emberi kapcsolatokat. Ez a szemlélet ma aktuálisabb, mint valaha.

Generatív AI szerepe (pl. terápiás szövegek, oktatási anyagok)

Az MI egyik leglátványosabb és leginkább vitatott területe napjainkban a generatív algoritmusok térnyerése. Ezek az eszközök – mint a GPT-4, Claude, Mistral vagy a Google Gemini – képesek teljes szövegeket, képeket, hangokat és akár videókat is

létrehozni. Míg néhány éve még csodaszámba ment egy értelmesnek tűnő gépi válasz, ma már a pszichológiai tanácsadásban, terápiás előkészítő anyagokban vagy egyetemi oktatásban is komoly szerep jut az ilyen rendszerek által generált tartalmaknak (Raviv et al., 2023).

Az oktatásban a generatív MI új szintre emelte a tanulási anyagok személyre szabását. Az algoritmusok képesek egy adott diák tudásszintjéhez, tanulási stílusához és érdeklődési köréhez igazítani az anyagot – például egyszerűbb nyelvezetet használva, vagy épp új példákkal illusztrálva az adott fogalmat. Ez különösen hasznos a pszichológiai oktatásban, ahol az elvont elméletek és gyakorlati készségek együttesen vannak jelen (Ahn et al., 2021).

A mentálhigiénés ellátásban a generatív MI egy másik dimenzióban mutat újat. Egyre több kísérlet zajlik arra, hogy az LLM-eket terápiás szövegek előállítására vagy akár kognitív viselkedésterápiás (CBT) forgatókönyvek írására használják (Shin et al., 2023). Ezek a rendszerek képesek rövid, empatikus válaszokat adni, alternatív gondolatokat javasolni, vagy támogató megerősítéseket kínálni – természetesen nem a pszichológus helyettesítőjeként, hanem annak kiegészítőjeként. Bár sokan tartanak attól, hogy a gépi válaszok felszínesek vagy „érzékletlenek”, számos kutatás szerint a megfelelően finomhangolt modellek sok esetben hitelesen tudják követni a terápiás diskurzus alapszabályait (Ravichander et al., 2023).

A generatív MI lehetőségei azonban nem válnak automatikusan erénnyé. Az egyik legkomolyabb kihívás a „hallucináció” jelensége, vagyis az, amikor a modell meggyőzően fogalmaz, de valótlan tartalmat állít elő. Ez különösen problematikus terápiás vagy oktatási kontextusban, ahol a pontosság és hitelesség alapvető. Emellett felmerülnek adatvédelmi, szerzői jogi és felelősségi kérdések is – például kié a tartalom, ha azt egy algoritmus generálta, és hogyan lehet kontrollálni, hogy a generált anyag valóban etikus és tudományosan megalapozott (Bender et al., 2021).

Összességében a generatív MI ígéretes, de érzékeny terület a pszichológia jövőjében. Nem csupán technológiai innovációról van szó, hanem arról, hogy hogyan tudjuk a rendszereket integrálni úgy, hogy azok kiegészítsék – és ne kiszorítsák – az emberi érzékenységet, szakértelmet és kapcsolatot.

Multimodális adatelemzés (hang, kép, viselkedés integrálása)

Ahogy az emberi viselkedés sem egyetlen dimenzió mentén értelmezhető, úgy a pszichológia is egyre inkább felismeri: ha mélyebben szeretnénk megérteni a gondolkodást, érzelmeket és döntéshozatalt, akkor különböző típusú adatokat kell együttesen vizsgálni. Ebből az igényből nőtt ki az úgynevezett multimodális

adatelemzés területe, amely hang-, képi-, mozgás- és nyelvi adatokat egyesítve próbál komplex viselkedési mintázatokat azonosítani. A mesterséges intelligencia, különösen a mélytanuló algoritmusok, ebben a folyamatban kulcsszerepet játszanak: képesek összekapcsolni azokat az adatcsatornákat, amelyeket az emberi megfigyelés elkülönítve látna. Például egy terápiás ülés során nemcsak az elhangzó szavak számítanak, hanem a hanghordozás, a mimika, a szemkontaktus vagy akár a testtartás változásai is. A modern MI-rendszerek képesek ezeket a jelzéseket párhuzamosan elemezni, és olyan érzelmi vagy kognitív állapotokra utaló mintázatokat azonosítani, amelyeket emberként gyakran intuitíven érzünk, de nehéz lenne egzakt módon mérni (Baltrušaitis et al., 2018). Az ilyen integrált megközelítéseknek nemcsak a pszichoterápiában lehet szerepe, hanem például az oktatásban is – egy multimodális rendszer képes lehet arra, hogy azonosítsa, mikor veszítette el a tanuló a figyelmét, vagy mikor frusztrált egy feladat során (D’Mello & Graesser, 2015).

Egyre több kutatás vizsgálja azt is, hogy a multimodális MI hogyan járulhat hozzá a mentális zavarok korai felismeréséhez. Egyes modellek például képesek az arc mimika és beszéd mintázat apró változásainak nyomon követésére, amelyek korai indikátorai lehetnek a depresszióknak vagy a szorongásos zavaroknak (Alhanai et al., 2017). Ezek a megközelítések különösen ígéretesek lehetnek a telemedicina és távpszichológiai ellátások fejlődésével párhuzamosan, hiszen olyan "láthatatlan" adatrétegekre is fényt deríthetnek, amelyek a klasszikus kérdőíves vagy verbális értékelésekből nem derülnek ki.

Ugyanakkor a multimodális MI nem mentes az etikai kihívásoktól sem. A különböző típusú adatok – különösen a biometrikus és érzelmi jelek – együttes kezelése érzékeny adatvédelmi kérdéseket vet fel. Nem mindegy, hogy milyen kontextusban történik a gyűjtés, mennyire transzparens az elemzés, és milyen módon vonják be a felhasználókat a folyamatba. E kihívások ellenére a multimodális elemzés egy olyan irány, amely valószínűleg meghatározza majd a pszichológiai kutatás és alkalmazás következő évtizedeit.

Etikai és jogi szabályozás

Ahogy a mesterséges intelligencia (MI) egyre szervezesebb része lesz a pszichológiai és mentálhigiénés gyakorlatoknak, úgy válik egyre sürgetőbbé az etikai és jogi keretek világos lefektetése. Míg korábban a pszichológus legfőbb dilemmája a szakmai titoktartás és a terápiás felelősség kérdéskörében mozgott, ma már új kihívások jelennek meg – például kié az adat, amit egy viselhető eszköz gyűjtött, és kié a döntés, ha egy MI-modell javasolja a beavatkozást?

A jogi szabályozás jelenleg gyakran lemaradásban van az innovációhoz képest. Az európai uniós AI Act (European Commission, 2023) például különböző kockázati szinteket határoz meg az MI-rendszerekre, és kiemelten kezeli az egészségügyben, oktatásban vagy igazságszolgáltatásban használt alkalmazásokat. Az ilyen rendszerek esetében a transzparencia, a magyarázhatóság és a felelősségvállalás elvét hangsúlyozzák. Ez különösen fontos lehet például akkor, amikor egy algoritmus személyiségprofilt állít fel egy állásinterjú során, vagy pszichés állapotokat próbál megjósolni egy viselkedésmintázat alapján (Floridi & Cowsls, 2022).

Az etikai dilemmák viszont nem mindig jogi kérdések. Egy terapeuta például használhat MI-alapú naplóelemző eszközt, amely segíti a kliensek gondolkodásának strukturálását. De vajon tudja-e a kliens, hogy a szövegeit egy gép is elemzi? És ha az algoritmus téved, ki a felelős? A World Health Organization (2021) etikai irányelvei szerint az MI alkalmazása az egészségügyben csak akkor etikus, ha biztosított a személyes adatok védelme, az érintettek informált beleegyezése, és a döntéshozatalban az emberi kontroll végig megmarad.

A pszichológiában különösen kényes az adatkezelés kérdése. A páciensek által megosztott információk bizalmasak, és egy MI-modell „tanulása” során nem várt módon is újra felhasználódhatnak. Éppen ezért fontos az ún. differential privacy technikák alkalmazása, amelyek csökkentik az egyének újraazonosításának kockázatát (Dwork & Roth, 2014).

A jelen kihívásai tehát nem csak technikai, hanem mélyen emberi természetűek is. Az MI-rendszereknek be kell illeszkedniük a már létező pszichológiai normák közé, nem pedig felforgatni azokat. Ez csak úgy történhet meg, ha az etikai és jogi szabályozás nemcsak utólagos reakcióként, hanem aktív párbeszédként működik a technológiafejlesztéssel együtt. A cél nem a fékezés, hanem a felelős, reflektív beágyazás.

Szakirodalom

- Ahn, J., Lin, J., Park, H., & Kim, J. (2021). Adaptive content delivery in higher education using generative AI. *Journal of Educational Technology Research*, 39(2), 145–162. <https://doi.org/10.1007/s11423-021-10023-7>
- Alhanai, T., Ghassemi, M., & Glass, J. (2017). Detecting Depression with Audio/Text Sequence Modeling of Interviews. *Proceedings of Interspeech 2017*, 1716–1720. <https://doi.org/10.21437/Interspeech.2017-1096>

- Baltrušaitis, T., Ahuja, C., & Morency, L.-P. (2018). Multimodal Machine Learning: A Survey and Taxonomy. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 41(2), 423–443. <https://doi.org/10.1109/TPAMI.2018.2798607>
- Bender, E. M., Gebru, T., McMillan-Major, A., & Shmitchell, S. (2021). On the Dangers of Stochastic Parrots: Can Language Models Be Too Big? *FACCT '21: Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency*, 610–623. <https://doi.org/10.1145/3442188.3445922>
- D’Mello, S. K., & Graesser, A. (2015). Feeling, thinking, and computing with affect-aware learning technologies. In R. A. Calvo, S. K. D’Mello, J. Gratch, & A. Kappas (Eds.), *The Oxford Handbook of Affective Computing* (pp. 419–434). Oxford University Press.
- Dwork, C., & Roth, A. (2014). The Algorithmic Foundations of Differential Privacy. *Foundations and Trends® in Theoretical Computer Science*, 9(3–4), 211–407. <https://doi.org/10.1561/04000000042>
- European Commission. (2023). Proposal for a Regulation Laying Down Harmonised Rules on Artificial Intelligence (Artificial Intelligence Act). Retrieved from <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX%3A52021PC0206>
- Floridi, L. (2021). *The Logic of Information: A Theory of Philosophy as Conceptual Design*. Oxford University Press.
- Floridi, L., & Cowls, J. (2022). A Unified Framework of Five Principles for AI in Society. *Harvard Data Science Review*, 4(1). <https://doi.org/10.1162/99608f92.be94bbd2>
- Mittelstadt, B. D., Allo, P., Taddeo, M., Wachter, S., & Floridi, L. (2016). The ethics of algorithms: Mapping the debate. *Big Data & Society*, 3(2). <https://doi.org/10.1177/2053951716679679>
- Ravichander, A., Gehrmann, S., Zhang, S., & McKeown, K. (2023). Challenges in evaluating generative models for mental health applications. *Proceedings of the ACL 2023*, 235–248. <https://doi.org/10.18653/v1/2023.acl-main.150>
- Raviv, N., Schneider, A. M., & Brody, D. (2023). Generative AI in Education and Mental Health: Promise and Peril. *AI & Society*. <https://doi.org/10.1007/s00146-023-01612-9>
- Shin, S., Liu, D., & Xu, Y. (2023). Large Language Models as CBT Co-Therapists: Experimental Evidence and Framework. *Journal of Digital Mental Health Interventions*, 5(1), 22–35. <https://doi.org/10.1037/dmh0000280>
- Topol, E. (2019). *Deep Medicine: How Artificial Intelligence Can Make Healthcare Human Again*. Basic Books.

World Health Organization. (2021). Ethics and Governance of Artificial Intelligence for Health: WHO Guidance.
<https://www.who.int/publications/i/item/9789240029200>