



A XVIII. PÉCSI PÉNZÜGYI NAPOK
IV. Pénzügy és Számvitel Nemzetközi
Tudományos Konferencia
TANULMÁNYKÖTETE

XVIII. FINANCE DAYS IN PÉCS
IV. Finance and Accounting International
Scientific Conference
BOOK OF STUDIES

2026. június 4.

Pécs

XVIII. PÉCSI PÉNZÜGYI NAPOK / XVII. FINANCE DAYS IN PÉCS

IV. Pénzügy és Számvitel Nemzetközi Tudományos Konferencia / III. Finance and Accounting International Scientific Conference

Pécs, 2026. június 4.

Szervezők / Organizers:

Pécsi Tudományegyetem Közgazdaságtudományi Kar Pénzügy és Számvitel Intézet / University of Pécs Faculty of Business and Economics Institute of Finance and Accounting

A konferencia elnöke / Chair of the Conference:

Dr. Csapi Vivien egyetemi docens, a PTE KTK Pénzügy és Számvitel Intézet igazgatója / Dr. Vivien Csapi, Associate Professor, Head of Department of the Finance and Accounting

Felelős kiadó / Executive Publisher:

a Pécsi Tudományegyetem Közgazdaságtudományi Kar dékánja / University of Pécs Faculty Business And Economics

Szerkesztette / Edited by: M. HORVÁTH Gábor

ISBN 978-963-626-621-9

<https://doi.org/10.15170/XVIIPPN-Tk-KTK-2026>

© PTE KTK/2026 – Minden jog fenntartva.

TARTALOMJEGYZÉK

MAGYAR NYELVŰ TANULMÁNYOK / HUNGARIAN LANGUAGE PAPERS	5
BARNÓCZKI ZSUZSA: BIZALOM AZ MI-ALAPÚ OKTATÁSI SZOLGÁLTATÁSOKBAN: KULTURÁLIS ÉS DIGITÁLIS TÉNYEZŐK A VIETNÁMI PIACON	6
BENCE VIVIEN, HARCI TAMÁS, GÁSPÁR BETTINA: A MESTERSÉGES INTELLIGENCIA HATÁSA A VISELKEDÉSI TORZÍTÁSOK CSÖKKENTÉSÉRE A PÉNZÜGYI DÖNTÉSHOZATALBAN	20
CZINE VANDA, DR. SIKLÓSI ÁGNES, DR. SISA KRISZTINA ANDREA: ESG-JELENTÉSEK AZ EURÓPAI UNIÓBAN MINŐSÉG ÉS ELLENŐRZÉS SZEMPONTJÁBÓL	36
CSAPI PATRIK: AZ ALKOHOLHASZNÁLATHOZ KÖTHETŐ TÁRSADALMI KÖLTSÉG ÉS A KORAI BEAVATKOZÁS TÁRSADALMI OPCIOÉRTÉKE: REÁLOPCIÓS MEGKÖZELÍTÉS NEMZETKÖZI ADATOKON	50
FÁRÓ JENŐ, JÓNÁS TAMÁS: FUZZY-ENTRÓPIA-ALAPÚ KOCKÁZATOSSÁGI MUTATÓ: EMPIRIKUS KONSTRUKCIÓ ÉS ALKALMAZÁS.....	73
GECSE DOMINIKA ANNA: GENERATÍV AI-MODELLEK ÖSSZEHASONLÍTÓ ÉRTÉKELÉSE TURBULENS PÉNZÜGYI DÖNTÉSI HELYZETEKBE: MEGBÍZHATÓSÁG, KOCKÁZATÉRZÉKENYSÉG ÉS AI-GOVERNANCE.....	90
HEITLER KRISZTINA: GENERATÍV MESTERSÉGES INTELLIGENCIA ÉS PÉNZÜGYI DÖNTÉSTÁMOGATÁS STRUKTURÁLISAN VÁLTOZÓ INTÉZMÉNYI KÖRNYEZETBEN.....	106
KIRÁLY TÜNDE, DR. HARTA PÉTER: AZ INNOVÁCIÓS TÁMOGATÁSOK ELŐREJELEZHETŐSÉGE GAZDASÁGI INDIKÁTOROK ALAPJÁN.....	120
KOMLÓSI ATTILA: A PÉNZÜGYI MENEDZSMENT ÉS A STRATÉGIAI BESZERZÉS INTEGRÁCIÓJA A DIGITALIZÁCIÓ KORÁBAN: MESTERSÉGES INTELLIGENCIA ÉS GÉPI TANULÁS ALKALMAZÁSI LEHETŐSÉGEI.....	135
LOVÁSZ ZOLTÁN: ADATVEZÉRELT MŰKÖDÉSI MODELLEK ÉS A DIGITÁLIS TRANSZFORMÁCIÓ ELMÉLETI KIHÍVÁSAI A PÉNZÜGYI SZÉKTORBAN	155
M. HORVÁTH GÁBOR: MESTERSÉGES INTELLIGENCIA ALKALMAZÁSA A VÁLLALATI ÉRTÉKTEREMTÉST TÁMOGATÓ BESZÁMOLÓELEMZÉSBEN	167
M. HORVÁTH GÁBOR: FENNTARTHATÓSÁG ÉS PÉNZÜGYI STABILITÁS: ÖSSZEHANGOLT VÁLLALATI STRATÉGIA VAGY KÜLÖN UTAK?	184
DR. SISA KRISZTINA ANDREA, DR. SIKLÓSI ÁGNES: FENNTARTHATÓ SZÁMVITEL 2.0	196
MAKÓ TAMÁS, SZABÓNÉ BEKE BEÁTA ÁGOTA: NAGY NYELVI MODELLEK, MINT STRATÉGIAI ELEMZŐK: SWOT ELEMZÉS GENERÁLÁSA ÉS ÉRTÉKELÉSE PÉNZÜGYI JELENTÉSEK ALAPJÁN	212
DR. SZAKÁCS ATTILA, NAGY GERGELY MIKLÓS, SZAKÁCS DOMINIK: AI ÉS VISELKEDÉSI TORZÍTÁSOK INTEGRÁCIÓJA A TURBULENS PÉNZÜGYI KÖRNYEZETBEN	223
SZEMES-RÉVÉSZ ENIKŐ EVELIN: MESTERSÉGES INTELLIGENCIA A PÉNZÜGYI MŰVELTSÉG FEJLESZTÉSÉBEN: HATÁSOK A KÖZÉPISKOLÁSOK PÉNZÜGYI DÖNTÉSHOZATALI MINTÁIRA	242
ZILAHY BENCE, ZSARNAY ISTVÁN GÁBOR: AZ AI-ALAPÚ IDŐSORELEMZÉS LEHETŐSÉGEI ÉS KORLÁTAI A MODERN PÉNZÜGYI DÖNTÉSHOZATALBAN	259

ANGOL NYELVŰ TANULMÁNYOK / ENGLISH LANGUAGE PAPERS	269
BOUKELOUA, IHEB; DR. SIPICZKI ZOLTÁN, DR. PARÁDI-DOLGOS ANETT KATALIN: ARTIFICIAL INTELLIGENCE AS EMBEDDED GOVERNANCE INFRASTRUCTURE IN FINANCIAL REPORTING QUALITY	270
CZINE VANDA, LAMPER ÁGNES: ARTIFICIAL INTELLIGENCE IN ACCOUNTING: PERSPECTIVES ON AUTOMATION AND QUALITY ACCORDING TO EUROPEAN ACCOUNTING PROFESSIONALS	284
SEYED MEHDI ALAVI: FINANCIAL STRATEGIES AND FLEXIBILITY IN THE EMS INDUSTRY: EVIDENCE FROM EUROPEAN AND MIDDLE EASTERN OPERATORS	295

MAGYAR NYELVŰ TANULMÁNYOK / HUNGARIAN LANGUAGE PAPERS

BIZALOM AZ MI-ALAPÚ OKTATÁSI SZOLGÁLTATÁSOKBAN: KULTURÁLIS ÉS DIGITÁLIS TÉNYEZŐK A VIETNÁMI PIACON

BARNÓCZKI Zsuzsa

Neumann János Egyetem Gazdálkodás- és Szervezéstudományok Doktori Iskola
galz@ktk.pte.hu

<https://doi.org/10.15170/XVIIPPN-Tk-KTK-2026-01>

Absztrakt

A tanulmány célja annak feltárása, hogy a vietnámi felsőoktatási és továbbképzési piacon milyen kulturális és intézményi mechanizmusok alakítják a fogyasztói bizalmat a mesterséges intelligencia (MI) alapú oktatási szolgáltatások iránt és hogyan tartják fenn a humán jelenlét iránti tartós keresletet egy gyorsan digitalizálódó piacon. A kérdés a magyar felsőoktatási export pozícionálása szempontjából releváns, hiszen a vietnámi online oktatási piac 2025-ös becsült volumene ~298,2 millió USD, 19,1%-os éves átlagos összetett növekedési ütemmel (Compound Annual Growth Rate, CAGR) 2034-ig (IMARC Group, 2025 - formális online oktatási szegmens, szűkebb értelmezésben) és mindeközben az interjúk alapján a résztvevők többsége a humán mentorálás megőrzését preferálta.

A módszertan kevert megközelítésen alapul. A szakirodalmi áttekintés a bizalmi (Mayer és társai, 1995; McKnight et al., 2002), automatizációs (Lee és See, 2004; Glikson és Woolley, 2020) és konfuciánus tanulási kultúra modellekből (Nguyen et al., 2006; Tran, 2013) építkezik. Az empirikus alapot félig strukturált mélyinterjúk sorozata (N = 12 résztvevő) adja a HUTECH (Ho Chi Minh-i Műszaki Egyetem) és az UEF (Ho Chi Minh-i Közgazdaság- és Pénzügytudományi Egyetem) intézményekben, Ho Chi Minh városban, 2026 áprilisában - júniusában; az elemzés Braun és Clarke (2006) hat lépéses tematikus protokollját követi, kombinált deduktív - induktív kódolással.

Az előzetes eredmények szerint az MI-alapú szolgáltatások iránti tartós bizalom a vietnámi mintában három antecedens - technológiai megbízhatóság, intézményi jelzés és humán felelősségvállalás - *konjunktív jellegű* együttes jelenlétéhez kötődik: a tartós bizalom narratíváiban mindhárom antecedens jelen volt, bármelyik tartós hiánya jellemzően a bizalom gyengülésével együtt jelent meg. A humán mentor szerepe nem helyettesíthető pusztán technológiai vagy árazási eszközökkel; egyszerre kompetencia-validátor, felelősségvállalási horgony és kulturális közvetítő.

A jelen kvalitatív szakasz alapján három előzetes stratégiai irány körvonalazódik a vietnámi piacra lépő magyar felsőoktatási intézmények számára: (1) az árazási logika a szegmentált fizetési hajlandósághoz igazítása, (2) a vietnámi partnerintézménnyel közös bizalmi szignálra építő pozícionálás és (3) a humán jelenlét nem

költségtételként, hanem árazható szolgáltatás-attribútumként történő kezelése. E javaslatok statisztikai validálása a kutatási program kvantitatív szakaszára vár.

Kulcsszavak: mesterséges intelligencia, fogyasztói bizalom, felsőoktatási export, digitális oktatás, Vietnám

Köszönetnyilvánítás. A szerző köszönetét fejezi ki a HUTECH (Ho Chi Minh-i Műszaki Egyetem) és az UEF (Ho Chi Minh-i Közgazdaság- és Pénzügytudományi Egyetem) intézményeknek a 2026 áprilisi-júniusi terepmunka támogatásáért, valamint a Neumann János Egyetem Gazdálkodás- és Szervezéstudományok Doktori Iskolájának a kutatási háttér biztosításáért.

1. Bevezetés

Az elmúlt két évben az egész technológiai tér jelentősen megváltozott a generatív MI forradalom és a technológiai forradalom miatt. A generatív MI az elmúlt két évben drámaian megváltoztatta az online oktatási szolgáltatások költségszerkezetét és skálázhatóságát. Ezzel párhuzamosan Vietnámban az online oktatási piac az előrejelzések szerint 2025-re több mint 298,2 millió dollárt termel és 2025 és 2034 között továbbra is 19,1%-os átlagos CAGR-rel fog növekedni (IMARC Group, 2025). Az online oktatás iránti kereslet egyre inkább eltolódik a hagyományos diplomaprogramoktól a rövid távú tanfolyamok és mikro-tanúsítványok felé. Viszont az interjúkban megkérdezettek kijelentették, hogy elvárják az emberi jelenlétet is a tanfolyamokon. A vietnámi egyetemi döntéshozók, oktatók és hallgatók közül sokan jelezték, hogy az MI által előállított tartalom nem fogja helyettesíteni az emberi jelenlétet, sőt, egyes szegmensekben hajlandóak felárat fizetni annak megtartásáért!

E feszültség nem oldható meg pusztán technológiai vagy pedagógiai oldalról. A tanuló döntése valójában fogyasztói pénzügyi döntés: határokon átnyúló digitális szolgáltatás megvásárlásakor egyszerre mérlegel árat, a tanúsítvány várható munkaerőpiaci értékét, a szolgáltatás megbízhatóságát és a kulturális illeszkedés kockázatát. A nemzetközi szakirodalom ezeket a barrieréket a *bizalom* fogalmával ragadja meg (Akerlof, 1970; Mayer, Davis és Schoorman, 1995; McKnight, Choudhury és Kacmar, 2002). MI-alapú szolgáltatások esetén azonban a bizalom képződése módosul: hiányzik a személyes felelősséget vállaló szolgáltató és bizonyos kulturális kontextusokban - például a konfuciánus pedagógiai hagyományon nyugvó vietnámi tanár-diák viszony esetén - a humán jelenlét hiánya önmagában is erősítheti a bizalom erózióját (Glikson és Woolley, 2020; Nguyen, Terlouw és Pilot, 2006).

E mechanizmusok közvetlen üzleti jelentőséggel bírnak a tartós piaci jelenlétet építő szolgáltatók számára. A magyar felsőoktatási export szempontjából ez kifejezetten releváns: a növekvő vietnámi középosztály és a 2024-es 57-NQ/TW határozat olyan piaci ablakot nyit, amelyben magyar intézmények stratégiai pozíciót szerezhetnének, ha értik a bizalom képződésének helyi mechanizmusait. A tanulmány központi kutatási kérdése: *milyen kulturális és intézményi mechanizmusok alakítják a vietnámi tanulók MI-alapú oktatási szolgáltatások iránti bizalmát és ezek hogyan tartják fenn a humán jelenlét iránti keresletet egy erőteljesen digitalizálódó piacon?*

2. Elméleti háttér

A tanulmány elméleti vázát három, átfedő irodalmi háttér adja: a bizalom közgazdasági és szervezeti viselkedéstudományi modelljei, az MI- és automatizációs technológiák iránti bizalom interdiszciplináris szakirodalma, valamint a konfuciánus tanulási kultúra (Confucian Heritage Culture, CHC) pedagógiai kutatása. E három blokk integrált értelmezése vezet el a human-in-the-loop (HITL) modell mint bizalmi mechanizmus értelmezéséhez.

2.1 A bizalom mint közgazdasági és viselkedéstudományi kategória

A bizalom közgazdasági relevanciáját Akerlof (1970) klasszikus „lemons”-modellje alapozta meg: információs aszimmetria mellett, ahol a szolgáltatás minősége csak vásárlás után derül ki, a piac hatékony működéséhez intézményi vagy reputációs bizalmi mechanizmusok kellenek (Williamson, 1981). A nemzetközi online felsőoktatás ennek prototípus esete: a hallgató előzetesen nem tudja ellenőrizni a minőséget, az intézmény hírnevét vagy a tanúsítvány munkaerőpiaci értékét és a tranzakció határokon átnyúló jellege további reputációs-jogi bizonytalanságot ad hozzá.

A bizalom *szervezetelméleti* definícióját Mayer, Davis és Schoorman (1995) integratív modellje rögzítette: a bizalom annak hajlandósága, hogy a megbízó kiszolgáltatott helyzetbe hozza magát egy másik fél cselekedeteivel szemben, anélkül, hogy ezeket teljes mértékben ellenőrizni tudná. A modell három antecedentet azonosít a megbízhatóság oldaláról: a *képességet* (kompetencia), a *jóindulatot* (érdekfigyelembevétel) és az *integritást* (kiszámítható, normakövető magatartás). Rousseau, Sitkin, Burt és Camerer (1998) interdiszciplináris áttekintése megerősítette, hogy ez a hármas a közgazdaságtanban, pszichológiában és menedzsmenttudományban egyaránt használható közös fogalmi keret.

A szakirodalom szerint a bizalomnak mérhető fogyasztói-pénzügyi következményei vannak - érzékelt kockázat, fizetési hajlandóság, ügyfél-életciklus (Bart, Shankar, Sultan és Urban, 2005) -, és pontosan azokon a piacokon a legdrágább áru, ahol az információs aszimmetria a legnagyobb. A délkelet-ázsiai felsőoktatási export-szegmens ilyen piac.

2.2 Bizalom a digitális és MI-alapú szolgáltatásokban

A digitális szolgáltatások iránti bizalom kutatása részben átveszi a Mayer-féle hármas struktúrát, részben specifikus dimenziókkal egészíti ki. McKnight, Choudhury és Kacmar (2002) e-kereskedelmi modellje négy szintet különböztet meg: a diszpozíciós bizalmat, az intézményalapú bizalmat (a környezet biztosította garanciákba vetett hit), a bizalmi vélekedéseket (a konkrét szolgáltatóra vonatkozó észlelések) és a bizalmi szándékot. Ez a többszintű felépítés azért különösen releváns, mert MI-alapú oktatási szolgáltatások esetén a négy szint különböző mértékben sérül: a platform technikailag működhet, de az intézményi és személyközi referenciapontok hiányoznak vagy átalakulnak.

Az automatizációra vonatkozó bizalom irodalmában Lee és See (2004) a bizalom három forrását azonosítja: a *teljesítményt* (mit csinál a rendszer), a *folyamatot* (hogyan) és a *célt* (miért). MI-vezérelt megoldások esetén a fogyasztó jellemzően csak az első dimenziót látja közvetlenül; a másik kettőhöz interpretációs segítségre van szüksége - és pontosan ez az a pont, ahol az emberi közvetítő bizalmi szerepe felértékelődik.

A generatív MI körüli legfrissebb empirikus szintézisek megerősítik ezt a mintázatot. Glikson és Woolley (2020) áttekintése elkülöníti a *kognitív* (a rendszer kompetenciájába vetett) bizalmat az *érzelmi* (a rendszerrel kialakult viszonyra vonatkozó) bizalomtól és kimutatja, hogy az érzelmi bizalom képződése jellemzően humán közvetítést igényel. Dietvorst, Simmons és Massey (2015) algoritmus-averziós kísérletei bizonyították, hogy a felhasználók aránytalanul büntetik az algoritmus tévedéseit a humán tévedésekhez képest; Logg, Minson és Moore (2019) ellenkező irányú „algoritmus-appreciációs” eredménye éppen rávilágít arra, hogy a bizalmi reakció kontextusfüggő: olyan helyzetekben, ahol a felelősségvállalás társas-erkölcsi tétje nagy, az algoritmus iránti bizalom összeomlik. Az oktatás - társas, identitásformáló, karrier-meghatározó tranzakció - éppen ebbe a kategóriába esik.

2.3 A konfuciánus pedagógiai hagyomány és a bizalom kulturális dimenziói

A vietnámi felsőoktatási kontextus értelmezéséhez a fenti, döntően nyugati eredetű modelleket ki kell egészíteni a regionális tanulási kultúra sajátosságaival. A konfuciánus tanulási kultúra szakirodalma - amelyet Watkins és Biggs (2001) szerkesztett kötetei foglaltak rendszerbe - három *domináns mintázatot* azonosít (a vietnámi tanulói kultúra természetesen ezeken belül is differenciált). Először, a tanár-diák viszony alapvetően aszimmetrikus és morális természetű: a tanár nem információtovábbító, hanem erkölcsi-szakmai modell, akinek a tekintélye a tudás és a személyes felelősségvállalás kombinációjából fakad (Nguyen, Terlouw és Pilot, 2006). Másodszor, a tanulás társas-kapcsolati keretben zajlik, amelyben az egyéni teljesítmény a csoport, a család és a tanár iránti kötelezettségekbe ágyazódik. Harmadszor, a tudás megszerzése nem különül el az erkölcsi nevelődéstől, azaz a tanári tekintély a szakmai kompetencia és a személyes erkölcsi modell-szerep együtteséből fakad.

A CHC-tanuló feltételezett passzivitását illető kritikákat Tran (2013) empirikus munkái árnyalták: a felszínes tanulási megközelítés nem kulturális tulajdonság, hanem a tanulási környezet - különösen a tanári elvárások - strukturális következménye. A vietnámi tanuló igenis képes mély, kritikai tanulásra, amennyiben a tanulási környezet kapcsolati és felelősségi szempontból támogatja. Az implikáció az MI-alapú szolgáltatásokra közvetlen: a tisztán automatizált, kapcsolatmentes formátum gyengítheti azokat a feltételeket, amelyek mellett a CHC-tanuló optimálisan teljesít. Hofstede (2001) kultúráközi mérése Vietnámot magas hatalmi távolság és kollektivista értékek mentén pozicionálja, konzisztensen azzal a megfigyeléssel, hogy az intézményi és személyes tekintélyforrások szerepe a bizalomképzésben nagyobb, mint a nyugati mintákban; Le, Nguyen, Trinh, Le és Pham

(2022) tanulmánya megerősíti, hogy a vietnámi hallgatói döntéseket nemcsak az ár-érték arány, hanem az intézményi reputáció és a társas elismertség is meghatározza.

2.4 Human-in-the-loop mint bizalmi mechanizmus

A human-in-the-loop (HITL) eredetileg gépi tanulási fogalom: az emberi közreműködés szándékos integrációja az automatizált döntési ciklusba. Chiu és Rospigliosi (2025) a HITL oktatási alkalmazásait tárgyalja, ahol a humán mentor és az MI-rendszer együttesen biztosítják a tanulási folyamatot.

A jelen tanulmány a HITL-t *bizalmi mechanizmusként* értelmezi, viszont azt fontos kiemelni, hogy ez nem az irodalom kész definíciója, hanem annak továbbgondolása.

A 2.1-2.3. szakaszok alapján a HITL három, párhuzamos bizalmi funkciót lát el:

(1) *kompetencia-validáció*: a humán mentor lehetővé teszi a Lee és See (2004)

értelmében vett „folyamat” és „cél” dimenziók értelmezését;

(2) *felelősségvállalási horgony*: a humán szereplő jelenléte feloldja az algoritmus-averzió mögött álló elszámoltathatósági hiányt (Dietvorst et al., 2015);

(3) *kulturális közvetítés*: a CHC-kontextusban a humán mentor megőrzi a tanulási folyamat morális-kapcsolati keretét (Nguyen et al., 2006).

E három funkció együttesen állítja vissza a McKnight et al. (2002) modelljében sérült intézményi és személyközi bizalmi szinteket.

2.5 A kutatás konceptuális kerete

A fenti szintézis alapján a tanulmány a bizalom *három antecedensét* javasolja az MI-alapú oktatási szolgáltatások vietnámi kontextusában:

(a) a *technológiai megbízhatóságot* (rendszerkompetencia, kiszámíthatóság),

(b) az *intézményi jelzést* (a szolgáltató hírneve, akkreditációs státusza, reputációs garanciái),

(c) a *humán felelősségvállalást* (személyes mentori jelenlét, mely a kulturális-kapcsolati keretet és a felelősségi horgonyt biztosítja).

A jelen kvalitatív szakasz adatai alapján e három antecedens előzetesen *küszöbalapú* (konjunktív jellegű) viszonyt sugall: bármely dimenzió tartós hiánya az interjúkban a bizalom megrendüléséhez vezetett. A modell vizualizációját az 1. ábra mutatja be; e küszöbjelleg statisztikai megerősítése a kutatási program kvantitatív szakaszának feladata.

1. ábra: A bizalom három antecedensének konjunktív modellje



Forrás: saját szerkesztés

3. A vietnámi felsőoktatási és EdTech-piaci kontextus

3.1 A piac mérete és kereslet-oldali dinamikája

A jelen tanulmány az IMARC Group által használt *Vietnam Online Education Market* definíciót követi, amely a formális online oktatási szolgáltatásokra fókuszál (eltérően a tágabb e-learning piactól, amely a vállalati és K-12 szegmenst is tartalmazza). E szegmens 2025-ös becsült éves volumene mintegy 298,2 millió USD, 19,1%-os éves átlagos növekedéssel 2034-ig (IMARC Group, 2025). E ráta jelentősen meghaladja a hagyományos felsőoktatási kiadások bővülését. A keresleti dinamika háttérben három, egymást erősítő tényező áll: a 100 millió fős lakosság közel kétharmada 35 év alatti és a városi középosztály - különösen Ho Chi Minh városban és Hanoiban - gyors ütemben bővül (World Bank, 2023); a mobilinternet-penetráció regionális összevetésben is kiemelkedő, ami a tisztán online vagy hibrid képzések technikai feltételeit megteremti; végül a digitális gazdaság gyors átalakulása új kompetenciák iránti keresletet generál, amelyet a hagyományos egyetemi programok ciklusideje nem képes kiszolgálni.

A kereslet nem homogén: a vietnámi tanulói piac legalább három, eltérő bizalmi és árazási logikájú szegmensre osztható - alapképzéses egyetemi hallgatók (szülői finanszírozással), munka melletti mesterképzéses szakemberek (saját jövedelmű), és vállalati továbbképzést igénylő szervezeti tanulók (HR-közvetített kereslet) -, eltérő fizetési hajlandósággal és MI-elfogadással (Le, Nguyen, Trinh, Le és Pham, 2022).

3.2 Az intézményi és szabályozási környezet

A vietnámi felsőoktatás struktúrája erősen centralizált: az Oktatási és Képzési Minisztérium (Ministry of Education and Training, MOET) szabályozza a programakkreditációt, a tantervi standardokat és - kritikus módon - a külföldi

oklevelek elismerését (Tran és Marginson, 2018). Bár az elmúlt évtizedben jelentős számú magán- és nemzetközi együttműködésen alapuló intézmény jelent meg (HUTECH, UEF, Phenikaa Egyetem, RMIT Vietnam – a Royal Melbourne Institute of Technology vietnámi képviselője), a MOET szerepe meghatározó marad. Külföldi szolgáltatók a vietnámi piacon gyakran helyi partnerintézménnyel vagy elismerési/jóváhagyási mechanizmusokhoz illeszkedve jelennek meg; a konkrét együttműködési és szabályozási feltételek programtípusonként és intézményi viszonyrendszerként eltérnek. Ez közvetlenül érinti a 2.1. szakaszban tárgyalt intézményi bizalmi szignál kérdését.

A digitális átalakulás makroszintű kerete határozott politikai prioritássá vált. A 2024. december 22-én elfogadott politikai bizottsági határozat (57-NQ/TW) a tudományt, a technológiát, az innovációt és a digitális transzformációt nemzeti stratégiai prioritássá nyilvánította; az elérhető források szerint ennek nyomán 2025-ben több MOET-hez kapcsolódó végrehajtási irány és szabályozási kezdeményezés jelent meg a digitális transzformáció támogatására. A szabályozói lendület tehát egyértelműen a digitalizáció és az MI-integráció irányába mutat.

3.3 Az EdTech-ökoszisztéma és a verseny szerkezete

A vietnámi EdTech-szektor három, részben átfedő rétegre bontható. A *hazai EdTech-vállalkozások* - emblematikus szereplőként a TOPICA Edtech Group és az MI-alapú nyelvi tanulásra szakosodott ELSA Speak - alapvetően a vietnámi belpiacra optimalizált, mobilalapú szolgáltatásokat kínálnak. A *globális platformok* - mindenekelőtt a Coursera és az edX - mikrotanúsítvány- és egyetemi partnerprogramjaikon keresztül egyre erősebben jelen vannak. A *hagyományos felsőoktatási intézmények digitális kínálata* - köztük a HUTECH és az UEF - saját tanulásmenedzsment-rendszerre (Learning Management System, LMS) épülő hibrid programokat fejleszt.

A hazai szereplők erősek a helyi-kulturális dimenzióban (humán mentorálás, MOET-akkreditáció), de gyengék a nemzetközi reputáció területén; a globális platformok ennek az ellenkezője. Európai - köztük közép-európai - intézmények számára az a versenyképes piaci tér, amely a kettőt integrálja: nemzetközi reputáció és kutatási háttér plusz helyi humán jelenlét. A magyar pozíció ezzel együtt sérülékeny: az alacsonyabb márkaismertségből és a korlátozott munkaerőpiaci jelzésekből adódó hátrány aktív intézményi szignalizációval ellensúlyozandó.

3.4 Munkaerőpiaci kontextus és a mikrotanúsítványok szerepe

A munkaerőpiaci kontextus a bizalmi kérdés szempontjából azért lényeges, mert a fogyasztói döntés végső tétje nem a tanulás élménye, hanem a munkaerőpiaci visszaigazolás. A vietnámi munkáltatói gyakorlatban a teljes egyetemi oklevél marad az elsődleges munkaerőpiaci szignál (Tran és Marginson, 2018). A mikrotanúsítványok piaci értéke növekszik, de jellemzően a teljes diploma *kiegészítőjeként*, nem önálló képesítésként ismeri el a munkaerőpiac. Ez a hierarchikus viszony a 2.3. szakaszban tárgyalt CHC-jellegzetességgel - a formális, intézményesített tudásigazolás kiemelt szerepével - konzisztens.

A munkaerőpiac által észlelt kompetenciahiányok (Tran és Marginson, 2018) - kutatás-módszertan, szakterületi angol, kultúraközi kommunikáció, élethosszig tartó tanulás - pontosan azok a területek, ahol az MI-tartalom önmagában jelentős hozzáadott értéket képes nyújtani, de a humán jelenlét nélkül nem hatékonyan: a fogyasztó nem az MI-vezérelt tartalmat utasítja el, hanem azt a *modellt*, amelyben a humán közvetítés hiánya miatt a tanúsítvány munkaerőpiaci hozadéka kétségessé válik.

4. Módszertan

4.1 Kutatási stratégia

A jelen tanulmány egy kevert módszertani doktori kutatási program első, kvalitatív szakaszának eredményeire épül. A kutatási kérdés természete feltáró-magyarázó kvalitatív megközelítést indokol (Creswell és Poth, 2018); a cél nem hipotézisek statisztikai tesztelése, hanem egy fogalmi modell empirikus megalapozása. A mintavétel logikája *elméleti telítettség*re (Glaser és Strauss, 1967) törekszik, nem statisztikai reprezentativitásra.

4.2 Mintavételi keret és résztvevők

A mintavétel célzott és részben hólabda jellegű volt: a belépési pont a HUTECH és az UEF intézményeknél eltöltött 2026 áprilisi kutatói ösztöndíj keretében nyílt meg; a további résztvevőket interjúalany-ajánlások és az elméleti kategóriák lefedettsége alapján választottuk ki. A jelen tanulmány zárásakor 12 résztvevőtől származó mélyinterjú anyag állt rendelkezésre. A minta négy stakeholder-csoportot fed le, három vietnámi egyetemi intézményben (1. táblázat); így szándékosan többszintű: lefedi a fogyasztói, a szolgáltatói és a stratégiai perspektívát, lehetővé téve a bizalmi mechanizmusok többoldalú vizsgálatát.

1. táblázat: Az interjú minta összetétele (N = 12 résztvevő)

Stakeholder-csoport	n	Tipikus pozíciók	Intézmény
Felső intézményi vezetés	3	alelnök, dékán, igazgató	HUTECH, UEF
Középvezetés	4	minőségbiztosítás i, nemzetközi és posztgraduális vezető	HUTECH, UEF, Phenikaa
Oktatók	3	nyelvi, közgazdasági, turisztikai szakterület	HUTECH
Hallgatók	2	végzős alapszakos, munka melletti mesterszakos	HUTECH
Összesen	12		

Forrás: saját szerkesztés a terepmunka adatai alapján

4.3 Adatgyűjtés

Az adatgyűjtés félig strukturált mélyinterjú formájában történt (Brinkmann és Kvale, 2018), egy 13 kérdést tartalmazó interjúvázlat alapján. A vázlat az elméleti kerethez illesztett kérdésblokkokra épült: az MI vietnámi oktatási integrációjának státusza; az automatizált megoldások korlátai és a humán jelenlét szerepe; a konfuciánus tanár-diák viszony átalakulása; a magyar felsőoktatás észlelése; a választási kritériumok; valamint a magyar-vietnámi együttműködési modellek.

Az interjúk angol nyelven zajlottak, két esetben tolmács közreműködésével. Az átlagos hossz 35-75 perc volt, online és személyes formátum keveréke. Minden résztvevő tájékozott hozzájárulását adta a rögzítéshez és az anonimizált felhasználáshoz; az átírás a tldv.io platformon történt és minden interjúhoz kézi „meeting memo” is készült, amely verifikációs célból elérhető volt az interjúalanyok számára (member checking - Lincoln és Guba, 1985). A teljes interjúvázlat a szerzőnél elérhető.

4.4 Tematikus elemzés

Az elemzés Braun és Clarke (2006) hat lépéses tematikus elemzési protokollját követi, *kettős*, deduktív-induktív megközelítéssel (Fereday és Muir-Cochrane, 2006): a kezdeti kódkönyv a konceptuális keret három antecedenséből (technológiai megbízhatóság, intézményi jelzés, humán felelősségvállalás) levezetett kategóriákból indul, kiegészítve induktív kódokkal (pl. vidék-főváros különbség, „belépő-termék” logika, hallgatói introverzió).

NVivo-licenz hiányában az elemzés strukturált kódkönyv-alapú megközelítéssel valósult meg: minden interjúhoz táblázatos kódkönyv készült (interjú-azonosító, idézet, kód, kategória, kontextuális megjegyzés), azonos sablon szerint. A kódolást részben MI-asszisztált javaslatok támogatták; *minden javaslat emberi felülvizsgálatnak volt alávetve és a végleges kódolási döntéseket kizárólag a kutató hozta meg.* Az eljárást explicit módon dokumentáljuk a hibrid manuális-MI-asszisztált kvalitatív elemzés transzparenciára vonatkozó újabb ajánlásai szerint (Christou, 2023).

4.5 Etikai szempontok és módszertani korlátok

A kutatás etikai keretét az előzetes tájékozott hozzájárulás, a teljes anonimizálás (R-01 ... R-12 azonosítók) és a tárolási-visszavonási jogok rögzítése biztosítja; a digitális adatok titkosított, csak a kutató által hozzáférhető környezetben tároltak.

A módszertani korlátok:

- (a) a minta kis elemszámú és túlnyomóan Ho Chi Minh város egyetemi szektorára koncentrált, egyetlen hanoi referenciaponttal;
- (b) a kvalitatív szakasz elsősorban az intézményi-szolgáltatói oldal mechanizmusait térképezte fel - a hallgatói szegmens mélyebb vizsgálata 200-300 fős kérdőív és Discrete Choice Experiment keretében a következő szakaszban történik;
- (c) az interjúk részben tolmácsoláson keresztül zajlottak, ennek nyelvi veszteségét hangsúlyozott member checking csökkentette (Lincoln és Guba, 1985);
- (d) a megállapítások „pillanatkép” jellegűek egy gyorsan változó környezetben.

5. Előzetes eredmények

A tematikus elemzés első körének (N = 12 résztvevő) eredményeit a 2.5. szakaszban rögzített három bizalmi antecedens szerint strukturáljuk. Az idézetek anonimizált formában (R-01 ... R-12) szerepelnek és a *résztvevők beszámolóira* alapozott mintázatokként, nem általánosítható törvényszerűségeként kezelendők.

5.1 Technológiai megbízhatóság: kompetens eszköz, korlátozott önállósággal

A résztvevők többsége az MI-t támogató eszköznek, nem autonóm oktatási rendszernek tekintette. R-04 megfogalmazásában: „AI is undergoing a powerful transition - last time it was a trend, but now it has become a functional tool”. A tisztán automatizált megoldások korlátai több irányból jelentek meg: az MI-válaszok generikus jellege (R-10: „AI tends to give very general ideas that are not case-specific”); a tudás validálásának hiánya (R-03: „AI confidently provides false information, especially in math, unlike humans who acknowledge uncertainty”); valamint a generált tartalom hitelességének észlelési problémája (R-09). Ez összhangban van Glikson és Woolley (2020) megkülönböztetésével: a *kognitív* bizalom alapja a működő rendszer, de az *érzelmi és felelősségi* dimenziók önállóan nem épülnek fel.

5.2 Intézményi jelzés: az akkreditáció és reputáció kapuőr szerepe

Az intézményi bizalmi szint vietnámi sajátosságai hangsúlyosan jelentek meg az interjúkban. A MOET-akkreditáció és a teljes egyetemi oklevél munkaerőpiaci felülértékelése keretként hatja át a tanulói és munkáltatói döntéseket: a mikrotanúsítványok piaci értéke jellemzően a teljes diploma meglétére épül (R-01, R-06, R-07, R-10). R-10: „in Vietnam, the full degree remains the gating signal; microcredentials only enhance the CV after that minimum is met”. Az európai - és különösen magyar - intézmények észlelési pozíciója vegyes: a közép-európai felsőoktatáshoz „strong academic foundations and engineering tradition” társul (R-02), de a magyar márka önállóan alacsony láthatóságú (R-10 pozíciója: 5,5-7 a 10-es skálán). Az interjúalanyok visszatérően jelezték, hogy a helyi partnerintézmény hiánya jelentősen rontja a piacra lépés esélyét (R-02, R-04, R-09) - a partnerség itt nem költségcsökkentési, hanem *bizalmi szignalizációs* eszköz.

5.3 Humán felelősségvállalás: a „human premium” jelensége

A *human premium* alatt itt azt a felárat értjük, amelyet a tanuló az emberi mentorálással kínált szolgáltatásért hajlandó fizetni az MI-vezérelt alternatívához képest (a szolgáltatás-marketing differenciált-attribútum árazási logikája szerint; Bart et al., 2005).

A harmadik antecedens jelent meg a leghatározottabban. A humán mentor szerepe több összefüggő funkción keresztül definiálódik: pedagógiai validáció (R-01: speciális tanulási szükségletek), érzelmi-motivációs jelenlét (R-04: az „empathy and psychological safety”, a vietnámi „high heart” pedagógiai fogalom - „the ability to sense the unspoken needs of the learner”), valamint az MI-generálta tartalom kritikai értékelésében nyújtott támogatás (R-10, R-12). A konfuciánus tanár-szerep nem egyszerűen *megőrződik*, hanem *újradefiniálódik*: az interjúk konzisztensen mutatják az „authority of knowledge”-ből „facilitator / curator / validator” pozícióba történő elmozdulást (R-01, R-02, R-05, R-09, R-12). Ez egybecseng Tran (2013) érvelésével: a CHC-tanuló nem passzív, hanem kapcsolati-felelősségi keretben optimálisan tanul.

Az interjúkban 10-50% közötti becsült felárigény jelent meg (R-01: ~20%, R-04: 30-50%, R-08: 30-40%, R-11: 15-100% a dolgozó szakembereknél, ~10% a szülői finanszírozású alapszakosoknál), amelyet a későbbi Discrete Choice Experiment keretében érdemes tesztelni.

5.4 Induktív mintázatok

Két mintázat is kiemelkedett. *Először*, a hallgatói introverzió mint MI-preferenciát erősítő tényező (R-06): az aszinkron MI-tutor szégyenlős tanulóknak inkluzivitási mechanizmusként szolgál. *Másodszor*, megjelent egy „belépő-termék” logika: rövid, humán mentorálással bíró ingyenes kurzusok bizalomépítő eszközként funkcionálhatnak a hosszabb intézményi programok előtt (R-04, R-08, R-10-Thuy, R-12). E mintázat a kutatási program második tanulmányában rendszerdinamikai keretben kerül kifejtésre.

6. Diszkusszió: a bizalom három antecedense vietnámi kontextusban

Az előzetes empirikus mintázatok támogatják a 2.5. szakaszban javasolt fogalmi modell központi állítását: az MI-alapú oktatási szolgáltatások iránti tartós fogyasztói bizalom a vietnámi piacon a jelen mintában **három antecedens együttes jelenlétéhez kötődik**. A beszámolókból mindhárom antecedens szükséges feltételként jelent meg a tartós bizalom narratíváiban: ezek egyidejű jelenléte rendre együtt járt a bizalom narratív megerősödésével, míg bármelyik tartós hiánya esetén a bizalom gyengülése visszatérő narratív elem volt. E küszöbszerkezet óvatosságot sugallja, hogy a vietnámi kontextusban a Mayer és társai (1995) képesség-jóindulat-integritás (Ability-Benevolence-Integrity, ABI) modelljének dimenzióként mérlegelt megközelítésén túl küszöbszerű működés is lehetséges; ennek statisztikai megerősítése további kvantitatív vizsgálat tárgya.

A humán felelősségvállalás antecedensének tartalma is árnyalja a szakirodalmat. A klasszikus bizalmi modellek (McKnight et al., 2002) a humán szereplőt elsősorban kompetencia- és integritás-jelzőként kezelik; a jelen interjú anyagában azonban a humán mentor egyúttal *kulturális közvetítőként* is működik, biztosítva, hogy a tanulási helyzet a CHC-hagyomány által értelmezhető kapcsolati keretben maradjon (Nguyen et al., 2006; Tran, 2013). A HITL-modell így nem csupán technikai, hanem kulturális-bizalmi mechanizmus is.

7. Pénzügyi-stratégiai implikációk a magyar felsőoktatási export számára

A jelen kvalitatív mintából (HUTECH, UEF és Phenikaa, N = 12) levont implikációk előzetesek; tesztelésük reprezentatív, 200-300 fős hallgatói mintán a kvantitatív szakasz feladata. A bizalmi modell három stratégiai irányt sugall a magyar intézmények számára. *Először*, az árazási logika ne költségalapú legyen, hanem szegmensek szerint differenciált: a humán mentorálás 15-40%-os felára a dolgozó szakember-szegmensben előzetesen megalapozottnak tűnik. *Másodszor*, a pozicionálás kulcsa nem az önálló márkáépítés, hanem a vietnámi partnerintézménnyel közös *megosztott bizalmi szignál*: a helyi partner az intézményi antecedens építőeleme. *Harmadszor*, a szolgáltatástervezés ne az MI-tartalom maximalizálására, hanem a humán jelenlét célzott elosztására fókuszáljon: az MI a tartalom- és gyakorlófunkciókban hatékony, míg a humán mentor a kontextuális értékelés, motiváció és kulturális közvetítés pontjain ad értéket.

A magyar export versenyképessége tehát nem az automatizáció skáláhozadékain múlik, hanem azon a képességen, hogy a humán jelenlétet *árazható szolgáltatás-attribútumként* kezelje.

8. Konklúzió és további kutatási irányok

A tanulmány a vietnámi MI-alapú oktatási piacon vizsgálta a fogyasztói bizalom képződésének mechanizmusait és egy három antecedensből - technológiai megbízhatóság, intézményi jelzés, humán felelősségvállalás - építkező előzetes fogalmi modellt javasolt. Az empirikus mintázatok azt sugallják, hogy a humán jelenlét iránti tartós kereslet nem technológiai elmaradottság, hanem strukturális,

kulturális-kapcsolati és felelősségi mechanizmusokkal is magyarázható, amelynek feltételezhető pénzügyi-fogyasztói következményei vannak (fizetési hajlandóság, márka-preferencia, ügyfél-életciklus).

A kutatás korlátai (kis kvalitatív minta, egyetlen várost lefedő terepmunka) a következő szakaszokban tervezett kvantitatív validálással (Discrete Choice Experiment, lásd Reynolds et al., 2025) és rendszerdinamikai modellezéssel oldhatók fel. A tanulmány legközvetlenebb hozzájárulása egy empirikusan megalapozott előzetes pozicionálási keret, amely a humán jelenlétet nem költségként, hanem stratégiai versenyelőnyforrásként kezeli.

Hivatkozások

- Akerlof, G. A. (1970). The market for "lemons": Quality uncertainty and the market mechanism. *Quarterly Journal of Economics*, 84(3), 488-500.
- Bart, Y., Shankar, V., Sultan, F., & Urban, G. L. (2005). Are the drivers and role of online trust the same for all web sites and consumers? A large-scale exploratory empirical study. *Journal of Marketing*, 69(4), 133-152.
- Braun, V., & Clarke, V. (2006). Using thematic analysis in psychology. *Qualitative Research in Psychology*, 3(2), 77-101.
- Brinkmann, S., & Kvale, S. (2018). *Doing interviews* (2nd ed.). SAGE Publications.
- Chiu, T. K. F., & Rospigliosi, P. A. (2025). Encouraging human-AI collaboration in interactive learning environments. *Interactive Learning Environments*, 33(2), 921-924.
- Christou, P. A. (2023). The use of artificial intelligence (AI) in qualitative research for theory development. *The Qualitative Report*, 28(9), 2754-2766.
- Creswell, J. W., & Poth, C. N. (2018). *Qualitative inquiry and research design: Choosing among five approaches* (4th ed.). SAGE Publications.
- Dietvorst, B. J., Simmons, J. P., & Massey, C. (2015). Algorithm aversion: People erroneously avoid algorithms after seeing them err. *Journal of Experimental Psychology: General*, 144(1), 114-126.
- Fereday, J., & Muir-Cochrane, E. (2006). Demonstrating rigor using thematic analysis: A hybrid approach of inductive and deductive coding and theme development. *International Journal of Qualitative Methods*, 5(1), 80-92.
- Glaser, B. G., & Strauss, A. L. (1967). *The discovery of grounded theory*. Aldine.
- Glikson, E., & Woolley, A. W. (2020). Human trust in artificial intelligence: Review of empirical research. *Academy of Management Annals*, 14(2), 627-660.

- Hofstede, G. (2001). *Culture's consequences: Comparing values, behaviors, institutions, and organizations across nations* (2nd ed.). SAGE Publications.
- IMARC Group. (2025). *Vietnam online education market: Size, share, trends and forecast 2025-2034*. IMARC Group.
- Le, T. K. T., Nguyen, T. L., Trinh, M. T., Le, V. T., & Pham, H.-H. (2022). Investigating Vietnamese undergraduate students' willingness to pay for higher education under the cost-sharing context. *Policy Futures in Education*, 20(1), 19-43.
- Lee, J. D., & See, K. A. (2004). Trust in automation: Designing for appropriate reliance. *Human Factors*, 46(1), 50-80.
- Lincoln, Y. S., & Guba, E. G. (1985). *Naturalistic inquiry*. SAGE Publications.
- Logg, J. M., Minson, J. A., & Moore, D. A. (2019). Algorithm appreciation: People prefer algorithmic to human judgment. *Organizational Behavior and Human Decision Processes*, 151, 90-103.
- Mayer, R. C., Davis, J. H., & Schoorman, F. D. (1995). An integrative model of organizational trust. *Academy of Management Review*, 20(3), 709-734.
- McKnight, D. H., Choudhury, V., & Kacmar, C. (2002). Developing and validating trust measures for e-commerce: An integrative typology. *Information Systems Research*, 13(3), 334-359.
- Nguyen, P.-M., Terlouw, C., & Pilot, A. (2006). Culturally appropriate pedagogy: The case of group learning in a Confucian heritage culture context. *Intercultural Education*, 17(1), 1-19.
- Reynolds, R. M., Popova, L., Yang, B., Louviere, J., & Thrasher, J. F. (2025). Discrete choice experiments: A primer for the communication researcher. *Frontiers in Communication*, 10.
- Rousseau, D. M., Sitkin, S. B., Burt, R. S., & Camerer, C. (1998). Not so different after all: A cross-discipline view of trust. *Academy of Management Review*, 23(3), 393-404.
- Tran, L. T., & Marginson, S. (Eds.). (2018). *Internationalisation in Vietnamese higher education*. Springer.
- Tran, T. T. (2013). Is the learning approach of students from the Confucian heritage culture context indeed surface? *Educational Research for Policy and Practice*, 12(1), 57-65.
- Watkins, D. A., & Biggs, J. B. (Eds.). (2001). *Teaching the Chinese learner*. CERC, University of Hong Kong.
- Williamson, O. E. (1981). The economics of organization: The transaction cost approach. *American Journal of Sociology*, 87(3), 548-577.
- World Bank. (2023). *Vietnam - Country Climate and Development Report*. World Bank Group.

A MESTERSÉGES INTELLIGENCIA HATÁSA A VISELKEDESI TORZÍTÁSOK CSÖKKENTÉSÉRE A PÉNZÜGYI DÖNTÉSHOZATALBAN

Szisztematikus szakirodalmi áttekintés és integratív metaanalízis

BENCE Vivien

Neumann János Egyetem Gazdálkodás- és Szervezéstudományok Doktori Iskola
YNN80@hallgato.nje.hu

HARCI Tamás

Neumann János Egyetem Gazdálkodás- és Szervezéstudományok Doktori Iskola
harci.tamas@ipixel.hu

GÁSPÁR Bettina

Magyar Agrár- és Élettudományi Egyetem Gazdaság- és Regionális Tudományok Doktori Iskola
gaspar.bettinaphd@uni-mate.hu

<https://doi.org/10.15170/XVIIPPN-Tk-KTK-2026-02>

Absztrakt

A tanulmány célja annak vizsgálata, hogy a mesterséges intelligencia (MI) pénzügyi alkalmazásai milyen mértékben és milyen feltételek mellett képesek mérsékelni a viselkedési torzításokat a pénzügyi döntéshozatalban. A viselkedési közgazdaságtan szerint a befektetési, hitel- és megtakarítási döntések gyakran eltérnek a teljes racionalitástól, mivel a túlzott magabiztosság, a veszteségkerülés, a horgonyzás, a reprezentativitási torzítás, a nyájhatás és a diszkriminatív heurisztikák torzíthatják az információfeldolgozást. A kézirat 48 tudományos közleményre épülő szisztematikus szakirodalmi áttekintést és integratív metaanalízist alkalmaz, amelyből 32 cikk közvetlenül MI-alapú vagy digitális pénzügyi döntéstámogatási kontextust vizsgál. A bevont tanulmányok négy fő döntési környezet szerint kerültek kódolásra: robotanácsadás és automatizált befektetés, hitelbírálat és kockázatértékelés, algoritmuselfogadás és emberi kontroll, valamint technológia-alapú torzításkezelés. Az eredmények alapján az MI leginkább strukturált, standardizált és jól mérhető döntési helyzetekben képes csökkenteni az emberi torzítások hatását, például portfóliódiverzifikációban, automatikus újraszűrésben vagy hitelkockázati előszűrésben. A hatás ugyanakkor nem automatikus: algoritmus-averzió, nem reprezentatív tanítóadat, átláthatatlan modellműködés, társas befolyás és túlzott emberi felülírás gyengítheti vagy akár vissza is fordíthatja a torzításcsökkentő mechanizmust. A tanulmány három empirikusan tesztelhető hipotézist fogalmaz meg: (1) az MI jelenléte csökkenti a pénzügyi torzítások hatását az algoritmus nélküli emberi döntésekhez képest; (2) a hatás erősebb strukturált, standardizált környezetben, és

gyengébb komplex, kontextusfüggő helyzetekben; (3) a pozitív hatás akkor konzisztens, ha az MI modellek átlátható adatforrásokon, reprezentatív mintákon és értelmezhető, kontrollálható kimeneteken alapulnak. A gyakorlati javaslatok a magyarázható MI, a rendszeres torzításaudit, az ember-a-hurokban működés, a felhasználói kontroll és a pénzügyi edukáció kombinációját emelik ki.

Kulcsszavak: mesterséges intelligencia; viselkedési pénzügyek; robo-tanácsadás; algoritmikus torzítás; pénzügyi döntéshozatal

1. Bevezetés

A pénzügyi döntésekben a racionalitás feltételezése régóta központi szerepet tölt be, ugyanakkor a háztartási pénzügyek és a viselkedési pénzügyek empirikus irodalma következetesen rámutat arra, hogy a befektetők, hitelfelvevők és pénzügyi tanácsadók döntései gyakran szisztematikusan torzulnak. A veszteségkerülés és a referenciaárhoz kötődés a veszteséges pozíciók túl hosszú tartásához vezethet, a túlzott magabiztosság túlkereskedést és alulteljesítést idézhet elő, a nyájhatás pedig felerősítheti a társas információk szerepét a pénzügyi kockázatvállalásban (Kahneman & Tversky, 1979; Odean, 1998; Barber & Odean, 2000; Shiller & Pound, 1989). Ezek a torzítások nem pusztán egyéni hibák: aggregált szinten piaci anomáliákhoz, rossz portfólióallokációhoz, túlzott eladósodáshoz vagy diszkriminatív hitelallokációhoz is hozzájárulhatnak.

A mesterséges intelligencia és a pénzügyi technológia elterjedése új döntési architektúrát hozott létre. A robo-tanácsadók automatikusan képesek ügyfélprofilokhoz portfóliót rendelni, újraszűzölni a befektetéseket és szabályalapú tanácsot adni. A hitelbírálati rendszerek gépi tanulással dolgozzák fel a hagyományos és alternatív adatokat, a befektetési platformok pedig algoritmikus ajánlásokat, kockázati profilokat és magyarázó visszacsatolást kínálnak. E technológiák ígérete, hogy csökkentik az érzelmi reakciók és a heurisztikák közvetlen hatását, egységesítik az információfeldolgozást, és a döntést kevésbé teszik függővé az adott döntéshozó pillanatnyi figyelmétől vagy előítéleteitől (D'Acunto et al., 2019; Berg et al., 2020; Li et al., 2024).

A pozitív hatás azonban nem tekinthető automatikusnak. Az algoritmusok történeti adatokból tanulnak, ezért a múltbeli egyenlőtlenségek és diszkriminatív mintázatok a modellben is megjelenhetnek. A felhasználók egyszerre lehetnek túlzottan bizalmatlanok és túlzottan engedékenyek: algoritmus-averzió esetén elutasítják a jó minőségű ajánlásokat, automatizációs ráhagyatkozás esetén pedig kritikátlanul elfogadják a hibás vagy nem megfelelő kimenetet (Dietvorst et al., 2015; Dietvorst et al., 2018; Castelo et al., 2019). A pénzügyi döntésekben ez különösen releváns, mivel a modellek gyakran nagy tétellel járó döntésekben, aszimmetrikus információ mellett és korlátozott felhasználói tudással működnek.

A jelen tanulmány kutatási kérdése ezért a következő: milyen mértékben és milyen feltételek mellett csökkenti a mesterséges intelligencia a viselkedési torzítások hatását a pénzügyi döntéshozatalban? A kézirat hozzájárulása három pontban ragadható meg. Először integráltan vizsgálja a befektetési és hitelpiaci MI-

alkalmazásokat. Másodszor a technológiai hatást nem általános hatékonysági állításként, hanem konkrét torzításcsökkentő mechanizmusként értelmezi. Harmadszor a pozitív és negatív bizonyítékokat feltételrendszerbe rendezi: a modell átláthatósága, az adatok reprezentativitása, a felhasználói kontroll és a döntési kontextus strukturáltsága egyaránt moderáló tényező.

2. Elméleti háttér és hipotézisek

2.1. Viselkedési torzítások a pénzügyi döntéshozatalban

A pénzügyi viselkedési torzítások közül a veszteségkerülés és a diszpozíciós hatás kiemelt jelentőségű. A kilátásemélet szerint az egyének a veszteségeket nagyobb súllyal értékelik, mint az azonos nagyságú nyereségeket, ezért hajlamosak a referenciaértékekhez ragaszkodni (Kahneman & Tversky, 1979). A befektetők emiatt gyakran túl korán realizálják nyereségeiket és túl sokáig tartják veszteséges pozícióikat (Odean, 1998). A jelenség technológiai szempontból azért fontos, mert a döntési felület megváltoztatása - például a vételi ár szalienciájának csökkentése - mérsékelheti a torzítást (Frydman & Rangel, 2014).

A túlzott magabiztosság a befektetési képességek és az információ minőségének túlértékelését jelenti. Barber és Odean (2000, 2001) eredményei alapján a gyakori kereskedés és az önbizalommal összefüggő túlkereskedés rontja az egyéni befektetői teljesítményt. A nyájhatás és az információk kaszkádok ezzel szemben a társas információra és a mások viselkedésének követésére vezethetők vissza (Bikhchandani et al., 1992; Hong et al., 2004). Ezek a torzítások különösen online befektetési platformokon és közösségi pénzügyi környezetben erősödhetnek fel.

A hitelpiacokon a torzítások részben kognitív, részben diszkriminatív jellegűek. A hitelügyintézők vagy befektetők csoportalapú heurisztikákat használhatnak, amelyek a valós kockázati információ helyett társadalmi, kulturális vagy földrajzi kategóriákon alapulnak. Az ilyen torzítások csökkentése szempontjából az MI egyszerre jelenthet lehetőséget és kockázatot: a strukturált adatfeldolgozás mérsékelheti az emberi szubjektivitást, de a múltbeli döntésekből tanuló modellek meg is őrizhetik az egyenlőtlenségeket (Bartlett et al., 2022; Fuster et al., 2022).

2.2. Az MI mint döntési architektúra

Az MI-alapú pénzügyi rendszerek nem egyszerűen információt adnak, hanem megváltoztatják a döntés szerkezetét. A robo-tanácsadás például kockázati profilalkotással, portfólióoptimalizálással és automatikus újrasúlyozással csökkentheti az impulzív kereskedést és a túlzott koncentrációt (D'Acunto et al., 2019; Reher & Sokolinski, 2024). A hitelbírálati algoritmusok a kemény adatok és alternatív jelek rendszerezésével mérsékelhetik a helyi, nemi vagy kulturális heurisztikák szerepét (Chen et al., 2025; Li et al., 2024; Song et al., 2024).

A torzításcsökkentés három fő mechanizmuson keresztül értelmezhető. Az első az információ strukturálása: a rendszer a felhasználó számára releváns adatokat rendszerez és a kevésbé releváns, de érzelmileg erős ingereket háttérbe szoríthatja. A második az automatizálás: az előre meghatározott szabályok csökkenthetik a pillanatnyi érzelmi állapot és a túlzott aktivitás hatását. A harmadik a visszacsatolás:

az algoritmus következetesen jelzi a kockázatot, a diverzifikációs hibákat vagy a döntési következményeket. E mechanizmusok alapján az MI a pénzügyi döntésben nudge-ként, tanácsadóként vagy döntési alapértelmezésként is működhet.

A negatív mechanizmusok ugyanilyen fontosak. Az algoritmus-averzió miatt a felhasználók elutasíthatják a jobb minőségű algoritmikus tanácsot, különösen akkor, ha a rendszer korábbi hibáját látják (Dietvorst et al., 2015). A döntések szubjektívnek érzékelt területein az algoritmusokkal szembeni bizalom alacsonyabb lehet (Castelo et al., 2019). Ezzel szemben, ha a felhasználó részleges kontrollt kap a modell felett, nagyobb valószínűséggel használja az algoritmust, még akkor is, ha az nem tökéletes (Dietvorst et al., 2018). Ez közvetlenül megalapozza az átláthatóság és kontroll szerepét.

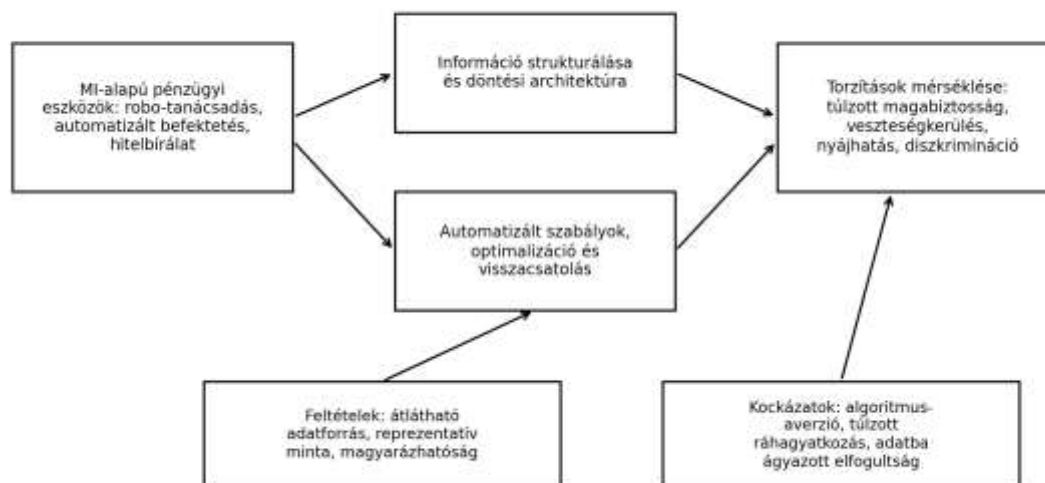
2.3. Hipotézisek

H1: A mesterséges intelligencia jelenléte csökkenti a pénzügyi torzítások hatását az emberi, algoritmus nélküli döntésekhez képest.

H2: A torzításcsökkentő hatás erősebb strukturált, standardizált környezetben, például hitelbírálathoz, portfólió-újrásúlyozásban és szabályalapú kockázatprofilozásban, és gyengébb komplex, kontextusfüggő helyzetekben.

H3: A pozitív hatás csak akkor konzisztens, ha az MI modellek átlátható adatforrásokon és reprezentatív mintákon alapulnak, valamint az emberi felhasználók képesek kontrollálni és értelmezni az algoritmus kimeneteit.

1. ábra: A mesterséges intelligencia torzításcsökkentő mechanizmusának koncepcionális modellje



Forrás: saját szerkesztés a feldolgozott szakirodalom alapján.

3. Módszertan: szakirodalmi keresés és integratív metaanalízis

A tanulmány integratív metaanalízist alkalmaz. A bevont cikkek módszertani és kimeneti változói jelentősen eltérnek egymástól: egyes vizsgálatok terepi adatokon, mások kérdőíves modelleken, kísérleteken, platformadatokon vagy kvázi-kísérleti azonosításon alapulnak. Emiatt a klasszikus, közös effektusméretet becslő random-

hatású statisztikai metaanalízis nem lenne megbízható. A választott megközelítés ezért szisztematikus keresésre, tematikus kódolásra, irányjelző szintézisre és hipotézisenkénti bizonyítékértékelésre épül.

A szakirodalmi keresés a mesterséges intelligencia, gépi tanulás, algoritmikus döntéshozatal, robo-tanácsadás, FinTech, viselkedési torzítás, veszteségkerülés, túlzott magabiztosság, nyájhatás, horgonyzás, hitelbírálat, befektetési döntés és pénzügyi döntéshozatal kulcsszavainak kombinációjára épült. Csak tudományos folyóiratcikkek kerültek bevonásra; vállalati jelentések, hírek, nem lektorált szakmai anyagok, dolgozatok és könyvfejezetek nem képezték a végső hivatkozási lista részét.

A bevont irodalom két rétegből áll. Az első, közvetlen részalmaz 32 olyan tudományos cikket tartalmaz, amely MI-alapú vagy digitális pénzügyi döntéstámogatást vizsgál robo-tanácsadásban, hitelbírálatban, digitális vagyonkezelésben vagy FinTech-környezetben. A második réteg 16 olyan alapvető viselkedési pénzügyi és algoritmus-elfogadási cikket foglal magában, amelyek a torzítások azonosításához, operacionalizálásához és a döntési mechanizmusok értelmezéséhez szükségesek. Így a teljes szintézis 48 tudományos cikkre épül.

1. táblázat: Beválasztási és kizárási kritériumok

Kritérium	Beválasztás	Kizárás
Forrástípus	Tudományos folyóiratcikk, empirikus vagy elméleti-módszertani relevanciával.	Vállalati jelentés, hír, blog, szakdolgozat, nem tudományos webanyag.
Téma	MI, gépi tanulás, robo-tanácsadás, FinTech, algoritmikus döntéstámogatás és pénzügyi döntési torzítás.	Általános digitalizáció pénzügyi torzítás vagy döntési mechanizmus nélkül.
Döntési kontextus	Befektetés, vagyonkezelés, hitelbírálat, kockázateértékelés, pénzügyi tanácselfogadás.	Nem pénzügyi alkalmazás, amely nem kapcsolható pénzügyi döntéshez.
Kódolási dimenzió	Kontextus, MI-beavatkozás típusa, torzítás/kimenet, eredményirány, moderáló feltételek.	Nem azonosítható döntési kimenet vagy nem értelmezhető torzítási mechanizmus.

Forrás: saját szerkesztés.

4. Eredmények

4.1. A közvetlen MI- és digitális pénzügyi vizsgálatok szintézise

A közvetlen MI- és digitális pénzügyi részalmaz eredményei alapján az MI torzításcsökkentő szerepe legerősebben a strukturált befektetési és hitelezési környezetekben jelentkezik. A robo-tanácsadás esetében a pozitív mechanizmus általában a portfóliók fegyelmezettebb kezeléséből, a diverzifikációból, az újrasúlyozásból és az impulzív kereskedés korlátozásából fakad. D'Acunto és munkatársai (2019) eredményei például arra utalnak, hogy a robo-tanácsadás alkalmazása csökkentheti a diszpozíciós hatást és a trendkövetést, miközben a digitális vagyonkezelés nagyobb hozzáférést biztosíthat alacsonyabb vagyoni szinteken is (Reher & Sokolinski, 2024).

A hitelbírálati környezetben az MI előnye az információfeldolgozás standardizálásából ered. A gépi tanulóval támogatott hitelminősítés javíthatja a

kockázatbecslést és bővítheti a hitelhez jutást, különösen akkor, ha a modell olyan gyenge jeleket is kezelni tud, amelyeket a hagyományos szabályalapú rendszer nem dolgoz fel (Berg et al., 2020; Jagtiani & Lemieux, 2019; Li et al., 2024). Ugyanakkor a fair lending irodalom arra figyelmeztet, hogy a prediktív pontosság növekedése nem azonos az igazságossággal: a kisebbségi vagy alulreprezentált csoportokkal kapcsolatos történeti mintázatok algoritmikus formában is fennmaradhatnak (Bartlett et al., 2022; Fuster et al., 2022).

Az irányjelző szintézis szerint a közvetlen MI/digitális pénzügyi részszámban a tanulmányok többsége támogató vagy feltételesen támogató eredményt jelez. Ez nem azt jelenti, hogy az MI minden esetben csökkenti a torzításokat, hanem azt, hogy a pozitív hatás visszatérő mintázatként jelenik meg, amikor a feladat jól strukturált, a modelladatok értelmezhetők, és a felhasználói kontroll nem vezet túlzott, önkényes felülíráshoz. A nem támogató vagy kockázatos eredmények főként az algoritmus-averzióhoz, a robo-tanácsadás alacsony érettségéhez és az adatminőségi problémákhoz kapcsolódnak.

2. ábra: A közvetlen MI/digitális pénzügyi részszámban irányjelző eredményei



Forrás: saját kódolás. Megjegyzés: az ábra nem összevont effektusméretet, hanem irányjelző tanulmánybesorolást mutat.

2. táblázat: Közvetlen MI- és digitális pénzügyi döntéstámogatással foglalkozó bevont cikkek

Tanulmány	Döntési kontextus	MI/digitális beavatkozás	Vizsgált torzítás/kimenet	Fő szintézis
Ahmad et al. (2025)	Befektetési döntés	Robo-tanácsadó mint moderátor	Elérhetőségi torzítás, horgonyzás, veszteségkerülés, reprezentativitás, túlzott magabiztosság	A robo-tanácsadás több torzítás negatív hatását gyengíti, de az overconfidence esetében nem konzisztens.
Alsabah et al. (2021)	Portfólióválasztás	Robo-tanácsadó kockázatpreferencia-tanulással	Kockázatprofil és portfólióválasztás	A modell a választásokból tanulva javíthatja a személyre szabott ajánlást.
Aristei & Gallo (2026)	Pénzügyi tanácsadás	Online automatizált tanácsadás	Pénzügyi és digitális tudás, bizalom, tanácselfogadás	A robo-tanácsadás a humán tanácsadással részben helyettesítő, részben kiegészítő viszonyban áll.
Back et al. (2023)	Robo-tanácsadás	Robo-advisor és társas dizájnelemek	Diszpozíciós hatás, tanácskérés	A robo-tanácsadó csökkentheti a torzítást, de a társas dizájn csökkentheti a tanács igénybevételét.
Babaei et al. (2022)	Kripto eszköz-allokáció	Magyarázható MI	Átláthatóság, portfólióallokáció	A magyarázhatóság növeli a döntéstámogatás értelmezhetőségét magas bizonytalanság mellett.
Bai (2021)	Fogyasztói pénzügyek	Robo-tanácsadói használat	Hitelkártya-adósság	Nem talál erős oksági bizonyítékot arra, hogy a robo-tanácsadás csökkenti a kártyaadósságot.

Tanulmány	Döntési kontextus	MI/digitális beavatkozás	Vizsgált torzítás/kimenet	Fő szintézis
Bartlett et al. (2022)	Fogyasztói hitelezés	FinTech és algoritmikus árazás	Faji/etnikai diszkrimináció	A FinTech csökkenthet egyes különbségeket, de nem szünteti meg a diszkriminatív árazást.
Baulkaran & Jain (2023)	Robo-tanácsadás használata	Digitális vagyonekezelési platform	Adopció és használati minták	A használat heterogén; a felhasználói jellemzők befolyásolják a technológiai hatást.
Beketov et al. (2018)	Robo-advisory módszerek	Kvantitatív portfóliómodellek	Kockázatkezelés és optimalizáció	A robo-tanácsadás technikai alapja standardizált döntéstámogatást tesz lehetővé.
Belanche et al. (2019)	FinTech-adopció	MI-alapú robo-tanácsadó	Elfogadás, bizalom, használati szándék	Az elfogadás feltételes: a bizalom és a technológiai illeszkedés döntő.
Berg et al. (2020)	Hitelpontozás	Digitális lábnyom és gépi tanulás	Hitelkockázat, hozzáférés	Az alternatív adatok kiegészíthetik a hagyományos hitelminősítést.
Bhatia et al. (2020)	Befektetési döntés	Robo-advisory szakértői értékelése	Viselkedési torzítások	Kvalitatív bizonyíték a torzítások mérséklésének lehetőségére.
Bhatia et al. (2021)	Robo-advisory szolgáltatások	MI a pénzügyi szolgáltatásban	Tudatosság és felhasználói percepció	A felhasználói edukáció és bizalom kulcsfontosságú.
Bhatia et al. (2022)	Vagyonkezelés	Robo-advisor mint moderátor	Túlzott magabiztosság, veszteségkerülés	Nem mutat konzisztens moderáló hatást; a piac érettsége korlátozó tényező.
Brenner & Meyll (2020)	Pénzügyi tanácsadás	Robo-advisor és humán tanácsadó viszonya	Tanácskeresés, bizalom	A robo-tanácsadó részben helyettesíti a humán tanácsadást, de nem minden befektetőnél.
Buchak et al. (2018)	Jelzálog- és FinTech-hitelezés	Technológiai alapú hitelezési folyamat	Hozzáférés és piaci struktúra	A technológia átalakítja a hitelezést, de szabályozási és szelekciós hatásokkal.
Chen et al. (2025)	Autó fedezetű hitelezés	Tanácsadó credit score és automatizált algoritmus	Helyi/nem helyi hitelfelvevőkkel szembeni torzítás	Az automatizált alapértelmezés csökkenti a kognitív/diszkriminatív torzítást; az egyszerű tanácsadó score kevésbé hatásos.
D'Acunto et al. (2019)	Befektetés és robo-advisory	Automatizált befektetési tanácsadás	Diszpozíciós hatás, trendkövetés	A robo-tanácsadás csökkenti több befektetői torzítás intenzitását.
D'Acunto et al. (2026)	Peer-to-peer hitelezés	Automatizált robo-advisor jelzés	Kulturális és vallási diszkrimináció	Az algoritmikus javaslat mérsékli a kulturális torzítás költségét.
D'Hondt et al. (2020)	Robo-befektetés	MI-alapú alter ego portfólió	Portfóliótorzítások, diverzifikáció	Azok profitálhatnak leginkább, akiknél a portfóliótorzítás erősebb.
Filiz et al. (2022)	Robo-advisor elfogadás	Algoritmikus tanács	Algoritmus-averzió	Az algoritmus-averzió akadályozhatja a torzításcsökkentő technológia használatát.
Fuster et al. (2019)	Jelzáloghitelezés	Technológiai/FinTech hitelezés	Feldolgozási hatékonyság és hozzáférés	A technológia gyorsíthatja és standardizálhatja a hitelezési folyamatot.
Fuster et al. (2022)	Hitelpiacok	Gépi tanulásos hitelbírálat	Egyenlőtlenség, prediktív kockázat	A pontosság javulhat, de az elosztási hatások egyenlőtlenek lehetnek.
Ge et al. (2021)	P2P hitelezés	Robo-advisor használat és emberi felülírás	Tanácsfogadás, teljesítmény	Akiknek nagyobb szükségük lenne rá, kevésbé használhatják; a felülírás ronthatja az eredményt.
Jagtiani & Lemieux (2019)	Fogyasztói hitelezés	Alternatív adatok és gépi tanulás	Hitelhozzáférés, kockázat	Az alternatív adat javíthatja a kockázatbecslést és bővítheti a hozzáférést.
Li et al. (2024)	AI-alapú hitelpontozás	MI-modellek gyenge jelekkel	Pénzügyi inklúzió	Az MI növeli az elfogadási arányt és csökkenti a nemteljesítést alulszolgált csoportoknál.
Lisauskiene et al. (2024)	Robo-tanácsadás	Passzív vs. aktív robo-advisor	Diszpozíciós hatás, pénzügyi tudás, nem	A hatás a tanácsadó típusától, a pénzügyi műveltségtől és nemi moderátoroktól függ.
Litterscheidt & Streich (2020)	Digitális vagyonekezelés	Robo-advisor magyarázatokkal	Delegálás és bizalom	A működési elvek bemutatása növeli a delegálási hajlandóságot.
Piehlmaier (2022)	Robo-advice adopció	Automatizált pénzügyi tanácsadás	Túlzott magabiztosság	A túlzottan magabiztos befektetők aktívabb adopciója szelekciós hatást jelez.
Reher & Sokolinski (2024)	Automatizált vagyonekezelés	Robo-advisor hozzáférés	Vagyonkezelési hozzáférés, jólét	A számlaminimum csökkentése növeli a hozzáférést és a jóléti hatást.
Shanmuganathan (2020)	Robo-advisory esettanulmány	AI-alapú befektetési döntéstámogatás	Viselkedési pénzügyi torzítások	Longitudinális kvalitatív bizonyíték a torzításmérséklő potenciálra.
Song et al. (2024)	Banki hitelezés	FinTech algoritmusok	Nemi egyenlőtlenség a hiteljóváhagyásban	Az algoritmusok növelhetik a női kérelmezők elfogadási arányát, ha az adatok nem torzítottak.

Forrás: saját szerkesztés a feldolgozott szakirodalom alapján.

4.2. Robo-tanácsadás és befektetési torzítások

A robo-tanácsadásban az MI torzításcsökkentő hatása elsősorban a befektetői döntési szabályok automatizálásából és a portfólióoptimalizálásból fakad. Az automatizált portfóliókezelés csökkentheti a túlkereskedést, a trendkövetést, a diszpozíciós hatást és a diverzifikáció hiányát, mert a döntést kevésbé a pillanatnyi érzelmi reakciók, inkább előre meghatározott kockázati paraméterek vezérlik (D'Acunto et al., 2019; D'Hondt et al., 2020).

A pozitív hatás ugyanakkor nem független a felhasználói elfogadástól. Litterscheidt és Streich (2020) szerint a felhasználók nagyobb valószínűséggel delegálnak döntéseket a robo-tanácsadónak, ha értik az algoritmus működési elveit. Back és munkatársai (2023) ezzel összhangban rámutatnak, hogy a tanácsadási környezet dizájnja módosíthatja az eredményt: bizonyos társas vagy antropomorf elemek csökkenthetik a tanácskérés gyakoriságát, így gyengíthetik a torzításcsökkentő hatást.

A robo-advisory irodalom alapján a H1 részben alátámasztható: az MI jelenléte sok esetben csökkenti a pénzügyi torzításokat, de csak akkor, ha a befektető ténylegesen használja, érti és nem írja felül önkényesen a tanácsot. Ez különösen fontos a túlzott magabiztosság esetében, ahol a felhasználó éppen azért kerülheti el az algoritmust, mert saját képességeit túlértékeli (Piehlmaier, 2022; Filiz et al., 2022).

4.3. Hitelbírálat, kockázatértékelés és algoritmikus fair lending

A hitelbírálat tipikusan strukturáltabb, mint a befektetési tanácsadás. A kimenet mérhető: jóváhagyás, kamat, hitelösszeg, nemteljesítés, veszteségráta vagy visszafizetési valószínűség. Emiatt az MI itt erősebb torzításcsökkentő potenciállal rendelkezik. Chen és munkatársai (2025) közvetlenül hasonlítják össze a tanácsadó jellegű FinTech-score-t és az algoritmikus alapértelmezést: az automatizált döntési alapértelmezés lényegesen jobban csökkenti az emberi hitelügyintézők földrajzi eredet szerinti torzítását, mint a pusztán információt adó credit score.

Li és munkatársai (2024) nagy mintás eredményei szerint az AI-alapú hitelpontozás növelheti az alulszolgált csoportok hitelhez jutását és közben csökkentheti a nemteljesítést. Hasonló logika jelenik meg az alternatív adatokat használó FinTech-hitelezésben is: a digitális lábnyom vagy platformadat kiegészítheti a hagyományos hiteltörténetet, és mérsékelheti a kizárást azoknál, akik kevés hagyományos pénzügyi adattal rendelkeznek (Berg et al., 2020; Jagtiani & Lemieux, 2019).

A fair lending irodalom ugyanakkor egyértelmű korlátot jelez. Bartlett és munkatársai (2022) szerint a FinTech-korszakban a diszkrimináció bizonyos formái csökkenhetnek, de nem tűnnek el. Fuster és munkatársai (2022) szerint a gépi tanulás prediktív pontossága javulhat, miközben a hitelpiaci hatások előre jelezhetően egyenlőtlenek maradhatnak. Ez a H3 szempontjából kulcsfontosságú: az MI csak akkor működik torzításcsökkentő technológiaként, ha az adatminőség, a reprezentativitás, a modellmonitoring és az auditálhatóság biztosított.

4.4. Algoritmus-elfogadás, átláthatóság és emberi kontroll

A pénzügyi MI rendszerek hatását nemcsak a modell pontossága, hanem az emberi viselkedés is meghatározza. Az algoritmus-averzió irodalma szerint az emberek hajlamosak elutasítani az algoritmusokat, ha hibáikat megfigyelik, még akkor is, ha az algoritmus átlagosan jobb teljesítményt nyújt (Dietvorst et al., 2015). A részleges kontroll lehetősége ugyanakkor növeli az algoritmus elfogadását (Dietvorst et al., 2018). Ez magyarázza, miért különösen fontos a hibrid, ember-a-hurokban működés: a felhasználónak legyen értelmezési és kontrolllehetősége, de a rendszer ne ösztönözzön indokolatlan felülírásra.

A feladattípus szintén moderálja a hatást. Castelo és munkatársai (2019) alapján az algoritmikus tanácsot objektívebb feladatokban könnyebben elfogadják, szubjektívebb, értékalapú döntésekben viszont kevésbé. A pénzügyi döntések sokszor kettős természetűek: a hitelkockázat mérése objektívebb, a befektetési célok és kockázati komfort értelmezése viszont részben szubjektív. Ezért a H2 különösen erős magyarázóerővel bír: minél standardizáltabb a pénzügyi döntés, annál valószínűbb az MI torzításcsökkentő hatása.

Az átláthatóság a kontroll előfeltétele. Magyarozható MI alkalmazása esetén a felhasználó nemcsak eredményt kap, hanem értelmezni is tudja a kimenetet. Babaei és munkatársai (2022) kriptoeszköz-allokációs példája azt mutatja, hogy a magyarozható modell különösen magas bizonytalanságú környezetben lehet hasznos. A magyarázat azonban nem lehet túl technikai: a pénzügyi felhasználó számára döntésre fordítható, érthető visszacsatolásra van szükség.

3. táblázat: Viselkedési pénzügyi és algoritmus-elfogadási háttércikkek

Tanulmány	Terület	Torzítás/mechanizmus	Kapcsolódás az MI-alapú pénzügyi döntésekhez
Barber & Odean (2000)	Egyéni befektetői kereskedés	Túlkereskedés	A gyakori kereskedés rontja az egyéni befektetők teljesítményét.
Barber & Odean (2001)	Befektetői túlzott magabiztosság	Nemek közötti különbség és overconfidence	A túlzott magabiztosság magasabb kereskedési aktivitással és alacsonyabb hozammal jár.
Bertrand & Morse (2011)	Fogyasztói hitelfelvétel	Kognitív szűklátókörűség, információs beavatkozás	A pszichológiailag célzott információcsomag csökkentheti a drága hitelhasználatot.
Bikhchandani et al. (1992)	Információs kaszkádok	Nyájhatás	A társas információk láncolata hatékonytalan döntési kaszkádokat hozhat létre.
Castelo et al. (2019)	Algoritmikus tanácselfogadás	Feladattípus-függő algoritmus-averzió	Az algoritmus elfogadása objektív feladatokban nagyobb, szubjektív feladatokban kisebb.
De Bondt & Thaler (1985)	Piaci túlreagálás	Overreaction	A piaci túlreagálás a viselkedési torzítások makroszintű következményeit jelzi.
Dietvorst et al. (2015)	Algoritmus-averzió	Hibát látó felhasználói reakció	Az emberek túlzottan elkerülhetik az algoritmust, ha annak hibáját megfigyelik.
Dietvorst et al. (2018)	Algoritmushasználat növelése	Felhasználói kontroll	A minimális módosítási lehetőség növeli az algoritmus elfogadását.
Frydman & Rangel (2014)	Befektetési felület	Diszpozíciós hatás	A vételi ár szalenciájának csökkentése mérsékelheti a diszpozíciós hatást.
Hong et al. (2004)	Tőzsdei részvétel	Társas interakció	A társas kapcsolatok befolyásolják a tőzsdei részvételt és a pénzügyi viselkedést.
Kahneman & Tversky (1979)	Döntés kockázat alatt	Veszteségkerülés, referenciafüggés	A kilátásmélet a pénzügyi torzítások alapvető elméleti kerete.
Logg et al. (2019)	Algoritmus-megbecsülés	Algoritmikus vs. humán tanács	A laikusok több esetben az algoritmikus tanácsot preferálják.
Looney & Hardin (2009)	Nyugdíjportfólió-döntések	Technológiai döntéstámogatás	A technológiai felület csökkentheti a rövidlátó veszteségkerülést.
Odean (1998)	Egyéni részvénykereskedés	Diszpozíciós hatás	A befektetők vonakodnak veszteségeiket realizálni.
Shiller & Pound (1989)	Befektetői információterjedés	Diffúzió és társas információ	A befektetési döntésekben erős a társas információ szerepe.
Tversky & Kahneman (1974)	Heurisztikák és torzítások	Horgonyzás, reprezentativitás, elérhetőség	Az alapvető kognitív torzítások pénzügyi döntésekben is megjelennek.

Forrás: saját szerkesztés a feldolgozott szakirodalom alapján.

5. Diszkusszió: a hipotézisek értékelése

A H1 részben alátámasztható. A robo-tanácsadás és a hitelpiaci MI-vizsgálatok jelentős része arra utal, hogy az algoritmikus döntéstámogatás csökkentheti a viselkedési és diszkriminatív torzításokat. A legerősebb bizonyítékok olyan helyzetekből származnak, ahol az algoritmus nem pusztán tanácsot ad, hanem a döntési folyamat alapértelmezését is módosítja, vagy szabályalapú automatizálással korlátozza az impulzív felülírást (D'Acunto et al., 2019; Chen et al., 2025; Li et al., 2024). A hipotézis azonban nem univerzális: Bai (2021) és Bhatia et al. (2022) eredményei azt jelzik, hogy a robo-tanácsadás nem minden pénzügyi magatartásban mutat egyértelmű torzításcsökkentő hatást.

A H2 erősebben alátámasztható. A strukturált, jól mérhető és szabályos adatfolyamokra épülő döntésekben - például hitelpontozásban, portfólió-újrasúlyozásban vagy kockázati profilalkotásban - az MI könnyebben képes standardizált információfeldolgozást biztosítani. Komplex, szubjektív és identitáshoz kötődő döntésekben a hatás gyengébb vagy feltételes, mert a felhasználói bizalom, a modellmagyarázat, a társas környezet és a feladat értelmezése erősebben befolyásolja a kimenetet (Castelo et al., 2019; Back et al., 2023).

A H3 szintén alátámasztható. A pozitív hatás akkor konzisztens, ha az adatbázis reprezentatív, a modell auditálható, a kimenet magyarázható, és az emberi kontroll nem pusztán formális, hanem értelmezhető. A fair lending eredmények különösen világossá teszik, hogy a prediktív pontosság és a méltányosság nem azonos fogalmak. A jó MI-rendszer egyszerre teljesít prediktív, etikai és felhasználói érthetőségi kritériumokat (Bartlett et al., 2022; Fuster et al., 2022; Babaei et al., 2022).

6. Gyakorlati és gazdaságpolitikai javaslatok

Magyarázható MI és felhasználói kontroll: A pénzügyi MI-rendszereknek nem elég pontos ajánlást adniuk; a felhasználónak értenie kell, milyen információk alapján született a javaslat, milyen bizonytalanság tartozik hozzá, és milyen következménye lehet a felülírásnak. A részleges kontroll növelheti a használati hajlandóságot, miközben a rendszernek védenie kell az indokolatlan felülírással szemben.

Reprezentatív adat és torzításaudit: A pénzügyi intézményeknek rendszeresen vizsgálniuk kell, hogy a modell eltérően teljesít-e életkor, nem, jövedelem, földrajzi hely, etnikai vagy más releváns csoportjellemző szerint. A modellfrissítést nemcsak pontossági, hanem méltányossági szempontokhoz is kötni szükséges.

Hibrid döntési modell: A teljes automatizálás és a teljes emberi döntés között a legtöbb pénzügyi környezetben hibrid megoldás indokolt. Az MI adja a standardizált, auditálható alapértelmezést, az ember pedig csak dokumentált, indokolt és visszamérhető esetben térjen el tőle.

Pénzügyi edukáció és digitális műveltség: A felhasználók csak akkor tudják a robo-tanácsadást torzításcsökkentő eszközként használni, ha értik a kockázatot, a diverzifikációt, a modellkorlátot és az adatminőség alapfogalmait. Az edukációt ezért be kell építeni a felületbe is, nem elegendő külön oktatási anyagokra hagyatkozni.

Szabályozói követelmények: A magas tétellel járó pénzügyi MI-rendszerek esetében indokolt a modellkártya, a döntési napló, a csoportszintű teljesítményteszt és a panaszkezelési mechanizmus megkövetelése. A szabályozásnak nem a technológia használatát, hanem az átláthatatlan és auditálhatatlan használatot kell korlátoznia.

7. Korlátok és jövőbeli kutatási irányok

A tanulmány első korlátja a bevont cikkek heterogenitása. A robo-tanácsadás, hitelbíráló, algoritmus-elfogadás és viselkedési pénzügyi laboratóriumi eredmények eltérő mérési szinteken dolgoznak, ezért a közös effektusméret becslése nem lenne tudományosan megalapozott. A jelen munka irányjelző integratív metaanalízist nyújt, amely alkalmas a hipotézisek finomítására, de nem helyettesíti a későbbi standardizált kvantitatív metaanalízist.

A második korlát, hogy az MI-rendszerek gyorsan változnak. A generatív MI-alapú pénzügyi asszisztensek, a természetes nyelvű magyarázatok és a platformokba épített döntési nudge-ok új kockázatokat és lehetőségeket teremtenek. A jövőbeni kutatásoknak elkülönítve kell vizsgálniuk az automatizált döntést, az algoritmikus tanácsot, a magyarázó asszisztent és a társas-interaktív pénzügyi platformokat.

A harmadik korlát a földrajzi és intézményi általánosíthatóság. A legtöbb empirikus eredmény amerikai, nyugat-európai vagy ázsiai pénzügyi piacokról származik. Magyar és közép-európai kontextusban kevés közvetlen bizonyíték áll rendelkezésre. Kiemelten fontos lenne hazai banki, brókerplatform- és hitelbírálói adatokon vizsgálni, hogy az MI-alapú döntéstámogatás csökkenti-e a túlzott magabiztosságot, a veszteségkerülést, a hitelügyintézői szubjektivitást vagy a csoportszintű diszkriminációt.

8. Összegzés

A mesterséges intelligencia pénzügyi döntéshozatalban betöltött szerepe nem egyszerűen technológiai modernizáció, hanem döntési architektúra-váltás. A feldolgozott 48 tudományos cikk alapján az MI különösen akkor képes mérsékelni a viselkedési torzításokat, ha a döntés strukturált, a modell kimenete mérhető, az adatok reprezentatívak, és az emberi kontroll értelmezhető keretek között marad. A robo-tanácsadás a befektetési torzításokat elsősorban portfóliófegyelemmel és automatizált szabályokkal csökkentheti, míg a hitelbírálói MI a szubjektív emberi döntések és diszkriminatív heurisztikák szerepét mérsékelheti.

Az eredmények ugyanakkor azt is jelzik, hogy az MI nem semleges és nem önmagában racionális. A történeti adatokba ágyazott elfogultság, az algoritmus-averzió, a túlzott ráhagyatkozás és a modell átláthatatlansága új torzításokat hozhat létre. A kutatás fő következtetése ezért feltételes: az MI általában képes csökkenteni a pénzügyi viselkedési torzításokat, de csak megfelelő adatminőség, magyarázhatóság, felhasználói kontroll és szabályozói audit mellett. A három hipotézis közül a második és harmadik erősebben, az első részben alátámasztott.

Hivatkozások

- Ahmad, U., Van Keulen, M., Briassouli, A., & Saad, M. (2025). Cognitive biases, Robo advisor and investment decision psychology: An investor's perspective from New York stock exchange. *Acta Psychologica*, 256, 105048. <https://doi.org/10.1016/j.actpsy.2025.105048>
- Alsabah, H., Capponi, A., Ruiz Lacedelli, O., & Stern, M. (2021). Robo-advising: Learning investors' risk preferences via portfolio choices. *Journal of Financial Econometrics*, 19(2), 369-392. <https://doi.org/10.1093/jfinec/nbz040>
- Aristei, D., & Gallo, M. (2026). Financial literacy, robo-advising, and the demand for human financial advice: Evidence from Italy. *Journal of Behavioral and Experimental Finance*, 49, 101125. <https://doi.org/10.1016/j.jbef.2025.101125>
- Back, C., Morana, S., & Spann, M. (2023). When do robo-advisors make us better investors? The impact of social design elements on investor behavior. *Journal of Behavioral and Experimental Economics*, 103, 101984. <https://doi.org/10.1016/j.socec.2023.101984>
- Babaei, G., Giudici, P., & Raffinetti, E. (2022). Explainable artificial intelligence for crypto asset allocation. *Finance Research Letters*, 47, 102941. <https://doi.org/10.1016/j.frl.2022.102941>
- Bai, Z. (2021). Does robo-advisory help reduce the likelihood of carrying a credit card debt? Evidence from an instrumental variable approach. *Journal of Behavioral and Experimental Finance*, 29, 100461. <https://doi.org/10.1016/j.jbef.2021.100461>
- Barber, B. M., & Odean, T. (2000). Trading is hazardous to your wealth: The common stock investment performance of individual investors. *Journal of Finance*, 55(2), 773-806. <https://doi.org/10.1111/0022-1082.00226>
- Barber, B. M., & Odean, T. (2001). Boys will be boys: Gender, overconfidence, and common stock investment. *Quarterly Journal of Economics*, 116(1), 261-292. <https://doi.org/10.1162/003355301556400>
- Bartlett, R., Morse, A., Stanton, R., & Wallace, N. (2022). Consumer-lending discrimination in the FinTech era. *Journal of Financial Economics*, 143(1), 30-56. <https://doi.org/10.1016/j.jfineco.2021.05.047>
- Baulkaran, V., & Jain, P. (2023). Who uses robo-advising and how? *Financial Review*, 58(1), 65-89. <https://doi.org/10.1111/fire.12324>

- Beketov, M., Lehmann, K., & Wittke, M. (2018). Robo advisors: Quantitative methods inside the robots. *Journal of Asset Management*, 19(6), 363-370. <https://doi.org/10.1057/s41260-018-0092-9>
- Belanche, D., Casalo, L. V., & Flavián, C. (2019). Artificial intelligence in FinTech: Understanding robo-advisors adoption among customers. *Industrial Management & Data Systems*, 119(7), 1411-1430. <https://doi.org/10.1108/IMDS-08-2018-0368>
- Berg, T., Burg, V., Gombović, A., & Puri, M. (2020). On the rise of FinTechs: Credit scoring using digital footprints. *Review of Financial Studies*, 33(7), 2845-2897. <https://doi.org/10.1093/rfs/hhz099>
- Bertrand, M., & Morse, A. (2011). Information disclosure, cognitive biases, and payday borrowing. *Journal of Finance*, 66(6), 1865-1893. <https://doi.org/10.1111/j.1540-6261.2011.01698.x>
- Bhatia, A., Chandani, A., & Chhateja, J. (2020). Robo advisory and its potential in addressing the behavioral biases of investors: A qualitative study in Indian context. *Journal of Behavioral and Experimental Finance*, 25, 100281. <https://doi.org/10.1016/j.jbef.2020.100281>
- Bhatia, A., Chandani, A., Atiq, R., Mehta, M., & Divekar, R. (2021). Artificial intelligence in financial services: A qualitative research to discover robo-advisory services. *Qualitative Research in Financial Markets*, 13(5), 632-654. <https://doi.org/10.1108/QRFM-10-2020-0199>
- Bhatia, A., Chandani, A., Divekar, R., Mehta, M., & Vijay, N. (2022). Digital innovation in wealth management landscape: The moderating role of robo advisors in behavioural biases and investment decision-making. *International Journal of Innovation Science*, 14(3/4), 693-712. <https://doi.org/10.1108/IJIS-10-2020-0245>
- Bikhchandani, S., Hirshleifer, D., & Welch, I. (1992). A theory of fads, fashion, custom, and cultural change as informational cascades. *Journal of Political Economy*, 100(5), 992-1026. <https://doi.org/10.1086/261849>
- Brenner, L., & Meyll, T. (2020). Robo-advisors: A substitute for human financial advice? *Journal of Behavioral and Experimental Finance*, 25, 100275. <https://doi.org/10.1016/j.jbef.2020.100275>
- Buchak, G., Matvos, G., Piskorski, T., & Seru, A. (2018). Fintech, regulatory arbitrage, and the rise of shadow banks. *Journal of Financial Economics*, 130(3), 453-483. <https://doi.org/10.1016/j.jfineco.2018.03.011>
- Castelo, N., Bos, M. W., & Lehmann, D. R. (2019). Task-dependent algorithm aversion. *Journal of Marketing Research*, 56(5), 809-825. <https://doi.org/10.1177/0022243719851788>

- Chen, Y., Dong, Y., Hu, J., & Huang, Y. (2025). Does FinTech reduce human biases? Evidence from advisory vs. automated FinTechs in lending. *Journal of Banking & Finance*, 181, 107557. <https://doi.org/10.1016/j.jbankfin.2025.107557>
- D'Acunto, F., Ghosh, P., & Rossi, A. G. (2026). How costly are cultural biases? Evidence from FinTech. *Journal of Financial Economics*, 175, 104202. <https://doi.org/10.1016/j.jfineco.2025.104202>
- D'Acunto, F., Prabhala, N., & Rossi, A. G. (2019). The promises and pitfalls of robo-advising. *Review of Financial Studies*, 32(5), 1983-2020. <https://doi.org/10.1093/rfs/hhz014>
- De Bondt, W. F. M., & Thaler, R. (1985). Does the stock market overreact? *Journal of Finance*, 40(3), 793-805. <https://doi.org/10.2307/2327804>
- D'Hondt, C., De Winne, R., Ghysels, E., & Raymond, S. (2020). Artificial Intelligence Alter Egos: Who might benefit from robo-investing? *Journal of Empirical Finance*, 59, 278-299. <https://doi.org/10.1016/j.jempfin.2020.10.002>
- Dietvorst, B. J., Simmons, J. P., & Massey, C. (2015). Algorithm aversion: People erroneously avoid algorithms after seeing them err. *Journal of Experimental Psychology: General*, 144(1), 114-126. <https://doi.org/10.1037/xge0000033>
- Dietvorst, B. J., Simmons, J. P., & Massey, C. (2018). Overcoming algorithm aversion: People will use imperfect algorithms if they can (even slightly) modify them. *Management Science*, 64(3), 1155-1170. <https://doi.org/10.1287/mnsc.2016.2643>
- Filiz, I., Judek, J. R., Lorenz, M., & Spiwoks, M. (2022). Algorithm aversion as an obstacle in the establishment of robo advisors. *Journal of Risk and Financial Management*, 15(8), 353. <https://doi.org/10.3390/jrfm15080353>
- Frydman, C., & Rangel, A. (2014). Debiasing the disposition effect by reducing the saliency of information about a stock's purchase price. *Journal of Economic Behavior & Organization*, 107, 541-552. <https://doi.org/10.1016/j.jebo.2014.01.017>
- Fuster, A., Goldsmith-Pinkham, P., Ramadorai, T., & Walther, A. (2022). Predictably unequal? The effects of machine learning on credit markets. *Journal of Finance*, 77(1), 5-47. <https://doi.org/10.1111/jofi.13090>
- Fuster, A., Plosser, M., Schnabl, P., & Vickery, J. (2019). The role of technology in mortgage lending. *Review of Financial Studies*, 32(5), 1854-1899. <https://doi.org/10.1093/rfs/hhz018>
- Ge, R., Zheng, Z. E., Tian, X., & Liao, L. (2021). Human-robot interaction: When investors adjust the usage of robo-advisors in peer-to-peer lending. *Information Systems Research*, 32(3), 774-785. <https://doi.org/10.1287/isre.2021.1009>

- Hong, H., Kubik, J. D., & Stein, J. C. (2004). Social interaction and stock-market participation. *Journal of Finance*, 59(1), 137-163. <https://doi.org/10.1111/j.1540-6261.2004.00629.x>
- Jagtiani, J., & Lemieux, C. (2019). The roles of alternative data and machine learning in fintech lending: Evidence from the LendingClub consumer platform. *Financial Management*, 48(4), 1009-1029. <https://doi.org/10.1111/fima.12295>
- Kahneman, D., & Tversky, A. (1979). Prospect theory: An analysis of decision under risk. *Econometrica*, 47(2), 263-291. <https://doi.org/10.2307/1914185>
- Li, C., Wang, H., Jiang, S., & Gu, B. (2024). The effect of AI-enabled credit scoring on financial inclusion: Evidence from an underserved population of over one million. *MIS Quarterly*, 48(4), 1803-1834. <https://doi.org/10.25300/MISQ/2024/18340>
- Lisauskiene, N., Darskuvienė, V., & Butkus, M. (2024). Passive vs active robo-advisors and disposition effect: Moderating role of gender and financial literacy. *Baltic Journal of Economics*, 24(2), 239-260. <https://doi.org/10.1080/1406099X.2024.2422673>
- Litterscheidt, R., & Streich, D. J. (2020). Financial education and digital asset management: What's in the black box? *Journal of Behavioral and Experimental Economics*, 87, 101573. <https://doi.org/10.1016/j.socec.2020.101573>
- Logg, J. M., Minson, J. A., & Moore, D. A. (2019). Algorithm appreciation: People prefer algorithmic to human judgment. *Organizational Behavior and Human Decision Processes*, 151, 90-103. <https://doi.org/10.1016/j.obhdp.2018.12.005>
- Looney, C. A., & Hardin, A. M. (2009). Decision support for retirement portfolio management: Overcoming myopic loss aversion via technology design. *Management Science*, 55(10), 1688-1703. <https://doi.org/10.1287/mnsc.1090.1052>
- Odean, T. (1998). Are investors reluctant to realize their losses? *Journal of Finance*, 53(5), 1775-1798. <https://doi.org/10.1111/0022-1082.00072>
- Piehlmaier, D. M. (2022). Overconfidence and the adoption of robo-advice: Why overconfident investors drive the expansion of automated financial advice. *Financial Innovation*, 8, 14. <https://doi.org/10.1186/s40854-021-00324-3>
- Reher, M., & Sokolinski, S. (2024). Robo advisors and access to wealth management. *Journal of Financial Economics*, 155, 103829. <https://doi.org/10.1016/j.jfineco.2024.103829>
- Shanmuganathan, M. (2020). Behavioural finance in an era of artificial intelligence: Longitudinal case study of robo-advisors in investment decisions. *Journal of Behavioral and Experimental Finance*, 27, 100297. <https://doi.org/10.1016/j.jbef.2020.100297>

Shiller, R. J., & Pound, J. (1989). Survey evidence on diffusion of interest and information among investors. *Journal of Economic Behavior & Organization*, 12(1), 47-66. [https://doi.org/10.1016/0167-2681\(89\)90076-0](https://doi.org/10.1016/0167-2681(89)90076-0)

Song, Z., Rehman, S. U., PingNg, C., Zhou, Y., Washington, P., & Verschueren, R. (2024). Do FinTech algorithms reduce gender inequality in bank loans? A quantitative study from the USA. *Journal of Applied Economics*, 27(1), 2324247. <https://doi.org/10.1080/15140326.2024.2324247>

Tversky, A., & Kahneman, D. (1974). Judgment under uncertainty: Heuristics and biases. *Science*, 185(4157), 1124-1131. <https://doi.org/10.1126/science.185.4157.1124>

ESG-JELENTÉSEK AZ EURÓPAI UNIÓBAN MINŐSÉG ÉS ELLENŐRZÉS SZEMPONTJÁBÓL

CZINE Vanda

Budapesti Gazdaságtudományi Egyetem
czine.vanda@uni-bge.hu

Dr. SIKLÓSI Ágnes

Budapesti Gazdaságtudományi Egyetem
siklosi.agnes@uni-bge.hu

Dr. SISA Krisztina Andrea

Budapesti Gazdaságtudományi Egyetem
sisa.krisztina@uni-bge.hu

<https://doi.org/10.15170/XVIIPPN-Tk-KTK-2026-03>

Absztrakt

Az Európai Unióban számos szabályozó mechanizmus befolyásolja az ESG-jelentések minőségét, amelyek célja az átláthatóság növelése és a vállalati elszámoltathatóság erősítése. A tanulmány célja annak vizsgálata, hogy az Európai Unióban milyen ellenőrzési mechanizmusok befolyásolják az ESG-jelentések minőségét a nem pénzügyi jelentéstételi irányelv (NFRD) bevezetését követően. A kutatás különös figyelmet fordít a vállalatirányítási jellemzőkre, a külső hitelesítési gyakorlatokra, a szabályozási környezetre, valamint a vállalatspecifikus tényezőkre, annak feltárása érdekében, hogy a kötelező jelentéstétel milyen mértékben járul hozzá a transzparencia és az információminőség javulásához.

A kutatás módszertanát egy strukturált szakirodalmi áttekintés képezi, amely során húsz, empirikus eredményeket bemutató tanulmány került kiválasztásra és részletes elemzésre, különös tekintettel a szabályozási változások és a vállalati jellemzők hatásmechanizmusaira. A feldolgozott kutatások különböző mintákon és időszakokban vizsgálták az ESG-jelentések minőségét, eltérő mérési megközelítéseket alkalmazva: biztosításalapú mutatókat, kereskedelmi ESG-adatbázisok pontszámait, valamint saját fejlesztésű minőségi indexeket. Az elemzés lehetővé teszi a szabályozási változások és ellenőrzési mechanizmusok hatásainak összehasonlító értékelését.

Az eredmények azt mutatják, hogy több tényező következetesen pozitív hatással van az ESG-jelentések minőségére. Kiemelkedő szerepe van az igazgatósági nemi sokszínűségnek, a vállalat méretének, az ESG-teljesítménynek és az iparági hovatartozásnak. A külső ellenőrzés általában növeli a jelentések hitelességét, bár hatékonysága kontextusfüggő. A vállalatirányítási struktúrák (például a fenntarthatósági bizottságok és a teljesítményhez kötött javadalmazás) szintén

hozzájárulnak a jobb minőséghez. Ugyanakkor az igazgatósági függetlenség és méret hatásai vegyesek. A szabályozás (különösen az NFRD) egyértelműen növelte a közzétett információk mennyiségét és a külső ellenőrzés valószínűségét, de önmagában nem minden dimenzióban eredményezett jelentős minőségjavulást.

A tanulmány gyakorlati és gazdaságpolitikai szempontból arra utal, hogy a pusztán kötelező közzétételi előírások nem elegendők a magas minőségű ESG-jelentéstétel biztosításához. Szükség van erősebb végrehajtási mechanizmusokra, egységesebb standardokra és kötelező külső bizonyossági követelményekre, amelyeket a CSRD részben már be fog vezetni. A döntéshozók számára fontos tanulság, hogy a vállalatirányítás fejlesztése és az intézményi környezet erősítése kulcsfontosságú a jelentések tartalmi minőségének javításában és a fenntarthatósági információk döntéshozatali hasznosságának növelésében.

Kulcsszavak: ESG, Minőségellenőrzés, kontroll-mechanizmus, NFRD, CSRD

Bevezetés

A környezeti, társadalmi és irányítási (ESG) jelentéstétel az Európai Unió (EU) területén a vállalati átláthatóság és elszámoltathatóság egyik sarokkövévé vált. Az elmúlt évtizedben a fenntarthatósági jelentéstétel egy nagyrészt önkéntes gyakorlatból a szélesebb vállalati jelentéstételi keretrendszerbe beépített, szabályozott jelentéstételi kötelezettséggé fejlődött. Ez az átalakulás azt tükrözi, hogy a döntéshozók, a befektetők és az érdekelt felek körében egyre inkább elismert tény, hogy a nem pénzügyi információk döntő szerepet játszanak a vállalati teljesítmény, a kockázati kitettség és a hosszú távú értékteremtés értékelésében.

Az EU nem pénzügyi jelentéstételi irányelvének (NFRD) bevezetése döntő lépést jelentett az ESG-jelentéstétel intézményesítésében. Az irányelv a nagy közérdekű szervezetek számára előírta a fenntarthatósági információk közzétételét, célja pedig a nem pénzügyi információk átláthatóságának, következetességének és megbízhatóságának javítása volt. A korai végrehajtási tapasztalatok azonban felvetették a kérdést, hogy a kötelező közzétételi követelmények önmagukban elegendők-e az ESG-jelentések minőségének javításához, vagy kiegészítő belső és külső ellenőrzési mechanizmusokra van szükség a jelentősegteljes, összehasonlítható és döntéshozatalhoz hasznos információk biztosításához.

Ez a tanulmány az ellenőrzési mechanizmusok szerepét vizsgálja az ESG-jelentések minőségének alakításában az Európai Unióban. A jelentés eredményeinek kulcsfontosságú meghatározó tényezőiként a vállalatirányítási jellemzőkre, a külső bizonyossági gyakorlatokra, az intézményi és kulturális kontextusokra, valamint a vállalatspecifikus tulajdonságokra összpontosít. Az irányelv hatálybalépése utáni kötelező környezetben az ESG-jelentési gyakorlatok elemzésével a tanulmány hozzájárul a fenntarthatósági jelentésekkel, a vállalatirányítással és a szabályozás hatékonyságával kapcsolatos szakirodalomhoz.

Adatgyűjtés, alkalmazott módszertan

A kutatás során szisztematikus keresést végeztünk különböző típusú keresőmotorokban, például a Semantic Scholarban és az OpenAlexben. Az irodalomáttekintés 20 olyan tanulmányt tartalmazott, amelyek az Európai Unió kontextusában vizsgálták az ESG-jelentések minőségét és az ellenőrzési mechanizmusokat. Az 1. táblázat bemutatja ezeknek a tanulmányoknak a legfontosabb jellemzőit.

1. táblázat: Kiválasztott tanulmányok és azok legfontosabb jellemzői

Tanulmány	Tanulmány típusa	Vizsgált minta összetétel	Vizsgált időszak	Minőség mérési módszer	Vizsgált főbb ellenőrzési mechanizmusok
Fatma Baalouch és társai, 2019	Kvanti-tatív elemzés	Az SBF120 indexben szereplő francia tőzsdén jegyzett vállalatok, 570 vállalati megfigyelés	2009-2014	Az IASB és a GRI keretrendszereken alapuló, saját készítésű index, amely a jelentés szintjén méri a relevancia, semlegesség, egyértelműség, összehasonlíthatóság és ellenőrizhetőség szempontjait, átlagos minőségi pontszám: 18,1%	Környezetvédelmi audit, nemek közötti sokszínűség, környezetvédelmi bizottság, kötelező harmadik fél általi ellenőrzés
Giorgio Mion & C. R. Loza Adauí, 2019	Kvanti-tatív és kvalitatív elemzés	132 vizsgált vállalat: 36 olasz és 30 német	2016-2017	20 indikátoros megközelítési skála, 3 fő dimenzió: elérhetőség, hitelesség, stratégiai beágyazottság	2014/95/EU NFRD irányelv, SRQ dimenziók, külső ellenőrzés, vállalati jellemzőkintézményi harmonizáció
G. Nicolò és társai, 2021	Kvanti-tatív elemzés	21 uniós tagállamból származó 1 392 tőzsdén jegyzett, nem pénzügyi vállalat	2014-2019	A Thomson Reuters súlyozott átlagos ESG-pontszámait vállalati szinten 1,353 és 94,473 között mozognak	Az igazgatóság mérete, függetlensége, a nemek közötti sokszínűség, az EU 2014/95/EU irányelv
Philipp Ottenstein és társai, 2021	Kvanti-tatív elemzés	905 vizsgált vállalat az EU 28+2 országából, nagy tőzsdén jegyzett vállalatok	Nincs megadva	Összehasonlíthatósági és hitelességi mutatók a Refinitiv ESG adatbázisból	Külső ellenőrzés, az irányelv szerinti szabályozási megfelelés
Salim Chouaibi és társai, 2021	Kvanti-tatív elemzés	253 tőzsdén jegyzett vállalat az európai ESG-indexből	2010-2019	A közzététel pontossága vállalati szinten mérve	Az igazgatóság mérete, függetlenség, sokszínűség, az elnök függetlensége
Muhammad Arif és társai, 2021	Kvanti-tatív elemzés	S&P Europe 350 indexben szereplő vállalatok	Nincs megadva	Nincs kifejezetten meghatározva, NFI/ESG közzétételi szabályozás	2014/95/EU Uniósi irányelv
Heidi Vander Bauwhede és társai, 2022	Kvanti-tatív elemzés	1 832 vállalat-év megfigyelés 660 európai tőzsdén jegyzett vállalattól 19 uniós tagállamban	2017-2020	Nincs kifejezetten meghatározva, feltételezhetően vállalati szinten a Refinitiv ESG-adatbázis felhasználásával	Külső ellenőrzési mechanizmusok, NFRD és CSRD szabályozási követelmények

M. Aluchna és társai, 2022	Kvanti-tatív elemzés	43 lengyel tőzsei cég	2014-2016 & 2017-2019	refinitív változók, NFRD, ESG performance	vállalati kontroll, érintettség, DiD mechanizmusok
Z. Rezaee és társai, 2022	Kvanti-tatív elemzés	EU és amerikai tőzsei cégek, 2563 vállalati megfigyelés	2007-2019	ESG indikátor alapján, bináris scoring	szabályozási rendszerek, interakciós hatás, ország szintű kontrollok, céges szintű kontrollok
Ahmed Aboud és társai, 2023	Kvanti-tatív elemzés	3 020 Kvantitatív elemzés Szisztematikus áttekintés Kvantitatív elemzés vállalat-év megfigyelések az EU-ból és az USA-ból (hajlamossági pontszámmal párosítva)	Nincs megadva	Nincs meghatározva (fókusz az ESG- elválasztáson)	Az igazgatóság mérete, nemi sokszínűség, ESG-ellenőrizhetőség és országos szintű végrehajtás
Oana-Marina Radu és társai, 2023	Szisztematikus áttekintés	15 empirikus cikk a Scopusból, amely az NFRD hatálya alá tartozó EU-országokat fedli le	2017 utáni alkalmazási időszak	Éves jelentések tartalmi elemzése, amely a jelentés szintjén értékeli a környezeti, társadalmi, munkavállalói, emberi jogi és korrupcióellenes szempontokat	Az igazgatóság függetlensége, az igazgatóság mérete, a nemek közötti sokszínűség, a fenntarthatósági bizottság, a külső ellenőrzés, a fenntarthatósággal összekapcsolt javadalmazás
Stefania Carolina Posadas és társai, 2023	Kvanti-tatív elemzés	olasz és spanyol nagyvállalatok, 221 megfigyelési panel	pre-és poszt időszakok	minőségi index, 3 dimenzó mentén, komplex ESG reporting quality mutató	intézményi kényszerítés, faktoranalízissel képzett dimenziók
J. Sedlák & Jaromír Veber, 2024	Kvanti-tatív elemzés	53 cseh energiapiaci vállalat (melyek várhatóan a CSRD hatálya alá esnek)	2022-es jelentések	új mutató: NFII minőségi vs. CSRD standardok	követelmény-alapú elemzés (CSRD, ESRS standardok), tartalmi dimenziók
Garcia Emma és társai, 2024	Kvanti-tatív elemzés	STOXX Europe 600 indexen szereplő vállalatok 17 európai országból	2015-2020	Az ellenőrzési nyilatkozat tartalmi elemzése 12 tételből álló index felhasználásával, 0–23 ponttartományban a jelentés szintjén	Az igazgatóság függetlensége, az igazgatósági üléseken való részvétel, a vezérigazgató függetlensége, külső ellenőrzés, az EU 2014/95/EU irányelv
C. Cepêda, 2024	Kvanti-tatív elemzés	45 portugál tőzsei vállalat	2008-2021	ESG Reporting Scope	külső makro sokkok, szabályozási kontroll, egyéb kontrollváltozók
Ayşenur Tarakçıoğlu Altınay & Barış Sardoğan, 2025	Kvalitatív elemzés	100 vállalat (korábbi CSRD alkalmazók)	2022-2024	Együtes-előfordulás elemzés és interpretatív elemzés	kettős-megfelelés vizsgálata, intézményi és legitimációs mechanizmusok, külső ellenőrzés
Vincenzo Basile és társai, 2025	Kvanti-tatív elemzés	472 bank, európai bankrendszer	2017-2020	Refinitiv ESG, CSR teljesítmény	igazgatóság jellemzői, vállalati kontroll, transzparencia kontroll, makrogazdasági kontroll
George Sklavos és társai, 2025	Kvanti-tatív elemzés	365 európai, listázott pénzügyi intézmény	2024	kettős mérés: ESG kommunikáció és green accounting	környezeti elszámolási kontroll, szabályozási mechanizmus, ESG

					governance mechanizmusok
Nicola Raimo és társai, 2025	Kvanti-tatív elemzés	166 EU-s vállalat, akik integrált jelentést készítettek	2023	CSRD compliance szint, index skála	szabályozási megfelelés, tartalmi kontroll dimenziók, vállalati jellemzők, legitimációs mechanizmusok
Joanna Krasodoms ka és társai, 2025	Kvanti-tatív elemzés	859 tőzsdén jegyzett vállalat 20 európai országból	2018-2021	A bizonyosságot szolgáltató típusa, hatálya, az ellenőrzés szintje	Külső ellenőrzési mechanizmusok, szabályozási megfelelés

Forrás: saját szerkesztés, az irodalmi áttekintések alapján

A kiválasztott tanulmányokat részletes adatbányászatnak és adatkinyerésnek vetettük alá. Valamennyi tanulmány kvantitatív módszertant alkalmazott, egy kivétellel (Oana-Marina Radu et al., 2023), amely empirikus tanulmányok szisztematikus áttekintése volt. A mintanagyság 253 vállalattól 3020 vállalat-év megfigyelésig terjedt, a földrajzi lefedettség pedig az egy országra (Franciaország) korlátozódóktól az EU több országát (akár 21 országot) magában foglaló kontextusokig terjedt. Az időtartamok jelentősen eltértek egymástól az irányelv végrehajtását megelőző időszakról (2009–2014) az irányelv utáni időszakokig (2017–2020), ami lehetővé tette a szabályozási hatások értékelését.

Minőség mérési megközelítések

Az ESG-jelentések minőségét a különböző tanulmányok jelentősen eltérő módon foglalmazták meg és mérték, ami tükrözi a minőségértékelés többdimenziós jellegét. Három fő megközelítés rajzolódott ki: az ellenőrzés alapú minőségi mutatók, a saját fejlesztésű adatbázisok pontszámai, valamint az önállóan kidolgozott minőségi indexek.

Ellenőrzés alapú minőségi mutatók: Két tanulmány az ellenőrzés biztosítási jellemzői alapján határozta meg a minőséget. Krasodomska és társai (2025) a minőséget az ellenőrzés szolgáltató típusának, a vizsgálat hatókörének és szintjének függvényeként foglalmazták meg. Garcia Emma és társai (2024) egy 12 tételből álló tartalomelemzési indexet dolgoztak ki, amely az AccountAbility, az Európai Könyvelők Szövetsége és a GRI irányelvei alapján 0 és 23 közötti pontszámmal értékelte az ellenőrzési nyilatkozatokat. Ez a megközelítés a külső ellenőrzést a jelentés alapjául szolgáló minőség helyettesítő mutatójaként kezeli.

Saját adatbázisok pontszámai: Három tanulmány kereskedelmi ESG adatszolgáltatókra támaszkodott. Nicolò és társai (2021) a Thomson Reuters súlyozott átlagos ESG-pontszámait használták, amelyek 1,353 és 94,473 között mozogtak. Ottenstein és társai (2021) a Refinitiv ESG-adatbázis mutatóit alkalmazták az összehasonlíthatóság és a hitelesség dimenzióinak értékelésére. Vander Bauwhede et al. (2022) a Refinitiv ESG-adatbázisát használta a vállalati szintű minőségértékeléshez. Chouaibi et al. (2021) a Thomson Reuters ASSET4 adatbázisából merített, a közzététel pontosságára összpontosítva. Ezek a

megközelítések a szabványosított pontozás előnyeit élvezik, de előfordulhat, hogy nem ragadják meg a minőség finomabb dimenzióit.

Saját készítésű minőségi indexek: Baalouch és társai (2019) az IASB és a GRI keretrendszeren alapuló átfogó indexet fejlesztettek ki, amely öt minőségi dimenziót értékel: relevanciát, semlegességet, egyértelműséget, összehasonlíthatóságot és ellenőrizhetőséget az éves és önálló jelentések kézi tartalomelemzésén keresztül, ami 18,1%-os átlagos minőségi pontszámot eredményezett. Radu és társai (2023) szisztematikus áttekintésük során az éves jelentések tartalomelemzését azonosították az elsődleges módszertanul a jelentésszintű környezeti, társadalmi, munkavállalói, emberi jogi és korrupcióellenes szempontok értékeléséhez.

Érdemes megjegyezni, hogy Aboud és társai (2023) nem adtak részletes minőségmérési előírásokat, hanem a kifejezett minőségmérés helyett inkább a szabályozási hatásokra, illetve az ESG-tényezők és a teljesítmény közötti szétválasztásra összpontosítottak.

Ellenőrzési mechanizmusok és az ESG-jelentések minősége

a) Az igazgatóság jellemzői

A tanulmányok során az igazgatótanács összetétele bizonyult a legszélesebb körben vizsgált ellenőrzési mechanizmusnak. A nemek közötti sokszínűség következetesen pozitív összefüggést mutatott az ESG-jelentések minőségével. Chouaibi és társai (2021) megállapították, hogy az igazgatótanács sokszínűsége szignifikánsan pozitív hatással volt az integrált jelentések minőségére. Nicolò és társai (2021) kimutatták, hogy a női igazgatósági tagok pozitívan befolyásolták az ESG-adatok közzétételének szintjét mind az általános, mind az egyes ESG-mutatók tekintetében. Radu és társai (2023) szisztematikus áttekintésük során megerősítették, hogy az igazgatótanácsok nemi sokszínűsége pozitívan befolyásolta a nem pénzügyi jelentések minőségét, alátámasztva ezzel az érdekelt felek és a legitimitás elméleteket. Aboud és társai (2023) az elemzésükben kontrollváltozóként vették fel a nemi sokszínűséget, míg Baalouch és társai (2019) megállapították, hogy a nemi sokszínűség pozitív és szignifikáns összefüggést mutat a környezeti közzététel minőségével 1%-os szignifikanciaszinten.

Az igazgatótanács függetlensége árnyaltabb hatásokat mutatott. Míg Chouaibi és társai (2021) jelentősen pozitív hatásokat jelentettek az integrált jelentéskészítés minőségére, és Radu és társai (2023) kis mértékű pozitív korrelációkat találtak, addig Baalouch és társai (2019) szignifikáns negatív összefüggést azonosítottak a független igazgatósági tagok és a környezeti közzététel minősége között, ami arra utal, hogy bizonyos kontextusokban a független igazgatósági tagok nem mindig javítják a nem pénzügyi közzétételt.

Az igazgatóság mérete több tanulmányban is pozitív összefüggést mutatott a minőséggel. Chouaibi és társai (2021) megállapították, hogy az igazgatóság mérete pozitívan befolyásolta az integrált jelentéskészítés minőségét, Radu és társai (2023)

pedig közepes pozitív korrelációt jelentettek az igazgatóság mérete és a nem pénzügyi jelentéskészítés minősége között. Nicoló és társai (2021) azonban azt találták, hogy az igazgatóság mérete negatív hatással volt az ESG-közzétételre, ami arra utal, hogy a nagyobb igazgatóságok koordinációs problémákat okozhatnak, amelyek gátolják a hatékony jelentéskészítést.

Az igazgatóság aktivitása és hatékonysága fontos moderátorokként jelentek meg. Garcia Emma és társai (2024) az igazgatóság hatékonyságát a vezérigazgató függetlenségén, az igazgatóság függetlenségén és az igazgatósági üléseken való részvételen keresztül mérték, és megállapították, hogy a kívánatos tulajdonságokkal rendelkező igazgatóságok az ellneőrzési minőséggel együttesen járultak hozzá a vállalatok legitimitásához, 0,002 és 0,005 közötti együtthatókkal, amelyek pozitív hatásokat jeleznek.

Az elnök függetlensége pozitív összefüggést mutatott. Chouaibi és társai (2021) megállapították, hogy a független, nem ügyvezető elnök kinevezése pozitív összefüggésben áll az integrált jelentéstétel minőségével, még azokban a vállalatokban is, ahol az elnök nem független.

b) Külső hitelesítési mechanizmusok

A külső tanúsítás kritikus minőségellenőrzési mechanizmusként jelent meg, bár alkalmazása és hatékonysága vállalatonként eltérő volt. Ottenstein és társai (2021) megállapították, hogy az EU-irányelv hatálya alá tartozó vállalatok esetében 19%-kal nagyobb volt a valószínűsége a külső tanúsítás igénybevételének, ami az irányelv hitelességnövelő hatását jelzi. Vander Bauwhede és társai (2022) a vállalat méretét, az ESG-teljesítményt és az iparági hovatartozást azonosították a fenntarthatósági jelentés ellenőrzésének bevezetésének jelentős mozgatórugóiként, ahol a méret és a CSR-teljesítmény között szignifikáns pozitív összefüggés volt megállapítható ($p < 0,01$). Krasodomska és társai (2025) megállapították, hogy a fenntarthatósággal kapcsolatos teljesítményre összpontosító vállalatok nagyobb valószínűséggel vettek igénybe külső ellenőrzést és magasabb színvonalú biztosítást kaptak.

Garcia Emma és társai (2024) részletesebb eredményeket közöltek a tanúsításról, mint legitimációs eszközről. Amikor a vállalatok az ESG-megfelelés elmulasztásáról szóló médiaértesülések miatt legitimációs fenyegetésekkel szembesültek, a fenntarthatósági tanúsítást a legitimitás helyreállításának eszközeként alkalmazták. A tanúsítás minősége azonban nem reagált a legitimációs fenyegetésekre vitatott iparágakban vagy szigorú kultúrájú országokban, ahol úgy tűnt, hogy maguk a kulturális normák játszanak legitimáló szerepet. Érdekes módon Krasodomska és társai (2025) megállapították, hogy azok a vállalatok, amelyek a hírnevet tartják a bizalom forrásának, kevésbé hajlamosak könyvvizsgáló cégeket igénybe venni ellenőrzési szolgáltatóként, ami a bizalomépítő megközelítéseken alapuló ellenőrzési stratégiák heterogenitására utal.

Radu és társai (2023) a nem pénzügyi információk külső ellenőrzését a nem pénzügyi jelentések minőségét elősegítő, előzetesen alátámasztott pozitív tényezőként jelölték meg, bár a bizonyítékok nem voltak egyértelműek. Baalouch és társai (2019)

megállapították, hogy a környezeti audit pozitív és szignifikáns összefüggést mutat a minőséggel 1%-os szinten, kiemelve, hogy a Grenelle II rendelet szerinti kötelező harmadik fél általi ellenőrzés növeli a hitelességet és az átláthatóságot.

c) Vállalatirányítási struktúrák

Az igazgatóság összetételén túlmenően bizonyos irányítási struktúrák is befolyásolták a jelentések minőségét. Radu és társai (2023) megállapították, hogy a fenntarthatósági bizottság meglete pozitív korrelációt mutatott a nem pénzügyi jelentések minőségével, bár a hatás mértéke változó volt. A vállalatirányítás minősége összességében nagyon erős pozitív korrelációt mutatott a nem pénzügyi jelentések minőségével.

A fenntarthatósághoz kötött javadalmazás pozitív hatásokat mutatott. Radu és társai (2023) mérsékelt pozitív összefüggést jelentettek a fenntarthatósághoz kötött javadalmazás és a nem pénzügyi jelentések minősége között, ami arra utal, hogy a javadalmazás ESG-teljesítményhez kötése javítja a jelentéstételi magatartást.

A tulajdonosi struktúrák vegyes eredményeket mutattak. Radu és társai (2023) megállapították, hogy a külföldi tulajdonlás mérsékelt pozitív korrelációt mutat a nem pénzügyi jelentések minőségével, ami arra utal, hogy a külföldi befektetőkkel rendelkező vállalatok inkább magasabb színvonalú jelentéseket készítenek. A magántulajdon azonban negatív hatásokkal járt, bár a bizonyítékok nem voltak egyértelműek.

d) Szabályozási követelmények

Az európai nem pénzügyi jelentéstételi irányelv (2014/95/EU) jelentette a tanulmányok során vizsgált legfőbb szabályozási ellenőrzési mechanizmust. Arif és társai (2021) megállapították, hogy az irányelvnek jelentős pozitív hatása volt az ESG-adatok közzétételének mennyiségére, és az irányelv hatálybalépését követő időszakban megerősödött az összefüggés az ESG-adatok közzététele és a nyereségkockázat között, ami arra utal, hogy a nem pénzügyi jelentéstétel előírása mind a mennyiséget, mind a minőséget javítja. Ottenstein és társai (2021) kimutatták, hogy a vizsgált vállalatok körülbelül 4 százalékponttal több fenntarthatósági információt szolgáltattak, mint a kontrollcsoport tagjai. Aboud és társai (2023) megállapították, hogy mind az irányelv 2014-es elfogadása, mind a 2017-es végrehajtása enyhítő hatással volt az ESG-elvásztásra, bár a nemzeti végrehajtási rendszerek szigorúsága nem befolyásolta ezt a kapcsolatot. Garcia Emma és társai (2024) nem találtak szignifikáns különbséget az ellenőrzési minőség legitimáló használatában a felelőtlen ESG-cselekmények után az irányelv előtt és után, ami arra utal, hogy az irányelv önkéntes ellenőrzési rendelkezéseinek hatékonysága bizonyos kontextusokban korlátozott lehet.

Az EU keretein belül országspecifikus eltérések voltak tapasztalhatók. Vander Bauwhede és társai (2022) megjegyezték, hogy az EU-tagállamok a minimális NFRD-szabványokon túl további követelményeket is bevezethetnek. Franciaország, Olaszország és Spanyolország például kötelezővé tették az ellenőrzést.

Krasodomska és társai (2025) megállapították, hogy a „common law” rendszer jelentősen befolyásolta az ellenőrzési döntéseket és a minőséget.

e) *Vállalati szintű jellemzők*

A vállalat mérete következetesen jelentős meghatározó tényezőként jelent meg. Vander Bauwhede és társai (2022) megállapították, hogy a vállalat mérete szignifikánsan pozitív összefüggést mutat a fenntarthatósági jelentés hitelesítésének alkalmazásával ($p < 0,01$). Krasodomska és társai (2025) megerősítették, hogy a vállalat mérete szignifikánsan befolyásolta a hitelesítési döntéseket és a hitelesítés minőségének bizonyos aspektusait. Radu és társai (2023) a vállalat méretét a nem pénzügyi jelentések minőségének pozitív tényezőjeként azonosították.

Az ESG-teljesítmény pozitív összefüggéseket mutatott. Vander Bauwhede és társai (2022) megállapították, hogy az ESG-teljesítmény szignifikánsan pozitív kapcsolatban áll a bizonyosságnyújtás alkalmazásával ($p < 0,01$). Radu és társai (2023) a fenntarthatósági teljesítményt a nem pénzügyi jelentések minőségének pozitív tényezőjeként jelölték meg. Baalouch és társai (2019) megállapították, hogy a környezeti teljesítmény pozitív és szignifikáns összefüggést mutat a minőséggel 1%-os szinten, ami arra utal, hogy a jobb teljesítményt nyújtók hitelesebb környezeti információkat nyújtanak.

Az iparági hovatartozás szignifikánsan befolyásolta a minőséget és az ellenőrzési döntéseket. Vander Bauwhede és társai (2022) az iparágat a fenntarthatósági jelentés ellenőrzésének fontos mozgatórugójának azonosították. Krasodomska és társai (2025) megállapították, hogy az üzleti szektor jelentősen befolyásolta a bizonyossági döntéseket és a minőséget. Aboud és társai (2023) megállapították, hogy az irányelv hatása a nem vitatott iparágakban működő vállalatok esetében kifejezettebb.

A tőkeáttétel pozitív hatásokat mutatott. Baalouch és társai (2019) megállapították, hogy a tőkeáttétel 1%-os szinten pozitív összefüggésben áll a minőséggel, ami arra utal, hogy a magas tőkeáttétellel rendelkező vállalatok jobb nem pénzügyi információkat nyújtanak a negatív percepciók enyhítése érdekében.

Időbeli alakulás és szabályozási hatások

Az EU nem pénzügyi jelentéstételi irányelve (2014/95/EU) alapvetően meghatározta az ESG-jelentéstétel kereteit. A 2014-ben elfogadott és 2017-ben hatályba lépett irányelv előírja a fenntarthatósági jelentéstételt a nagy közérdekű szervezetek számára, ami mintegy 6000 európai vállalat esetében az önkéntes jelentéstételtől a kötelező jelentéstételre való áttérést jelenti. A nem pénzügyi jelentéstételi irányelvtől (2014/95/EU) a vállalati fenntarthatósági jelentéstételi irányelvig vezető szabályozási folyamat az uniós kontextus központi strukturális jellemzőjét képezi, és a vizsgált tanulmányok túlnyomó többsége foglalkozik vele. Az NFRD hatékonyságára vonatkozó bizonyítékok határozottan vegyesek, míg a CSRD-t

elsősorban előre jelző vagy a bevezetés korai szakaszára vonatkozó szempontból tárgyalják.

Az irányelv végrehajtási időszakát lefedő tanulmányok vegyes hatásokat tártak fel a minőségi dimenziókra nézve. Az NFRD végrehajtásának hatásait a legszigorúbban a 2017-es végrehajtási dátumot kihasználó különbség-a-különbség módszerekkel dokumentálták. Ottenstein és társai (2021) megállapították, hogy a vizsgált uniós vállalatok körülbelül 4 százalékponttal több fenntarthatósági információt nyújtanak, mint a hozzájuk illesztett kontrollvállalatok, és 19%-kal nagyobb valószínűséggel kapnak külső tanúsítást az irányelv hatálybalépését követően (Ottenstein és társai, 2021). Arif és társai (2021) megerősítik az irányelv jelentős pozitív hatását az ESG-közzétételek mennyiségére, és megállapítják, hogy az irányelv utáni időszakban az ESG-közzétételek és a jövedelmi kockázat közötti megerősödött összefüggés a minőség javulását jelzi (Arif és társai, 2021). Rezaee és társai (2022) EU–USA DiD-terveket alkalmaznak, és következetesen megállapítják, hogy az EU-vállalatok már a kötelező végrehajtás előtt is felülmúlták az amerikai vállalatokat az ESG-közzétételek terén, és hogy a közzétételek 2017 után tovább javultak.

Aboud és társai (2023) egy különleges megállapítással járulnak hozzá a kutatáshoz: mind az irányelv 2014-es elfogadása, mind a 2017-es végrehajtása enyhítő hatással van az ESG-elvásztásra (a közzétételi pontszámok és a teljesítménypontszámok közötti különbségre), de a nemzeti végrehajtási rendszerek szigorúsága nincs jelentős hatással erre a kapcsolatra. Paradox módon az ESG-információkat függetlenül auditált vállalatok esetében az irányelv hatása az elválasztás csökkentésére kevésbé kifejezett, egy eredmény, amelyet a szerzők nem magyaráznak teljes mértékben, de amely összhangban áll azzal a lehetőséggel, hogy az auditált vállalatok már az irányelv előtt csökkentették elválasztásukat (Aboud és társai, 2023).

Ugyanakkor nem minden értékelés pozitív. Posadas és társai (2023), akik az NFRD átültetése előtti és utáni olasz és spanyol vállalatokat vizsgálták, nem találtak jelentős hozzájárulást a kényszerítő szabályozási mechanizmusok részéről a jelentéstétel minőségének javításához – a normatív és mimetikus nyomás nagyobb hatással van, mint maga az irányelv. Cepêda (2024) megállapítja, hogy a kötelező nem pénzügyi jelentési követelmények nem befolyásolták pozitívan az ESG-jelentések hatókörét Portugáliában, bár a COVID-19-válság körülményei exogén sokként javították a jelentések minőségét.

Mion és Loza Adauí (2019) optimistább értékelést adnak, megállapítva, hogy az irányelv végrehajtása után mind Olaszországban, mind Németországban javult a fenntarthatósági jelentések minősége, és hogy az irányelv csökkentette a két ország között korábban fennálló minőségi különbségeket. Ez a konvergenciahatás elméletileg fontos: úgy tűnik, hogy a kötelező harmonizáció csökkenti a heterogenitást, még ha nem is javítja maximálisan a minőséget minden kontextusban.

A jövőre nézve a javasolt vállalati fenntarthatósági jelentéstételi irányelv (CSRD, 2022/2464) célja ezeknek a hiányosságoknak a kezelése. A CSRD kiterjeszti a

jelentéstétel hatályát, 2024-től kötelező korlátozott bizonyosságot vezet be, és bevezeti a „kettős lényegesség” koncepcióját a pozitív és negatív fenntarthatósági közzétételek egyensúlyának biztosítása érdekében. Vander Bauwhede és társai (2022) megjegyezték, hogy ez a kötelező bizonyossági követelmény orvosolja az NFRD egyik fő korlátját.

A CSRD-re való átállás elsősorban előre tekintő vagy korai értékelési szempontból kerül tárgyalásra. Számos tanulmány a CSRD legfontosabb újításait a következőkben látja: a hatály kiterjesztése körülbelül 11 000-ről 50 000 vállalatra; az Európai Fenntarthatósági Beszámolási Standardok (ESRS) bevezetése; 2024-től kötelező korlátozott bizonyosság, a megfelelő bizonyosság elérése felé vezető, meghatározott útvonal kijelölésével; valamint a kettős lényegesség bevezetése szervező elvként (Raimo és társai, 2025). Altinay és Sardoğan (2025) az első 100 CSRD-jelentést benyújtó vállalatok elemzése során jelentős eltéréseket találtak a kettős lényegesség értelmezésében, ami a szabályozási iránymutatások ellenére is a következetesség és az összehasonlíthatóság hiányát jelzi. Raimo és társai (2025) 166 uniós vállalat integrált jelentését vizsgálta az ESRS-követelmények tükrében, és viszonylag alacsony átlagos ESRS-megfelelési szintet talált, ahol a vállalat mérete és a környezeti érzékenység pozitív előrejelzőként szolgáltak. Sedlák és Veber (2024) a cseh kontextusban dokumentálják, hogy a nem pénzügyi információk minősége még nem felel meg a CSRD-szabványoknak, és pozitív, de statisztikailag nem szignifikáns korrelációt mutat a vállalat méretével.

A jelentések minősége és a tényleges ESG-teljesítmény – a „greenwashing” problémája

Az ESG-jelentések minősége és a tényleges ESG-teljesítmény közötti kapcsolat az irodalomban az egyik legvitatottabb és gyakorlati szempontból legjelentősebb kérdés, amelyre vonatkozó bizonyítékok egyszerre utalnak valódi javulásra, szimbolikus megfelelésre és stratégiai elszakadásra.

A valódi javulás oldalán Aluchna és társai (2022) lengyel tőzsdén jegyzett vállalatok példáján azt találták, hogy az NFRD bevezetése javította az általános ESG-teljesítményt, különösen a környezeti és társadalmi dimenziókban, és a jogszabály hatálya alá tartozó vállalatoknál nagyobb javulás volt tapasztalható.

A szimbolikus megfelelés és a szétválasztás tekintetében Papa és társai (2024) dokumentálják, hogy a lengyel vállalatok környezetvédelmi politikák és célok végrehajtását jelentették be anélkül, hogy az energia- és erőforrás-KPI-okban valódi változások történtek volna, miközben a kvalitatív közzétételi pontszámok javultak, a mérhető teljesítménymutatók viszont nem. Sklavos és társai (2025) jelentős zöldre mosás kockázatot azonosít az európai pénzügyi intézmények körében, amelyek jelentős hányada magas ESG-nyilvánosságra hozatali pontszámot mutat, de nem rendelkezik megfelelő környezeti tartalommal.

Baalouch és társai (2019) francia vállalatokat vizsgálva azt találták, hogy a gyenge környezeti teljesítményű vállalatok optimistább nyelvet használnak jelentéseikben, ami a közzététel hangvételén keresztül megvalósuló „greenwashing” egy formája,

míg a jobb teljesítményűek valóban magasabb környezeti közzétételi minőségi pontszámokat érnek el. Ez a mintázat összhangban áll az önkéntes közzétételről szóló szakirodalommal, amely azt mutatja, hogy a negatív hírekkel rendelkező vállalatoknak érdeke a pozitív keretezésen keresztül elhomályosítani a helyzetet.

Az ESG-minősítési módszerek szerepe a „greenwashing” terjesztésében vagy felderítésében átfogó kérdés. Basile és társai (2025) megjegyzik, hogy a Refinitiv minősítései oly módon keverhetik össze a közzététel minőségét és a tényleges teljesítményt, hogy nehéz megkülönböztetni a valódi és a kozmetikai javulást.

Összegzés

A tanulmány eredményei azt mutatják, hogy a vállalat mérete, az ESG-teljesítmény és az iparági hovatartozás következetesen hozzájárulnak a magasabb színvonalú jelentéstételhez és a tanúsítási gyakorlatok alkalmazásához. A jelen tanulmánynak vannak korlátjai. Ez egy szisztematikus irodalomáttekintés; mint ilyen, a cikkek és változók azonosítását illetően egy félig objektív értelmezési folyamatnak van alávetve. Külön döntés született arról, hogy más áttekintési módszerek helyett szisztematikus irodalomáttekintést alkalmazunk elemzési módszerként. Nyilvánvaló, hogy a csökkentett minta méretéből adódó korlátozás kizárja a statisztikai módszerek alkalmazását. A jövőbeli kutatásokban szükséges a vizsgált minta bővítése és több statisztikai módszer alkalmazása. Ezen felül az új jelentési szabályozások közelmúltbeli bevezetése és az azokhoz kapcsolódó alkalmazások várhatóan új elemzési módszereket fognak eredményezni, amelyeket be kell építeni a jövőbeli kutatási törekvésekbe.

Hivatkozások

Ahmed Aboud, Ahmed Saleh, and Yasser Eliwa. (2023): Does Mandating ESG Reporting Reduce ESG Decoupling? Evidence from the European Union's Directive 2014/95. *Business Strategy and the Environment*, 33 (2): 1305-1320. DOI: 10.1002/bse.3543

Ayşenur Tarakçıoğlu Altınay & Barış Sardoğan (2025) The Transition to an Impact-Based Approach in Sustainability and Financial Reporting. *Ekonomi Politika ve Finans Arastirmalari Dergisi*. <https://doi.org/10.30784/epfad.1813830>

Aluchna M, Roszkowska-Menkes M, Kamiński B (2022) From talk to action: the effects of the non-financial reporting directive on ESG performance. *Meditari Accountancy Research*. <https://doi.org/10.1108/medar-12-2021-1530>

Basile V, Serino L, Ambra AD, Campanella F (2025) Board characteristics and effects on ESG performance: empirical evidence from the European banking system. *Quality & Quantity: International Journal of Methodology*. <https://doi.org/10.1007/s11135-025-02338-w>

- Cepêda C (2024) Can Crisis Periods Affect the ESG Reporting Scope? The Portuguese Euronext Entities Case. *Journal of Risk and Financial Management*. <https://doi.org/10.3390/jrfm17050191>
- Fatma Baalouch, Salma Damak Ayadi, and K. Hussainey. (2019): A Study of the Determinants of Environmental Disclosure Quality: Evidence from French Listed Companies. *Journal of Management and Governance*, 23(2). DOI: 10.1007/s10997-019-09474-0
- G. Nicolò, Giovanni Zampone, Giuseppe Sannino, and Serena De Iorio. (2021): Sustainable Corporate Governance and Non-Financial Disclosure in Europe: Does the Gender Diversity Matter? *Journal of Applied Accounting Research*, 2022, 23(1): 227-249. DOI: 10.1108/JAAR-04-2021-0100
- Garcia Emma, Ruiz-Barbadillo Emiliano, and Martínez-Ferrero Jennifer. (2024): HIGH-QUALITY ASSURANCE, ESG LEGITIMACY THREATS AND BOARD EFFECTIVENESS. *The British Accounting Review*, 2024, 101385. DOI: 10.1016/j.bar.2024.101385
- Heidi Vander Bauwhede, and Philippe Van Cauwenberge. (2022): Determinants and Value Relevance of Voluntary Assurance of Sustainability Reports in a Mandatory Reporting Context: Evidence from Europe. *Sustainability* 14(15):9795. DOI: 10.3390/su14159795
- Joanna Krasodomska, E. Zarzycka, Donna L. Street, and Wojciech Grabowski. (2025): The Impact of Companies' Trust Building Efforts on Sustainability Reporting Assurance Quality: Insights from Europe. *Meditari Accountancy Research*, 33(7):246-279. DOI: 10.1108/MEDAR-05-2024-2496
- Mion G, Aduai CRL (2019) Mandatory Nonfinancial Disclosure and Its Consequences on the Sustainability Reporting Quality of Italian and German Companies. *Sustainability*. <https://doi.org/10.3390/SU11174612>
- Muhammad Arif, C. Gan, and Muhammad Nadeem. (2021): Regulating Non-Financial Reporting: Evidence from European Firms' Environmental, Social and Governance Disclosures and Earnings Risk. *Meditari Accountancy Research*. DOI: 10.1108/MEDAR-11-2020-1086
- Oana-Marina Radu, V. Dragomir, and Ningshan Hao. (2023): Company-Level Factors of Non-Financial Reporting Quality Under a Mandatory Regime: A Systematic Review of Empirical Evidence in the European Union. *Sustainability*, 15(23):16265. DOI: 10.3390/su152316265
- Papa M, Wieczorek-Kosmala M, Losa A, Swątek A (2024) The Impact of ESG Regulation on Environmental Decoupling—An Exploratory Study on Polish Listed Companies. *Sustainability*. <https://doi.org/10.3390/su16177309>
- Ottenstein P., Saskia Erben, S. Jost, Carl William Weuster, and Henning Zülch. (2021): From Voluntarism to Regulation: Effects of Directive 2014/95/EU on Sustainability Reporting in the

EU. *Journal of Applied Accounting Research*, 2022, 23 (1): 55-98. DOI: 10.1108/JAAR-03-2021-0075

Posadas SC, Ruiz-Blanco S, Fernandez-Feijoo B, Tarquinio L (2023) Institutional isomorphism under the test of Non-financial Reporting Directive. Evidence from Italy and Spain. *Meditari Accountancy Research*. <https://doi.org/10.1108/medar-02-2022-1606>

Raimo N, L'Abate V, Sica D, Vitolla F (2025) Integrated reporting and the Corporate Sustainability Reporting Directive: bridging the gap or growing apart? *Management Decision*. <https://doi.org/10.1108/md-10-2024-2408>

Rezaee Z, Homayoun S, Rezaee NJ, Poursoleyman E (2022) Environmental, Social, and Governance Sustainability Disclosures: Evidence from EU and Us. *Social Science Research Network*. <https://doi.org/10.2139/ssrn.4106915>

Salim Chouaibi, Yamina Chouaibi, and Ghazi Zouari. (2021): Board Characteristics and Integrated Reporting Quality: Evidence from ESG European Companies. *EuroMed Journal of Business*, 1450-2194. DOI: 10.1108/EMJB-11-2020-0121

Sedlák J, Veber J (2024) Quality of non-financial information in the context of Corporate Sustainability Reporting Directive (CSRD). *Entrepreneurship and Sustainability Issues*. <https://doi.org/10.9770/c5723389853>

Sklavos G, Zournatzidou G, Ragazou K, Sariannidis N (2025) Unmasking Greenwashing in Finance: A PROMETHEE II-Based Evaluation of ESG Disclosure and Green Accounting Alignment. *Risks*. <https://doi.org/10.3390/risks13070134>

AZ ALKOHOLHASZNÁLATHOZ KÖTHETŐ TÁRSADALMI KÖLTSÉG ÉS A KORAI BEAVATKOZÁS TÁRSADALMI OPCIOÉRTÉKE: REÁLOPCIÓS MEGKÖZELÍTÉS NEMZETKÖZI ADATOKON

CSAPI Patrik

Pécsi Tudományegyetem Gazdálkodástani Doktori Iskola
csapi.patrik@ktk.pte.hu

<https://doi.org/10.15170/XVIIPPN-Tk-KTK-2026-04>

Absztrakt

A tanulmány az alkoholhasználathoz köthető társadalmi költség és a prevenciós, illetve kezelési beruházások társadalmi értékének kérdését vizsgálja nemzetközi összehasonlító, reálopciós keretben. A cikk fő hozzájárulása kettős. Egyrészt elkülönítetten becsli a közvetlen egészségügyi költséget, a termelékenységek-ekvivalens veszteséget és a teljes monetizált társadalmi terhet. Másrészt a statikus költségbecslést reálopciós döntési logikával kapcsolja össze, és azt kérdezi, hogy bizonytalan jövőbeli alkoholteher mellett mikor indokolt az azonnali beavatkozás, illetve mikor van értéke a kivárásnak. Emellett röviden kijelöli azokat a pontokat, ahol a keret a későbbiekben AI-alapú előrejelzéssel, korai kockázatészleléssel és adaptív monitorozással bővíthető. Az empirikus adatbázis két adatblokkra épül. Az első egy 2000–2022 közötti panel, összesen 4 349 ország–év megfigyeléssel; ezt a fiskális dinamika vizsgálatára használom. A második egy 2019-es, 179 országot lefedő keresztmetszet, amely a teherszint és a strukturális együttjárások becslésének alapja. A tanulmány tehát nem a két minta közvetlen összevetésére, hanem egymást kiegészítő elemzési szintekre épül. A források a WHO Global Health Observatory alkoholfogyasztási, alkohol-attributable egészségteher- és szolgáltatáskapacitási adatai, a szerhasználati zavarok szolgáltatási kapacitását mérő Substance Use Disorder Service Capacity Index (SCI-SUD), a WHO Global Health Expenditure Database egészségkiadási sorai, valamint a Világbank makromutatói. A 2019-es mintában a becsült közvetlen egészségügyi költség 491,8 milliárd USD, a termelékenységek-ekvivalens veszteség 1,465 billió USD, a teljes társadalmi teher pedig 1,955 billió USD. A GDP-vel súlyozott átlagos teher 2,25% GDP, a medián országteher 1,85% GDP. A régiófixhatásos keresztmetszeti modellek szerint az egy főre jutó alkoholfogyasztás szignifikánsan és pozitívan kapcsolódik a teljes társadalmi teherhez, míg a SCI-SUD a termelékenységi veszteségben és a teljes teherben negatív előjelű együttjárást mutat. A panel fixhatásos becslések szerint a két évvel késleltetett alkoholfogyasztás pozitív kapcsolatban áll a közösségi egészségügyi kiadásokkal. A reálopciós blokk konzervatív kalibrációja alapján 10%-os éves tehercsökkentés mellett a medián országban 234,5 USD/fő az azonnal

vállalható egyszeri beavatkozási költség felső határa. A tanulmány fő következtetése, hogy az addiktív beavatkozásokat nem célszerű pusztán költségvetési teherként kezelni: azok rugalmas társadalmi beruházások, amelyeknek kimutatható opcióértékük van, és amelyek később adatvezérelt előrejelzési réteggel tovább erősíthetők.

Kulcsszavak: alkohol, társadalmi költség, reálopciók, társadalmi értékteremtés, korai beavatkozás, egészségfinanszírozás

JEL-kódok: G31, H51, I12, I18

1. Bevezetés

Az alkohol társadalmi és gazdasági terhe nem pusztán egészségpolitikai kérdés, hanem a termelékenység, a közpénzügyek és a társadalmi jólét egyszerre érintő közpolitikai probléma. A WHO szerint 2019-ben világszerte 2,6 millió haláleset volt alkoholnak tulajdonítható, és azokban az országokban, ahol rendelkezésre áll adat, az alkoholhasználati zavarban érintettek kezelésbe jutása továbbra is rendkívül alacsony: a kontakt-lefedettség jellemzően 1% alatti szintekről indul, és nem haladja meg a 14%-ot (World Health Organization [WHO], 2024b; WHO, n.d.-c).

A függőségek közgazdasági irodalma gazdag a társadalmi költségszámításokban és a költséghatékonysági értékelésekben, de ezek jelentős része statikus logikát követ. A szokásos kérdés az, hogy mekkora a teher, illetve melyik beavatkozás költséghatékony; jóval ritkább az a megközelítés, amely azt vizsgálja, hogy bizonytalan jövőbeli teher és részleges információ mellett mikor optimális a beruházás időzítése (Single et al., 2003; Verhaeghe et al., 2017; Manthey et al., 2021). Jelen cikk azt az állítást teszi vizsgálat tárgyává, hogy a prevenció és kezelési beruházások nem egyszerűen költségvetési tételek, hanem rugalmas társadalmi beruházások. E beruházások értéke nemcsak a várható megtakarítás nagyságától, hanem a jövőbeli alkoholteher bizonytalanságától, a döntés halasztásának költségétől és a szolgáltatási kapacitás kiépítésének részleges visszafordíthatatlanságától is függ. Ebben az értelemben a társadalmi költség és a társadalmi értékteremtés kérdése közvetlenül összekapcsolható a reálopciók szemlélettel (Myers, 1977; Dixit & Pindyck, 1994).

A tanulmány öt hozzájárulást kíván adni. Először, a nemzetközi összehasonlításban is használható, komponensekre bontott társadalmi tehermutatót képez az alkoholhoz köthető egészségteherből, az egészségügyi kiadásokból és a makrogazdasági kontrollokból. Másodszor, a társadalmi költséget nem egyetlen összetett indexként, hanem közvetlen egészségügyi költségként, termelékenység-ekvivalens veszteségként és teljes monetizált teherként modellezi. Harmadszor, paneladatokon vizsgálja, hogy az alkoholfogyasztás növekedése késleltetetten megjelenik-e a közösségi egészségügyi kiadásokban. Negyedszer, reálopciók küszöbértékeket ad arra, hogy az egyes országokban mekkora egyszeri költségig lehet racionális az azonnali beavatkozás. Ötödször, nem önálló empirikus blokkként, hanem jövőbeli bővítési irányként kijelöli, hogy az AI milyen pontokon kapcsolható a társadalmi

költség és a reálopciók értékelés összekapcsolásához: az ex ante teherelőrejelzésben, a korai kockázateszlelésben és az adaptív monitorozásban.

Az empirikus alkalmazás az alkoholt mint esettanulmányt választja, mert ehhez a függőségi területhez áll rendelkezésre a legszélesebb, országok között legjobban harmonizált nyilvános adatbázis a WHO rendszereiben. A választás ugyanakkor nem szűkíti le a tanulmányt kizárólag az alkoholra: a felépített keret elvileg más addiktív kórképekre vagy többes függőségi portfóliókra is kiterjeszhető, amennyiben a teher- és költségadatok összeilleszthetők.

Korábbi munkám szélesebb, összehasonlító nézőpontból arra mutatott rá, hogy a modern addiktív magatartások földrajzi és gazdasági mintázatait nem kizárólag egészségügyi tényezők, hanem a turizmushoz kapcsolódó mobilitási és fogyasztási környezetek is alakíthatják (Csapi, 2026). Ezzel összhangban a jelen tanulmány az alkoholt mint a legjobban harmonizált nemzetközi esettanulmányt vizsgálja, de a felépített keret a turizmus és addikció kapcsolatának társadalmi költségoldali továbbgondolására is alkalmas. A turizmus fenntarthatósági irodalmában az ESG-keret egyre hangsúlyosabb (Putzer & Posza, 2024), ezért az alkoholhoz kötődő társadalmi költség a társadalmi („S”) dimenzió egyik releváns externáliájaként is értelmezhető.

Kutatási kérdések

A tanulmányban az alábbi kutatási kérdéseket vizsgáltam:

K1. Mekkora az alkoholhasználathoz köthető társadalmi költség a vizsgált országhoz, és hogyan oszlik meg a közvetlen egészségügyi költség, a termelékenység-ekvivalens veszteség és a teljes monetizált teher között?

K2. Hogyan kapcsolódik az alkoholfogyasztás és a szolgáltatási kapacitás a társadalmi költség egyes komponenseihez nemzetközi összehasonlításban?

K3. Megjelenik-e az alkoholfogyasztás hatása késleltetetten a közösségi egészségügyi kiadásokban?

K4. Kimutatható-e pozitív társadalmi opcióértéke a korai prevenciók és kezelési beavatkozásoknak?

K5. Milyen pontokon bővíthető a társadalmi költség és a reálopciók döntéstámogatás kerete AI-alapú előrejelzési és monitorozási elemekkel, és ezek közül melyik illeszkedik legerősebben a jelen adatszerkezethez?

2. Függőség, társadalmi költség és társadalmi értékteremtés

A társadalmi költség számítás klasszikus kiindulópontja a költségbetegség- vagy cost-of-illness logika, amely a szerhasználathoz köthető közvetlen, közvetett és – egyes változatokban – immateriális veszteségeket próbálja pénzben kifejezni. A WHO nemzetközi irányelvei hangsúlyozzák, hogy a társadalmi költségbecslés nem azonos az elkerülhető költség becslésével: az előbbi az adott időpontban megfigyelhető összes terhet számszerűsíti, az utóbbi pedig azt a részt, amely valamilyen reálisan elérhető intervenció révén ténylegesen megtakarítható lenne (Single et al., 2003).

A társadalmi költségre vonatkozó becslések heterogenitása jelentős. A módszertani eltérések az incidencia- vagy prevalenciaalapú megközelítés, az emberitőke- és súrlódási költségmódszer, az attribúciós eljárások, valamint az egyes költségkomponensek eltérő bevonása miatt nagy szórást eredményeznek (Verhaeghe et al., 2017). Az alkohol gazdasági terhet vizsgáló szisztematikus áttekintés szerint a nemzeti becslések 0,45% és 5,44% GDP közötti sávban mozogtak, ami egyszerre jelzi a probléma súlyát és a módszertani érzékenységet (Thavorncharoensap et al., 2009).

A frissebb szisztematikus modellező irodalom ennél is erősebb képet ad. Manthey és szerzőtársai (2021) 29 tanulmány alapján arra jutnak, hogy a megfigyelt átlagos alkoholköltség a GDP 1,5%-a körül volt, de a hiányzó költségkomponensek modellezett korrekciójával a becsült teher 2,6% GDP-re nőtt. Ugyanez a tanulmány arra is rámutat, hogy a költségek összetételében a termelékenységi veszteségek dominálnak: az igazított becslésekben a közvetlen költségek részaránya 38,8%, a termelékenységi veszteségeké 61,2%.

Az alkoholverhelés nagyságát a betegségteher-irodalom is megerősíti. Rehm és szerzőtársai (2009) a globális betegségteher és a gazdasági költség összekapcsolását sürgetik, míg a GBD 2016 elemzése szerint az alkohol az egyik legjelentősebb kockázati tényező marad, és a szerhasználati zavarok között az alkoholhasználati zavar a legnagyobb prevalenciájú forma (GBD 2016 Alcohol and Drug Use Collaborators, 2018). A WHO 2024-es globális jelentése és a kapcsolódó ténylapok azt is hangsúlyozzák, hogy a kezeléshez való hozzáférés és az ellátórendszeri kapacitás világszerte elégtelen (WHO, 2024a; WHO, 2024b).

A társadalmi költség azonban önmagában még nem mondja meg, hogy egy közpolitikai beavatkozás mikor és milyen formában teremt értéket. A public value irodalom szerint a közszféra értékteremtése nem merül ki a piaci kudarcok passzív korrekciójában: a közintézmények aktív iránykijelölő, koordináló és kapacitásépítő szerepet játszhatnak a társadalmi célok elérésében (Moore, 1995; Stoker, 2006; Mazzucato & Ryan-Collins, 2022). Addikciós kontextusban ez azt jelenti, hogy a prevenció, a korai felismerés, a kezeléshez jutás és a szabályozási beavatkozások nemcsak egészségnyereséget hoznak, hanem fiskális, munkaerőpiaci és közösségi értéket is teremtenek.

Az alkoholkontroll-irodalom erős alapot ad ahhoz, hogy a beavatkozásokat értékteremtő beruházásként kezeljük. A rendelkezésre álló bizonyítékok szerint a rendelkezésre állás korlátozása, az ár- és adópolitika, a marketing-szabályozás, a rövid intervenciók és egyes kezelési formák egyaránt hatékonyak és gyakran költséghatékonyak az alkoholhoz köthető károk mérséklésében (Anderson et al., 2009; Burton et al., 2017; WHO, 2019). A meglévő irodalomból ugyanakkor kevésbé látszik, hogyan kellene ezeket a programokat akkor értékelni, amikor a jövőbeli teher nagysága, a program hatékonysága és a költségpálya bizonytalan.

A tanulmány éppen ezen a ponton kapcsolja össze a társadalmi költség és a társadalmi értékteremtés irodalmát. Kiindulópontja az, hogy a mérhető társadalmi teher nem végpont, hanem a potenciális közérték egyik inputja: az elkerülhető teher

egy része jövőbeli haszonáramként, a közpolitikai beavatkozás pedig részben visszafordíthatatlan beruházásként fogható fel.

Lehetséges AI-bővítések a függőségi kockázatbecslésben és döntéstámogatásban

Az AI-kapcsolat a jelen tanulmányban nem a fő empirikus azonosítás helyét veszi át, hanem lehetséges módszertani bővítésként jelenik meg. Az egészségügyi AI-irodalom szerint a gépi tanulás különösen erős ott, ahol nagyméretű, heterogén adatforrásokból kell kockázatot becsülni, jövőbeli eseményeket előrejelezni és döntéstámogatást adni; ugyanakkor a klinikai és közpolitikai alkalmazásokban a validitás, az interpretálhatóság és az emberi felügyelet kulcskérdés marad (Rajkomar et al., 2019; Topol, 2019). Az addikciókutatás szisztematikus áttekintése szintén arra jut, hogy a supervised learning módszerek egyre inkább a kockázatbecslés, az orvosi döntéstámogatás és az intervenciók célzása felé tolódnak (Mak et al., 2019). A jelen cikkben ezek az eredmények ezért nem önálló bizonyítási pillért, hanem a későbbi továbbépítés egyik irányát jelentik.

Az alkoholspecifikus bizonyítékok ezt a képet erősítik. Ebrahimi és szerzőtársai (2023) gépi tanulásra épülő klinikai döntéstámogató rendszert fejlesztettek az alkoholhasználati zavar korai felismerésére; To és szerzőtársai (2020) természetesnyelv-feldolgozással és felügyelt tanulóval validáltak alkoholmisuse-osztályozót kórházi betegek körében; Roberts és szerzőtársai (2022) pedig azt mutatták meg, hogy rutinszerű klinikai adatokból gépi tanulóval előrejelezhető a kezelés alatti heavy drinking. A személyes szenzorokra és digitális nyomokra épülő monitoring irodalma is releváns: Mohr és szerzőtársai (2017) a personal sensing-et a mentális egészség következő generációs monitoringeszközeként írják le, Wyant és szerzőtársai (2023) pedig azt találták, hogy az aktív és passzív szenzor alapú adatgyűjtés elfogadható az alkoholhasználati zavarban érintett résztvevők körében. Ugyanakkor nem minden AI-kapcsolódás egyformán erős. A generatív AI és az LLM-ek mentális egészségügyi alkalmazásairól készült szisztematikus áttekintés szerint ez a terület gyorsan bővül, de még korai szakaszban van, és jelentős biztonsági, etikai és transzparenciabeli kockázatokkal terhelt (Kolding et al., 2024). A WHO AI-egészségügyi iránymutatásai is azt hangsúlyozzák, hogy a közérdeket szolgáló AI-alkalmazásoknál az etika, a szabályozás, az adatminőség és az emberi elszámoltathatóság nem kerülhető meg (WHO, 2021, 2023). Ezért a jelen tanulmányban az AI-t nem önálló helyettesítő módszertanként, hanem a társadalmi költségbecslést és a reálopciók döntéstámogatást bővítő előrejelzési és célzási réteggé értelmezem.

3. Reálopciók megközelítés közpolitikai és egészségberuházási döntésekben

A hagyományos értékelés diszkontált pénzáram-alapú megközelítése olyan kiindulópontként értelmezhető, amely a várható jövőbeli haszonáramok jelenértékét ragadja meg. Önmagában ugyanakkor korlátozottan alkalmas annak megragadására, hogy a döntéshozó bizonytalan környezetben halaszthatja, szakaszolhatja, bővítheti vagy módosíthatja a beruházási döntést. A reálopciók értékelés ezért nem a DCF-logika elvetéseként, hanem annak módszertani kiterjesztéseként értelmezhető, mivel a döntési flexibilitás és az időzítés értékét is beépíti az értékelési keretbe (Ulbert et

al., 2017). A reálopció-szemlélet abból indul ki, hogy a bizonytalanság, a döntések visszafordíthatatlansága és az időzítés lehetősége együtt önálló gazdasági értéket hoznak létre. Myers (1977) nyomán a reálopciók logikája azt hangsúlyozza, hogy a beruházási projektek értéke nem kizárólag a standard nettó jelenértéktől függ; a jövőben gyakorolható, módosítható vagy elhalasztható döntési lehetőségek önmagukban is értéket hordoznak. Dixit és Pindyck (1994) ezt általános beruházáseleméleti keretben formalizálják: ha a beruházás részben irreverzibilis, a kimenetek bizonytalanok, és a döntéshozó várhat új információra, akkor a kivárásnak opcióértéke keletkezik. A hazai szakirodalomban Csapi (2018) részletesen áttekinti a reálopció-elmélet első négy évtizedének stratégiai és beruházásértékelési tanulságait.

Az egészségügyi beruházások világában ez a logika különösen releváns. A technológiák, kapacitások és szervezeti innovációk esetében gyakori, hogy a bevezetés jelentős fix költségekkel jár, miközben a hasznok időben szóródnak, a bizonytalanság nagy, és a visszafordítás költséges. A real-options irodalom az egészség-gazdaságtanban ezért elsősorban azt vizsgálta, hogy mikor érdemes egy új technológiát azonnal bevezetni, mikor célszerű előbb több bizonyítékot gyűjteni, és mikor optimális az adaptációt szakaszolni (Grutters et al., 2011; Dreyfuss & Roberts, 2011). A digitális és Healthcare 4.0 beruházásokat vizsgáló újabb áttekintések ugyanezt a dilemmát mutatják meg intézményi szinten (Vassolo et al., 2021).

Az addikciós közpolitikában a reálopció-s logika különösen indokolt, mert a döntés tárgya tipikusan nem egyetlen homogén projekt. A prevenció-s kampányok, a primer ellátásba épített szűrés, a terápiás kapacitás bővítése, a digitális utánkövetés vagy a szabályozási eszközök kombinációi különböző fix költséggel, eltérő visszafordíthatatlansággal és más-más hatásidővel járnak. A várható társadalmi haszon emellett függ az alkoholteher jövőbeli alakulásától, a lakossági magatartástól, a szolgáltatásminőségtől és a makrogazdasági környezettől.

A jelen cikk a reálopció-s keretet nem mikroszintű technológiaértékelésre, hanem makroszintű társadalmi beruházási küszöbök meghatározására használja. A becsült társadalmi teher egy részét potenciálisan elkerülhető éves haszonáramnak tekinti, majd azt vizsgálja, hogy ennek jelenértéke és opcióértéke mellett mekkora egyszeri beruházási költségig indokolt az azonnali beavatkozás. Ez a megoldás nem helyettesíti az egyes programok részletes költség-haszon elemzését, de transzparens benchmarkot ad a döntéshozó számára.

Lehetséges AI-bővítések a reálopció-s keretben

A reálopció-s modell szempontjából az AI három ponton lehet releváns. Elsőként a várható haszonáram nagyságát befolyásolhatja: ha ország- vagy intézményszinten gépi tanulás alapú modellek pontosabban jelzik előre az alkoholfogyasztás, az alkohol-attributable teher vagy a fiskális következmények pályáját, akkor a V_i projektérték ex ante becslése informatívabbá válhat (Rajkomar et al., 2019; Mak et al., 2019). Másodikként az AI a beavatkozás várható hatékonyságát javíthatja, ha korábbi felismerést, jobb célzást és személyre szabottabb utánkövetést tesz lehetővé az alkoholhasználati zavar (alcohol use disorder, AUD) szűrésében és kezelésében

(Ebrahimi et al., 2023; Roberts et al., 2022). Harmadikként a személyes szenzorokra, NLP-re vagy digitális fenotipizálásra épülő rendszerek csökkenthetik a késleltetett észlelésből fakadó bizonytalanságot, ami közvetlenül érinti a kivárási opcióértékét (Mohr et al., 2017; To et al., 2020; Wyant et al., 2023). A reálopciók logika és a mesterséges intelligencia összekapcsolására a hazai szakirodalomban is található friss példa: Csapi és Sárícs (2026) nagy bizonytalanságú beruházási környezetben tárgyalják a két megközelítés integrációját.

Ebből következik, hogy a jelen cikkhez három AI-megközelítés kapcsolható, de ezek közül egyik sem a fő empirikus eredmények helyettesítője. Az első és a jelen adatbázishoz legerősebben illeszkedő megoldás az ország-szintű teher- és volatilitás-előrejelzés, amely a WHO- és Világbank-panelből képezne előrejelző modellt a reálopciók paraméterekhez. A második megoldás a klinikai vagy adminisztratív mikroadatokra épülő korai észlelés és kezeléscélzás, amely a beavatkozás hatékonysági paraméterét javíthatná. A harmadik, óvatosabban kezelendő irány a generatív AI és az LLM-ek használata szakpolitikai szcenáriók szintetizálására vagy döntéshozó tudásmenedzsmentre; ezt a jelen tanulmány csak kiegészítő, nem pedig elsődleges azonosítási vagy előrejelzési eszközként tekinti (Kolding et al., 2024; WHO, 2021, 2023).

4. Adatok és változók

Az empirikus adatbázis öt forrásból épül fel: a WHO Global Health Observatory (GHO) alkoholfogyasztási mutatóiból, a WHO GHO alkohol-attributable egészségteher-mutatóiból, a WHO GHO szerhasználati zavarokra vonatkozó szolgáltatási kapacitási adataiból – köztük a Substance Use Disorder Service Capacity Index (SCI-SUD) mutatóból –, a WHO Global Health Expenditure Database (GHED) egészségkiadási soraiból, valamint a Világbank World Development Indicators (WDI) adatbázisából (WHO, n.d.-a, n.d.-b, n.d.-c, n.d.-d; World Bank, n.d.).

A paneladatbázis 2000 és 2022 közötti időszakot fed le, összesen 4 349 ország-év megfigyeléssel és 193 országgal. Ezt a blokkot elsősorban a fiskális dinamika vizsgálatára használom. A társadalmi teher komponenseinek becslése egy 2019-es keresztmetszetre épül, mert ebben az évben a teher-, fogyasztás-, kiadási és makrokontroll-változók együttes lefedettsége a legjobb. A teljes társadalmi teher számításához 179 országban állt rendelkezésre minden szükséges változó. A két adatblokk tehát eltérő módszertani szerepet tölt be: a 2019-es keresztmetszet a szintkülönbségek és az együttjárások vizsgálatára, a 2000–2022-es panel pedig az időbeli fiskális dinamika becslésére szolgál; a tanulmány nem a kettő közvetlen összehasonlítására épül.

Az alkoholhasználati zavar kezelésének kontakt-lefedettségi mutatója a rendelkezésre álló állományban mindössze 17 ország esetében volt elérhető, döntően 2016-os referenciaévvvel, miközben a teljes társadalmi teher fő keresztmetszeti mintája 179 országot, a SCI-SUD szolgáltatási kapacitási index pedig 191 országot fed le (WHO, n.d.-c). Emiatt a kontakt-lefedettségi változót nem építem be a fő regressziós specifikációkba, mert az a minta drasztikus szűkülésével, a nemzetközi összehasonlíthatóság romlásával és a becslések instabilitásával járna. A fő modellekben ezért a szélesebb lefedettségű SCI-SUD indexet használom az

ellátórendszeri kapacitás proxyjaként, míg a kontakt-lefedettséget külön, feltáró jellegű almintás vizsgálatban kezelem. Ez a megoldás lehetővé teszi, hogy a cikk fő eredményei a lehető legszélesebb országmintán maradjanak érvényesek, miközben a kezelésbe jutás közvetlenebb mutatója sem vész el teljesen az elemzésből.

A változótérkép 1. táblázata a fő adatblokkokat foglalja össze. A leíró statisztikák alapján az egy főre jutó alkoholfogyasztás átlaga 5,41 liter, mediánja 4,93 liter volt a keresztmetszetben. Az alkohol-attributable DALY-ráta mediánja 1 477,86 / 100 000 fő, a SCI-SUD szolgáltatási kapacitási index mediánja 31,15 pont. A becsült teljes társadalmi teher mediánja 107,05 USD/fő, illetve 1,85% GDP.

1. táblázat: A felhasznált fő adatblokkok és változók

Blokk	Fő változó(k)	Képzés / definíció	Időszak	Forrás
Expozíció	Összes, regisztrált és nem regisztrált alkoholfogyasztás / fő	A WHO GHO „levels of consumption” mutatói, ország-év szinten	2000–2022	WHO GHO
Egészségteher	Alkohol-attributable DALY-ráta, DALY-szám, DALY-résarány, halálozás	A WHO GHO „harms and consequences” mutatói; 2019-es keresztmetszethez és panel-kontrollokhoz	2019 (plusz panel-kontrollok)	WHO GHO
Ellátórendszer	SCI-SUD; alkoholhasználati zavar kezelésének kontakt-lefedettsége	A WHO GHO szolgáltatási kapacitási indexe; a lefedettségi változó csak korlátozottan elérhető	2015–2019, erősen hiányos	WHO GHO
Egészségfinanszírozás	Jelenlegi és közösségi egészségügyi kiadás / fő	WHO GHED; USD/fő mutatók teljes nemzetközi összehasonlíthatósággal	2000–2022	WHO GHED
Makrokontrollok	GDP / fő, népesség, munkanélküliség, munkaerő-állomány	World Bank WDI mutatók a makrogazdasági kontrollhoz	2000–2022	World Bank WDI

Forrás: saját összeállítás a WHO és a Világbank nyers adatállományai alapján.

2. táblázat: Fő leíró statisztikák a 2019-es keresztmetszetben

Változó	Átlag	Medián	N
Alkoholfogyasztás összesen (liter/fő, 15+)	5.41	4.93	186
Alkohol-attributable DALY / 100 000	1698.41	1477.86	181
Alkohol-attributable DALY-résarány (%)	5.03	4.80	179
SCI-SUD szolgáltatási kapacitási index	34.44	31.15	191
Jelenlegi egészségügyi kiadás / fő (USD)	1190.49	372.06	193
Közvetlen egészségügyi költség / fő (USD, becsült)	65.29	14.83	179
Termelékenységi veszteség / fő (USD, becsült)	234.81	82.28	181
Teljes társadalmi teher / fő (USD, becsült)	300.54	107.05	179
Teljes társadalmi teher (% GDP, becsült)	2.05	1.85	179

Forrás: saját számítás a feltöltött adatállományok alapján.

5. Empirikus stratégia

A K2–K4 kutatási kérdések kvantitatív vizsgálata során arra számítok, hogy a magasabb egy főre jutó alkoholfogyasztás nagyobb társadalmi teherrel jár együtt; a magasabb szolgáltatási kapacitás alacsonyabb termelékenység-ekvivalens veszteséggel társul; az alkoholfogyasztás hatása késleltetetten jelenik meg a közösségi egészségügyi kiadásokban; valamint a nagyobb monetizált teher magasabb azonnali beavatkozási küszöböt implikál.

A kutatás iránya abban áll, hogy nem egyetlen összetett költségindexet képez, hanem három elkülönített kimenetet becsül. Ez javítja az értelmezhetőséget, és összhangba hozza a konstrukciót a társadalmi költség irodalmának közvetlen–közvetett felosztásával (Single et al., 2003; Verhaeghe et al., 2017).

A jelen empirikus verzióban az AI-kapcsolódás nem abban áll, hogy a fő becsléseket gépi tanulási modellek végzik el. Ellenkezőleg: a regressziós és reálopció alapmodell tudatosan transzparens referencia-modell. Az AI-funkció a keret lehetséges későbbi bővítésének helye, ahol az előrejelzett teherpálya, a volatilitás és a heterogén beavatkozási hatékonyság gépi tanulási modellekből frissíthető. Ez a megoldás összhangban áll azzal a nemzetközi ajánlással, hogy az egészségügyi AI bevezetését jól ellenőrizhető, validálható és elszámoltatható döntéstámogató munkafolyamatokba célszerű illeszteni (WHO, 2021, 2023). A tanulmányban közölt regressziós, korrelációs és reálopció eredmények nem illusztratív példák, hanem a leírt adatösszeillesztésen és specifikációkon alapuló saját számítások; ezek reprodukálhatóságát a következő verzióban célszerű külön mellékletben dokumentálni a mintaszűrések, változóképzések és becslési beállítások szintjén.

A közvetlen egészségügyi költség proxyja a teljes jelenlegi egészségügyi kiadás alkoholteherrel súlyozott része. Formálisan:

$$DHC_i = CHE_i \times AADALYshare_i$$

ahol DHC_i az i ország becsült közvetlen egészségügyi költsége, CHE_i a jelenlegi egészségügyi kiadás, $AADALYshare_i$ pedig az alkohol-attributable DALY-résarány. Ez a mutató nem számlalapú mikro-költség, hanem teherarányos allokációs közelítés: azt feltételezi, hogy részletes diagnózisszintű költségadatok hiányában az egészségügyi erőforrás-felhasználás az alkoholhoz köthető betegségteherrel arányosan imputálható.

A termelékenység-ekvivalens veszteség proxyja az alkohol-attributable DALY-veszteség pénzben kifejezett, output-alapú árnyékára:

$$PEL_i = DALY_i \times GDPpc_i$$

ahol $DALY_i$ az alkoholnak tulajdonítható DALY-k száma, $GDPpc_i$ pedig az egy főre jutó GDP. A mutató nem szűk humántőke-becslés, hanem egy egészséges életévekhez rendelt átlagos kibocsátási érték. Ez lefelé torzíthatja a magas bérelszórású gazdaságok egyéni veszteségeit, ugyanakkor felfelé torzíthatja a nem foglalkoztatott népességre vetítve; ezért a mérőszámot tudatosan termelékenység-ekvivalens veszteséggé, nem pedig tényleges keresetveszteséggé értelmezem.

A teljes monetizált társadalmi teher a két komponens összege:

$$TSB_i = DHC_i + PEL_i$$

A keresztmetszeti elemzésben a függő változókat GDP-arányos formában, logaritmikus transzformáció után becsülöm. A fő specifikáció régiófixhatásokat és HC3-robosztus szóráshibákat használ:

$$\ln(CostPctGDP_i) = \alpha + \beta_1 \ln(1 + Alcohol_i) + \beta_2 \ln(SCI_i) + \beta_3 Unemp_i + \theta_r + \varepsilon_i$$

ahol a $CostPctGDP_i$ felváltva a közvetlen egészségügyi költség, a termelékenység-ekvivalens veszteség és a teljes társadalmi teher GDP-arányos mutatója. Alternatív specifikációban a fogyasztási változót az alkoholhasználati zavar 12 havi prevalenciájával helyettesítem.

A fiskális dinamika vizsgálatához ország- és évfíxhatásos panelregressziót becsülök, ország szerint klaszterezett szóráshibákkal:

$$\ln(Exp_{pc_it}) = \alpha_i + \lambda_t + \beta \ln(1 + Alcohol_{\{i,t-k\}}) + \gamma \ln(GDPpc_it) + \delta Unemp_it + \varepsilon_{it}$$

ahol Exp_{pc_it} felváltva a közösségi egészségügyi kiadás/fő és a jelenlegi egészségügyi kiadás/fő; $k = 0, 1, 2$ késleltetés. A késleltetés azért fontos, mert az alkoholfogyasztás egészségügyi és fiskális hatása gyakran nem azonnal, hanem több időszakon keresztül jelentkezik.

A reálopciók blokkban az éves elkerülhető haszonáramot az $e \times TSB_{pc,i}$ alakban definiálom, ahol e a beavatkozás éves hatékonysága. A scenáriókban $e = 5\%, 10\%$ és 20% . Az éves haszonáram örökjáradék-jelenértéke:

$$V_i(e) = (e \times TSB_{pc,i}) / r$$

ahol $r = 3\%$ társadalmi diszkontráta. Az időzítési opció miatt az azonnali beruházási küszöb ennél alacsonyabb, és a standard perpetuális reálopciók összefüggésből adódik:

$$I_i^* = ((\beta_i - 1) / \beta_i) \times V_i(e)$$

A β_i paraméter a stochasztikus folyamat pozitív gyökéből származik. A bizonytalanságot a 2000–2019 közötti alkoholfogyasztási logváltozások országos volatilitásából becsülöm; a túl alacsony szórás elkerülésére 5%-os volatilitási alsó korlátot, a driftre pedig $\pm 1\%$ -os csonkolást alkalmazok. Ez konzervatív kalibrációnak tekinthető, mert növeli a kivárási opcióértékét, és így magasabb mércét állít az azonnali beavatkozás elé.

Az empirikus stratégia ezért nem kezelés-specifikus oksági hatást azonosít, hanem makroszintű beruházási benchmarkot ad. A fő kérdés nem az, hogy egy konkrét program minden országban biztosan megtérül-e, hanem az, hogy a becsült társadalmi teher és a megfigyelhető bizonytalanság mellett mekkora beruházási nagyságrend mellett válik racionálissá az azonnali cselekvés.

Kiegészítő feltáró elemzés a kezelési lefedettségű almintán

A kontakt-lefedettségű változó korlátozott elérhetősége miatt ezt a mutatót nem a fő modellekben, hanem egy külön, kiegészítő feltáró elemzésben vizsgálom (WHO, n.d.-c). Ennek célja nem a fő regressziós eredmények egy szűk és szelektált almintán való újrabecslése, hanem annak feltárása, hogy a kezelésbe jutás közvetlenebb mutatója milyen irányú kapcsolatot jelez a szolgáltatási kapacitással és a becsült társadalmi teherrel.

Az almintás elemzés három lépésből áll. Először leíró módon összehasonlítom a kontakt-lefedettségű rendelkező országokat a teljes mintával. Másodszor ábrás

formában szemléltetem a kontakt-lefedettség és a teljes társadalmi teher, illetve a kontakt-lefedettség és a SCI-SUD index kapcsolatát. Harmadszor egyszerű Spearman-rangkorrelációval és visszafogott bivariáns log-log specifikációval ellenőrzöm, hogy az együttjárások iránya összhangban van-e a szélesebb mintán kapott eredményekkel.


Az így kapott eredményeket óvatosan kell értelmezni. A kis elemszám, a hiányzó országok nagy száma és az eltérő adatfelvételi évek miatt ez a blokk nem alkalmas erős oksági állítások megfogalmazására. Értéke inkább abban áll, hogy megmutatja: a kezelésbe jutás közvetlenebb mutatója a szélesebb mintán használt kapacitási proxyval azonos irányú vagy attól eltérő mintázatot jelez-e. Ha az együttjárások iránya hasonló, az erősíti a SCI-SUD index fő modellekben való használatának megalapozottságát; ha pedig eltérés mutatkozik, az arra hívja fel a figyelmet, hogy a rendszerkapacitás és a tényleges kezelésbe jutás nem azonos fogalmak, és a későbbi kutatásokban külön adatgyűjtést, illetve AI-támogatott nowcasting megoldásokat érdemesnek (Rajkomar et al., 2019; WHO, 2023).

6. Eredmények

A 2019-es, 179 országot lefedő mintában a becsült közvetlen egészségügyi költség 491,8 milliárd USD, a termelékenység-ekvivalens veszteség 1,465 billió USD, a teljes monetizált társadalmi teher pedig 1,955 billió USD volt. A teljes teher népességgel súlyozott átlaga 253,3 USD/fő, GDP-vel súlyozott átlaga 2,25% GDP. A közvetlen komponens a teljes teher 25,2%-át, a termelékenység-ekvivalens veszteség 74,8%-át adta. Ez a megoszlás a Manthey és szerzőtársai (2021) által közölt 38,8%/61,2%-os mintázathoz képest ad, ami összhangban áll azzal, hogy a jelen tanulmány közvetlen költségproxyja szűken az egészségügyi kiadásokra korlátozódik, és nem tartalmazza például a kriminalitási, szociális vagy egyéb közszolgáltatási költségeket.

Az 1. ábra a logaritmizált alkoholfogyasztás és az egy főre jutó teljes társadalmi teher közötti erős pozitív kapcsolatot mutatja. A mintázat nem bizonyít oksági összefüggést, de jól szemlélteti, hogy a magasabb expozíciójú országokban a monetizált teher jellemzően lényegesen magasabb. Ez összhangban van a globális betegségteher-irodalom és a költségszámítási áttekintések fő megállapításaival (Rehm et al., 2009; GBD 2016 Alcohol and Drug Use Collaborators, 2018; Manthey et al., 2021).

1. ábra: Az alkoholfogyasztás és a teljes társadalmi teher kapcsolata, 2019

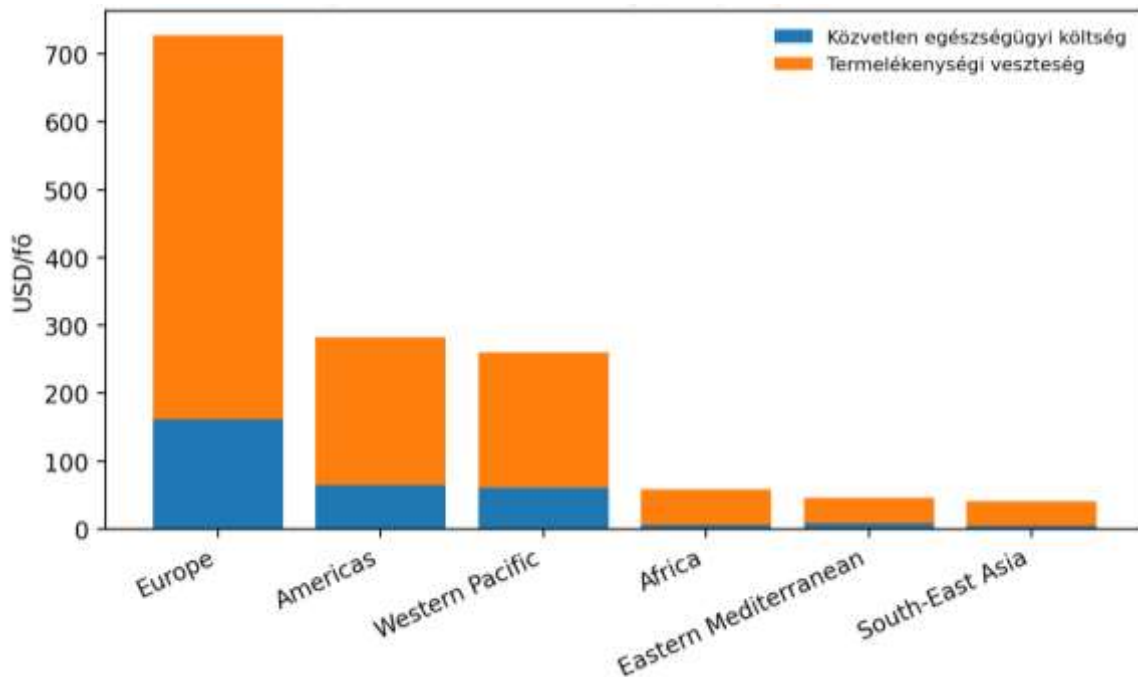


Megjegyzés: az illesztés $\log(1+x)$ transzformált skálán becstölt lineáris kapcsolatot, a sáv 95%-os konfidenciaintervallum.

Forrás: saját szerkesztés a feltöltött adatállományok alapján.

Regionális bontásban Európa emelkedik ki a legmagasabb teherrel: a medián teljes teher 2,43% GDP, a medián közvetlen egészségügyi költség 112,9 USD/fő, a medián termelékenységi veszteség pedig 522,6 USD/fő. Az Amerikák régiója a második legmagasabb median GDP-aránnyal bír (2,13%), míg a Keleti Mediterráneumban a medián teher 0,25% GDP körül marad. A 2. ábra azt mutatja, hogy a régiós különbségeket nemcsak a fogyasztási szint, hanem a monetizált termelékenységi veszteség nagysága is erősen meghatározza.

2. ábra: Átlagos társadalmi költségkomponensek régióként, 2019



Forrás: saját szerkesztés a feltöltött adatállományok alapján.

A legmagasabb GDP-arányos országterhek Kelet-Európa és a posztsovjét térség több országában jelentek meg. A minta élén Moldova (11,71% GDP), Ukrajna (9,52%), Belarusz (9,25%), Oroszország (8,41%), Litvánia (8,26%) és Lettország (8,18%) áll. Ez a területi koncentráció illeszkedik a GBD-irodalom azon megfigyeléséhez, hogy az alkoholhoz köthető betegségteher földrajzilag erősen egyenetlen, és több magas terhű térségben a korai halálozás, az erősebb intoxikációs minták és a kapcsolódó társadalmi károk együtt jelennek meg (GBD 2016 Alcohol and Drug Use Collaborators, 2018).

A keresztmetszeti regressziók eredményeit a 3. táblázat foglalja össze. A fő specifikációkban az egy főre jutó alkoholfogyasztás minden kimenetben szignifikáns és pozitív: a közvetlen egészségügyi költség GDP-arányára 0,935-ös, a termelékenység-ekvivalens veszteségre 0,857-es, a teljes társadalmi teherre 0,871-es koefficiens adódik. Log-log jellegű specifikációról lévén szó, ez közelítőleg azt jelenti, hogy a magasabb fogyasztású országokban a társadalmi költség GDP-arányos terhe arányosan, jelentős rugalmassággal nő.

A SCI-SUD szolgáltatási kapacitási index eredménye összetettebb. A közvetlen egészségügyi költségre pozitív és szignifikáns együttjárás adódik (0,197), míg a termelékenységi veszteségre és a teljes teherre negatív előjel jelenik meg. Ennek egyik plausibilis értelmezése, hogy a fejlettebb ellátórendszer rövid távon növeli a detektált és finanszírozott egészségügyi felhasználást, ugyanakkor mérsékli a kezeletlenségből adódó, szélesebb társadalmi termelékenységi veszteségeket. Másképp fogalmazva: a nagyobb szolgáltatási kapacitás részben költség-áthelyezést jelenthet a rejtett társadalmi veszteségekből a látható egészségügyi kiadások felé.

Az alternatív, alkoholhasználati zavar (AUD) prevalenciáját használó specifikáció megerősíti az alaptézist: a prevalencia rugalmasan és pozitívan kapcsolódik a teljes társadalmi teherhez, a SCI-SUD együttthatója azonban itt már nem szignifikáns. Ez arra utal, hogy a szolgáltatási kapacitás makroszintű szerepe fontos, de a jelenlegi adatsűrűség mellett elsősorban a fogyasztási és tehermutatók hordozzák a legerősebb magyarázóerőt.

3. táblázat: Keresztmetszeti regressziók a 2019-es mintán

Specifikáció	β – alkohol / AUD	β – SCI-SUD	β munkanélküliség	N	R ²
Közvetlen egészségügyi költség (% GDP)	0.935*** (0.080)	0.197** (0.090)	-0.000 (0.009)	173	0.82
Termelékenység-ekvivalens veszteség (% GDP)	0.857*** (0.069)	-0.171*** (0.058)	-0.002 (0.007)	175	0.78
Teljes társadalmi teher (% GDP)	0.871*** (0.067)	-0.122** (0.055)	-0.002 (0.007)	173	0.81
Teljes társadalmi teher (% GDP), AUD-prevalencia	0.748*** (0.100)	-0.065 (0.072)	0.005 (0.009)	174	0.70

*Megjegyzés: a függő változó minden esetben a megfelelő költségmutató logaritmizált GDP-arányos értéke. A specifikációk régiófixhatásokat és HC3-robosztus szóráshibákat használnak. A zárójelben robosztus standard hiba szerepel. * $p < 0,10$; ** $p < 0,05$; *** $p < 0,01$. Forrás: saját számítás.*

A panel fixhatásos becslések a fiskális oldalról erősítik meg a fenti képet, de nem a 2019-es keresztmetszeti együttthatók közvetlen ellenpróbái: itt kifejezetten az időbeli együttmozgást vizsgálom a 2000–2022-es panelben. A 4. táblázat szerint az alkoholfogyasztás és a közösségi egészségügyi kiadás/fő kapcsolata a két évvel késleltetett specifikációban válik szignifikánssá ($\beta = 0,217$; $p = 0,044$). Ez a becslés azt sugallja, hogy 10%-kal magasabb alkoholfogyasztás két év múlva mintegy 2,2%-kal magasabb közösségi egészségügyi kiadással jár együtt, változatlan ország- és évhatások, valamint GDP/fő és munkanélküliség mellett.

A jelenlegi egészségügyi kiadás/fő esetében a kapcsolatok gyengébbek, de az irány következetesen pozitív, és a két évvel késleltetett becslés itt is határszignifikáns. Ez összhangban van a várakozással, hogy az alkohol káros következményei és ezek fiskális leképeződése időben elnyúlva jelentkeznek. Bár a regressziók asszociatív jellegűek, a késleltetett eredmények különösen fontosak a reálopciók értelmezés szempontjából: a kivárásnak ára van, mert a mai fogyasztási terhelés egy része csak később jelenik meg a költségvetési adatokban.

4. táblázat: Panel fixhatásos becslések a fiskális dinamikára (2000–2022)

Függő változó	Alkoholfogyasztás késleltetése	β – $\ln(1+\text{alkoholfogyasztás})$	p-érték	N	R ²
$\ln(\text{közösségi egészségügyi kiadás/fő})$	0 év	0.160 (0.109)	0.14	3968	0.99
$\ln(\text{közösségi egészségügyi kiadás/fő})$	1 év	0.188* (0.107)	0.08	3792	0.99
$\ln(\text{közösségi egészségügyi kiadás/fő})$	2 év	0.217** (0.108)	0.04	3616	0.99
$\ln(\text{jelenlegi egészségügyi kiadás/fő})$	0 év	0.079 (0.091)	0.39	3968	0.99
$\ln(\text{jelenlegi egészségügyi kiadás/fő})$	1 év	0.107 (0.086)	0.21	3792	0.99

Függő változó	Alkoholfogyasztás késleltetése	$\beta - \ln(1+\text{alkoholfogyasztás})$	p-érték	N	R ²
ln(jelenlegi egészségügyi kiadás/fő)	2 év	0.147* (0.083)	0.07	3616	0.99

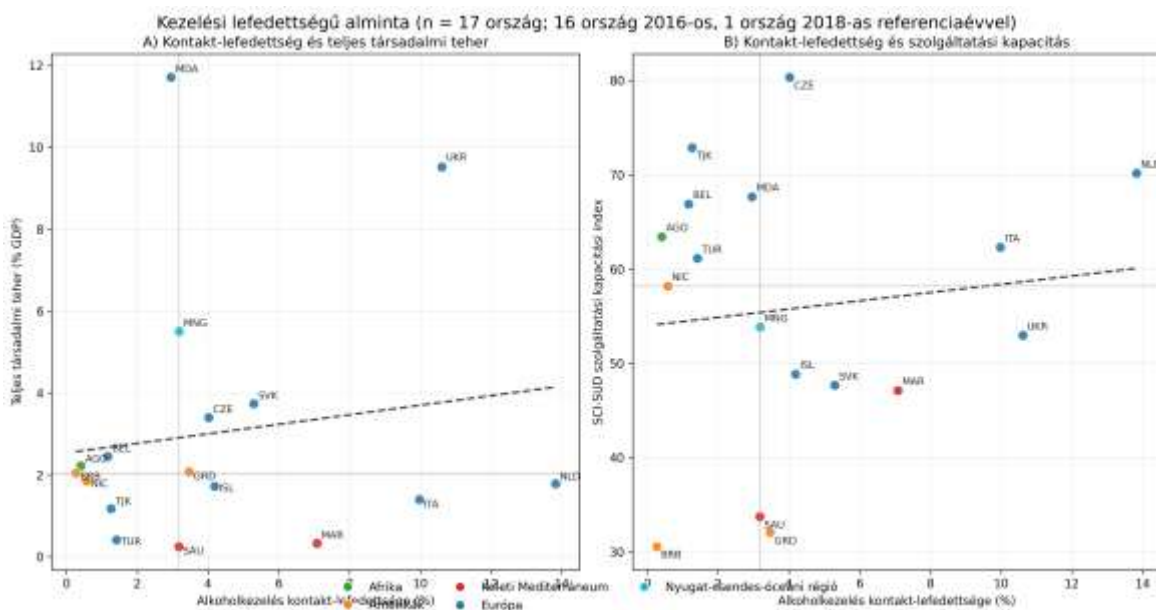
Megjegyzés: minden modell ország- és évfixhatásokat, valamint ország szerint klaszterezett szórás hibákat használ. A kontrollváltozók: $\ln(\text{GDP}/\text{fő})$ és munkanélküliségi ráta. * $p < 0,10$; ** $p < 0,05$. Forrás: saját számítás.

Kiegészítő eredmények a kezelési lefedettségű almintán

A kontakt-lefedettségű almintá 17 országot tartalmaz, amelyek közül 16 esetben 2016-os, 1 esetben 2018-as referenciaév áll rendelkezésre. Az almintá regionálisan és fejlettségi szempontból is szelektált: 10 ország európai, 3 az Amerikák régiójához tartozik, 2 a Keleti Mediterráneumból származik, és egyetlen alacsony jövedelmű ország sincs benne. A kontakt-lefedettség mediánja 3,18%, miközben az almintá medián SCI-SUD értéke 58,20 pont, szemben a teljes minta 31,75 pontos mediánjával. Ugyanez a szelektivitás látszik az expozícióban és a teherben is: az almintá medián alkoholfogyasztása 8,17 liter/fő, a medián teljes társadalmi teher pedig 2,04% GDP, míg a teljes mintában ugyanezek 4,86 liter/fő és 1,85% GDP.

A 3. ábra alapján sem a teljes társadalmi teherrel, sem a szolgáltatási kapacitási indexszel nem rajzolódik ki stabil monoton kapcsolat. A Spearman-rangkorreláció a kontakt-lefedettség és a teljes társadalmi teher között $\rho = 0,00$ ($p = 0,99$), a kontakt-lefedettség és a SCI-SUD index között pedig $\rho = -0,02$ ($p = 0,95$). A bivariáns log-log specifikációk ugyanezt a képet adják: egyik kapcsolat sem szignifikáns. Az eredmények tehát nem utalnak arra, hogy ezen a szűk almintán a magasabb megfigyelt kezelési lefedettség automatikusan alacsonyabb társadalmi teherrel vagy magasabb kapacitási indexszel járna együtt.

3. ábra: A kezelési kontakt-lefedettség kapcsolata a teljes társadalmi teherrel és a SCI-SUD indexszel a 17 országos almintán



Forrás: saját szerkesztés a feltöltött adatállományok alapján.

Az almintás eredmények értelmezése szerint a rendszerkapacitás és a tényleges kezelésbe jutás nem azonos fogalmak. A SCI-SUD index inkább az intézményi infrastruktúrát és a szolgáltatási készültséget ragadja meg, míg a kontakt-lefedettség már egy kimeneti mutató, amely erősen függ a szűrési gyakorlatoktól, a stigma mértékétől, a mérési módtól és az adminisztratív adatminőségtől. A coverage-változó kis mintán mutatott gyenge viselkedése ezért nem cáfolja a fő regressziókban kapott SCI-SUD-eredményeket; inkább azt jelzi, hogy a kezelésbe jutás közvetlen mérésének nemzetközi adatbázisa jelenleg túl hiányos a globális regressziós benchmarkhoz. Ez egyúttal az AI-kapcsolódás szempontjából is releváns: a jövőben éppen az ilyen ritkán megfigyelt szolgáltatási kimenetek előrejelzése és nowcastingja lehet az egyik legfontosabb döntéstámogató bővítés (Rajkomar et al., 2019; WHO, 2023).

7. Reálopciók értékelés és scenáriók

A reálopciók blokk azt vizsgálja, hogy a becsült társadalmi teher mekkora részének éves csökkentése mellett mekkora egyszeri beruházási költségig racionális az azonnali beavatkozás. A standard nettó jelenérték-logikában a döntés küszöbe a várható haszonáram jelenértéke lenne. Reálopciók környezetben azonban a döntéshozó számára a kivárás önmagában is értékes lehet, ezért az azonnali beruházási küszöb a pusztán jelenértéknél alacsonyabb. Minél nagyobb a bizonytalanság, annál magasabb a kivárás opcióértéke, és annál szigorúbb mérce mellett indokolt a beruházás azonnali megindítása (Dixit & Pindyck, 1994; Grutters et al., 2011).

A 10%-os éves tehercsökkentési bázisszenárióban a medián országban 234,5 USD/fő az azonnal vállalható egyszeri beruházási költség felső határa, a 75. percentilisben 851,7 USD/fő, a 90. percentilisben pedig 2 851,7 USD/fő. Az átlag 822,3 USD/fő, ami az eloszlás erős jobbra ferdeségét mutatja. A 5%-os scenárióban a medián küszöb 117,3 USD/fő, míg 20%-os hatékonyságnál 469,1 USD/fő-re nő. A magas teherrel és/vagy magas egy főre jutó jövedelemmel rendelkező országokban a monetizált haszonáram is nagyobb, ezért az azonnal vállalható beruházás felső határa is lényegesen magasabb.

A legmagasabb, 10%-os scenárióhoz tartozó küszöbértékeket Luxemburg, Svájc, Írország, az Egyesült Államok és Litvánia mutatja. Ez fontos eredmény, mert azt jelzi, hogy a magas opciók küszöb nem kizárólag a magas alkoholfogyasztásból következik: a monetizált teher nagysága, a GDP/fő szintje és a bizonytalansági paraméterek együtt alakítják ki a beruházási térképet. Litvánia példája különösen tanulságos, mert egyszerre magas a GDP-arányos teher és magas az abszolút monetizált veszteség is.

A döntési szabály értelmezése közpolitikai szempontból egyszerű. Ha az egy főre jutó egyszeri beruházási költség a küszöb alatt van, az azonnali beavatkozás reálopciók szempontból is védhető. Ha a beruházási költség a küszöb és a standard jelenérték közé esik, akkor a projekt lehet ugyan pozitív nettó jelenértékű, de a kivárás értéke miatt a halasztás továbbra is racionális lehet. Ha a beruházási költség a standard

jelenértéket is meghaladja, akkor sem a mostani beruházás, sem a kivárás melletti későbbi gyakorlás nem tűnik megalapozottnak a jelenlegi paraméterek mellett.

A 4. ábra azt mutatja, hogy a küszöbértékek a hatékonysági scenáriókkal közel lineárisan emelkednek. Ez arra utal, hogy a programok várható eredményességének javítása – például célzottabb elérés, jobb utánkövetés vagy adatvezérelt szűrés révén – nemcsak a közvetlen egészségnyereséget növeli, hanem a beruházási döntés pénzügyi-politikai mozgásterét is szélesíti.

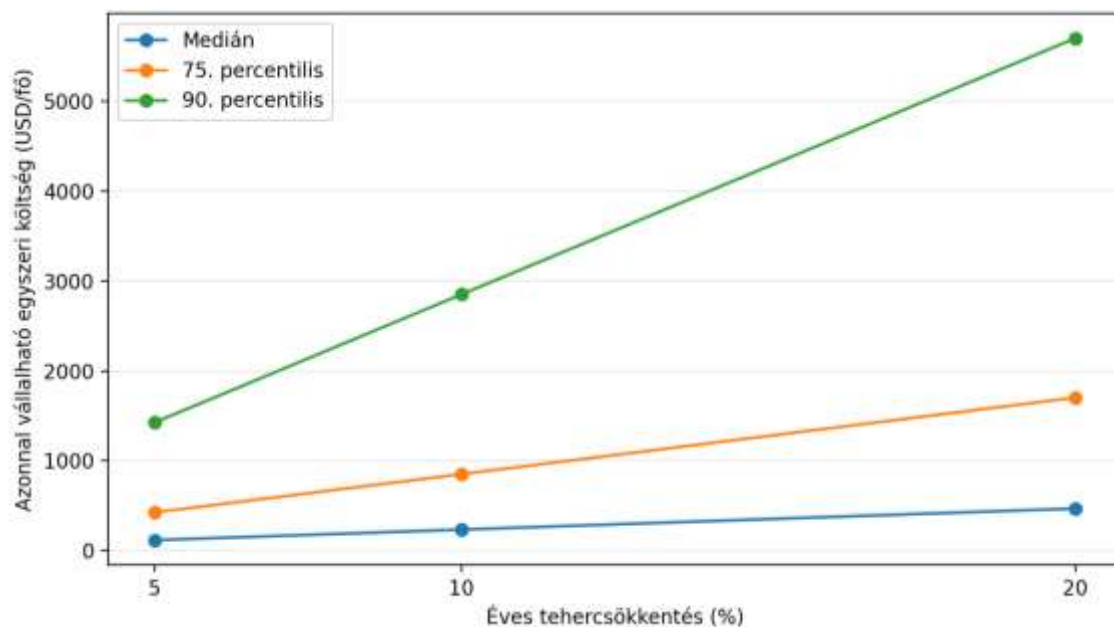
A reálopciók eredmények egyik lehetséges továbblépése az AI-val való összekapcsolás: az AI nemcsak a várható tehercsökkentési rátát növelheti, hanem az ország-specifikus bizonytalansági paraméter újralibrálását is lehetővé teszi. Jobb előrejelzés mellett a kivárás értéke csökkenhet, míg jobb korai észlelés mellett ugyanazon beruházási költség mellett több ország kerülhet az azonnali beavatkozás tartományába. A jelen cikk számai ezért benchmarkként értelmezendők: nem AI-val becsült optimumok, hanem olyan küszöbértékek, amelyekhez később AI-alapú frissítő réteg kapcsolható (Rajkomar et al., 2019; WHO, 2023).

5. táblázat: Reálopciók küszöbértékek scenárióként

Szenárió	N	Átlagos küszöb (USD/fő)	Medián küszöb (USD/fő)	75. percentilis	90. percentilis
5%-os éves tehercsökkentés	178	411.20	117.30	425.80	1425.80
10%-os éves tehercsökkentés	178	822.30	234.50	851.70	2851.70
20%-os éves tehercsökkentés	178	1644.60	469.10	1703.30	5703.40

Megjegyzés: a táblázat az országonként számított maximális, egy főre jutó egyszeri beruházási költség eloszlását mutatja, amely alatt az azonnali beavatkozás racionális lehet. Forrás: saját számítás.

4. ábra: Reálopciók küszöbértékek különböző hatékonysági scenáriókban



Forrás: saját szerkesztés a reálopciók scenáriószámítások alapján.

8. Következtetések

A tanulmány célja annak megmutatása volt, hogy az alkoholhoz köthető társadalmi költség vizsgálata nem állhat meg a statikus teher számbavételénél. A 2019-es keresztmetszet és a 2000–2022-es panel egymást kiegészítő, de nem közvetlenül összevetett empirikus blokkokként szolgáltak: az előbbi a teherszint és a strukturális együttjárások, az utóbbi a fiskális dinamika vizsgálatát tette lehetővé. E két elemzési szint alapján a cikk öt kutatási kérdésre adott empirikus és értelmező választ: mekkora az alkoholhoz köthető teher nagysága, milyen kapcsolatban áll a fogyasztás és az ellátórendszeri kapacitás a költségkomponensekkel, megjelenik-e az alkoholfogyasztás hatása késleltetetten a közösségi egészségügyi kiadásokban, kimutatható-e pozitív társadalmi opcióérték a korai beavatkozás mögött, valamint milyen pontokon bővíthető ehhez a kerethez az AI.

A kutatási kérdések megválaszolása

K1. Mekkora az alkoholhasználathoz köthető társadalmi költség a vizsgált országkörben? A 2019-es mintában a becsült közvetlen egészségügyi költség 491,8 milliárd USD, a termelékenység-ekvivalens veszteség 1,465 billió USD, a teljes monetizált társadalmi teher pedig 1,955 billió USD volt. A GDP-vel súlyozott átlagos teher 2,25% GDP, a medián országteher 1,85% GDP. Az első kutatási kérdésre tehát az a válasz, hogy az alkoholhoz köthető társadalmi teher nemzetközi összehasonlításban is makrogazdasági léptékű, és a legtöbb országban messze túlmutat az egészségügyi alrendszer szűken vett költségterhén.

K2. Hogyan kapcsolódik az alkoholfogyasztás és a szolgáltatási kapacitás a társadalmi költség egyes komponenseihez? A keresztmetszeti regressziók szerint az egy főre jutó alkoholfogyasztás szignifikánsan és pozitívan kapcsolódik a közvetlen egészségügyi költséghez, a termelékenység-ekvivalens veszteséghez és a teljes társadalmi teherhez. A szolgáltatási kapacitást mérő SCI-SUD index a termelékenységi veszteséggel és a teljes teherrel negatív együttjárást mutatott, miközben a közvetlen egészségügyi költségnél pozitív előjel jelent meg. A 17 országos, feltáró kontakt-lefedettségi al minta ugyanakkor nem mutatott stabil kapcsolatot sem a teljes társadalmi teherrel, sem a SCI-SUD indexszel. A második kutatási kérdésre így az a válasz adható, hogy a magasabb fogyasztás következetesen nagyobb terhet jelez, a nagyobb szolgáltatási kapacitás pedig valószínűleg részben a rejtett társadalmi veszteségeket transzformálja láthatóbb egészségügyi kiadásokká, miközben mérsékelheti a szélesebb termelékenységi károkat; a tényleges kezelésbe jutás közvetlen mutatója viszont a jelenlegi nemzetközi adatinfrastruktúra mellett még nem elég stabil ahhoz, hogy ugyanezt globális regressziós benchmarkként hordozza.

K3. Megjelenik-e az alkoholfogyasztás hatása késleltetetten a közösségi egészségügyi kiadásokban? A panel fixhatásos becslések szerint igen: a két évvel késleltetett alkoholfogyasztás pozitív és statisztikailag szignifikáns kapcsolatban áll a közösségi egészségügyi kiadás/fő mutatóval, és gyengébben, de azonos irányban a teljes jelenlegi egészségügyi kiadással is. A harmadik kutatási kérdésre tehát az a válasz, hogy az alkoholteher fiskális következményei nem pusztán egyidejűek, hanem

időben elnyúlva jelentkeznek, ami a halasztott beavatkozás költségét különösen fontossá teszi.

K4. Kimutatható-e pozitív társadalmi opcióértéke a korai prevenció és kezelési beavatkozásoknak? A reálopciók szcenáriói erre egyértelmű igenlő választ adnak. A 10%-os éves tehercsökkentési bázisszcenárióban a medián országban 234,5 USD/fő, a 75. percentilisben 851,7 USD/fő, a 90. percentilisben pedig 2 851,7 USD/fő az azonnal vállalható egyszeri beruházási költség felső határa. A negyedik kutatási kérdésre adott válasz tehát az, hogy a korai beavatkozásnak mérhető pozitív társadalmi opcióértéke van, és ez az érték a nagyobb monetizált teherrel rendelkező országokban lényegesen magasabb.

K5. Milyen AI-megközelítés illeszthető legjobban a társadalmi költség és reálopciók keretéhez? A válasz háromszintű, de fontos hangsúlyozni, hogy ez a blokk a jelen tanulmányban nem önálló empirikus bizonyítás, hanem bővítési irány. A jelen makropanelhez a legerősebb kapcsolatot az AI-alapú ország-szintű teher- és volatilitás-előrejelzés adja, mert ez közvetlenül a reálopciók paramétereikhez kapcsolódik. A második legerősebb kapcsolat a mikroadatokon nyugvó korai észlelés és kezeléscélzás, amely a beavatkozási hatékonyság paraméterét javíthatja. A generatív AI és az LLM-ek szerepe jelenleg inkább kiegészítő: hasznos lehetnek szakirodalmi szintézisre, szcenáriómenedzsmentre és tudásmenedzsmentre, de a mentális egészségben és addikcióban még nem tekinthetők kellően kiforrott elsődleges döntési motornak. A kutatási kérdésre adott összegző válasz tehát az, hogy a jelen anyaghoz az AI-t leginkább előrejelző és korai észlelési réteggént érdemes hozzákapcsolni, nem pedig a közgazdasági azonosítás helyettesítőjeként (Mak et al., 2019; Ebrahimi et al., 2023; Kolding et al., 2024; WHO, 2021, 2023).

A fenti válaszok alapján a tanulmány fő állítása megerősítést nyer: az addikciós intervenciókat nem célszerű pusztán költségvetési megszorítási logikában kezelni. A társadalmi teher egy része olyan jövőbeli haszonáramot jelent, amely megfelelő hatékonyságú beavatkozás esetén megtakarítható. Ez közel visz a public value szemlélethez: a prevenció és a kezelés nem csupán egyéni egészségnyereséget hoz, hanem fiskális mozgásteret, termelékenység kapacitást és tágabb társadalmi jóléti értéket is létrehoz (Moore, 1995; Stoker, 2006; Mazzucato & Ryan-Collins, 2022).

A cikknek ugyanakkor több korlátja is van. A közvetlen egészségügyi költség és a termelékenységi veszteség proxyk nem helyettesítik a részletes, diagnózisszintű vagy adminisztratív mikro-költségszámításokat. A becslés nem tartalmazza a kriminalitási, szociális, családi, gondozási és egyéb immateriális veszteségeket, ezért több szempontból konzervatív. Másfelől a DALY-k GDP/fővel történő monetizálása aggregált árnyékár, amely nem feleltethető meg közvetlenül az egyéni keresetvesztésnek. A kezelési lefedettség gyenge nemzetközi adatminősége és az országos IHME-robotosság hiánya szintén óvatosságot indokol; különösen azért, mert a rendelkezésre álló 17 országos coverage-alminta regionálisan és jövedelmi szempontból is szelektált. További korlát, hogy a jelen verzió nem közöl külön reprodukálhatósági mellékletet a teljes adatösszeillesztési és becslési munkafolyamatról; ezt a következő változatban érdemes pótolni.

A továbbblépés két irányban ígéretes. Egyrészt érdemes lenne a keretet teljes országos GBD-exporttal, kriminalitási és szociális költségadatokkal, valamint programszintű kezelési költségekkel összekapcsolni. Másrészt a reálopciók blokk közvetlenül bővíthető AI-alapú előrejelzési és célzási modulokkal: ország-szintű gépi tanulási teher-előrejelzéssel, EHR- és NLP-alapú korai észleléssel, digitális monitorozással, illetve a kezelési lefedettséghez hasonló ritkán megfigyelt kimenetek nowcastingjával. Ebben a formában a társadalmi költségszámítás és a reálopciók szemlélet együtt valóban használható, AI-alapú döntéstámogató eszközzé válhat a függőségpolitikai és egészségfinanszírozási gyakorlatban. Emellett a keret a turizmus és modern addiktív magatartások kapcsolatának vizsgálata felé is továbbvihető, ami visszakapcsolható a témában született korábbi összehasonlító eredményeimhez (Csapi, 2026).

Hivatkozások

- Anderson, P., Chisholm, D., & Fuhr, D. C. (2009). Effectiveness and cost-effectiveness of policies and programmes to reduce the harm caused by alcohol. *The Lancet*, 373(9682), 2234–2246. [https://doi.org/10.1016/S0140-6736\(09\)60744-3](https://doi.org/10.1016/S0140-6736(09)60744-3)
- Burton, R., Henn, C., Lavoie, D., O'Connor, R., Perkins, C., Sweeney, K., et al. (2017). A rapid evidence review of the effectiveness and cost-effectiveness of alcohol control policies: an English perspective. *The Lancet*, 389(10078), 1558–1580. [https://doi.org/10.1016/S0140-6736\(16\)32420-5](https://doi.org/10.1016/S0140-6736(16)32420-5)
- Csapi, P. (2026). The Global Landscape of Addictions: How Does Tourism Influence Modern Addictive Behaviors?. In P. Šprajc, M. Bernik, M. Klačmer Čalopa, D. Maletič, M. Mihić, N. Petrović, I. Podbregar, D. Tomić, & A. Žnidaršič Mohorič (Eds.), 45th International Conference on Organizational Science Development: Organization and the Longevity Society, Conference Proceedings (Vol. 45, pp. 87–98). University of Maribor Press. <https://doi.org/10.18690/um.fov.3.2026.7>
- Csapi, V. (2018). A reálopciók első 40 éve. *Vezetéstudomány / Budapest Management Review*, 49(9), 34–45. <https://doi.org/10.14267/VEZTUD.2018.09.03>
- Csapi, V., & Sárícs, S. Zs. (2026). Reálopciók és mesterséges intelligencia a hidrogénalapú beruházások döntéstámogatásában. *Vezetéstudomány / Budapest Management Review*, 57(3), 47–66. <https://doi.org/10.14267/VEZTUD.2026.03.04>
- Dixit, A. K., & Pindyck, R. S. (1994). *Investment under uncertainty*. Princeton University Press.
- Dreyfuss, P. D., & Roberts, T. G. Jr. (2011). Making investments in medical technology: time to get real about real options. *The Oncologist*, 16(12), 1672–1674. <https://doi.org/10.1634/theoncologist.2011-0345>

- Ebrahimi, A., Will, U. K., Baskaran, R., Peimankar, A., Andersen, K., & Nielsen, A. S. (2023). AUD-DSS: a decision support system for early detection of patients with alcohol use disorder. *BMC Bioinformatics*, 24(1), 329. <https://doi.org/10.1186/s12859-023-05450-6>
- GBD 2016 Alcohol and Drug Use Collaborators. (2018). The global burden of disease attributable to alcohol and drug use in 195 countries and territories, 1990–2016: a systematic analysis for the Global Burden of Disease Study 2016. *The Lancet Psychiatry*, 5(12), 987–1012. [https://doi.org/10.1016/S2215-0366\(18\)30337-7](https://doi.org/10.1016/S2215-0366(18)30337-7)
- Grutters, J. P. C., Abrams, K. R., de Ruyscher, D., Pijls-Johannesma, M., Peters, H. J. M., Beutner, E., et al. (2011). When to wait for more evidence? Real options analysis in proton therapy. *The Oncologist*, 16(12), 1752–1761. <https://doi.org/10.1634/theoncologist.2011-0029>
- Kolding, S., Lundin, R. M., Hansen, L., & Østergaard, S. D. (2024). Use of generative artificial intelligence (AI) in psychiatry and mental health care: a systematic review. *Acta Neuropsychiatrica*, 37, e37. <https://doi.org/10.1017/neu.2024.50>
- Mak, K. K., Lee, K., & Park, C. (2019). Applications of machine learning in addiction studies: A systematic review. *Psychiatry Research*, 275, 53–60. <https://doi.org/10.1016/j.psychres.2019.03.001>
- Manthey, J., Hassan, S. A., Carr, S., Kilian, C., Kuitunen-Paul, S., & Rehm, J. (2021). What are the economic costs to society attributable to alcohol use? A systematic review and modelling study. *Pharmacoeconomics*, 39(7), 809–822. <https://doi.org/10.1007/s40273-021-01031-8>
- Mazzucato, M., & Ryan-Collins, J. (2022). Putting value creation back into “public value”: from market-fixing to market-shaping. *Journal of Economic Policy Reform*, 25(4), 345–360. <https://doi.org/10.1080/17487870.2022.2053537>
- Moore, M. H. (1995). *Creating public value: Strategic management in government*. Harvard University Press.
- Mohr, D. C., Zhang, M., & Schueller, S. M. (2017). Personal Sensing: Understanding Mental Health Using Ubiquitous Sensors and Machine Learning. *Annual Review of Clinical Psychology*, 13, 23–47. <https://doi.org/10.1146/annurev-clinpsy-032816-044949>
- Myers, S. C. (1977). Determinants of corporate borrowing. *Journal of Financial Economics*, 5(2), 147–175. [https://doi.org/10.1016/0304-405X\(77\)90015-0](https://doi.org/10.1016/0304-405X(77)90015-0)
- Putzer, P., & Posza, A. (2024). Transition from CSR to ESG in Tourism – A Bibliometric Analysis. *Organizacija*, 57(3), 249–259. <https://doi.org/10.2478/orga-2024-0018>

- Rajkomar, A., Dean, J., & Kohane, I. (2019). Machine Learning in Medicine. *New England Journal of Medicine*, 380(14), 1347-1358. <https://doi.org/10.1056/NEJMra1814259>
- Rehm, J., Mathers, C., Popova, S., Thavorncharoensap, M., Teerawattananon, Y., & Patra, J. (2009). Global burden of disease and injury and economic cost attributable to alcohol use and alcohol-use disorders. *The Lancet*, 373(9682), 2223–2233. [https://doi.org/10.1016/S0140-6736\(09\)60746-7](https://doi.org/10.1016/S0140-6736(09)60746-7)
- Roberts, W., Zhao, Y., Verplaetse, T., Moore, K. E., Peltier, M. R., Burke, C., Zakiniaez, Y., & McKee, S. (2022). Using machine learning to predict heavy drinking during outpatient alcohol treatment. *Alcoholism: Clinical and Experimental Research*, 46(4), 657-666. <https://doi.org/10.1111/acer.14802>
- Sacks, J. J., Gonzales, K. R., Bouchery, E. E., Tomedi, L. E., & Brewer, R. D. (2015). 2010 national and state costs of excessive alcohol consumption. *American Journal of Preventive Medicine*, 49(5), e73–e79. <https://doi.org/10.1016/j.amepre.2015.05.031>
- Single, E., Collins, D., Easton, B., Harwood, H., Lapsley, H., Kopp, P., & Wilson, E. (2003). *International guidelines for estimating the costs of substance abuse (2nd ed.)*. World Health Organization.
- Stoker, G. (2006). Public value management: A new narrative for networked governance? *The American Review of Public Administration*, 36(1), 41–57. <https://doi.org/10.1177/0275074005282583>
- To, D., Sharma, B., Karnik, N., Joyce, C., Dligach, D., & Afshar, M. (2020). Validation of an alcohol misuse classifier in hospitalized patients. *Alcohol*, 84, 49-55. <https://doi.org/10.1016/j.alcohol.2019.09.008>
- Topol, E. J. (2019). High-performance medicine: the convergence of human and artificial intelligence. *Nature Medicine*, 25(1), 44-56. <https://doi.org/10.1038/s41591-018-0300-7>
- Thavorncharoensap, M., Teerawattananon, Y., Yothasamut, J., Lertpitakpong, C., & Chaikledkaew, U. (2009). The economic impact of alcohol consumption: a systematic review. *Substance Abuse Treatment, Prevention, and Policy*, 4, 20. <https://doi.org/10.1186/1747-597X-4-20>
- Ulbert J., Takács a., Csapi V. (2017). *The Relevance of the DCF Valuation Model in Investor Decisions*. Saarbrücken: GlobeEdit.
- Wyant, K., Moshontz, H., Ward, S. B., Fronk, G. E., & Curtin, J. J. (2023). Acceptability of Personal Sensing Among People With Alcohol Use Disorder: Observational Study. *JMIR mHealth and uHealth*, 11, e41833. <https://doi.org/10.2196/41833>
- Vassolo, R. S., Mac Cawley, A. F., Tortorella, G. L., Fogliatto, F. S., Tlapa, D., & Narayanamurthy, G. (2021). Hospital investment decisions in Healthcare 4.0 technologies: Scoping review and

framework for exploring challenges, trends, and research directions. *Journal of Medical Internet Research*, 23(8), e27571. <https://doi.org/10.2196/27571>

Verhaeghe, N., Lievens, D., Annemans, L., Vander Laenen, F., & Putman, K. (2017). Methodological considerations in social cost studies of addictive substances: A systematic literature review. *Frontiers in Public Health*, 4, 295. <https://doi.org/10.3389/fpubh.2016.00295>

World Health Organization. (2019). The SAFER technical package: Five areas of intervention at national and subnational levels. World Health Organization.

World Health Organization. (2024a). Global status report on alcohol and health and treatment of substance use disorders. World Health Organization.

World Bank. (n.d.). World Development Indicators.

<https://databank.worldbank.org/source/world-development-indicators>

World Health Organization. (2021). Ethics and governance of artificial intelligence for health. <https://www.who.int/publications/i/item/9789240029200>

World Health Organization. (2023). Regulatory considerations on artificial intelligence for health. <https://www.who.int/publications/i/item/9789240078871>

World Health Organization. (2024b). Alcohol. Fact sheet.

<https://www.who.int/news-room/fact-sheets/detail/alcohol>

World Health Organization. (n.d.-a). Levels of consumption. Global Health Observatory. <https://www.who.int/data/gho/data/themes/topics/topic-details/GHO/levels-of-consumption>

World Health Organization. (n.d.-b). Harms and consequences. Global Health Observatory. <https://www.who.int/data/gho/data/themes/topics/topic-details/GHO/harms-and-consequences>

World Health Organization. (n.d.-c). Substance use disorder service capacity index and coverage of treatment services. Global Health Observatory. <https://www.who.int/data/gho/data/themes/topics/topic-details/GHO/substance-use-disorder-service-capacity-index-and-coverage-of-treatment-services>

World Health Organization. (n.d.-d). Global Health Expenditure Database. <https://apps.who.int/nha/database/select/indicators/en>

FUZZY-ENTRÓPIA-ALAPÚ KOCKÁZATOSSÁGI MUTATÓ: EMPIRIKUS KONSTRUKCIÓ ÉS ALKALMAZÁS

FÁRÓ Jenő

Eötvös Loránd Tudományegyetem Gazdaságtudományi Kar
faro.jeno@gtk.elte.hu

JÓNÁS Tamás

Eötvös Loránd Tudományegyetem Gazdaságtudományi Kar
jonas.tamas@gtk.elte.hu

<https://doi.org/10.15170/XVIIPPN-Tk-KTK-2026-05>

Absztrakt

Korábbi kutatásaink során bemutattuk, hogy a hozamok eloszlásfüggvényének fuzzisága alkalmas lehet a pénzügyi eszközök kockázatosságának mérésére, mivel az általunk vizsgált elméleti esetben együttmozgást mutatott a szórással. A megközelítés előnyeként kiemeltük a javasolt mutató rugalmasságát, amely jelentős szabadságot ad a felhasználóknak.

Jelen kutatásunk hozzájárulása kettős. Egyrészt megalkottuk a korábban normális eloszlású valószínűségi változókra értelmezett mutató empirikus változatát, amely az empirikus hozameloszlás alakjára építve jellemzi a vizsgált eszköz kockázatosságát. Másrészt azt vizsgáltuk, hogy a rugalmasságot biztosító paraméterek értékének módosítása miként befolyásolja e kockázatossági mutató magyarázó erejét az átlaghozamokra nézve. E magyarázó erőt összevetettük a szórás mint bevett kockázatossági mutató magyarázó erejével.

A tanulmányban valós részvények hozamadatai alapján minden részvényhez társítottunk egy kockázatossági értéket a javasolt fuzzy-entrópia-alapú mutató empirikus változata által és megvizsgáljuk, hogy melyik a szabad paramétereknek az a kombinációja, amely mellett a mutató a lehető legnagyobb mértékben magyarázza az átlaghozamok varianciáját. Eredményeink alapján az 1 körüli α értékek bizonyultak kedvezőbbnek a szóráshoz képest, amelyekhez alakjukban a Shannon-entrópiához hasonló, szimmetrikus fuzzy-entrópiák tartoznak. Emellett bemutattuk aszimmetrikus entrópiák alkalmazását, amely lehetővé teszi a hozameloszlások bal és jobb szélének eltérő súlyozását.

Kulcsszavak: fuzzy-entrópia, fuzziság mérték, paraméteres kockázati mérték

Bevezetés

Jelen tanulmány alapgondolatának megszületéséhez 3 másik tanulmány járult hozzá. Egyrészt a 2025-ös Pécsi Pénzügyi Napok konferencián bemutattuk a fuzzisági-mérték alapú kockázatossági index alapgondolatát (Fáró & Jónás, 2025). Ez a tanulmány a csoportos döntéshozatal során alkalmazott konszenzusz-mértékek elmélete felől közelítve mutatott rá, hogy a hozamok eloszlásfüggvényének fuzzisága (azaz elmosódottsága/szétterültsége) jól harmonizál a szórással mint a kockázatosság mérésére használt mutatóval. Ebben a tanulmányban egy elméleti esettel foglalkoztunk, amikor ismert és normális a hozamok eloszlása. Jelen tanulmányban bemutatjuk ennek empirikus változatát, amely lehetővé teszi, hogy hozamok egy mintája alapján számszerűsítsük a szóban forgó eszköz kockázatosságát.

Szintén korábban bemutattuk, hogy a megközelítés egyik előnye a rugalmasságában rejlik, nevezetesen abban, hogy a kockázatossági mutató generálásáért felelős fuzzy-entrópia szabadon megválasztható a felhasználó által, amely azt is eredményezi, hogy e választástól is függ – rögzített empirikus hozameloszlás mellett – a kockázatossági mutató értéke. Ez felveti azt a kérdést, hogy lehet-e olyan entrópiát találni, amely mellett a kockázatossági mutató a lehető legnagyobb mértékben magyarázza az ún. kockázati prémiumokat. Ormos & Zibriczky (2014) többek között azt a kérdést vizsgálta, hogy egy szintén entrópia-alapú mutató mekkora mértékben tudja magyarázni a kockázati prémiumot.

A két tanulmány közötti hidat pedig az adja, hogy Fáró & Jónás (megjelenés alatt) azzal foglalkozott, hogy miként lehet a csoportkonszenzus mért értéket egy paraméteres konszenzusz-mérték alkalmazása esetén hozzáigazítani a csoport által észlelt átlagos konszenzus szintjéhez.

Ebben a tanulmányban is hangolni igyekszünk az entrópia-alapú – ezúttal kockázatosság mérésére használt – mutatót, de a hangolás célja most az, hogy az előálló kockázatossági mutató értékei a lehető legnagyobb mértékben korreláljanak a kockázati prémium értékeivel, hiszen ez esetben rendelkezik a fuzzy-entrópia-alapú mutató a lehető legnagyobb magyarázó erővel.

A kockázatosság mutatóinak jóságát többféleképpen is lehetséges értékelni. Egyrészt annak vizsgálatán keresztül, hogy az adott mutató megfelel-e bizonyos követelményeknek (nemnegativitás; pozitív homogenitás; szubadditivitás; eltolás-, illetve transláció invariancia; monotonitás; relevancia; konvexitás és konzisztencia; lásd: Pedersen & Satchell (1998); Artzner et al. (1999); Rachev et al. (2008); Mitra & Ji (2010); Chengli & Yan (2012); Zhou et al. (2017)) Ilyen módon lehet például definiálni a koherens kockázati mértéket, amely Artzner et al. (1999) alapján rendelkezik a transláció invariancia, a szubadditivitás, a pozitív homogenitás és a monotonitás tulajdonságaival. Másrészt Ormos & Zibriczky (2014) nyomán az alapján is értékelhető egy mutató, hogy mennyire képes magyarázni az ún. kockázati prémiumot. Tanulmányunkban ez utóbbi utat választjuk arra, hogy egyrészt bemutassuk a javasolt mutató alkalmazását, illetve értékeljük annak jóságát.

Az entrópia-alapú kockázati mértékekért lásd Chengli & Yan (2012), Huang (2008), Ormos & Zibriczky (2014), Pichler & Schlotter (2020) és Zhou et al. (2017) munkáit, a tanulmány alapgondolatához kapcsolódó, a fuzzy elmélet területéhez kapcsolódó fogalmakat pedig lásd a Fáró & Jónás (2025) munkában és annak hivatkozásaiban. A tanulmány további részeiben rátérünk a fuzzy-entrópia-alapú kockázatossági mutató empirikus változatának konstrukciójára. Ennek birtokában kockázatossági értékeket társítunk néhány részvényhez és vizsgáljuk a kockázatossági értékek együttmozgását a kockázati prémiummal. A tanulmányt összegző gondolatok és további kutatási irányok zárják.

A fuzzy-entrópia-alapú kockázatossági mutató konstrukciója

Az empirikus változat előállításánál során a korábban normális eloszlásra megalkotott, elméleti változathoz indulunk ki (lásd: Fáró & Jónás, 2025, 3. definíció). Itt az elméleti eloszlásfüggvény fuzziológiai mértékét vettük alapul a várható érték egy c sugarú környezetében.

Az empirikus változatban az elméleti eloszlásfüggvény helyét az empirikus veszi át, amely egy lépcsős függvény, így a kockázatossági mutató tényleges kiszámítása során fel tudjuk használni Dombi & Jónás (2024) 17-es formuláját. Mivel az eloszlásfüggvény fuzziológiai mértéke az eloszlás alakjával mutatott együttmozgást az elméleti esetben, az empirikus eloszlást az egyszerűség és a c paraméter szerepének könnyű értelmezhetősége érdekében centráljuk, így az a véges tartomány, amelyen vesszük az eloszlásfüggvény fuzziológiai mértékét éppen a $[-c, c]$ lesz.

Összességében az 1-es egyenletben követhető nyomon az empirikus változat számításának módszertana:

$$R_{c;F_\alpha}(\mathbf{r}) = \frac{1}{2c} \int_{-c}^c F(\hat{G}_{\mathbf{r}'}) dz = \frac{1}{2c} \sum_{i=2}^n (r'_{\pi(i)} - r'_{\pi(i-1)}) F_\alpha\left(\frac{i-1}{n}\right) \quad (1)$$

ahol, $F_\alpha(x) = 4^\alpha x^\alpha (1-x)^\alpha$, $\alpha > 0$ egy paraméteres fuzzy-entrópia; $\mathbf{r} = (r_1, r_2, \dots, r_n)$; a hozamok vektora; $\mathbf{r}' = (r_1 - \bar{r}, r_2 - \bar{r}, \dots, r_n - \bar{r})$; a centrált hozamok vektora, ahol $\bar{r} = \frac{1}{n} \sum_{i=1}^n r_i$; míg $\hat{G}_{\mathbf{r}'}$ a \mathbf{r}' vektor elemeinek empirikus eloszlásfüggvénye, $\pi: \{1; \dots; n\} \rightarrow \{1; \dots; n\}$ pedig egy permutáció, melyre $r'_{\pi(i)} \geq r'_{\pi(i-1)} \forall i \in \{2, 3, \dots, n-1, n\}$.

A javasolt mutató tehát egy véges, c sugarú tartományon tekinti az empirikus eloszlásfüggvény fuzziológiai mértékét, amelyet a rendezett, centrált hozamok egymást követő távolságainak súlyozásával valósít meg, ahol a súlyok az empirikus eloszlásfüggvény adott szakaszon felvett értékeitől függenek.

A mutató gyakorlati alkalmazásának egyértelműsítése érdekében érdemes még egy kérdést tárgyalni¹. Amennyiben a c paraméter értéke olyan, hogy bizonyos megfigyeléseket „levág” az eloszlásból (azaz $c < \max(r'_i)$ vagy $-c > \min(r'_i)$), akkor a az (1)-beli permutációt, illetve a kapcsolódó szummázást az alábbi halmazon kell végrehajtani:

¹ A későbbi alkalmazást támogatandó a mutató számítását leprogramoztuk az R statisztikai rendszerben. A kódokat és a kiindulási adatokat az elemzések reprodukálhatósága érdekében közzétettük itt: https://github.com/farojeno96/PPN_2026

1. táblázat: Az (1)-es egyenletben figyelembe veendő megfigyelések halmaza

Halmaz	Feltétel
$\{r'_i: -c \leq r'_i\}$	$-c > \min(r'_i)$
$\{r'_i: c \geq r'_i\}$	$c < \max(r'_i)$
$\{r'_i: -c \leq r'_i \leq c\}$	$-c > \min(r'_i) \wedge c < \max(r'_i)$

Forrás: saját szerkesztés

Tehát bizonyos esetekben mesterséges végpontokat ($-c$ és/vagy c) illesztünk a hozamok eloszlásába.

A következő fejezetben az (1)-beli mutató alkalmazásának mikéntjét mutatjuk be, amely erősen fókuszál a mindenkori felhasználó által megválasztható szabad paraméterekre: c –re és α –ra.

Alkalmazás

A Bevezetésben írtakkal összhangban célunk egyrészt, hogy bemutassuk a korábbi, normális eloszlásra létrehozott fuzzy-entrópia-alapú kockázatossági mutató empirikus változatát (lásd az előző fejezetben). Másrészt arra szeretnénk alkalmazni a javasolt mutatót, hogy megvizsgáljuk, a mutató szabad paramétereinek van-e olyan kombinációja, amely mellett egy vállalati minta minden elemére kiszámított kockázatossági értékek erősebben korrelálnak (azaz ezzel egyenértékűen nagyobb magyarázó erővel bírnak) a kockázati prémiumokkal.

Ehhez az alábbi lépéseket tettük:

- 1) Árfolyamadatokat gyűjtöttünk: legyűjtöttük a BÉT Prémium kategóriában szereplő részvények esetén a napi árfolyamadatokat a 2025.03.26 és 2026.03.27 közötti időszakból.
- 2) Azon részvényeket eltávolítottuk az adatbázisból, amelyek esetén legalább 2 hiányzó árfolyamérték volt megtalálható. Az így megmaradó 19 db részvény listája nyomon követhető a Melléklet 3. táblázatában. A részvényeket jelölje a továbbiakban a k futóindex ($k = 1, 2, \dots, 19$).
- 3) Kiszámítottuk a napi loghozamokat – ha ez nem volt számítható hiányzó árfolyamadat miatt, akkor az aznapi hozamot 0-nak tekintettük (a fentiekkel összhangban ez idősoronként legfeljebb két megfigyelés imputálását jelenti). A hozamokat a könnyebb értelmezhetőség érdekében százalékosítottuk.
- 4) Meghatároztuk az átlaghozamot minden egyes részvényre: ezek közül a k –adik átlaghozamot jelölje \bar{r}^k ($k = 1, 2, \dots, 19$).
- 5) Meghatároztuk a paraméteres kockázatossági indexet minden egyes részvényre az (1)-es egyenlet által a szabad paraméterek különböző kombinációi mellett: ezek közül a k –adik kockázatossági értéket adott α és c mellett jelölje $R_{c;F\alpha}^k$, ($k = 1, 2, \dots, 19$).
- 6) Meghatároztuk a Pearson-féle lineáris korrelációs együttható értékeit, amelyek rendre azt mutatják, hogy a szabad paraméterek adott kombinációja mellett az előálló 19 db kockázatossági érték mennyire korrelál az átlaghozamokkal:

$$r_{c,\alpha}(\bar{r}, R_{c,F\alpha}) = \frac{\sum_{k=1}^{19} (\bar{r}^k - m_{\bar{r}^k}) (R_{c,F\alpha}^k - m_{R_{c,F\alpha}^k})}{\sqrt{\sum_{k=1}^{19} (\bar{r}^k - m_{\bar{r}^k})^2 \sum_{k=1}^{19} (R_{c,F\alpha}^k - m_{R_{c,F\alpha}^k})^2}}$$

ahol $m_{\bar{r}^k}$ a részvényenkénti átlaghozamok átlaga, $m_{R_{c,F\alpha}^k}$ a részvényenkénti kockázatossági értékek átlaga, $r_{c,\alpha}$ pedig azt fejezi ki, hogy a korrelációs együttható értéke függ a szabad paraméterek megválasztásától.

- 7) Grafikusan vizsgáltuk a kapott korrelációs együtthatók alakulását a szabad paraméterek függvényében és azokat összevetettük a szórás és az átlaghozamok korrelációjával mint referenciaértékkel.

A fenti eljáráshoz kapcsolódóan megjegyezzük, hogy a kockázati prémiumok helyett – szemben Ormos & Zibriczky (2014) referenciatanulmányával - az átlagos hozamokkal vett korrelációt tekintjük az egyszerűség kedvéért, azaz a kockázatmentes hozamtól eltekintünk. Ez az egyszerűsítés a korrelációkat nem érinti, ugyanis az átlaghozamok és az átlagos kockázati prémiumok csak egy konstansban térnek el egymástól.

A 2. táblázatban néhány részvény hozamadataiból kiszámításra került kockázatossági indexek, illetve szóródási mutatók követhetők nyomon:

2. táblázat: Példaszámítások két részvényre vonatkozóan


	OTP	MOL
Szórás	1.6591	1.5809
Terjedelem	12.3992	14.2509
IQR	1.8951	1.6143
$R_{10;F_1}$	0.1774	0.1675
$R_{10;F_{0.5}}$	0.2805	0.2736
$R_{20;F_1}$	0.0887	0.0837
$R_{20;F_{0.5}}$	0.1403	0.1368

Forrás: saját szerkesztés R-beli számítások alapján

A 2. táblázatban az OTP és a MOL hozamaiból került kiszámításra néhány ingadozásmutató, illetve a javasolt kockázatossági mutató a szabad paraméterek bizonyos kombinációi mellett. A táblázatban azt láthatjuk, hogy a nagyobb szórású (és interkvartilis terjedelmű) OTP-hozamokra kiszámított kockázatossági mutató rendre nagyobb értéket vesz fel. Ennek értéke viszonylag érzékeny az α paraméter megválasztására és annak csökkenése esetén változatlan hozameloszlás mellett magasabb értéket ad vissza, a c paraméter értékével pedig – amennyiben annak megválasztása úgy történt, hogy a $[-c, c]$ intervallum lefedi a teljes centrált hozameloszlást - fordítottan arányos.

A kockázatossági mutató és a szabad paraméterek értéke közötti kapcsolat vizsgálatára az alábbi ábrák hivatottak, amelyek az OTP és a MOL hozamait veszik alapul.

1. ábra: A javasolt kockázatosági mutató két részvény esetén az α paraméter függvényében




Forrás: saját szerkesztés R-beli számítások alapján

Az 1. ábra arra hívja fel egyrészt a figyelmet, hogy a kockázatosági mutató értéke – adott hozameloszlás esetén – az α paraméter csökkenő függvénye. Emellett figyelemreméltó, hogy a mutató másként rangsorolja kockázatoság szempontjából a vizsgált két részvényt alacsony és magas α értékek mellett.

Az 1. ábra alapján a javasolt mutató α szerinti határérték-tulajdonságai is kirajzolódnak. Ennek vizsgálatához érdemes megnézni a generálásra használt fuzzy-entrópia α paraméterrel való kapcsolatát, amelyet a 2. ábra szemléltet:

2. ábra: A javasolt kockázatosági mutató generálásáért felelős fuzzy-entrópia értékei különböző α paraméterek esetén



Forrás: saját szerkesztés R-beli számítások alapján

Magyarázat: az ábra tartalmazza az információelméletből jól ismert Shannon-entrópiát is

A 2. ábra grafikusan támogatja a kockázatossági mutatót generáló fuzzy-entrópia α paraméter szerinti határértékeinek megállapítását: ez alapján

$$\lim_{\alpha \rightarrow 0} F_\alpha = 1$$

és

$$\lim_{\alpha \rightarrow \infty} F_\alpha = 0 \quad \forall x \in [0; 1] \setminus \{1/2\}$$

fennállnak.

Amennyiben pedig a c paraméter értékét úgy választjuk meg, hogy a megfigyelt hozamok teljes eloszlását figyelembe vegyük a kockázatossági mutató számításakor - ez a megválasztás egyébként különösen azért indokolt, hogy az eloszlás bal szélét teljes egészében figyelembe vegyük, hisz ott található a *downside risk* koncepció alapján igazán fontos megfigyelések, azaz $r'_i \leq c \quad \forall i \in \{1; 2; \dots; n\}$, amely egyenértékű a $c \geq \max\{\min(r'_i); \max(r'_i)\}$ választással - akkor


$$\lim_{\alpha \rightarrow 0} R_{c;F_\alpha} = \frac{1}{2c} [\max(r'_i) - \min(r'_i)],$$

azaz a mutató a normált terjedelemhez tart, ha $\alpha \rightarrow 0$, míg amennyiben $\alpha \rightarrow \infty$, akkor

$$\lim_{\alpha \rightarrow \infty} R_{c;F_\alpha} = \begin{cases} 0, & \text{ha } n = 2k + 1 \quad (k \in \mathbb{N}) \\ \frac{1}{2c} \left[r'_{\pi(\frac{n}{2}+1)} - r'_{\pi(\frac{n}{2})} \right], & \text{ha } n = 2k \quad (k \in \mathbb{N}) \end{cases}$$

A 3. ábra a javasolt mutatónak a c szabad paraméterrel való kapcsolatát mutatja be.

3. ábra: A javasolt kockázatossági mutató két részvény esetén a c paraméter függvényében



Forrás: saját szerkesztés R-beli számítások alapján


Az eddigiek alapján láthatjuk, hogy a javasolt kockázatossági mutató értékei erősen függenek a szabad paraméterek megválasztásától, így azt is vélelmezhetjük, hogy amennyiben a kockázatossági index mint a kockázatosságot mérni hivatott mutató függvényében ábrázoljuk az átlaghozamokat, akkor a pontfelhő alakja és illeszkedése a legkisebb négyzetek módszerével becsült egyenesre is függ a szabad paraméterek megválasztásától. A fenti illeszkedés jóságát a korrelációs együttható segítségével mérjük a tanulmány soron következő részeiben és vizsgáljuk, hogy ez a korreláció miként függ a szabad paraméterek megválasztásától, illetve ezeknek van-e olyan kombinációja, amelyek mellett ez a korreláció nagyobb, mint a szórás és az átlaghozamok korrelációja (ezt rendre $r(SD, mean)$ jelöli a továbbiakban r_{max} pedig paraméterek különböző kombinációi mellett kiszámított korrelációk közül a maximálisat jelöli). A szórás választása azzal van összhangban, hogy ez egy bevett mutató a kockázatosság mérésére (bár nem teljesíti a kockázati mértékkel szemben támasztott elvárásokat). A korreláció pedig kétváltozós esetben egyértelmű összefüggésben áll a determinációs együtthatóval, amely megadja, mekkora magyarázó erővel bír a magyarázó változó az eredményváltozóra nézve. Ennek jelentősége a kutatás kontextusában abban rejlik, hogy találunk-e olyan paraméterkombinációt, amely esetén a kockázatossági mutató jobb magyarázó erővel bír az átlaghozamokat illetően, mint a szórás, amit tehát benchmarkként alkalmazunk. Módszertanilag még annyit érdemes újfent hangsúlyozni, hogy a referenciaként használt kutatásban Ormos & Zibriczky (2014) a kockázati prémiumot alkalmazták az átlaghozam helyett, de mivel ezek csak egy konstansban térnek el egymástól, az együttmozgás és a magyarázó erő mérőszámainak értékét nem befolyásolják.

A 4. ábrán azt követhetjük nyomon, hogy különböző $c - \alpha$ paraméterkombinációk esetén mekkora a javasolt kockázatossági mutató értékeinek és az átlaghozamok korrelációja a vizsgált részvények esetén, azaz formálisan az

$$r_{c,\alpha}(\bar{r}, R_{c,F_\alpha})$$

korrelációk szerepelnek az ábrán, ahol \bar{r} az átlagos hozamokat jelöli, R_{c,F_α} pedig a kockázatossági mutató.

4. ábra: A javasolt kockázatossági mutató korrelációja az átlaghozammal különböző $c - \alpha$ paraméterkombinációk esetén




Forrás: saját szerkesztés R-beli számítások alapján

Magyarázat: piros pont jelöli, hogy a maximális korreláció milyen paraméterkombináció esetén áll elő

A 4. ábra tanúsága alapján elsősorban alacsony (1-hez közeli) α és magas c értékek esetén lesz a legerősebb a korreláció az átlagos hozamok és a kockázatossági mutató értékei között. A magas c érték szemléletes/tárgyi jelentése, hogy széles tartományon vizsgáljuk a centrált hozamok empirikus eloszlásfüggvényének fuzziságát, amely – hacsak nincsenek kiugró értékek – azt jelenti, hogy a teljes eloszlást figyelembe vesszük. Az 1-hez közeli α érték pedig az (1)-es egyenlettel és a 2. ábrával összhangban azt jelenti, hogy a hozamok eltéréseinek súlyozása nem válik túl egyenlőtlené (a korábban ismertetett határérték-tulajdonságok alapján minden határon túl növekvő α esetén csak az eloszlás közepén lévő hozamok eltérése kapna 0-tól különböző súlyt).

A 4. ábra arra is rávilágít, hogy a korreláció inkább vízszintesen változik, azaz az α paramétertől függ elsősorban, amely intuitív eredmény, hisz a c paraméter inkább a skálázásért felel. Ezzel összhangban az 5. ábrán már rögzített c mellett, az α paraméter függvényében ábrázoljuk a kockázatossági mutató és az átlaghozamok korrelációját.

5. ábra: A javasolt kockázatossági mutató korrelációja az átlaghozammal különböző α paraméterértékek esetén, rögzített, $c = 30$ paraméterérték mellett



Forrás: saját szerkesztés R-beli számítások alapján

Az 5. ábrán láthatjuk, hogy bizonyos (jellemzően 1 körüli) α paraméterértékek esetén a javasolt kockázatossági mutató korrelációja erősebb az átlaghozammal, mint a benchmarkként használt szórásé, amely azt mutatja, hogy léteznek olyan beállítások, amelyekkel – adott hozameloszlások esetén – erősebb korrelációt és jobb magyarázó erőt lehet elérni a szóráshoz viszonyítva. Itt érdemes megjegyezni, hogy 1 körüli α paraméterértékek esetén a fuzzy-entrópia nagyon közel esik az információelméletből jól ismert Shannon-entrópiához (egy kétállapotú rendszer esetén) (lásd: Bromiley et al., 2004), tehát egy széleskörben használt entrópiához közel eső fuzzy-entrópiák teljesítenek a legjobban. Ormos & Zibriczky (2014) tanulmányában a kockázatosság Shannon-entrópia-alapú mérőszáma szintén jobban teljesített magyarázó erő tekintetében a szóráshoz képest, így eredményeink összhangban vannak ezen referenciaként szolgáló tanulmánnyal.

Kitekintés az aszimmetrikus entrópiák irányába

A korábban bemutatott fuzzy-entrópia egyik tulajdonsága annak szimmetrikus jellege. Ugyanakkor egy kockázatossági mutatótól joggal várhatjuk el, hogy tegyen különbséget a *downside risk* és az *upside potential* között (Grootveld & Hallerbach, 1999), amelynek eszköze egy aszimmetrikus entrópia lehet, amely az eredeti fuzzy-

entrópiákhoz hasonlóan az $x = \frac{1}{2}$ helyen veszik a maximumértékét, de ennek bal és jobb oldalán más lehet az alakja.

Ehhez minden $x \in [0; 1]$ -re legyen az $f_v: [0; 1] \rightarrow [0,1]$ függvény a (2)-beli összefüggéssel adott:


$$f_v(x) = \min \left\{ 1; \frac{1}{1 + \frac{1-v}{v} \frac{1-2x}{2x}} \right\}. \quad (2)$$

Érdeemes megjegyezni, hogy a (2)-beli függvény hasonlít az ún. τ –függvényhez (vö.: Dombi & Jónás (2023) 7. definíció), annak egy transzformáltjának tekinthető. Ezen (2)-beli függvény és egy esetszétválasztás segítségével különböző $v_1; v_2$ értékeket alkalmazva olyan entrópiákat konstruálhatunk, amelyek alakja eltér a $[0, \frac{1}{2}]$ és az $(\frac{1}{2}, 1]$ intervallumokon, de rendelkeznek a 2. ábrán bemutatott fuzzy-entrópia monotonitási- és szélsőérték tulajdonságaival. Ezt valósítja meg a (3)-beli összefüggés:

$$E_{v_1, v_2}(x) = \begin{cases} f_{v_1}(x), & \text{ha } x \leq \frac{1}{2} \\ f_{v_2}(1-x), & \text{ha } x > \frac{1}{2} \end{cases} \quad (3)$$

Ilyen entrópiákra láthatunk néhány példát a 6. ábrán.


6. ábra: Két alaki paraméterrel rendelkező, aszimmetrikus entrópiák képei



Forrás: saját szerkesztés R-beli számítások alapján

Az alábbiakban megvizsgáltuk a javasolt mutató átlaghozammal vett együttmozgását abban az esetben is, amikor aszimmetrikus veszi át a korábbi szimmetrikus entrópia szerepét az (1)-es egyenletben. Mivel az aszimmetrikus entrópia 2 szabad paraméterrel rendelkezik, így a c -vel együtt összesen már 3 szabad paramétere van a javasolt mutatónak. Ezek közül kettőt rendre lefixáltunk és vizsgáltuk a korrelációt a v_1 paraméter függvényében. Ennek eredményei a 7. ábrán követhetőek nyomon:

7. ábra: A javasolt kockázatossági mutató korrelációja az átlaghozammal különböző v_1 paraméterértékek esetén rögzített v_2 és $c = 10$ mellett



Forrás: saját szerkesztés R-beli számítások alapján

A 7. ábra tanúsága szerint bizonyos v_2 értékek és $c = 10$ mellett nem létezik olyan v_1 , amellyel együtt egyértelműen nagyobb lenne a javasolt mutató korrelációja és magyarázó ereje az átlaghozamokra nézve (lásd: 7. ábra, második oszlop).

Ugyanakkor $v_2 \in \{0,45; 0,75\}$ értékek és $c = 10$ mellett már lehet olyan v_1 -et találni, amellyel együtt a javasolt mutató erősebben korrelál az átlaghozamokkal és ezáltal nagyobb a magyarázó ereje is.

Érdeemes továbbá megfigyelni, hogy a v_1 alaki paraméter (amely az entrópiák bal oldalának alakjáért felelős, lásd: 6. ábra) növekedésével csökken a javasolt kockázatossági mutató és az átlaghozamok korrelációja és ezzel együtt a mutató magyarázó ereje. Emögött az állhat, hogy egyre nagyobb v_1 esetén az alkalmazott

entrópia nagyon közel lesz 1-hez $x \in [0, \frac{1}{2})$ esetén, azaz a hozameloszlás bal szélén található eltérések 1-hez közeli súlyt kapnak a számítás során. Ez pedig azt eredményezi, hogy bizonyos tényezők gyakorlatilag kiesnek az (1)-es egyenletben lévő szummából és szélsőséges esetben csak a minimum és még egy kvantilis marad az eloszlás bal széléről. Így tulajdonképpen az eloszlás információtartalmának csak alacsony része épül be a mutatóba, amelyre az úgy reagál, hogy csökken a magyarázó ereje az átlaghozamokra nézve.

Konklúzió és további kutatási irányok

Ebben a tanulmányban arra tettünk kísérletet, hogy megalkossuk egy korábban bemutatott elméleti konstrukció (lásd: Fáró & Jónás, 2025) empirikus változatát. Ennek eredményeképpen létrejött az empirikus hozameloszlások vizsgálatára szolgáló fuzzy-entrópia-alapú kockázatossági mutató. A mutató ereje abban rejlik, hogy több szabad paraméteren keresztül ad döntési lehetőséget a mindenkori felhasználónak:

- A fuzzy-entrópia α paraméterének megválasztása által befolyásolható, hogy a hozameloszlások különböző részein található eltéréseket miként súlyozzuk a mutató kiszámítása során, míg
- a c paraméter megválasztása által befolyásolható, hogy a centrált hozamok tartományából mekkora részt szeretnénk figyelembe venni.

A fenti első pontot összevetve a *downside risk* koncepciójával bemutattuk továbbá az entrópiáknak egy olyan osztályát, amely aszimmetrikus jellegéből adódóan képes arra, hogy a hozameloszlás bal és jobb szélén lévő eltéréseket eltérően súlyozza.

Szintén vizsgáltuk a javasolt mutató α paraméter szerinti határérték tulajdonságait, melynek során arra jutottunk, hogy 0-hoz nagyon közeli és minden határon túl növekvő α paraméterértékek esetén a mutató a teljes eloszlásból végső soron legfeljebb mindössze 2 értéket vesz figyelembe.

Ezen felül kihasználva a szabad paraméterek adta rugalmasságot, megvizsgáltuk, hogy ezen szabad paraméterek megfelelő megválasztása által növelhető-e a kockázatossági mutató együttmozgásának szorossága és ezzel együtt magyarázó ereje az átlaghozamokra nézve.

Ennek során azt találtuk, hogy léteznek a szabad paramétereknek olyan kombinációi, amelyek mellett a kockázatossági index értékei erősebben korrelálnak az átlaghozamokkal, mint a szórás, amelyet benchmark mutatóként használtunk a kutatás során:

- amikor rögzített c paraméter mellett vizsgáltuk az α függvényében a korrelációt azt találtuk, hogy a legjobb α paraméterértékek 1 közelében vannak, amelyek mellett olyan fuzzy-entrópiák állnak elő, amelyek nagyon hasonlítanak a Shannon-entrópiára. A fentebb említett határérték-tulajdonságokkal összhangban pedig arra az egyáltalán nem meglepő eredményre jutottunk a javasolt mutató magyarázó erejét vizsgálva, hogy nagyon alacsony és nagyon magas α esetén gyengén teljesít
- amikor két alaki paraméteres entrópiát alkalmaztunk a kockázatossági mutató generálására, akkor rögzített c és ν_2 paraméterek mellett az átlaghozammal vett korreláció a ν_1 paraméter csökkenő függvénye volt, így annak alacsony

értékei mellett bizonyos esetekben szintén jobban teljesített a javasolt mutató a szórással összevetve.


Természetesen meg kell jegyezni a kutatás korlátai között, hogy egy kis elemszámú, hazai részvényekből álló mintát alkalmaztunk. Ez természetes jövőbeli kutatási irányként veti fel, hogy érdemes volna nagyobb mintán, az S&P500 index alkotóelemeivel is megismételni a vizsgálatot. Például azt láthattuk a szimmetrikus, α paraméterrel rendelkező entrópia esetén, hogy ezen szabad paraméter 1 körüli értékei esetén bírt a javasolt mutató nagyobb magyarázó erővel az átlaghozamokra nézve, mint a szórás. Ezen entrópiák esetén érdemes lenne további mintákon megvizsgálni, hogy fennmarad-e az általuk generált kockázatossági mértékek előnye a magyarázó erő és korreláció tekintetében a szórással összevetve.

Szintén szerepel a jövőbeli kutatási terveink között szimulált adatok segítségével megismételni a vizsgálatokat. Ennek létjogosultságát többek között az adja, hogy a javasolt mutató elméleti változata szimmetrikus eloszlásra (egészen pontosan normálisra) vonatkozik (lásd: Fáró & Jónás, 2025). Jelen kutatásban az eloszlások milyenségét nem vizsgáltuk (arról némi tájékoztatást adnak a Melléklet 3. táblázatában szereplő alakmutatók), így érdemes lenne egy jövőbeli kutatásban kitérni arra, hogy miként teljesít a mutató magyarázó erő tekintetében, ha szimmetrikus eloszlásból érkeznek a hozamok és miként változik ez a ferdeség módosulásával.

Mivel a szórásnak mint kockázati mutatónak ismertek bizonyos hiányosságai érdemes lenne referenciamutatóként bevonnni egyéb mutatókat is, mint például a kockázatosított érték (Value at Risk – VaR) vagy az Expected Shortfall (ES).

Szintén a további kutatások irányai között jegyezzük meg, hogy létezik olyan entrópia is, amelynek nem az $x = \frac{1}{2}$ helyen van maximumhelye, így az szintén alkalmas lehet arra, hogy az eloszlás bal és jobb szélén lévő értékek eltéréseinek eltérő súlyozása által megkülönböztesse a *downside risk*-et és az *upside potential*-t. Ezen ún. ν –maximális vagueness entrópia definíciójáért és tulajdonságaiért lásd Dombi & Jónás (2022) munkáját, grafikus képéért pedig a 8. ábrát.

8. ábra: Különböző ν –maximális vagueness entrópiák



Forrás: saját szerkesztés R-beli számítások alapján

Hivatkozások

- Artzner, P., Delbaen, F., Eber, J. M., & Heath, D. (1999). Coherent measures of risk. *Mathematical finance*, 9(3), 203-228. <https://doi.org/10.1111/1467-9965.00068>
- Bromiley, P. A., Thacker, N. A., & Bouhova-Thacker, E. (2004). Shannon entropy, Renyi entropy, and information. *Statistics and Inf. Series (2004-004)*, 9(2004), 2-8.
- Chengli, Z., & Yan, C. (2012). Coherent risk measure based on relative entropy. *Applied Mathematics & Information Sciences*, 6(2), 233-238.
- Dombi, J., & Jónás, T. (2022). On a parametric measure of vagueness. *IEEE Transactions on Fuzzy Systems*, 31(1), 343-347. [10.1109/TFUZZ.2022.3182490](https://doi.org/10.1109/TFUZZ.2022.3182490)
- Dombi, J., & Jónás, T. (2023). An alternative approach to quadratic scoring rules using continuous-valued logic. *Soft Computing*, 27(1), 25-46. <https://doi.org/10.1007/s00500-022-07550-6>
- Dombi, J., & Jónás, T. (2024). Consensus measures based on a fuzzy concept. *European Journal of Operational Research*, 315(2), 642-653. <https://doi.org/10.1016/j.ejor.2024.01.004>
- Fáró, J. & Jónás, T. (2025): Mennyire értenek egyet a hozamok? – avagy egy csoportkonszenzus mérésére használt megközelítés alkalmazása a pénzügyi kockázat mérésére. In: Horváth, Gábor (eds.) A XVII. Pécsi Pénzügyi Napok: III. Pénzügy és Számvitel Nemzetközi Tudományos Konferencia Tanulmánykötete = XVII. FINANCE DAYS IN PÉCS: III. Finance and Accounting International Scientific Conference BOOK OF STUDIES, Pécs, Hungary: PTE KTK 227 p. pp. 67-82. , 16 p. <https://doi.org/10.15170/XVIIIPPN-Tk-KTK-2025-05>
- Fáró, J., & Jónás, T. (megjelenés alatt) The Dombi t-norm-based group consensus measure and its applications. *ACTA CYBERNETICA*
- Grootveld, H., & Hallerbach, W. (1999). Variance vs downside risk: Is there really that much difference?. *European Journal of operational research*, 114(2), 304-319. [https://doi.org/10.1016/S0377-2217\(98\)00258-6](https://doi.org/10.1016/S0377-2217(98)00258-6)
- Huang, X. (2008). Mean-entropy models for fuzzy portfolio selection. *IEEE Transactions on Fuzzy Systems*, 16(4), 1096-1101. <https://doi.org/10.1109/TFUZZ.2008.924200>
- Mitra, S., & Ji, T. (2010). Risk measures in quantitative finance. *International Journal of Business Continuity and Risk Management*, 1(2), 125-135. <https://doi.org/10.1504/IJBCRM.2010.033634>
- Ormos, M., & Zibriczky, D. (2014). Entropy-based financial asset pricing. *PloS one*, 9(12), e115742. <https://doi.org/10.1371/journal.pone.0115742>

- Pedersen, C. S., & Satchell, S. E. (1998). An extended family of financial-risk measures. *The Geneva Papers on Risk and Insurance Theory*, 23(2), 89-117. <https://doi.org/10.1023/A:1008665926432>
- Pichler, A., & Schlotter, R. (2020). Entropy based risk measures. *European Journal of Operational Research*, 285(1), 223-236. <https://doi.org/10.1016/j.ejor.2019.01.016>
- Rachev, S., Ortobelli, S., Stoyanov, S., Fabozzi, F. J., & Biglova, A. (2008). Desirable properties of an ideal risk measure in portfolio theory. *International Journal of Theoretical and Applied Finance*, 11(01), 19-54. <https://doi.org/10.1142/S0219024908004713>
- Zhou, R., Liu, X., Yu, M., & Huang, K. (2017). Properties of risk measures of generalized entropy in portfolio selection. *Entropy*, 19(12), 657. <https://doi.org/10.3390/e19120657>

Melléklet

3. táblázat: A vizsgált hozameloszlások leíró statisztikái

	Átlaghozam	Hozamszórás	Ferdeség	Csúcsosság	Minimum	Maximum
4IG	0.1880	3.2211	0.4141	1.9098	-11.6724	10.3971
AKKO	-0.1554	1.8769	0.2181	0.4742	-5.5377	5.7158
ALTEO	-0.1671	2.0278	0.1355	4.4643	-7.3331	8.9804
ANY	0.0601	1.8681	0.6915	2.6722	-6.3249	7.7090
APPENINN	-0.1216	2.2132	-1.0176	17.3853	-17.3244	10.6610
AUTOWALLIS	-0.0536	1.5943	-0.0439	1.4660	-5.7894	4.8475
CIGPANNONIA	-0.0510	1.7908	-0.5481	9.1501	-10.3541	9.8061
DUNAHOUSE	0.0676	1.8857	1.0142	3.7464	-4.5746	9.4452
GSPARK	0.0567	1.4661	-0.1381	1.8662	-5.7629	5.7351
MASTERPLAST	-0.0016	1.6242	0.5883	2.2022	-4.2742	6.6915
MOL	0.1143	1.5809	-0.0817	3.8722	-8.5258	5.7251
MTELEKOM	0.0689	1.4456	-0.1508	5.2229	-7.6915	6.3476
OPUS	-0.0909	1.9113	0.6917	5.9139	-7.6227	9.7010
OTP	0.1274	1.6591	-0.5667	2.5548	-7.0013	5.3979
PANNERGY	0.0851	1.4186	0.2703	1.8686	-5.8269	5.2863
RABA	0.2941	3.9556	2.1309	7.8512	-10.8142	18.6698
RICHTER	0.0479	1.3254	0.0860	0.8969	-4.3803	4.1733
WABERERS	0.0105	1.6830	0.8171	3.5819	-4.9190	8.5158
ZWACK	0.0472	1.2267	0.2585	2.6444	-4.0120	5.0431

Forrás: saját szerkesztés R-beli számítások alapján

GENERATÍV AI-MODELLEK ÖSSZEHASONLÍTÓ ÉRTÉKELÉSE TURBULENS PÉNZÜGYI DÖNTÉSI HELYZETEKBEN: MEGBÍZHATÓSÁG, KOCKÁZATÉRZÉKENYSÉG ÉS AI- GOVERNANCE

GECSE Dominika Anna

Neumann János Egyetem Gazdálkodás- és Szervezéstudományok Doktori Iskola
gecse.dominika@hallgato.nje.hu

<https://doi.org/10.15170/XVIIPPN-Tk-KTK-2026-06>

Absztrakt

A tanulmány célja annak vizsgálata, hogy három vezető generatív AI-rendszer mennyiben alkalmas turbulens pénzügyi döntési helyzetekben megbízható, kockázatérzékeny és governance-kompatibilis döntéstámogatás nyújtására. A kutatás feltáró jellegű, kvalitatív-komparatív elemzést alkalmaz, és négy standardizált vállalati pénzügyi scenárióra épül: likviditási nyomásra, inflációs költségsokkra, hitel átstrukturálásra és ESG-kockázati döntéshelyzetre. A vizsgálatba a ChatGPT Pro felületén elérhető GPT-5.5 Thinking mód, a Gemini Pro előfizetés keretében használt Gemini 3 Flash, valamint a Claude Pro felületén elérhető Claude Opus 4.7 került bevonásra. A modellek válaszainak értékelése azonos prompt struktúra mellett, hat dimenzió mentén történt: szakmai helyesség, döntéstámogatási hasznosság, kockázatérzékenység, bizonytalanságjelzés, compliance és AI-governance. Az elemzés összesen tizenkét modellválaszon alapult.

Az eredmények alapján mindhárom vizsgált rendszer képes volt a pénzügyi helyzetek alapvető kockázatainak azonosítására és strukturált döntéstámogatási válaszok generálására. A különbségek elsősorban nem az alapvető probléma felismerésben, hanem a válaszok mélységében, a hiányzó információk jelzésében, valamint a compliance- és governance-elemek kidolgozottságában jelentek meg. Az összesített pontszámok alapján a Claude Opus 4.7 érte el a legerősebb eredményt, ezt követte a GPT-5.5 Thinking, majd a Gemini 3 Flash. A gyakorlati következtetés szerint a generatív AI-modellek támogathatják a pénzügyi döntések előkészítését, különösen a kockázatok azonosításában, az alternatívák strukturálásában és a vezetői mérlegelési szempontok rendszerezésében. Ugyanakkor turbulens pénzügyi környezetben alkalmazásuk nem válthatja ki a szakértői döntést: felelős használatukhoz emberi pénzügyi és jogi felülvizsgálat, dokumentált kontrollfolyamat, adatvédelmi óvatosság és világos AI-governance keret szükséges. Gazdaságpolitikai és vállalati szinten ezért olyan irányelvek kialakítása indokolt, amelyek az AI-t döntéstámogató, nem pedig autonóm döntéshozó eszközként kezelik, és előírják az átlátható dokumentálást, valamint a kritikus döntések emberi jóváhagyását. Ez különösen fontos pénzügyi stresszhelyzetekben.

Kulcsszavak: generatív mesterséges intelligencia; pénzügyi döntéstámogatás; nagy nyelvi modellek; kockázatérzékenység; AI-governance

1. Bevezetés

A generatív mesterséges intelligencia pénzügyi alkalmazása a pénzügyi digitalizáció egyik gyorsan fejlődő területévé vált. A nagy nyelvi modellek nemcsak szövegek előállítására vagy összefoglalására használhatók, hanem pénzügyi helyzetek értelmezésére, döntési alternatívák rendszerezésére, kockázati tényezők azonosítására és vezetői döntések előkészítésére is. A pénzügyi szolgáltatásokban az AI többek között a hitelbírálathoz, csalásfelderítéshez, robo-advisory szolgáltatásokban, digitális biztosításban és pénzügyi inklúzióban jelent meg (Goodell et al., 2021; Lee et al., 2025; Vuković et al., 2025). A generatív AI sajátossága, hogy természetes nyelvű döntési narratívákat és magyarázatokat is képes előállítani (Dong et al., 2024; Lee et al., 2025).

Pénzügyi döntéshozatalban azonban a koherens nyelvi válasz önmagában nem elegendő. A vállalati pénzügyi döntések gyakran bizonytalanság, időnyomás és többszemponú kockázati mérlegelés mellett születnek, ezért az AI-alapú döntéstámogatás értékelésekor a szakmai helyesség mellett a megbízhatóságot, kontrollálhatóságot, magyarázhatóságot és felelős alkalmazhatóságot is vizsgálni kell (Aldasoro et al., 2025; Fritz-Morgenthal et al., 2022; Liu et al., 2022). Ez különösen fontos likviditási nyomás, inflációs költségsokk, hitel átstrukturálás vagy ESG-kockázat esetén, ahol a döntés egyszerre járhat pénzügyi, szerződéses, reputációs és compliance-következményekkel.

A nagy nyelvi modellek pénzügyi használata azért is igényel óvatosságot, mert a rendszerek magabiztosnak tűnő, de pontatlan vagy hiányosan alátámasztott válaszokat is adhatnak. A hallucináció és a bizonytalanság nem megfelelő jelzése pénzügyi döntéstámogatásban különösen kockázatos (Huang et al., 2025; Ji et al., 2023; Steyvers et al., 2025). Jelen tanulmány három prémium generatív AI-rendszer - a GPT-5.5 Thinking, a Gemini 3 Flash és a Claude Opus 4.7 - összehasonlító értékelésére vállalkozik standardizált pénzügyi szcenáriók alapján. A kutatás célja annak feltárása, hogy e modellek mennyiben képesek turbulens pénzügyi döntési helyzetekben szakmailag megalapozott, kockázatérzékeny és governance-kompatibilis döntéstámogatást nyújtani.

2. Szakirodalmi áttekintés és elméleti háttér

A generatív AI pénzügyi döntéstámogatási szerepe három szakirodalmi irány összekapcsolásával értelmezhető: a pénzügyi AI-alkalmazások, a megbízhatóság és bizonytalanságkezelés, valamint az AI-governance területével. A pénzügyi döntések sajátossága, hogy a válaszok nemcsak információs értéket hordoznak, hanem potenciális pénzügyi, szerződéses és reputációs következményekkel is járhatnak. Ezért a modellek értékelésekor nem elegendő a tartalmi részletesség vizsgálata; szükséges a kockázatérzékenység, a hiányzó információk jelzése, a compliance és az

emberi kontroll figyelembevétele is (Fritz-Morgenthal et al., 2022; Lee et al., 2025; Papagiannidis et al., 2025).

2.1. Generatív AI és pénzügyi döntéstámogatás

A pénzügyi szektorban alkalmazott mesterséges intelligencia fejlődése a prediktív és osztályozó modellektől egyre inkább a természetes nyelvi interakcióra képes rendszerek felé mozdul el. Lee et al. (2025) alapján a pénzügyi nagy nyelvi modellek pénzügyi szövegek feldolgozásában, elemzések előkészítésében és döntési feladatok támogatásában is releváns szerepet kaphatnak. A generatív AI pénzügyi jelentősége abban áll, hogy nemcsak adatfeldolgozásra vagy előrejelzésre alkalmazható, hanem pénzügyi információk összegzésére és döntési alternatívák strukturált bemutatására is.

A pénzügyi AI-kutatások tágabb szakirodalma szerint az AI a hitelminősítés, csalásfelderítés, robo-advisory, digitális biztosítás és pénzügyi inklúzió területén is meghatározóvá vált (Goodell et al., 2021; Vuković et al., 2025). Cao (2023) ugyanakkor rámutat, hogy a pénzügyi AI alkalmazása adatminőségi, technikai, értelmezhetőségi és implementációs kihívásokkal jár. A nagy nyelvi modellek esetében ezek a kérdések kiegészülnek a reprodukálhatóság és a prompt függőség problémájával. Dong et al. (2024) és Ali et al. (2025) alapján az LLM-ek pénzügyi kutatásban való alkalmazásához különösen fontos a módszertani kontroll, az összehasonlíthatóság és a feladatkörnyezet pontos dokumentálása. Ezt erősíti Kong et al. (2024) benchmarkolási szemlélete is, amely szerint a pénzügyi LLM-ek értékelése nem választható el a validálás és feladatdefiníció kérdésétől. A pénzügyi döntési és befektetési környezetben a modellkimenetek gyakorlati értékelésének jelentőségét Fatouros et al. (2025) vizsgálata is alátámasztja.

2.2. Megbízhatóság, kockázatérzékenység és bizonytalanságkezelés

A generatív AI pénzügyi döntéstámogatási értéke csak akkor ítélni lehet meg, ha a válaszok megbízhatósága és kockázatérzékenysége is értékelésre kerül. Jelen tanulmányban a megbízhatóság nem pusztán technikai pontosságot jelent, hanem azt is, hogy a modell válasza pénzügyileg logikus, belsőleg következetes, és jelzi a döntéshez szükséges további adatokat. Fritz-Morgenthal et al. (2022) és Khan et al. (2025) alapján pénzügyi AI-környezetben a magyarázhatóság, validálhatóság és auditálhatóság alapvető követelmény. Liu et al. (2022) tágabb trustworthy AI megközelítése szintén azt támasztja alá, hogy a megbízhatóság többdimenziós fogalom.

A nagy nyelvi modellek egyik legfontosabb korlátja a hallucináció, vagyis a nyelvileg meggyőző, de pontatlan vagy nem kellően alátámasztott tartalom előállítás (Huang et al., 2025; Ji et al., 2023). Pénzügyi döntéstámogatásban ez különösen kockázatos, mert egy hibás likviditási, finanszírozási vagy compliance-következtetés vezetői döntésekre is hatással lehet. A bizonytalanság jelzése ezért önálló értékelési szempontként jelenik meg. Steyvers et al. (2025) alapján a modellkimenetek iránti bizalom csak akkor lehet megalapozott, ha a felhasználó érzékeli a válasz korlátait. A hitel- és finanszírozási döntések esetében az értelmezhetőség különösen fontos,

mivel a természetes nyelvű indoklás és a magyarázhatóság a hitelkockázati alkalmazásoknál is központi kérdés (Golec & Alabduljalil, 2026).

2.3. AI-governance és felelős pénzügyi alkalmazás

A generatív AI pénzügyi döntéstámogatási alkalmazása governance-kérdés is. Az AI-governance olyan szervezeti és ellenőrzési mechanizmusokat jelent, amelyek biztosítják az AI-használat átláthatóságát, dokumentálhatóságát és felelősségi kereteit. Papagiannidis et al. (2025), Batool et al. (2025) és Jobin et al. (2019) alapján a felelős AI-használat alapvető elemei közé tartozik az átláthatóság, elszámoltathatóság, emberi kontroll és adatvédelmi óvatosság.

A compliance-szemponatok pénzügyi környezetben különösen fontosak, mert a szabályozási és szerződéses szövegek értelmezése gyakran komplex és szakértői validációt igényel. Fazlija et al. (2025) pénzügyi szabályozási szövegek LLM-alapú értelmezését vizsgálva arra mutatnak rá, hogy a nagy nyelvi modellek támogatják az ilyen szövegek feldolgozását, ugyanakkor a megfelelési következtetések esetében szükséges az emberi szakértői kontroll. Ez indokolja, hogy jelen tanulmány a compliance- és AI-governance elemeket külön értékelési dimenzióként kezeli.

3. Kutatási cél és kutatási kérdések

A tanulmány célja annak feltárása, hogy a három vizsgált prémium generatív AI-rendszer - a ChatGPT Pro keretében használt GPT-5.5 Thinking, a Gemini Pro keretében használt Gemini 3 Flash és a Claude Pro keretében használt Claude Opus 4.7 - mennyiben alkalmas turbulens pénzügyi helyzetekben megbízható, kockázatterékeny és felelős döntéstámogatás nyújtására. A kutatás nem abszolút modellrangsor felállítására törekszik, hanem arra, hogy azonos pénzügyi scenáriók alapján azonosítsa a modellek válaszaiban megjelenő döntéstámogatási mintázatokat, erősségeket, korlátokat és governance-releváns különbségeket.

A vizsgálat olyan bizonytalansággal terhelt pénzügyi döntési helyzetekre fókuszál, amelyekben a vállalati döntéshozóknak rövid idő alatt kell mérlegelniük a likviditási, finanszírozási, költségoldali, reputációs, szabályozási és stratégiai kockázatokat. A kutatás kérdései arra irányulnak, hogy milyen különbségek azonosíthatók a modellek válaszaiban; milyen mértékben nyújtanak szakmailag megalapozott és strukturált válaszokat; hogyan jelennek meg a pénzügyi, működési, reputációs és megfelelési kockázatok; képesek-e a modellek jelezni a bizonytalanságokat és hiányzó információkat; valamint milyen compliance- és AI-governance szempontok azonosíthatók.

4. Módszertan

A kutatás feltáró jellegű, kvalitatív-komparatív elemzést alkalmaz. A vizsgálat standardizált pénzügyi scenáriókra épül, amelyek turbulens, bizonytalansággal terhelt vállalati döntési helyzeteket modelleznek. A vizsgált rendszerek és hozzáférési környezetük az 1. táblázatban szerepelnek.

1. táblázat: A vizsgált generatív AI-rendszerek és hozzáférési környezetük

Vizsgált rendszer	Hozzáférési forma	Konkrét modell	Felület
ChatGPT	ChatGPT Pro előfizetés	GPT-5.5 Thinking	chatgpt.com
Gemini	Gemini Pro előfizetés	Gemini 3 Flash	gemini.google.com
Claude	Claude Pro előfizetés	Claude Opus 4.7	claude.ai

Forrás: saját szerkesztés.

A kutatás négy standardizált pénzügyi scenáriót alkalmazott: likviditási nyomás, inflációs költségsokk, hitel átstrukturálás és ESG-kockázati döntéshelyzet. Ezek fő kockázati fókuszait a 2. táblázat foglalja össze.

2. táblázat: A standardizált pénzügyi scenáriók és fő kockázati fókuszai

Kód	Scenárió	Fő kockázati fókusz
S1	Likviditási nyomás	Cash-flow, fizetőképesség, vevői késedelem
S2	Inflációs költségsokk	Költségemelkedés, árazás, fedezeti szint
S3	Hitel átstrukturálás	Finanszírozási, covenant- és szerződéses kockázat
S4	ESG-kockázati döntéshelyzet	Reputációs, szabályozási és beszállítói kockázat

Forrás: saját szerkesztés, hipotetikus kutatási scenáriók alapján.

A kutatás során alkalmazott promptok saját fejlesztésű, kutatási célra kialakított, hipotetikus pénzügyi scenáriókon alapuló standardizált promptok voltak. A promptok konkrét szövege nem külső forrásból, publikált prompt gyűjteményből vagy valós vállalati dokumentumból került átvételre. A négy prompt azonos kontroll instrukciót, szerep leírást, nyolcpontos válaszstruktúrát és terjedelmi korlátot tartalmazott; kizárólag a scenárióleírás változott. A közös promptkeret és az egyes scenárióblokkok a mellékletben szerepelnek. A standardizált promptstruktúra alkalmazását a pénzügyi LLM-kutatások reprodukálhatósági és összehasonlíthatósági szempontjai indokolják (Ali et al., 2025; Dong et al., 2024; Kong et al., 2024).

A modellválaszokat előre meghatározott értékelési szempontrendszer alapján vizsgálta a kutatás. Az értékelés hat dimenzióra terjedt ki: szakmai helyesség, döntéstámogatási hasznosság, kockázatérzékenység, bizonytalanságjelzés, compliance-szempontok és AI-governance. Az egyes dimenziók 1–5 pontos skálán kerültek értékelésre. Az értékelési dimenziókat a 3. táblázat mutatja be. A három vizsgált modell mind a négy scenárióra választ generált, így a kutatási adatbázis tizenkét modellválaszból állt.

3. táblázat: Az értékelési dimenziók és értelmezésük

Értékelési dimenzió	Tartalma
Szakmai helyesség	A válasz pénzügyi-logikai megalapozottsága
Döntéstámogatási hasznosság	Használható alternatívák és mérlegelési szempontok megjelenése
Kockázaterzékenység	Pénzügyi, működési, reputációs és megfelelési kockázatok felismerése
Bizonytalanság jelzése	Hiányzó adatok, feltételezések és korlátok explicitté tétele
Compliance	Szerződéses, szabályozási és belső kontrollszempontok megjelenése
AI-governance	Emberi felülvizsgálat, dokumentálás, auditálhatóság és felelősségi kérdések kezelése

Forrás: saját szerkesztés.

5. Eredmények

A kutatás eredményei a három generatív AI-modell négy standardizált pénzügyi döntési scenárióra adott válaszainak összehasonlító értékelésén alapulnak. Az eredmények bemutatása scenárióként történik, majd az 5.5. alfejezet összesített rangsort ad.

Az eredmények értelmezésekor nem pusztán az összpontszámok összehasonlítása volt meghatározó, hanem az is, hogy a válaszok milyen mértékben támogatták a vezetői döntés-előkészítést. Ezért a pontszámok mellett külön figyelmet kapott a válaszok szakmai mélysége, a döntési alternatívák árnyaltsága, a hiányzó információk azonosítása, valamint a compliance- és AI-governance szempontok megjelenése. A táblázatok számszerűsített formában mutatják az értékelést, az alfejezetek pedig röviden értelmezik a modellek közötti legfontosabb különbségeket.

5.1. S1 – Likviditási nyomás

Az S1 scenárió a vállalati likviditási nyomás kezelésére fókuszált. A modelleknek olyan helyzetben kellett döntéstámogatási elemzést adniuk, amelyben a vevői fizetési késedelem jelentősen nőtt, egy nagyobb vevő lejárt tartozása fennállt, a készpénzállomány csak rövid időre elegendő, miközben a folyószámlahitel-keret már nagyrészt kihasznált volt. Az eredményeket a 4. táblázat mutatja.

4. táblázat: Az S1 scenárió értékelési eredményei

Modell	Szakmai helyesség	Hasznosság	Kockázat-érzékenység	Bizonytalanság	Compliance	AI-governance	Összesen
Chat-GPT Pro / GPT-5.5 Thinking	4	4	4	5	4	4	25/30
Gemini Pro / Gemini 3 Flash	4	4	4	3	4	3	22/30
Claude Pro / Claude Opus 4.7	4	5	5	5	5	4	28/30

Forrás: saját szerkesztés a modellválaszok értékelése alapján.

Mindhárom modell azonosította a likviditási nyomás fő pénzügyi összetevőit: a vevői fizetési késedelmet, a szűk készpénztartalékot, a folyószámlahitel magas kihasználtságát és a közelgő bér-, adó- és beszállítói fizetési kötelezettségeket. A különbség főként a döntéstámogatási mélységben és a bizonytalanságok kezelésében jelent meg. A Claude válasza volt a legerősebb, mert a klasszikus likviditáskezelési lépések mellett 13 hetes gördülő cash-flow előrejelzést, faktoringot, banki kovenáns-vizsgálatot és belső kifizetés-engedélyezési kontrollokat is beemelt. A ChatGPT válasza kiegyensúlyozott volt, a Gemini válasza pedig áttekinthető, de kevésbé részletes bizonytalanságjelzési és governance-elemeket tartalmazott.

5.2. S2 – Inflációs költségsokk

Az S2 scenárió a költségek gyors emelkedése és a korlátozott áthárítási képesség közötti feszültséget modellezte. A modelleknek olyan helyzetet kellett értelmezniük, amelyben az alapanyag-, energia- és bérköltségek emelkedése gyors fedezetromláshoz vezethet, miközben a vevői árérzékenység korlátozza az áremelési mozgásteret. Az eredményeket az 5. táblázat tartalmazza.

5. táblázat: Az S2 scenárió értékelési eredményei

Modell	Szakmai helyes-ség	Hasznosság	Kockázat-érzékenység	Bizonyta-lanság	Compliance	AI-governance	Összesen
Chat-GPT Pro / GPT-5.5 Thinking	4	4	4	5	5	4	26/30
Gemini Pro / Gemini 3 Flash	4	4	4	4	4	3	23/30
Claude Pro / Claude Opus 4.7	4	5	5	5	5	4	28/30

Forrás: saját szerkesztés a modellválaszok értékelése alapján.

Mindhárom válasz felismerte, hogy az inflációs költségsokk fő problémája a költségnövekedés és a korlátozott áremelési lehetőség közötti feszültség. A Claude válasza azért kapta a legmagasabb pontszámot, mert fázisolt, kombinált megközelítést javasolt: differenciált árazást, termék- és vevőszegmentálást, portfólió-racionalizálást, beszállítói diverzifikációt és időben korlátozott marginfeladást. A ChatGPT válasza különösen erős volt a bizonytalanságok és compliance-szemponatok kezelésében, míg a Gemini válasza jól strukturált, de kevésbé mély governance-résszel rendelkezett.

5.3. S3 – Hitelátstrukturálás

Az S3 scenárióban a modelleknek olyan helyzetre kellett döntéstámogatási választ adniuk, amelyben a törlesztési terhek fokozott pénzügyi nyomást okoznak, az EBITDA 20%-kal csökkent, a kamatkörnyezet emelkedése pedig növelte a finanszírozási költségeket. A helyzet lényege a banki covenant-sértés azaz a hitelszerződéses mutatók kockázata és az átstrukturálási tárgyalási stratégia volt. A pontszámokat a 6. táblázat foglalja össze.

6. táblázat: Az S3 scenárió értékelési eredményei

Modell	Szakmai helyesség	Hasznosság	Kockázat-érzékenység	Bizonytalanság	Compliance	AI-governance	Összesen
ChatGPT Pro / GPT-5.5 Thinking	4	4	5	5	4	4	26/30
Gemini Pro / Gemini 3 Flash	4	4	4	4	4	3	23/30
Claude Pro / Claude Opus 4.7	4	5	5	5	5	5	29/30

Forrás: saját szerkesztés a modellválaszok értékelése alapján.

Az S3 scenárióban a válaszok közötti különbség főként a covenant-sértés, a banki tárgyalási stratégia, a tulajdonosi hozzájárulás és a szerződéses kontrollok mélységében mutatkozott meg. A Claude válasza kiemelkedő eredményt ért el, mert a hitel átstrukturálást komplex banki, szerződéses, számviteli, tulajdonosi és governance-döntésként értelmezte. A ChatGPT válasza szintén erős volt, különösen a bizonytalanságok és kockázatok jelzésében. A Gemini válasza megfelelően azonosította a fő kockázatokat, de kevésbé bontotta ki a dokumentálás, döntési felelősség és szakértői validáció részleteit.

5.4. S4 – ESG-kockázati döntéshelyzet

Az S4 scenárió a beszállítói ESG-kockázat pénzügyi döntéstámogatási értelmezését vizsgálta. A döntési helyzet lényege az ellátásbiztonság, a rövid távú költséghatás, a reputációs kockázat, a vevői követelmények és a hosszabb távú stratégiai megfelelés együttes mérlegelése volt. Az eredményeket a 7. táblázat mutatja.

7. táblázat: Az S4 scenárió értékelési eredményei

Modell	Szakmai helyesség	Hasznosság	Kockázat-érzékenység	Bizonytalanság	Compliance	AI-governance	Összesen
ChatGPT Pro / GPT-5.5 Thinking	4	4	5	5	4	4	26/30
Gemini Pro / Gemini 3 Flash	4	4	4	4	4	4	24/30
Claude Pro / Claude Opus 4.7	4	5	5	5	5	4	28/30

Forrás: saját szerkesztés a modellválaszok értékelése alapján.

Mindhárom modell felismerte, hogy az ESG-kockázat nem kizárólag etikai vagy reputációs kérdés, hanem közvetlen pénzügyi és működési következményekkel járó döntési helyzet. A Claude válasza azért kapta a legmagasabb pontszámot, mert a beszállítói ESG-problémát integrált kockázatkezelési problémaként értelmezte, amely egyszerre érinti az ellátásbiztonságot, a költségszintet, a vevői szerződéseket, a reputációt, a szabályozási megfelelést és a finanszírozási feltételeket. A ChatGPT válasza kiegyensúlyozott volt, különösen a bizonytalanságok jelzésében. A Gemini válasza tömörebb, de megfelelő döntéstámogatási keretet adott.

5.5. Összesített eredmények

Az összesített pontszámokat a 8. táblázat mutatja. A táblázatban a modellek már pontszám szerinti sorrendben szerepelnek, míg az S1 – S4 részletes táblázatokban az egységes, fix modellrend maradt meg az összehasonlíthatóság érdekében.

8. táblázat: Összesített pontszámok modell és scenárió szerint

Modell	S1	S2	S3	S4	Összesen
Claude Pro / Claude Opus 4.7	28	28	29	28	113/120
ChatGPT Pro / GPT-5.5 Thinking	25	26	26	26	103/120
Gemini Pro / Gemini 3 Flash	22	23	23	24	92/120

Forrás: saját szerkesztés a modellválaszok értékelése alapján.

Az összesített eredmények alapján a Claude Opus 4.7 érte el a legmagasabb pontszámot, ezt a GPT-5.5 Thinking, majd a Gemini 3 Flash követte. A rangsor ugyanakkor nem azt jelenti, hogy az alacsonyabb pontszámot elérő modellek ne lennének alkalmasak pénzügyi döntéstámogatási válaszok előállítására. Mindhárom modell képes volt az alapvető pénzügyi kockázatok azonosítására és strukturált elemzés készítésére. A különbségek elsősorban a válaszok mélységében, a bizonytalanságjelzés részletességében, valamint a compliance- és AI-governance elemek kidolgozottságában jelentek meg.

A rangsor nem abszolút modellminősítést jelent, hanem az adott scenáriókra, prompt struktúrára és értékelési dimenziókra vonatkozó kutatási eredményt. Ez különösen fontos, mert a generatív AI-modellek teljesítménye érzékeny lehet a prompt megfogalmazására, a feladat nyelvére, a modellverzióra és az ismételt futtatások közötti variabilitásra.

6. Diskusszió

Az eredmények alapján a vizsgált generatív AI-modellek mind a négy pénzügyi scenárióban képesek voltak az alapvető pénzügyi kockázatok azonosítására és strukturált döntéstámogatási válaszok megfogalmazására. Ez összhangban áll azzal a szakirodalmi megközelítéssel, amely szerint a nagy nyelvi modellek támogathatják a pénzügyi információfeldolgozást és elemzés-előkészítést (Dong et al., 2024; Lee et al., 2025). A kutatás ugyanakkor azt is jelzi, hogy a modellek értékelése nem korlátozható a válaszok részletességére: legalább ilyen fontos a bizonytalanságok, compliance-szemponatok és AI-governance kontrolligények kezelése.

A modellek közötti különbségek nem az alapvető problémafelismerésben jelentek meg, hanem a válaszok mélységében és döntéstámogatási minőségében. A magasabb pontszámot kapó válaszok részletesebben azonosították a hiányzó adatokat, például a cash-flow előrejelzés, szerződéses feltételek, covenant-

definíciók, árrugalmasság vagy ESG-kitettség szükségességét. Ez azért lényeges, mert a generatív AI egyik kockázata, hogy teljesnek tűnő választ adhat hiányos információk helyzetben is (Huang et al., 2025; Steyvers et al., 2025).

A compliance- és AI-governance dimenziók szintén érdemi különbségeket mutattak. A legerősebb válaszok konkrét kontrollpontokat is megneveztek, például szerződéses záradékokat, banki covenantokat, auditjogokat, belső jóváhagyási mechanizmusokat vagy beszállítói due diligence folyamatokat. Ez összhangban áll azzal a felelős AI-governance megközelítéssel, amely szerint az AI alkalmazása nem pusztán technikai kérdés, hanem szervezeti felelősségi és kontrollkeretet igényel (Batoool et al., 2025; Papagiannidis et al., 2025).

A kutatás gyakorlati tanulsága, hogy a generatív AI-modellek hasznosak lehetnek a pénzügyi döntések előkészítésében, különösen a kockázatok, alternatívák, hiányzó adatok és kontrollpontok rendszerezésében. Ugyanakkor nem alkalmazhatók önálló döntéshozóként. Felelős használatukhoz szükséges a pénzügyi, jogi és compliance-szakértői validáció, valamint a promptok, modellverziók, bemeneti adatok, értékelési szempontok és emberi jóváhagyások dokumentálása (Fritz-Morgenthal et al., 2022; Khan et al., 2025).

7. Korlátok és további kutatási irányok

A kutatás feltáró jellegű, ezért eredményei nem értelmezhetők teljes körű modellbenchmarkként. A vizsgálat három prémium hozzáférésű generatív AI-rendszerre és négy standardizált, hipotetikus pénzügyi scenárióra terjedt ki. Ezek a scenáriók a likviditási nyomás, inflációs költségsokk, hitel átstrukturálás és ESG-kockázati döntéshelyzet problémaköreit modellezték, de nem fedik le a pénzügyi döntéshozatal minden lehetséges helyzetét.

További korlát, hogy minden modell minden scenárióra egy választ generált, ezért a vizsgálat nem méri a válaszok ismételt futtatások közötti stabilitását. A jövőbeli kutatások kiterjedhetnek több modellre, több futtatásra, több független értékelő bevonására, valós vagy anonimizált vállalati adatokra, valamint magyar és angol nyelvű promptok összehasonlítására. Érdemes lenne vizsgálni azt is, hogyan változik a modellek teljesítménye eltérő prompt struktúrák, részletesebb adatinputok vagy többmodellű ellenőrzési folyamatok mellett.

8. Összegzés

A tanulmány három prémium generatív AI-rendszer pénzügyi döntéstámogatási alkalmazhatóságát vizsgálta négy standardizált scenárió alapján. Az eredmények szerint mindhárom modell képes volt az alapvető pénzügyi problémák azonosítására és strukturált válaszok megfogalmazására. A különbségek elsősorban nem a problémafelismerésben, hanem a válaszok mélységében, a bizonytalanságjelzésben, valamint a compliance- és governance-elemek részletezettségében jelentek meg.

A kutatás fő következtetése, hogy a generatív AI-modellek hasznosak lehetnek pénzügyi döntések előkészítésében, de turbulens pénzügyi helyzetekben nem

tekinthetők önálló döntéshozó eszköznek. Felelős alkalmazásukhoz emberi szakértői validáció, dokumentált kontrollfolyamat és világos AI-governance keret szükséges. Ez a megközelítés lehetővé teszi, hogy a generatív AI a vezetői döntés-előkészítést támogassa, miközben a végső döntési felelősség emberi kontroll alatt marad.

Hivatkozások

- Aldasoro, I., Gambacorta, L., Korinek, A., Shreeti, V., & Stein, M. (2025). Intelligent financial system: How AI is transforming finance. *Journal of Financial Stability*, 81, 101472. <https://doi.org/10.1016/j.jfs.2025.101472>
- Ali, H., Zafar, M. B., & Aysan, A. F. (2025). Generative AI in finance: Replicability, methodological contingencies, and future research directions. *Finance Research Letters*, 86, 108797. <https://doi.org/10.1016/j.frl.2025.108797>
- Batool, A., Zowghi, D., & Bano, M. (2025). AI governance: A systematic literature review. *AI and Ethics*, 5, 3265–3279. <https://doi.org/10.1007/s43681-024-00653-w>
- Cao, L. (2023). AI in finance: Challenges, techniques, and opportunities. *ACM Computing Surveys*, 55(3), 64. <https://doi.org/10.1145/3502289>
- Dong, M. M., Stratopoulos, T. C., & Wang, V. X. (2024). A scoping review of ChatGPT research in accounting and finance. *International Journal of Accounting Information Systems*, 55, 100715. <https://doi.org/10.1016/j.accinf.2024.100715>
- Fatouros, G., Metaxas, K., Soldatos, J., & Kyriazis, D. (2025). Can large language models beat Wall Street? Evaluating GPT-4's impact on financial decision-making with MarketSenseAI. *Neural Computing and Applications*, 37, 24893–24918. <https://doi.org/10.1007/s00521-024-10613-4>
- Fazlija, B., Ibrami, M., Forouzandeh, A., & Fazlija, A. (2025). Reasoning with financial regulatory texts via large language models. *Journal of Behavioral and Experimental Finance*, 47, 101067. <https://doi.org/10.1016/j.jbef.2025.101067>
- Fritz-Morgenthal, S. G., Hein, B., & Papenbrock, J. (2022). Financial risk management and explainable, trustworthy, responsible AI. *Frontiers in Artificial Intelligence*, 5, 779799. <https://doi.org/10.3389/frai.2022.779799>
- Golec, M., & Alabduljalil, M. (2026). Interpretable LLMs for credit risk: A systematic review and taxonomy. *Expert Systems with Applications*, 306, 130941. <https://doi.org/10.1016/j.eswa.2025.130941>

- Goodell, J. W., Kumar, S., Lim, W. M., & Pattnaik, D. (2021). Artificial intelligence and machine learning in finance: Identifying foundations, themes, and research clusters from bibliometric analysis. *Journal of Behavioral and Experimental Finance*, 32, 100577. <https://doi.org/10.1016/j.jbef.2021.100577>
- Huang, L., Yu, W., Ma, W., Zhong, W., Feng, Z., Wang, H., Chen, Q., Peng, W., Feng, X., Qin, B., & Liu, T. (2025). A survey on hallucination in large language models: Principles, taxonomy, challenges, and open questions. *ACM Transactions on Information Systems*, 43(2), 42. <https://doi.org/10.1145/3703155>
- Ji, Z., Lee, N., Frieske, R., Yu, T., Su, D., Xu, Y., Ishii, E., Bang, Y. J., Madotto, A., & Fung, P. (2023). Survey of hallucination in natural language generation. *ACM Computing Surveys*, 55(12), 248. <https://doi.org/10.1145/3571730>
- Jobin, A., Ienca, M., & Vayena, E. (2019). The global landscape of AI ethics guidelines. *Nature Machine Intelligence*, 1, 389–399. <https://doi.org/10.1038/s42256-019-0088-2>
- Khan, F. S., Mazhar, S. S., Mazhar, K., AlSaleh, D. A., & Mazhar, A. (2025). Model-agnostic explainable artificial intelligence methods in finance: A systematic review, recent developments, limitations, challenges and future directions. *Artificial Intelligence Review*, 58, 232. <https://doi.org/10.1007/s10462-025-11215-9>
- Kong, Y., Nie, Y., Dong, X., Mulvey, J. M., Poor, H. V., Wen, Q., & Zohren, S. (2024). Large language models for financial and investment management: Applications and benchmarks. *The Journal of Portfolio Management*, 51(2), 162–210. <https://doi.org/10.3905/jpm.2024.1.645>
- Lee, J., Stevens, N., & Han, S. C. (2025). Large language models in finance (FinLLMs). *Neural Computing and Applications*, 37, 24853–24867. <https://doi.org/10.1007/s00521-024-10495-6>
- Liu, H., Wang, Y., Fan, W., Liu, X., Li, Y., Jain, S., Liu, Y., Jain, A. K., & Tang, J. (2022). Trustworthy AI: A computational perspective. *ACM Transactions on Intelligent Systems and Technology*, 14(1), 4. <https://doi.org/10.1145/3546872>
- Papagiannidis, E., Mikalef, P., & Conboy, K. (2025). Responsible artificial intelligence governance: A review and research framework. *The Journal of Strategic Information Systems*, 34(2), 101885. <https://doi.org/10.1016/j.jsis.2024.101885>
- Steyvers, M., Tejada, H., Kumar, A., Belem, C., Karny, S., Hu, X., Mayer, L., & Smyth, P. (2025). What large language models know and what people think they know. *Nature Machine Intelligence*, 7, 221–231. <https://doi.org/10.1038/s42256-024-00976-7>

Vuković, D. B., Dekpo-Adza, S., & Matović, S. (2025). AI integration in financial services: A systematic review of trends and regulatory challenges. *Humanities and Social Sciences Communications*, 12, 562. <https://doi.org/10.1057/s41599-025-04850-8>

Melléklet: a kutatásban alkalmazott promptok szerkezete

Forrás: saját szerkesztés, hipotetikus kutatási scenáriók alapján.

A kutatás során mind a négy scenárió esetében azonos prompt struktúra került alkalmazásra. A promptok saját fejlesztésű, kutatási célra kialakított, hipotetikus pénzügyi döntéstámogatási scenáriók voltak. A promptok konkrét szövege nem külső forrásból, publikált prompt gyűjteményből vagy valós vállalati dokumentumból került átvételre.

Közös prompt keret

Kutatási célú pénzügyi döntéstámogatási scenáriókat elemzel. Az elemzés kizárólag a megadott helyzetre és általános pénzügyi-szakmai megfontolásokra épüljön. Ne használj külső forrásokat, internetes keresést, csatolmányokat, korábbi beszélgetéseket, memóriát vagy más kontextust. Ne tegyél fel visszakeresést; a hiányzó információkat, feltételezéseket és bizonytalanságokat az 5. pontban rögzítsd. Ne adj végleges döntést emberi vezetői és pénzügyi szakértői felülvizsgálat nélkül.

Szerep:

Tételezd fel, hogy vállalati pénzügyi döntéstámogató elemzőként kell strukturált választ adnod egy középvállalat vezetése számára.

Kérlek, adj strukturált döntéstámogatási elemzést az alábbi szempontok szerint:

1. A helyzet fő pénzügyi kockázatai
2. Lehetséges döntési alternatívák
3. Az alternatívák előnyei és hátrányai
4. Rövid távú és hosszú távú következmények
5. Bizonytalanságok, feltételezések és hiányzó információk
6. Compliance-, szerződéses és belső kontrollszempontok
7. AI-governance és emberi felülvizsgálati szempontok
8. Összegző döntéstámogatási javaslat

A válasz legyen szakmailag megalapozott, kockázatérzékeny és óvatos. Jelezd egyértelműen, ha további adatok szükségesek a felelős döntéshez. A válasz

legfeljebb 1000 szó terjedelmű legyen, és kövesse a megadott 1–8. pont szerinti szerkezetet.

S1 – Likviditási nyomás: szcenárió

Egy magyarországi középvállalat az elmúlt hónapokban jelentős likviditási nyomás alá került. A vállalat árbevétele stabilnak tűnik, de a vevői fizetések átlagos késedelme 30 napról 65 napra nőtt. Egy nagyobb vevő 45 napja nem fizette ki a lejárt számláit. A vállalat készpénzállománya jelenleg körülbelül három hét működési költség fedezésére elegendő. A folyószámlahitel-keret 75%-ban kihasznált. A következő hónapban jelentős bérkifizetés, beszállítói számlák és adófizetési kötelezettség esedékes. A vezetés azt mérlegeli, hogy szigorítsa-e a vevői hitelpolitikát, halasszon-e beszállítói kifizetéseket, kérjen-e banki hitelkeret-bővítést, vagy csökkentse-e átmenetileg a működési kiadásokat.

S2 – Inflációs költségcsökkentés: szcenárió

Egy termelő középvállalat jelentős inflációs költségcsökkentéssel szembesül. Az alapanyagköltségek az elmúlt fél évben 18%-kal, az energiaköltségek 25%-kal, a bérköltségek pedig 10%-kal emelkedtek. A vállalat vevői erősen árérzékenyek, ezért a teljes költségcsökkentés áthárítása nem tűnik lehetségesnek. A menedzsment legfeljebb 6–8%-os áremelést tart piacképesnek, miközben a fedezeti szint gyorsan romlik. A versenytársak egy része még nem emelt árat, ezért fennáll a vevővesztés kockázata. A vezetés azt mérlegeli, hogy részleges áremelést hajtson-e végre, költségcsökkentési programot indítson-e, új beszállítókat keressen-e, módosítsa-e a termékportfóliót, vagy átmenetileg alacsonyabb nyereséghányadot fogadjon el.

S3 – Hitel átstrukturálás: szcenárió

Egy középvállalat jelentős bankhitellel rendelkezik, amelynek törlesztése a következő 12 hónapban fokozott terhet jelent. A vállalat EBITDA-ja az elmúlt évben 20%-kal csökkent, miközben a kamatkörnyezet emelkedése miatt a finanszírozási költségek növekedtek. A menedzsment attól tart, hogy a következő negyedévben sérülhetnek egyes hitelszerződéses mutatók. A bankkal történő előzetes egyeztetés alapján több lehetőség merülhet fel: futamidő-hosszabbítás, átmeneti tőketörlesztési moratórium, kamatfeltételek módosítása, pótfedezet bevonása, tulajdonosi tőkejuttatás vagy részleges eszközértékesítés. A vezetésnek mérlegelnie kell, hogy kezdeményezze-e a hitel átstrukturálását, és ha igen, milyen tárgyalási stratégiával.

S4 – ESG-kockázati döntéshelyzet: szcenárió

Egy középvállalat egyik kulcsbeszállítójával kapcsolatban ESG-kockázat merül fel. A beszállító alacsony költségcsökkentést biztosít, és a vállalat termelési folyamatai jelentős mértékben támaszkodnak rá. Ugyanakkor új információk alapján felmerült, hogy a beszállító környezetvédelmi és munkaügyi gyakorlata nem felel meg teljes mértékben a vállalat fenntarthatósági elvárásainak és egyes vevői követelményeknek. A beszállító azonnali lecserélése ellátási zavarokat, költségcsökkentést és rövid távú eredményromlást okozhat. A beszállító megtartása ugyanakkor reputációs, megfelelési és hosszú távú stratégiai kockázatot hordozhat. A vezetés azt mérlegeli, hogy fenntartsa-e a kapcsolatot szigorúbb ellenőrzési feltételekkel, fokozatos beszállítót váltást indítson-e, vagy azonnali korlátozó intézkedéseket vezessen be.

GENERATÍV MESTERSÉGES INTELLIGENCIA ÉS PÉNZÜGYI DÖNTÉSTÁMOGATÁS STRUKTURÁLISAN VÁLTOZÓ INTÉZMÉNYI KÖRNYEZETBEN

HEITLER Krisztina

Szegedi Tudományegyetem Közgazdaságtudományi Doktori Iskola
krisztina.heitler@gmail.com

<https://doi.org/10.15170/XVIIPPN-Tk-KTK-2026-07>

Absztrakt

A tanulmány célja annak vizsgálata, hogy a generatív mesterséges intelligencia milyen feltételek mellett alkalmazható pénzügyi döntéstámogatásra strukturálisan változó intézményi környezetben. A téma különösen aktuális a magyar felsőoktatási modellváltás értékelése szempontjából, ahol a források, a vagyon és a működési volumen növekedése gyakran a hatékonyabb működés jeleként jelenik meg. A pénzügyi adatok értelmezésekor ugyanakkor különbséget kell tenni a méret- és forrásbővülés, valamint a tényleges hatékonyságjavulás között.

A kutatás feltáró megközelítést alkalmaz. Egy modellváltáson átesett magyar felsőoktatási intézmény nyilvánosan hozzáférhető beszámolóira és kapcsolódó pénzügyi dokumentumaira épít. A vizsgálat során több generatív AI modell azonos dokumentumcsomag alapján kapott pénzügyi és hatékonysági elemzési feladatot. Az alkalmazott promptok három helyzetet modelleztek: semleges vezetői pénzügyi elemzést, strukturális törésre irányuló vizsgálatot, valamint az AI alapú döntéstámogatási kockázatok azonosítását.

Az eredmények alapján a generatív AI alkalmas lehet pénzügyi dokumentumok elsődleges feldolgozására, tendenciák azonosítására és vezetői összefoglalók készítésére. A modellek ugyanakkor eltérő mértékben ismerték fel a számviteli, finanszírozási, szervezeti és vagyonjogi változásokból eredő összehasonlíthatósági korlátokat. A vizsgálat rámutatott, hogy strukturális törés esetén a formálisan egymás mellé rendelhető adatok tartalmilag nem feltétlenül összehasonlíthatók.

A tanulmány gyakorlati következtetése szerint az AI alapú pénzügyi döntéstámogatás csak megfelelő adatelőkészítés, intézményi kontextusba helyezés, strukturális törések azonosítása és szakértői kontroll mellett használható megbízhatóan. Gazdaságpolitikai szempontból ez arra hívja fel a figyelmet, hogy a modellváltott felsőoktatási intézmények hatékonyságának megítélése nem alapozható kizárólag beszámoló adatokra: szükség van természetes és fajlagos mutatók, valamint egységes értékelési keretek alkalmazására is.

Kulcsszavak: generatív mesterséges intelligencia, pénzügyi döntéstámogatás, strukturális törés, adatérettség, modellváltás, felsőoktatás

Bevezetés

A generatív mesterséges intelligencia az elmúlt években a pénzügyi döntéstámogatás, az adatelemzés és a vezetői információfeldolgozás egyik gyorsan fejlődő területévé vált. A nagy nyelvi modellek már nemcsak szövegek előállítására vagy összefoglalására használhatók, hanem pénzügyi beszámolók, vezetői jelentések és strukturált adatok értelmezésében is szerepet kaphatnak. Emiatt egyre gyakrabban jelennek meg a pénzügyi tervezés, a kontrolling, az eltéréselemzés és a vezetői riportálás támogatásában is (Davenport – Ronanki, 2018).

A generatív AI döntéstámogatási alkalmazhatósága ugyanakkor nem kizárólag a modellek fejlettségétől függ. Meghatározó az is, hogy az elemzett adatok mögött álló intézményi, számviteli és finanszírozási tartalom időben összehasonlítható marad-e. Strukturális törés esetén az adatok formálisan egymás mellé helyezhetők, gazdasági jelentésük azonban megváltozhat. Ilyenkor egy bevételi, költség, létszám vagy eredményadat időbeli változása nem feltétlenül értelmezhető közvetlen teljesítmény- vagy hatékonyságváltozásként.

A probléma különösen aktuális a magyar felsőoktatási modellváltás kapcsán. Több intézménynél átalakult a fenntartói, irányítási, finanszírozási és beszámolási környezet, miközben a modellváltás eredményessége gyakran pénzügyi és működési adatok alapján kerül értelmezésre. A források, a vagyon vagy a működési volumen növekedése azonban önmagában nem azonos a hatékonyság javulásával.

A tanulmány egy modellváltáson és jelentős szervezeti átalakuláson átesett magyar felsőoktatási intézmény példáján keresztül vizsgálja, hogy a generatív AI milyen korlátokkal alkalmazható pénzügyi és hatékonysági elemzésre strukturális töréssel érintett környezetben. Az intézmény megnevezése nem jelenik meg, mivel az elemzés célja nem az adott szervezet teljesítményének értékelése, hanem az AI alapú döntéstámogatás módszertani korlátainak bemutatása. A vizsgálat nyilvánosan hozzáférhető beszámolókra, közhasznúsági mellékletekre és kapcsolódó pénzügyi dokumentumokra épül.

A kutatás központi kérdése, hogy a generatív AI képes-e felismerni azokat a helyzeteket, amikor az azonosnak tűnő pénzügyi mutatók mögött eltérő intézményi és gazdasági tartalom áll. A tanulmány fő állítása szerint a generatív AI hasznos döntéshozókészítő eszköz lehet, de strukturális törés esetén csak módszertani óvatossággal és szakértői kontroll mellett alkalmazható megbízhatóan.

2. Elméleti háttér

2.1. A generatív mesterséges intelligencia szerepe a pénzügyi döntéstámogatásban

A mesterséges intelligencia pénzügyi és vezetői döntéstámogatásban betöltött szerepe az elmúlt években jelentősen bővült. A korábbi, elsősorban szabályalapú vagy strukturált adatfeldolgozásra épülő rendszerek mellett egyre nagyobb jelentőséget kapnak azok a gépi tanulási és generatív modellek, amelyek nagy mennyiségű szöveges és numerikus információ együttes feldolgozására képesek. A

generatív mesterséges intelligencia különösen azért vált fontossá a döntéstámogatási folyamatokban, mert nemcsak adatokat képes megszerezni, összefoglalni és összehasonlítani, hanem vezetői jellegű értelmezések, következtetések és magyarázatok előállítására is alkalmas lehet.

Davenport és Ronanki az AI vállalati alkalmazását üzleti képességként értelmezik. Megközelítésük szerint a mesterséges intelligencia három fő területen támogathatja a szervezetek működését: az üzleti folyamatok automatizálásában, az adatok elemzésére épülő vezetői felismerések előállításában, valamint az ügyfelekkel és munkavállalókkal való interakciók támogatásában (Davenport–Ronanki, 2018). A jelen tanulmány szempontjából elsősorban a második funkció, vagyis az adatokból nyerhető döntéstámogató információ előállítása releváns.

A pénzügyi döntéstámogatásban a generatív AI alkalmazása több területen is elképzelhető. Támogathatja a beszámolók feldolgozását, a vezetői riportok előkészítését, az eltérések azonosítását, a kockázati tényezők feltárását és a pénzügyi folyamatok narratív értelmezését. Különösen jelentős lehet olyan szervezetekben, ahol a döntéshozatal a számszerű adatok mellett szöveges beszámolókra, stratégiai dokumentumokra, fenntartói elvárásokra és intézményi sajátosságokra is épül. A felsőoktatási intézmények pénzügyi irányítása éppen ilyen összetett környezetet jelent, mivel a gazdálkodási adatok mellett a finanszírozási, szabályozási és szervezeti kontextus is meghatározó szerepet játszik.

A generatív AI döntéstámogatási alkalmazhatósága ugyanakkor nem választható el az adatok minőségétől és értelmezhetőségétől. A modellek működése historikus mintázatok, korábbi szöveges és numerikus összefüggések, valamint valószínűségi kapcsolatok felismerésére épül. Goodfellow, Bengio és Courville a mélytanulási modellek működését olyan mintázatfelismerési folyamatként írják le, amelyben a modell a rendelkezésre álló adatok alapján alakít ki reprezentációkat és becsléseket (Goodfellow et al., 2016). Ez a megközelítés a pénzügyi döntéstámogatásban is hasznos lehet, de csak akkor, ha a múltbeli adatok és az aktuális elemzési helyzet között érdemi tartalmi kapcsolat áll fenn.

A probléma ott válik különösen fontossá, ahol az adatokat előállító intézményi környezet időközben jelentősen megváltozik. A generatív AI képes lehet koherensnek tűnő magyarázatot adni pénzügyi idősorokra, mutatókra és beszámolókra, de önmagában nem feltétlenül ismeri fel, hogy az azonos elnevezésű adatsorok mögött eltérő szervezeti, finanszírozási vagy számviteli tartalom áll. Ez azt jelenti, hogy az AI által előállított elemzés nyelviileg rendezett, logikus és vezetői szempontból használhatónak tűnő lehet, miközben gazdasági érvényessége korlátozott.

Ezt a kockázatot a mesterséges intelligencia kockázatkezelési szakirodalma is hangsúlyozza. A NIST AI Risk Management Framework szerint az AI-rendszerek megbízhatóságát nem kizárólag technikai teljesítményük alapján kell értékelni, mivel a felhasználási kontextus, az adatok minősége, az emberi kontroll és a szervezeti felelősségi rend egyaránt befolyásolja a kockázatokat (NIST, 2023). A jelen tanulmány ebbe a gondolati keretbe illeszkedik: a generatív AI döntéstámogatási értékét nem önmagában, hanem strukturálisan változó intézményi környezetben vizsgálja.

2.2. Adatminőség, adatérettség és az összehasonlíthatóság problémája

A pénzügyi döntéstámogatás egyik alapfeltétele, hogy az elemzéshez használt adatok megbízhatóak, értelmezhetőek és összehasonlíthatóak legyenek. A vezetői tervezés, az eltéréselemzés, a teljesítményértékelés és a pénzügyi előrejelzés egyaránt abból indul ki, hogy az egymást követő időszakok adatai között fennáll valamilyen tartalmi folytonosság. Ez a folytonosság azt jelenti, hogy az egymást követő időszakok adatai azonos vagy legalább megfelelően korrigálható gazdasági tartalmat fejeznek ki.

Az adatminőség ezért nem szűkíthető le arra, hogy az adatok technikailag hozzáférhetőek vagy számszakilag rendezettek-e. A pénzügyi adatok döntéstámogatási értékét az is meghatározza, hogy ismert-e az adatok keletkezési módja, szervezeti háttere, számviteli tartalma és módszertani korlátja. A DAMA-DMBOK adatmenedzsment keretrendszer az adatkormányzás, adatminőség, integráció és interoperabilitás kérdéseit a szervezeti adatvagyon kezelésének központi elemeiként tárgyalja (DAMA International, 2017). Ez különösen fontos olyan szervezetekben, ahol az adatok több rendszerből, eltérő szervezeti egységekből és különböző beszámolási logikákból származnak.

A generatív AI szempontjából az adatminőség kérdése tovább bővül. Nemcsak azt kell vizsgálni, hogy az adatok hibátlanok-e, hanem azt is, hogy a modell számára biztosított információ elegendő-e az adatok helyes értelmezéséhez. Egy pénzügyi beszámoló számszakilag pontos lehet, de ha az elemzés nem tartalmazza az intézményi átalakulás, integráció, finanszírozási logikaváltás vagy beszámolási módszertan változásának magyarázatát, akkor az AI könnyen úgy kezelheti az adatokat, mintha azok homogén idősor részei lennének.

Ez a probléma összekapcsolható a gépi tanulási rendszerek sérülékenységeivel is. Sculley és szerzőtársai arra hívják fel a figyelmet, hogy a valós környezetben működő gépi tanulási rendszerekben jelentős rejtett technikai adósság keletkezhet, különösen akkor, ha a modell működési környezete, az adatok szerkezete vagy az adatgeneráló folyamat megváltozik (Sculley et al., 2015). E gondolat a jelen tanulmányban pénzügyi döntéstámogatási problémaként jelenik meg: ha az adatok mögötti szervezeti, finanszírozási vagy beszámolási tartalom megváltozik, az AI által azonosított mintázatok csak korlátozottan értelmezhetőek.

A pénzügyi elemzésben az összehasonlíthatóság sérülése különösen nagy kockázatot jelent. Egy adott költségsor növekedése például utalhat hatékonyságromlásra, de jelezhet feladatbővülést, intézményi integrációt, finanszírozási szerkezetváltozást vagy elszámolási módszertani módosulást is. Hasonlóképpen a bevételek, támogatások, személyi jellegű ráfordítások vagy beruházási értékek változása csak akkor értelmezhető érdemben, ha ismert, hogy az adott időszakokban az intézmény azonos szervezeti és működési tartalommal rendelkezett-e.

A generatív AI ebben a helyzetben kettős szerepet tölthet be. Egyrészt képes lehet az adatok gyors feldolgozására és az eltérések előzetes azonosítására. Másrészt éppen

a nyelvileg meggyőző, koherens válaszok miatt fennáll annak veszélye, hogy az elemzés túlzott magabiztossággal fogalmaz meg következtetéseket. Ezért strukturális változásokkal terhelt környezetben az AI alapú pénzügyi döntéstámogatás nem választható el az adatok szakértői előkészítésétől, a módszertani kontrolltól és az intézményi kontextus pontos rögzítésétől.

2.3. Strukturális törések és a historikus adatok értelmezhetősége

A strukturális törés fogalma azokat a helyzeteket írja le, amikor az adatokat előállító rendszer működésében olyan változás következik be, amely megszakítja a korábbi mintázatok közvetlen értelmezhetőségét. Idősoros és pénzügyi elemzésekben ez azt jelenti, hogy az adatok formailag továbbra is egymás után rendezhetők, gazdasági tartalmuk azonban már nem feltétlenül azonos módon értelmezhető. A klasszikus idősoros gondolkodás egyik alapfeltevése, hogy a múltbeli folyamatokból akkor vonhatók le következtetések, ha az adatgeneráló rendszer viszonylag stabil marad (Chatfield, 2003).

Strukturális törést több tényező is okozhat. Ilyen lehet a szervezeti integráció, a fenntartói modell átalakulása, a finanszírozási rendszer változása, a számviteli vagy beszámolási szabályok módosulása, a működési méret jelentős bővülése vagy szűkülése, valamint az intézményi feladatellátás átrendeződése. Ezek a változások nem feltétlenül jelennek meg közvetlenül az egyes pénzügyi sorok elnevezésében, de befolyásolják azok tartalmát és értelmezhetőségét.

A strukturális törés ezért nem azonos az egyszerű adatváltozással. Egy pénzügyi mutató növekedése vagy csökkenése önmagában még nem jelenti azt, hogy az intézmény működése hatékonyabbá vagy kevésbé hatékonyá vált. Az értelmezéshez tudni kell, hogy az adott mutató mögött azonos szervezeti kör, azonos finanszírozási logika és azonos beszámolási tartalom áll-e. Ha ezek bármelyike lényegesen megváltozik, az idősoros összehasonlítás csak módszertani korrekcióval vagy kiegészítő magyarázattal lehet érvényes.

A generatív AI működése szempontjából ez a helyzet különösen érzékeny. A modell az elemzés során összefüggéseket keres, eltéréseket azonosít, és a rendelkezésére álló információk alapján magyarázatokat állít elő. Ha azonban az adatokhoz nem kapcsolódik megfelelő kontextusinformáció, az AI a strukturális törést könnyen egyszerű trendként vagy teljesítményváltozásként értelmezheti. Ez a pénzügyi döntéstámogatásban torz következtetésekhez vezethet, különösen akkor, ha az elemzés előrejelzési, hatékonyságvértékelési vagy vezetői beszámolási célokat szolgál.

A strukturális törések kezelése ezért nem várható el kizárólag magától a technológiától. Az AI-alapú döntéstámogatás megbízhatóságának feltétele, hogy az adatok előkészítése során az intézményi változásokat, a beszámolási eltéréseket és az összehasonlíthatósági korlátokat expliciten rögzítsék. Ezt a szemléletet erősíti az AI kockázatkezelési megközelítése is, amely szerint az AI-rendszerek alkalmazása során a kontextus, az emberi felügyelet és a kockázatok folyamatos értékelése alapvető követelmény (NIST, 2023).

2.4. Modellváltás és összehasonlíthatósági korlátok a felsőoktatásban

A magyar felsőoktatási modellváltás a jelen tanulmány szempontjából olyan intézményi környezetet jelent, amelyben a strukturális törések problémája jól vizsgálható. A fenntartói, irányítási, finanszírozási és szervezeti változások több intézménynél a pénzügyi adatok értelmezési környezetét is módosították. Ez különösen fontos akkor, amikor a modellváltás eredményességét pénzügyi mutatók időbeli összehasonlításával kívánják értékelni.

A hatékonyság vizsgálata csak akkor lehet módszertanilag megalapozott, ha az összehasonlított időszakok mögött álló intézményi tartalom kellően homogén, vagy az eltérések megfelelően korrigálhatók. A felsőoktatásban ezt nehezíti, hogy az oktatási, kutatási, közfeladatellátási és vagyongazdálkodási funkciók egyszerre jelennek meg, a finanszírozás pedig többféle forrás kombinációjára épül.

Az European University Association Magyarországról szóló elemzése szerint az alapítványi fenntartású egyetemeken esetében a kuratóriumi típusú fenntartói testület és az intézményi vezetés közötti hatáskörmegosztás új irányítási logikát eredményezett, amely a döntési és adat-előállítási folyamatokat is befolyásolhatja (EUA, 2023).

Ebben a környezetben a generatív AI alkalmazása hasznos lehet a beszámolók és pénzügyi adatok gyors áttekintésére, de kockázatot jelenthet, ha az intézményi változásokból eredő összehasonlíthatósági korlátokat nem ismeri fel. A jelen tanulmány ezért nem a modellváltás sikerességét értékeli, hanem azt vizsgálja, hogy az Alapú elemzés milyen módszertani kockázatokkal jár strukturálisan változó intézményi környezetben.

3. Módszertan

3.1. A kutatás jellege és célja

A tanulmány feltáró jellegű kvalitatív esettanulmányként vizsgálja a generatív mesterséges intelligencia pénzügyi döntéstámogatási alkalmazhatóságát strukturálisan változó felsőoktatási környezetben. A kutatás célja annak feltárása, hogy a szervezeti, fenntartói, finanszírozási és beszámolási változások miként befolyásolják a pénzügyi adatok összehasonlíthatóságát, valamint az AI alapú elemzés megbízhatóságát.

A tanulmány a generatív AI-t egyszerre kezeli elemzési eszközként és vizsgálati tárgyként. A kiinduló feltevés szerint az AI képes lehet pénzügyi adatok gyors rendszerezésére és vezetői következtetések előkészítésére, strukturális törés esetén azonban fennáll annak kockázata, hogy az eltérő intézményi tartalmú adatokat homogén időszorként értelmezi.

3.2. A vizsgálati környezet és az adatforrások

A vizsgálat egy modellváltáson és jelentős intézményi átalakuláson átesett magyar felsőoktatási intézmény nyilvánosan hozzáférhető éves beszámolóira, közhasznúsági mellékleteire, szöveges beszámolóira és kapcsolódó pénzügyi dokumentumaira épül. Az intézmény neve a tanulmányban nem jelenik meg, mivel a kutatás célja nem intézményi teljesítményértékelés, hanem annak bemutatása, hogy strukturális törések esetén milyen korlátai lehetnek az AI alapú pénzügyi döntéstámogatásnak.

A vizsgált időszak a modellváltást megelőző és az azt követő éveket is magában foglalja, így alkalmas az időbeli összehasonlítás problémáinak elemzésére. A nyilvánosan hozzáférhető dokumentumok erősítik a kutatás ellenőrizhetőségét, ugyanakkor nem tartalmazzák teljes körűen azokat a belső vezetői, kontrolling és naturális adatokat, amelyek egy átfogó hatékonyságvizsgálathoz szükségesek lennének. A tanulmány ezért másodelemzéseként az összehasonlíthatóság, az AI-értelmezés és a szakértői kontroll kérdésére fókuszál.

3.3. Az elemzés menete

Az elemzés első lépése a vizsgált dokumentumok áttekintése és azoknak a strukturális változásoknak az azonosítása volt, amelyek befolyásolhatják az adatok összehasonlíthatóságát. Ilyen tényezőként jelent meg a fenntartói modell változása, az intézményi integráció, a szervezeti struktúra módosulása, a finanszírozási logika átalakulása, valamint a beszámolási és adat-előállítási keretek változása.

A második lépésben a népszerűbb generatív AI modellek azonos dokumentumcsomag alapján pénzügyi és hatékonysági elemzési feladatot kaptak. Az AI által előállított válaszok értékelése arra irányult, hogy a modellek mennyiben ismerték fel a strukturális törésből eredő összehasonlíthatósági korlátokat.

A harmadik lépés az AI által generált megállapítások szakértői értelmezése volt. Az értékelés azt vizsgálta, hogy a modellek milyen mértékben vették figyelembe az intézményi környezet változását, a modellváltásból eredő töréspontokat és a pénzügyi adatok tartalmi korlátait. Kiemelt szempont volt, hogy az AI megkülönbözteti-e a tényleges gazdálkodási teljesítményváltozást azoktól a változásoktól, amelyek szervezeti, finanszírozási vagy beszámolási okokra vezethetők vissza.

3.4. Értékelési szempontok

Az AI által készített elemzések értékelése előre meghatározott szempontok alapján történt. A vizsgálat azt elemezte, hogy a modellek milyen mértékben képesek pénzügyi és hatékonysági következtetéseket megfogalmazni, illetve felismerik-e az intézményi, finanszírozási és beszámolási változásokból eredő összehasonlíthatósági korlátokat. Ennek érdekében három prompt került alkalmazásra: egy semleges vezetői elemzési feladat, egy strukturális törésre irányuló vizsgálat, valamint döntéstámogatási kockázatokat feltáró kérdés.

Az alkalmazott promptok a következők voltak:

1. prompt: semleges vezetői elemzés

„Készíts vezetői szintű pénzügyi és hatékonysági elemzést a feltöltött felsőoktatási beszámolókat alapján. Térj ki a bevételek, ráfordítások, eredményesség, vagyoni helyzet, finanszírozási szerkezet és működési hatékonyság alakulására. A végén foglalmazz meg óvatos következtetést arról, hogy a rendelkezésre álló adatok alapján megítélhető-e az intézmény hatékonyságának változása.”

2. prompt: strukturális törésre fókuszáló elemzés

„Vizsgáld meg a feltöltött beszámolókat abból a szempontból, hogy az adatok alkalmasak-e közvetlen idősoros összehasonlításra. Azonosítsd az esetleges szervezeti, fenntartói, finanszírozási vagy beszámolási változásokat, amelyek strukturális törést okozhatnak. Foglalmazz meg, hogy ezek miként korlátozzák a pénzügyi és hatékonysági következtetéseket.”

3. prompt: AI-döntéstámogatási kockázatok

„A feltöltött dokumentumok alapján mutasd be, milyen döntéstámogatási kockázatok merülhetnek fel, ha generatív AI készít pénzügyi vagy hatékonysági elemzést strukturálisan változó intézményi környezetben. Térj ki arra, mely következtetések lehetnek megalapozottak, melyek igényelnek óvatosságot, és milyen szakértői kontroll szükséges.”

Az értékelés fő szempontjai a következők voltak:

1. táblázat: Az AI alapú pénzügyi és hatékonysági elemzések értékelési szempontjai

Értékelési szempont	Vizsgálati kérdés
Dokumentumfeldolgozhatóság	Képes volt-e a modell a feltöltött dokumentumok érdemi feldolgozására?
Pénzügyi adatok rendszerezése	Áttekinthetően azonosította-e a fő bevételi, ráfordítási, eredményességi és vagyoni adatokat?
Strukturális törés felismerése	Érzékelte-e a modell, hogy a vizsgált időszakban az intézményi környezet jelentősen megváltozott?
Összehasonlíthatósági korlátok jelzése	Felhívta-e a figyelmet arra, hogy az adatok nem feltétlenül alkotnak homogén idősorokat?
Számviteli és beszámolási logika kezelése	Figyelembe vette-e a költségvetési és eredményszemléletű beszámolási kategóriák eltérését?
Intézményi és finanszírozási kontextus kezelése	Értelmezte-e a fenntartói, szervezeti, finanszírozási és vagyoni jogi változások hatását?
Hatékonysági következtetések óvatossága	Kerülte-e a túlzottan közvetlen vagy magabiztos hatékonysági állításokat?
További adatigény és szakértői kontroll jelzése	Utalt-e arra, hogy természetes, fajlagos vagy belső kontrollingadatokra, valamint szakértői értelmezésre van szükség?
Döntéstámogatási használhatóság	Milyen mértékben alkalmas a válasz vezetői döntés-előkészítés támogatására?

Forrás: saját szerkesztés

Az értékelési szempontok együttesen azt szolgálták, hogy az AI válaszok ne pusztán tartalmi teljességük vagy nyelvi minőségük alapján legyenek megítélhetők. A vizsgálat szempontjából legalább ilyen fontos volt, hogy a modell képes volt-e felismerni az adatok keletkezési környezetének változását, és ennek megfelelően korlátozta-e saját következtetéseinek érvényességét.

3.5. A módszertan korlátai

A kutatás feltáró jellegű, ezért eredményei nem általánosíthatók automatikusan valamennyi felsőoktatási intézményre vagy minden AI alapú döntéstámogatási helyzetre. A vizsgálat egy konkrét, nyilvánosan hozzáférhető dokumentumokra épülő felsőoktatási intézmény példáján keresztül mutatja be a strukturális törésekből eredő módszertani kockázatokat.

A felhasznált beszámolók és kapcsolódó dokumentumok ellenőrizhető adatforrást jelentenek, ugyanakkor nem tartalmazzák teljeskörűen azokat a belső vezetői, kontrolling és természetes adatokat, amelyek egy átfogó hatékonyságvizsgálathoz szükségesek lennének. Emiatt a tanulmány nem vállalkozik a modellváltás eredményességének teljes körű értékelésére. Fókusza az AI alapú elemzés összehasonlíthatósági és értelmezési korlátainak vizsgálatára irányul.

A vizsgálat eredményeit az is befolyásolja, hogy a generatív AI modellek válaszai függhetnek az alkalmazott modelltől, a dokumentumok technikai feldolgozhatóságától, valamint a prompt megfogalmazásától. Ezért a modellválaszok a dolgozatban olyan elemzési példaként jelennek meg, amelyek az AI alapú döntéstámogatás lehetőségeit és korlátait teszik láthatóvá.

4. A generatív AI modellek válaszainak tapasztalatai

A vizsgálat során három generatív AI-modell került bevonásra: a ChatGPT, a Gemini és a Claude. A modellek azonos vagy tartalmilag azonos dokumentumcsomag alapján kaptak pénzügyi és hatékonysági elemzési feladatot. A promptok célja annak feltárása volt, hogy a modellek miként értelmezik a strukturálisan változó intézményi környezetből származó pénzügyi adatokat, felismerik-e az összehasonlíthatósági korlátokat, és milyen döntéstámogatási kockázatok jelenhetnek meg az AI-alapú elemzés során.

Az értékelés a válaszok tartalmi részletessége, pénzügyi értelmezhetősége, módszertani óvatossága és döntéstámogatási használhatósága alapján történt. Kiemelt szempont volt, hogy a modellek érzékelik-e az adatok mögötti intézményi és számviteli változásokat, valamint jelzik-e saját következtetéseik érvényességi határait.

4.1. A Gemini válaszainak tapasztalatai

A Gemini válaszai a strukturális törés felismerése szempontjából erős eredményt mutattak. A modell nem egyszerű pénzügyi idősróként kezelte a vizsgált dokumentumokat, és már a célzottabb elemzési helyzetben jelezte, hogy a 2018–

2022. év közötti adatok közvetlen, lineáris összehasonlítása módszertanilag korlátozott. A válasz több olyan tényezőt azonosított, amely az összehasonlíthatóságot befolyásolhatja: beszámolási és számviteli rendszerváltást, fenntartói és finanszírozási modellváltást, szervezeti integrációt, valamint vagyoni átalakulást.

A Gemini erőssége, hogy a strukturális törést többdimenziós problémaként értelmezte. Különbséget tett a modellváltás előtti költségvetési intézményi beszámolási logika és a modellváltás utáni, számviteli törvény szerinti beszámolási rendszer között. Ez a tanulmány szempontjából lényeges, mivel a költségvetési kiadási és bevételi kategóriák nem feleltethetők meg automatikusan az eredményszemléletű ráfordítási és bevételi kategóriáknak.

A modell az AI alapú döntéstámogatási kockázatok azonosításában is erős volt. Kiemelte a folytonosság téves feltételezésének kockázatát, az eltérő számviteli kategóriák összemosásának veszélyét, valamint azt, hogy az AI a bevételi vagy eszközállományi növekedést módszertanilag nem igazolt hatékonyságjavulásként értelmezheti. A válasz ugyanakkor több helyen túl erős vagy publicisztikus fordulatokat használt, például a folytonosság „halucinációjáról” vagy az összehasonlítás „ellehetetlenüléséről” írt. Ezek a megállapítások gondolatilag hasznosak, de tudományos szövegben óvatosabb megfogalmazást igényelnek.

Összességében a Gemini módszertani szempontból erős választ adott: jól felismerte, hogy a vizsgált adatok nem homogén időszorként értelmezhetők, és azonosította azokat a strukturális tényezőket, amelyek az AI-alapú pénzügyi és hatékonysági elemzést korlátozzák.

4.2. A ChatGPT válaszainak tapasztalatai

A ChatGPT válasza vezetői szempontból jól strukturált pénzügyi elemzést adott. A modell elkülönítette a modellváltás előtti és utáni időszakot, ezzel jelezve, hogy érzékelt az intézményi környezet változását. A válasz logikusan tárgyalta a bevételi trendeket, a ráfordítások és költségszerkezet változását, a vagyoni helyzetet, a finanszírozási szerkezetet és a működési hatékonyságra utaló jeleket.

A modell erőssége a vezetői logikájú szerkesztés volt. A válasz áttekinthetően mutatta be a fő pénzügyi területeket, és alkalmas volt arra, hogy a vezetői olvasó gyors képet kapjon a vizsgált dokumentumokból kirajzolódó főbb tendenciákról. Ugyanakkor több ponton fejlődési narratívát épített a vizsgált időszakra. Ilyen volt például a „vállalatszerűbb gazdálkodási logika”, a „finanszírozási diverzifikáció javulása” vagy a „szerkezeti modernizáció” megfogalmazása. Ezek a következtetések további módszertani ellenőrzést igényelnek, mivel a pozitív eredmény, a cash-flow szemlélet vagy a megváltozott beszámolási kategóriák önmagukban nem igazolják a működési hatékonyság javulását.

A ChatGPT felismerte a strukturális törés jelenlétét, de annak módszertani következményeit kevésbé részletezte, mint a Gemini. A válaszban megjelent a modellváltás előtti és utáni időszak elkülönítése, ugyanakkor a számviteli és beszámolási logikák eltérése kisebb hangsúlyt kapott. A költségvetési beszámolók

pénzforgalmi kategóriái és a későbbi eredményszemléletű beszámolók kategóriái közötti különbség kulcskérdés, mivel ezek közvetlen összevetése torzíthatja a hatékonysági következtetéseket.

A végkövetkeztetés ugyanakkor módszertanilag óvatos volt. A modell nem állította egyértelműen, hogy az intézmény hatékonyabbá vált, és jelezte, hogy a tényleges oktatási, kutatási vagy működési hatékonyság megítéléséhez további természetes és fajlagos mutatókra lenne szükség. A ChatGPT válasza ezért kettős képet mutat: vezetői áttekintésként jól használható, de strukturálisan változó környezetben szakértői ellenőrzést igényel.

4.3. A Claude alkalmazásának tapasztalatai

A vizsgálat harmadik modellje a Claude először ingyenes, majd előfizetéses verziója volt. A kísérlet során dokumentumbeolvasási korlát jelentkezett: a modell nem volt képes a feltöltött beszámolók megbízható feldolgozására, így nem készült olyan tartalmi pénzügyi elemzés, amely azonos feltételek mellett összevethető lett volna a ChatGPT és a Gemini válaszaival.

Ez a tapasztalat az AI alapú döntéstámogatás gyakorlati alkalmazhatóságának egyik fontos korlátjára mutat rá. A pénzügyi és intézményi beszámolók gyakran hosszú, eltérő szerkezetű, táblázatokat, mellékleteket és szöveges értékeléseket tartalmazó dokumentumok. Egy AI modell elemzési képessége csak akkor értékelhető érdemben, ha előzetesen képes ezeket technikailag feldolgozni, a releváns adatokat kiemelni és a dokumentumrészeket összekapcsolni.

A Claude esete ezért a módszertani korlátok közé tartozik. Ebben a vizsgálati helyzetben nem tartalmi összehasonlítási pontként, hanem technikai alkalmazhatósági korlátként jelent meg. Ez nem a modell általános képességeiről ad átfogó értékelést, csupán azt mutatja, hogy a konkrét dokumentumcsomag és felhasználási helyzet esetében a dokumentumbeolvasás akadályozta az elemzés elkészítését.

4.4. A modellek összehasonlító értékelése

A három modell eltérő alkalmazhatósági mintázatot mutatott. A Gemini elsősorban a strukturális törés felismerésében és az összehasonlíthatósági korlátok azonosításában teljesített erősen. Válaszai jól mutatták, hogy a modell képes az adatok mögötti intézményi és számviteli kontextus több rétegét felismerni. A ChatGPT erőssége a vezetői szintű, áttekinthető elemzési szerkezet volt. A modell jól elkülönítette a fő pénzügyi területeket, és óvatos végkövetkeztetést fogalmazott meg, de a strukturális törés mélyebb módszertani következményeit kevésbé bontotta ki. A Claude esetében az érdemi összehasonlítást a dokumentumbeolvasási korlát akadályozta.

A vizsgálat alapján a generatív AI modellek eltérő módon járulhatnak hozzá a pénzügyi döntéstámogatáshoz. Egyes modellek erősebbek lehetnek az adatok gyors rendszerezésében és vezetői összefoglalásában, mások jobban felismerhetik az

összehasonlíthatósági és módszertani korlátokat. A döntéstámogatási értéket ezért nemcsak a válasz részletezettsége vagy nyelvi minősége határozza meg, hanem az is, hogy a modell képes-e érzékelni az adatok mögötti strukturális változásokat.

2. táblázat: A vizsgált generatív AI modellek válaszainak összehasonlító értékelése

Értékelési szempont	Gemini	ChatGPT	Claude
Dokumentumfeldolgozhatóság	Képes volt érdemi elemzésre	Képes volt érdemi elemzésre	Dokumentumbeolvasási korlát jelentkezett
Pénzügyi adatok rendszerezése	Közepes-jó	Jó	Nem volt értékelhető
Strukturális törés felismerése	Erős	Közepes-jó	Nem volt értékelhető
Összehasonlíthatósági korlátok jelzése	Erős	Közepes	Nem volt értékelhető
Számviteli és beszámolási logika kezelése	Erős	Közepes	Nem volt értékelhető
Intézményi és finanszírozási kontextus kezelése	Erős	Közepes-jó	Nem volt értékelhető
Hatékonyági következtetések óvatossága	Erős	Jó	Nem volt értékelhető
További adatigény és szakértői kontroll jelzése	Erős	Jó	Nem volt értékelhető
Döntéstámogatási használhatóság	Módszertani figyelmeztetésként erős	Vezetői áttekintésként erős, módszertani kontrollal	A konkrét vizsgálatban nem volt használható

Forrás: saját szerkesztés

Összegzés

A tanulmány a generatív mesterséges intelligencia pénzügyi döntéstámogatási alkalmazhatóságát vizsgálta strukturálisan változó intézményi környezetben. A kutatás arra irányult, hogy az AI modellek felismerik-e azokat az összehasonlíthatósági korlátokat, amelyek modellváltás, szervezeti átalakulás, finanszírozási logikaváltás és beszámolási rendszerváltás esetén jelentkeznek.

A vizsgálat egy modellváltáson átesett magyar felsőoktatási intézmény nyilvánosan hozzáférhető beszámolóira és kapcsolódó pénzügyi dokumentumaira épült. Az intézmény elemzési környezetként szerepelt, amely jól szemlélteti, hogy strukturális törés esetén a pénzügyi adatok formális rendelkezésre állása nem jelent automatikus tartalmi összehasonlíthatóságot.

A modellek eltérően kezelték ugyanazt az elemzési helyzetet. A Gemini erősebben azonosította a számviteli, fenntartói, finanszírozási, szervezeti és vagyoni változásokat. A ChatGPT vezetői szempontból rendezettebb elemzést készített, de a strukturális törés módszertani következményeit kevésbé részletezte. A Claude előfizetéses verziójánál dokumentumbeolvasási korlát jelentkezett, ami az AI alapú döntéstámogatás technikai előfeltételeire hívta fel a figyelmet.

A vizsgálat alapján a generatív AI alkalmas lehet pénzügyi dokumentumok elsődleges feldolgozására, tendenciák azonosítására és vezetői összefoglalók készítésére. Strukturális törés esetén azonban kockázatos, ha az AI a pénzügyi mutatók változását közvetlenül hatékonysági következtetéssé alakítja, miközben azok háttérben intézményi, finanszírozási vagy számviteli átalakulás is állhat.

A téma aktualitását a hazai felsőoktatási modellváltás értékelése adja. A források, a vagyon és a beruházási volumen növekedése sokszor a modellváltás sikerességének bizonyítékaként jelenik meg, miközben a méret és forrásbővülés nem azonos a

tényleges hatékonyságjavulással. A generatív AI alkalmazása ebben a helyzetben azért releváns, mert láthatóvá teszi, hogy a modellek érzékelik-e ezt a módszertani különbséget.

A tanulmány eredményei feltáró jellegűek. A vizsgálat nyilvános dokumentumokra, általánosan elérhető AI modellekre és meghatározott prompthelyzetekre épült. Vállalati vagy intézményi AI megoldások erősebb eredményt mutathatnak, különösen strukturált adatbázisok, belső kontrollingadatok, egységesített mutatórendszerek és előkészített dokumentumállomány használata mellett. A strukturális törések elemzésére emellett normalizált pénzügyi mutatók, fajlagos hatékonysági indikátorok, töréspontvizsgálatok és szakértői összehasonlító keretek is alkalmazhatók.

Összességében a generatív AI értékes elemzéstámogató eszköz lehet, de strukturálisan változó intézményi környezetben csak kontextusba helyezett adatokkal, módszertani óvatossággal és szakértői kontroll mellett használható megbízhatóan.

Hivatkozások

- Chatfield, C. (2003). *The analysis of time series: An introduction* (6th ed.). Chapman & Hall/CRC. <https://doi.org/10.4324/9780203491683>
- DAMA International. (2017). *DAMA-DMBOK: Data management body of knowledge* (2nd ed.). Technics Publications.
- Davenport, T. H., & Ronanki, R. (2018). Artificial intelligence for the real world. *Harvard Business Review*, 96(1), 108–116. https://academichelptoday.com/assets/documents/Artificial_Intelligence_for_the_Real_World_-_HBR.pdf
- European University Association. (2023). *The evolution of university autonomy in Hungary: A complementary analysis to University Autonomy in Europe IV: The Scorecard 2023*. https://www.eua.eu/downloads/publications/2023%20eua%20autonomy%20scorecard_hungary.pdf
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press. <https://www.deeplearningbook.org>
- National Institute of Standards and Technology. (2023). *Artificial intelligence risk management framework (AI RMF 1.0)* (NIST AI 100-1). U.S. Department of Commerce. <https://nvlpubs.nist.gov/nistpubs/ai/NIST.AI.100-1.pdf>

Sculley, D., Holt, G., Golovin, D., Davydov, E., Phillips, T., Ebner, D., Chaudhary, V., Young, M., Crespo, J.-F., & Dennison, D. (2015). Hidden technical debt in machine learning systems. In C. Cortes, N. Lawrence, D. Lee, M. Sugiyama, & R. Garnett (Eds.), *Advances in neural information processing systems 28* (pp. 2503–2511). Curran Associates. https://proceedings.neurips.cc/paper_files/paper/2015/file/86df7dcfd896fcdf2674f757a2463eba-Paper.pdf

AZ INNOVÁCIÓS TÁMOGATÁSOK ELŐREJELEZHETŐSÉGE GAZDASÁGI INDIKÁTOROK ALAPJÁN

KIRÁLY Tünde

Pannon Egyetem

kiraly.tunde@gtk.uni-pannon.hu

Dr. HARTA Péter

Pannon Egyetem

harta.peter@gtk.uni-pannon.hu

<https://doi.org/10.15170/XVIIPPN-Tk-KTK-2026-08>

Absztrakt

Magyarország innovációs teljesítménye és versenyképessége szempontjából kiemelt jelentőségű az innovációs ökoszisztémák fejlődése, amelyekben az egyetemek, a vállalatok és a kormányzat együttműködése meghatározó szerepet játszik. A Triple Hélix modell alapján a kormányzati szereplők, különösen a Nemzeti Kutatási, Fejlesztési és Innovációs Hivatal (NKFIH) pályázati rendszerein keresztül, jelentős forrásokkal támogatják az ipari és egyetemi szereplők innovációs tevékenységeit. Ugyanakkor kevésbé ismert, hogy a támogatások elosztása milyen jellemzők és indikátorok mentén történik, illetve mely tényezők befolyásolják leginkább a megszerzett források mennyiségét.

A tanulmány célja annak vizsgálata, hogy az innovációs ökoszisztéma egyetemi és vállalati szereplői milyen tulajdonságaik alapján részesülnek NKFIH támogatásokban, valamint az egyes indikátorok relatív fontosságának meghatározása. A kutatás során XGBoost gépi tanulási modellt tanítunk fel olyan intézmények adataival, amelyek a 2019-2025 időszakban rendelkeznek nyertes NKFIH pályázatokkal. A feltanult modell lehetővé teszi az egyes magyarázó változók fontosságát a pályázatok során elnyert összeg függvényében.

Eredményeink rámutatnak, hogy néhány kulcsindikátor – mint az Értékesítés Nettó Árbevétele (OPR) és az Összes Eszköz (TA) – kiemelkedő szerepet játszik a támogatások elnyerésében, míg más változók hatása elhanyagolható. A modell alapján nemcsak a múltbeli támogatási döntések magyarázhatók, hanem becsülhető egy adott vállalat jövőbeli pályázati esélye is. A kutatás hozzájárul az innovációs ökoszisztéma működésének jobb megértéséhez, valamint a vállalati és szakpolitikai döntéshozatal támogatásához.

Kulcsszavak: innovációs ökoszisztéma, gépi tanulás, előrejelzés, xgboost

Bevezetés

A globális gazdasági versenyben az innováció egyre inkább a hosszú távú növekedés, a termelékenység és a nemzetközi versenyképesség egyik legfontosabb meghatározó tényezőjévé vált. A technológiai fejlődés nemcsak új termékek és szolgáltatások megjelenését eredményezi, hanem átalakítja a vállalatok működését, a piaci struktúrákat és a gazdasági kapcsolatrendszereket is. Így a napjainkban egyre nagyobb figyelem irányul arra, hogy az innovációs támogatások elnyerését milyen vállalati, pénzügyi és szabadalmi környezet befolyásolja.

Az innováció ösztönzése olyan gazdaságokban kiemelten fontos, ahol a termelékenység fokozása és a magasabb hozzáadott értékű termelés stratégiai célként jelenik meg. Magyarország esetében az innovációs ökoszisztéma fejlesztése kiemelt szakpolitikai terület, amelyben meghatározó szerepet töltenek be az állami támogatások. A Nemzeti Kutatási, Fejlesztési és Innovációs Hivatal pályázati rendszerein keresztül jelentős források kerülnek vállalati és egyetemi szereplőkhöz annak érdekében, hogy növekedjen az innovációs aktivitás és erősödjenek az egyetem–ipar kapcsolatok (NKFIH, 2025). Ez szorosan kapcsolódik a Triple Hélix modell logikájához, amely szerint az innovációs teljesítmény az egyetemek, a vállalatok és a kormányzat együttműködésének eredményeként alakul ki [(Etzkowitz & Leydesdorff, 2000); (Cai & Etzkowitz, 2021)].

Bár az innovációs támogatások gazdasági hatásait számos kutatás vizsgálta [(Banai, Lang, Nagy, & Stancsics, 2017); (Varga & Farkas, 2021); (Halmosi, 2021)], kevesebb figyelem irányul arra, hogy maga a támogatási forrásallokáció milyen mechanizmusok mentén is működnek. Valamint kevésbé ismert, hogy milyen vállalati, pénzügyi és szabadalmi jellemzők növelik a támogatások megszerzésének valószínűségét, illetve mely tényezők befolyásolják leginkább az elnyert források nagyságát. A nemzetközi szakirodalmak szerint megállapítható, hogy a támogatási döntések nem tekinthetők véletlenszerűeknek, hanem szorosan összefüggnek a vállalatok pénzügyi és innovációs jellemzőivel [(Falk & Svensson, 2018); (Espinosa-Blasco, Penagos-Londoño, & Ruiz-Moreno, 2023); (Yu, Zhang, & Zhu, 2025)].

Az elmúlt években a gépi tanulási módszerek egyre nagyobb szerepet kaptak az ilyen komplex döntési mechanizmusok elemzésében. A Random Forest, a Gradient Boosting módszerek között az XGBoost lehetővé teszi az innovációs támogatások allokációját (Espinosa-Blasco, Penagos-Londoño, & Ruiz-Moreno, 2023), európai uniós forráselosztási mechanizmusok elemzését (Caravaggio, Resce, & Vaquerp-Pineiro, 2025), valamint vállalati innovációs (Seong-Won & Hee-Chan, 2020) és szabadalmi aktivitás (Mashhadi, Saghezchi, & Kashani, 2025) előrejelzését.

Jelen tanulmány célja annak vizsgálata, hogy a magyar innovációs ökoszisztéma egyetemi és vállalati szereplői milyen jellemzőik alapján részesülnek NKFIH támogatásokban, valamint mely indikátorok játszanak meghatározó szerepet a források elosztásában. A kutatás során XGBoost módszert – mint gépi tanulási módszert – alkalmazunk a 2020–2025 közötti időszak nyertes pályázati adatain, amely lehetőséget biztosít az egyes változók relatív fontosságának meghatározására és a támogatási döntések mögött meghúzódó mintázatok feltárására. A tanulmány

célja ezzel nemcsak a hazai innovációs ökoszisztéma működésének mélyebb megértése, hanem a bizonyítékalapú szakpolitikai döntéshozatal támogatása is. Továbbá a tanulmány célja, hogy alapot szolgáltatson az innovációs ökoszisztéma szereplőinek a pályázataik sikerességének növelésében.

Szakirodalmi áttekintés

Az innováció a modern gazdasági növekedés és versenyképesség egyik legfontosabb meghatározó tényezője. A klasszikus növekedésméleti megközelítések közül Robert Solow (1957) modellje rámutat arra, hogy a hosszú távú gazdasági növekedést elsősorban a technológiai fejlődés hajtja, amely közvetlenül befolyásolja a termelékenységet és a gazdasági teljesítményt. Tehát az innováció nem csak az új termékek és technológiák megjelenését, bevezetését jelenti, hanem a gazdasági struktúrák és piacok átalakulását is. Schumpeter értelmezésében az innováció magában foglalja az új termékek létrehozását, új termelési eljárások bevezetését, új piacok megnyitását, új beszerzési források megteremtését és új szervezeti formák kialakítását (Schumpeter, 1980).

Az innováció gazdasági jelentősége túlmutat az egyedi vállalati szinten, mivel a tudás és technológia tovagyűrűző hatásai révén hozzájárul a termelékenység növekedéséhez és a gazdasági fejlődéshez [(Barta, 2002), (Halpern, 2020)]. Ehhez hasonló következtetésre jut az MNB 2024-es Termelékenységi jelentési is, amely alapján az államnak fontos szerepe van az innovációs ökoszisztéma létrehozásában, a termelékenységnövelő hatás elérése érdekében (MNB, 2024). Valamint Bódis – Kiss (2025) tanulmánya is, amely szerint ehhez az innováló vállalatok számát és arányát kell a gazdaságban növelni.

Az innováció ösztönzésének egyik központi eszköze a szellemi tulajdon védelme, különösen a szabadalmi rendszer. A schumpeteri modellben a szabadalom nem pusztán az innováció eredményének tekinthető, hanem annak egyik legfontosabb ösztönző mechanizmusa, hiszen ideiglenesen monopolhelyzetet biztosít az újítók/feltalálók számára. Ez a monopólium lehetővé teszi az innovációba történő beruházások megtérülését, ugyanakkor korlátozza a versenyt is. Schumpeter ezt az ellentmondást úgy oldja fel, hogy a verseny fókuszát a „piacon” folyó versenyről a „piacért” folyó versenyre helyezi át, ahol a vállalatok a domináns piaci pozíció megszerzéséért versenyeznek. Ezt a gondolatot Joseph Stiglitz és Bruce Greenwald (2014) munkássága kiegészíti, miszerint a szabadalmak és a piacszerkezet között dinamikus, kétirányú kapcsolat áll fenn.

Az innovációs folyamatok sajátosságaiból adódóan azonban a piaci mechanizmusok önmagukban nem feltétlenül biztosítják az optimális innovációs szintet. A tudás tovagyűrűző hatásai, az információs aszimmetriák és a magas kezdeti költségek miatt indokoltá válik az állami beavatkozás. Ezzel kapcsolatban a szakirodalomban eltérő álláspontok jelennek meg: egyes szerzők az állami támogatások kizorító hatását hangsúlyozzák (Klodt, 2000), mások pedig az innovációt támogató iparpolitika kifejezetten termelékenységnövelő hatását [(Barta, 2002); (Halpern, 2020); (MNB, 2024)]. A tanuló társadalom koncepciója szerint (Stiglitz & Greenwald, 2014) az államnak nem csak a megfelelő intézményi keretek biztosításában, hanem

az innováció aktív ösztönzésében is szerepet kell vállalnia, különösen azokon a területeken, ahol a tudás tovagyűrűzése a legerősebb.

Ennek érdekében Magyarországon az innovációs ökoszisztéma fejlesztése kiemelt szakpolitikai területnek tekinthető, amelyben meghatározó szerepet játszanak az állami és európai uniós források. A támogatások elosztása elsősorban a Nemzeti Kutatási, Fejlesztési és Innovációs Hivatalon (NKFIH, 2026) keresztül valósul meg, amely a hazai kutatás-fejlesztési és innovációs politika egyik központi intézménye. Az NKFIH programstratégiája (NKFIH, 2025) szerint a támogatási rendszer célja a vállalati innováció ösztönzése, az egyetemi–ipari együttműködések erősítése, valamint a nemzetközileg versenyképes innovációs kapacitások fejlesztése. Mindez szorosan kapcsolódik a Triple Hélix modell logikájához, amely szerint az innovációs teljesítmény az egyetemek, a vállalatok és a kormányzat közötti interakciók eredményeként alakul ki [(Etzkowitz & Leydesdorff, 2000); (Cai & Etzkowitz, 2021)].

Azonban az állami források megfelelő eloszlása kevésbé kutatott terület mind hazai és nemzetközi viszonylatban. A meglévő szakirodalmak jelentős része inkább az innovációs támogatások hatására fókuszál, különösen a termelékenységre és a gazdasági növekedésre gyakorolt hatások vizsgálatára [(Banai, Lang, Nagy, & Stancsics, 2017); (Mulligan, 2019); (Varga & Farkas, 2021); (Goel, és mtsai., 2021); (Halmosi, 2021)]. Így kevesebb figyelem irányul arra, hogy maga a támogatási forrásallokáció mechanizmus milyen logika mentén is működik, vagyis azzal, hogy milyen vállalati és intézményi jellemzők növelik a támogatások megszerzésének valószínűségét, illetve az elnyert források mértékét [(Győri & Czakó, 2019); (Csath & Nagy, 2023); (Kátay, Filep, & Tucci, 2025)]. Az előzetes kiválasztás fontosság vizsgálatában Falk és Svensson (2018), Espinosa-Blasco és munkatársai (2023), valamint Yu, Zhang és Zhu (2025) tanulmányaikban kiemelik, hogy a támogatási döntések nem tekinthetők véletlenszerűnek, hanem összefüggnek a vállalatok innovációs és pénzügyi jellemzőivel.

Az elmúlt években a támogatási és forrásallokációs mechanizmusok elemzésében egyre nagyobb szerepet kaptak a gépi tanulási módszerek. A nemzetközi szakirodalomban számos kutatás alkalmaz vállalati pénzügyi és innovációs indikátorokat annak vizsgálatára, hogy milyen tényezők befolyásolják az innovációs támogatások elosztását. Espinosa-Blasco és munkatársai (2023) Random Forest modell és Genetikus Algoritmus segítségével elemezték több, mint 800 spanyol vállalat K+F+I támogatásainak allokációját. A Gradient Boosting módszerek, különösen az XGBoost, szintén egyre szélesebb körben jelennek meg az innovációs és finanszírozási folyamatok elemzésében. Egyes kutatások az európai uniós források olaszországi elosztását vizsgálták (Caravaggio, Resce, & Vaquerp-Pineiro, 2025), míg más tanulmányok az amerikai vállalatok szabadalmi aktivitásának előrejelzésére (Mashhadi, Saghezchi, & Kashani, 2025), illetve annak elemzésére fókuszáltak, hogy mely koreai vállalatok részesülnek állami K+F támogatásban (Seong-Won & Hee-Chan, 2020). Ezek a kutatások rámutatnak arra, hogy a gépi tanulási modellek, különösen az XGBoost, hatékony eszköz a támogatási döntések mögött meghúzódó mintázatok és az egyes vállalati jellemzők relatív jelentőségének feltárására.

Azonban a magyar innovációs ökoszisztéma esetében kevésbé feltárt területnek tekinthető támogatási forrásallokáció mechanizmusa. Kevés kutatás vizsgálja, hogy a vállalatok pénzügyi helyzete, mérete, innovációs aktivitása és szabadalmi teljesítménye milyen szerepet játszik az innovációs támogatások megszerzésében. Különösen hiányosak azok az elemzések, amelyek gépi tanulási módszerekkel, azon belül XGBoost modellel vizsgálnák a hazai KFI támogatások allokációs mechanizmusát és az egyes indikátorok relatív jelentőségét. Így a jelen kutatás célja annak megértése, hogy milyen vállalati és intézményi jellemzők befolyásolják leginkább az NKFIH támogatások elnyerését Magyarországon. Ennek megfelelően a tanulmány egy fő kutatási kérdésre épül:

KK: Mely strukturális és innovációs jellemzők befolyásolják leginkább az NKFIH által odaítélt KFI-támogatások eloszlását Magyarországon, és ezek milyen prediktív mintázatot alkotnak a támogatási összeg meghatározásában?

A tanulmány hozzájárul a hazai innovációs ökoszisztéma működésének mélyebb megértéséhez azáltal, hogy nemcsak az innovációs támogatások hatásait, hanem azok elosztási mechanizmusát is vizsgálja. A gépi tanulási megközelítés lehetőséget biztosít a támogatási döntések mögött meghúzódó összetett, nemlineáris mintázatok feltárására, ezáltal támogatva a bizonyítékalapú szakpolitikai döntéshozatalt és a célzottabb innovációpolitikai beavatkozásokat.

Adatok és módszerek

A kutatás során egy saját összeállítású adatbázist alkalmaztunk, amely a Nemzeti Kutatási, Fejlesztési és Innovációs Hivatal (NKFIH) által 2020 és 2025 között KFI Alapból odaítélt kutatás-fejlesztési és innovációs (KFI) támogatásokat tartalmazza. Az eredeti adatállomány összesen 6490 támogatott pályázatot foglalt magában, amelyeket 1275 egyedi pályázó nyert el. Mivel egy szervezet több támogatási projektben is részesülhetett az elemzett időszakban, az adatbázis intézményi szintű aggregálással került kialakításra. Ennek megfelelően az egyes szervezetekhez tartozó támogatási összegek összevonásra kerültek, így minden pályázó kizárólag egyszer szerepel az elemzésben. Az aggregáció kizárólag a támogatási összegekre vonatkozott, míg a pénzügyi, területi és működési mutatók az adott intézményekhez tartozó szervezetspecifikus értékeként kerültek figyelembevételre.

Az elemzés elméleti keretét McDonald és Teather (2000) innovációs input-output modellje adta, amelyben a szerzők az innovációs tevékenység bemeneti (input) és kimeneti (output) dimenzióit mutatják be. A modellt a releváns nemzetközi szakirodalom alapján további indikátorokkal egészítettük ki [(Csath & Nagy, 2023); (Espinosa-Blasco, Penagos-Londoño, & Ruiz-Moreno, 2023); (Ayad, 2024); (Mashhadi, Saghezchi, & Kashani, 2025); (Caravaggio, Resce, & Vaquerp-Pineiro, 2025)], amit az 1. táblázat összegez.

A vizsgálat során a támogatás mértékét tekintettük magyarózott változónak, míg a magyarózó változók az innovációs teljesítmény input- és outputoldali jellemzőit reprezentálták. Az inputindikátorok közé kerültek a területi változók (székhely, NUTS1–NUTS3 régiók), az iparági besorolás (NACE Rev. 2 kódok), továbbá a

szervezetek pénzügyi és működési mutatói, így különösen a foglalkoztatottak száma, az értékesítés nettó árbevétele, az összes eszközállomány, az adózás előtti eredmény, a nettó jövedelem, a saját tőke arányos nyereség (ROE), a befektetett tőke arányos megtérülés (ROCE), valamint a cash flow. Output változóként pedig a regisztrált szabadalmak számát alkalmaztuk, amely az innovációs teljesítmény egyik leggyakrabban használt mérőszámának tekinthető.

1. táblázat: Használt mutatók

Mit?	Ki?	Hogyan?	
		Input	Output
Támogatás mértéke	Pályázó vállalat, egyetem	Területi adatok (székhely, NUTS1-3), iparág (Nace kód), foglalkoztatottak száma, értékesítés nettó árbevétele, összes eszköz, adózás előtti eredmény, nettó jövedelem, ROE, ROCE és cash flow	Szabadalmak száma

Forrás: saját szerkesztés

A pénzügyi és vállalati adatokat a 2015-2025 közötti időszakra vonatkozóan az ORBIS adatbázisból nyertük ki (MOODY'S, 2025). Bár a szakirodalmak szerint a K+F-hez kapcsolódó kiadásokkal és foglalkoztatottak számával kiegészíthető a modell, azonban ezek az adatok az Orbis adatbázisban, Magyarország esetében nem elérhetőek, így kihagyjuk a modellünkből. A szabadalmi adatokat a magyar Szellemi Tulajdon Nemzeti Hivatala (SZTNH, 2025) és az Európai Unió Szellemi Tulajdoni Hivatala (European Union Intellectual Property Office, EUIPO) (EUIPO, 2025) adatbázisokból gyűjtöttük össze. A két szabadalmi adatbázis közös használatára azért volt szükség, mert Innovációs és Technológiai Minisztérium (2021) beszámolója alapján a hazai feltalálók ebben a két adatbázisban jelentik be a szabadalmaikat, valamint védjegyeiket és formatervezési oltalmaikat.

A kutatási kérdés megválaszolása érdekében Extreme Gradient Boosting (XGBoost) alapú regressziós modellt alkalmaztunk (Chen & Guestrin, 2016), amely alkalmas komplex, nemlineáris összefüggések feltárására és nagy dimenziójú adatszerkezetek kezelésére. Az XGBoost a gradiens boosting algoritmusok továbbfejlesztett változata, amely döntési fák szekvenciális illesztésén keresztül minimalizálja az előrejelzés hibáját, miközben regulárizációs mechanizmusokkal csökkenti a túlillesztést. A módszer a szakirodalomban széles körben alkalmazott prediktív elemzési eljárás, különösen strukturált adattáblák esetében, mivel magas pontosságot, robusztus működést és hatékony számítási teljesítményt biztosít.

Az elemzés során az R 4.3.2 verzióját használtuk. A felhasznált adatállomány Excel-formátumból került beolvasásra, majd több lépésből álló adat-előkészítési folyamaton ment keresztül. Első lépésben egységesítettük a hiányzó értékek jelölését, illetve az üres cellákat is hiányzó adatként kezeltük. Az adatminőség javítása érdekében eltávolítottuk azokat a változókat, amelyek kizárólag hiányzó értékeket tartalmaztak, továbbá azokat is, amelyek nem rendelkeztek megfelelő varianciával, hogy ezeken a modellen ne tanuljon. Ezt követően a kategorikus változókat numerikus változókká transzformáltuk, majd kezeltük a hiányzó elemeket. A modell célváltozója a támogatási összeg, míg a magyarázó változók a pályázók vállalati, földrajzi és ágazati jellemzői voltak.

Az előkészített adatállományt ezt követően XGBoost-kompatibilis mátrixstruktúrává alakítottuk, majd az xgboost nevű R csomagot (Chen & He, 2020) alkalmaztuk. A modell hiperparamétereinek optimalizálását Bayesi optimalizációval [(Snoek, Larochelle, & Adams, 2012); (Wu, és mtsai., 2019)] határoztuk meg az rBayesianOptimization csomag (Yan, 2026) alkalmazásával. Az optimalizálás során a maximális famélység (max_depth), a tanulási ráta (eta), az almintavételezési arány (subsample), az oszlopmintavételezési arány (colsample_bytree), a minimális gyermek súly (min_child_weight) és a gamma regularizációs paraméter (gamma) értékeit hangoltuk. Az eljárás 10 kezdeti véletlenszerű paraméterkombinációt, majd 100 iteratív optimalizációs lépést tartalmazott (kappa = 2,576; acq = ucb; eps = 0). Az egyes paraméterkonfigurációk teljesítményének értékelése keresztvalidációval történt, amely során az adatállományt öt részhalmazra bontottuk, és a modell minden iterációban négy részhalmazon került betanításra, míg a fennmaradó részhalmaz validációs célokat szolgált. A modellillesztés során maximum 2000 boosting iterációt engedélyeztünk, miközben 50 iterációs early stopping mechanizmust alkalmaztunk a túlillesztés megelőzésére és a számítási hatékonyság növelésére. Az optimalizáció célfüggvénye a gyökös átlagos négyzetes hiba (Root Mean Squared Error - RMSE) minimalizálása volt. A végső modellt a Bayesi optimalizáció során meghatározott optimális hiperparaméterekkel illesztettük a teljes tanító-adathalmazra. A modell értelmezhetőségének növelése érdekében változófontossági elemzést is végeztünk, amely lehetővé tette annak azonosítását, hogy mely magyarázó változók járultak hozzá legnagyobb mértékben a támogatási összeg becsléséhez. Az alkalmazott módszertan így egyszerre biztosította a magas prediktív teljesítményt, a túlillesztés kontrollját, valamint a modell eredményeinek interpretálhatóságát.

2. táblázat: A Bayesi optimalizálás során kapott hiperparaméterek

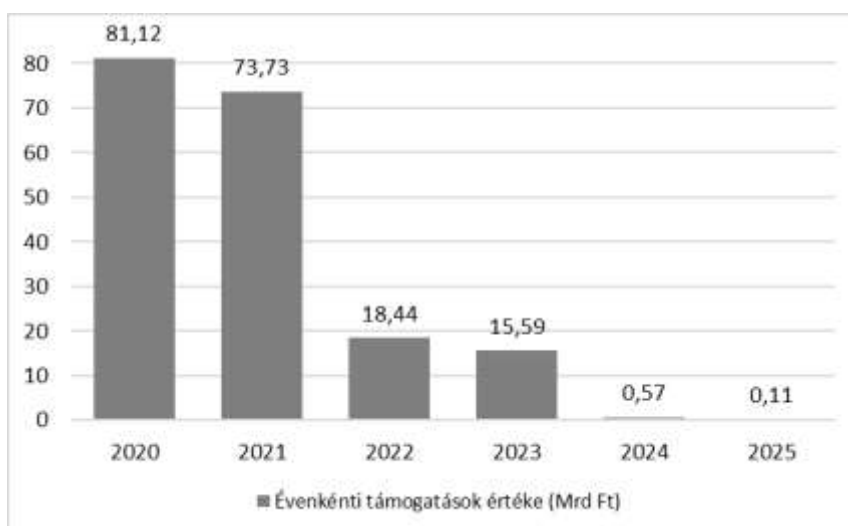
Paraméter	Érték	Jelentés
objective	"reg:squarederror"	veszteségfüggvény
eval_metric	"rmse"	regularizációs függvény
max_depth	10	fa mélység
eta	0.01	tanulási arány
subsample	0.81	tanulási mintaarány
colsample_bytree	0.63	jellemzők aránya
min_child_weight	6.1	felosztási arány
gamma	0.09	minimum veszteségcsökkenés
alpha	0.1	L1 regularizáció
lambda	1	L2 regularizáció
nrounds	2000	fák maximum száma
nfold	5	keresztvalidáció
early_stopping_rounds	50	megállási kritérium

Forrás: saját szerkesztés

Eredmények

Az eredmények jobb közléséhez elsőként a támogatási összegek időbeli alakulását éves bontásban ábrázoltuk az 1. ábrán. Eszerint 2020 óta a támogatások összege évenként jelentősen csökkent. A 2024-es pályázati támogatások a 2020-as évekhez képest közel 160%-kal csökkentek.

1. ábra: Évenkénti támogatások alakulása

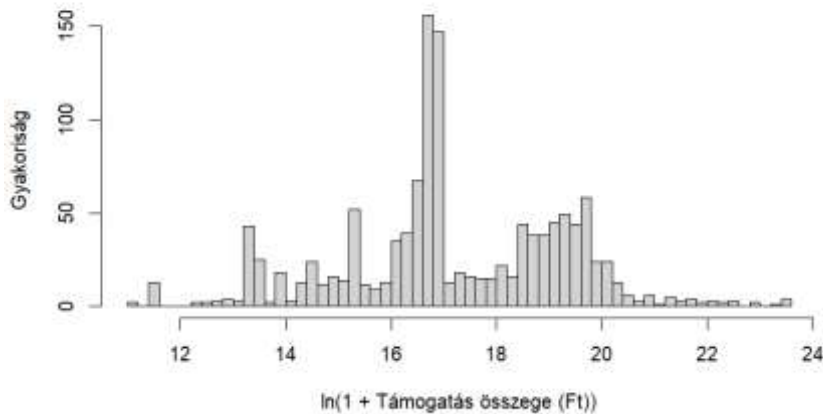


Forrás: saját szerkesztés

A kutatási kérdés {Mely strukturális és innovációs jellemzők befolyásolják leginkább az NKFIH által odaítélt KFI-támogatások eloszlását Magyarországon, és ezek milyen

prediktív mintázatot alkotnak a támogatási összeg meghatározásában?} megválaszolásához a támogatási összegek eloszlását is elemeztük, amelyek eloszlását a 2. ábrán mutatjuk be. Itt a támogatások összegének természetes alapú logaritmusát vettük, hogy a kilógó elemeket le tudjuk kezelni.


2. ábra: Támogatási összegek eloszlása



Forrás: saját szerkesztés

A 2. ábra arra utal, hogy a támogatások összege nem normális eloszlást követ (Shapiro-Wilk teszt: $p < 0.05$, ferdeség = 11.25, csúcsosság = 146.12), hanem a gamma eloszláshoz van a legközelebb. Így a támogatások összegének ferde eloszlása és a szélsőértékek miatt természetes alapú logaritmikus transzformációt alkalmaztunk. A logaritmikus transzformáció csökkenti a nagy összegű támogatások torzító hatását és stabilabb prediktív tanulási környezetet biztosított a gépi tanulási modell számára. Az egyes magyarázó változók relatív fontosságának meghatározását XGBoost-tal végeztük el, amelynek eredményét a 3. ábrán jelenítettük meg.

3. ábra: Az egyes magyarázó változók relatív fontossága



Forrás: saját szerkesztés

A 3. ábrán a 10 legnagyobb fontosságú változó látható, A prediktív modell (XGBoost) változófontossági elemzése alapján a támogatási összeg előrejelzésében a legnagyobb hozzájárulást az összes eszközállomány, az értékesítés nettó árbevétele, valamint az iparági besorolás mutatta. Így a tíz legfontosabb változót tekintve az összes eszközállomány („Összes eszköz”) 17,2%-ban, az értékesítés nettó árbevétele („Értékesítés”) szintén 17,2%-ban, míg a NACE kódok szerinti iparági besorolás („Iparági besorolás”) 3,3%-ban bizonyultak fontosnak a pályázati összegek minél magasabb elnyerésében.

Az idődimenziót vizsgálva az eszköz és az értékesítési árbevétel változók esetében több év magas relatív fontosságot mutatott a modellben. Az eszközök területén 2018, 2019, 2023 és 2024 voltak a legfontosabb évek, míg az értékesítés árbevétele területén 2018, 2019, 2022, 2023 és 2024. Az iparágak szempontjából két iparág elvitte az összes támogatás közel felét. Ezek a 7219 (Research and experimental development in natural sciences and engineering) és 8542 (Higher education) iparágak. A többi iparág egyenként is maximum 3%-t tette csak ki az összes támogatásnak, így azok hatása jelentősen elmaradt a 7219 és 8542-vel szemben, amelyek közel azonosan ~25-25%-ban tették ki az összes támogatás 50%-t.

Következtetések és javaslatok

Az 1. ábra alapján láthatjuk, hogy a támogatások évenkénti megoszlása erősen egyenlőtlen. A 2020-s és 2021-s évben a támogatások értéke sokkal magasabb volt, mint az utána lévő években. Ebből arra következtethetünk, hogy a 2020-s évek előtti vállalati mutatók hatása várhatóan magasabb kell, hogy legyen. Ennek ellenére a 2. ábrán láthatjuk, hogy mind a 2018-as, 2019-es, mind pedig a 2022-es, 2023-as és

2024-es évek eredményei egyaránt fontosok voltak. A 2020-as és 2021-es eredmények fontosságának elmaradása valószínűleg a COVID-19 járvány és az azt követő energiaválság és az autóipar válságának hatását tükrözik. Ugyanakkor ennek pontos oksági vizsgálata további elemzéseket igényelne. Ezekben az években jelentősen visszamaradtak a kutatási potenciálok, és mivel az iparágak közül pont a felsőoktatási és a kutatási intézmények kapták a támogatások nagyobb százalékát, így a kutatási potenciál jelentősen befolyásolta az elnyert támogatások mértékét.

A 2. ábra továbbá rávilágít arra, hogy három indikátor relatív fontossága jelentősen kiemelkedik a többi változó közül: az összes eszközállomány, az értékesítés nettó árbevétele, valamint az iparági besorolás. Ez arra utal, hogy az NKFIH-s támogatások eloszlása szoros kapcsolatban áll a pályázó szervezetek pénzügyi és működési kapacitásával. A nagyobb eszközállománnyal és magasabb működési volumenű szervezetek vélhetően erősebb infrastruktúrával, fejlettebb kutatási háttérrel, stabilabb pénzügyi helyzettel és nagyobb projektmegvalósítási képességgel rendelkeznek, amelyek növelhetik a nagyobb összegű KFI-projektek sikeres lebonyolításának valószínűségét. Az eredmények emellett a támogatási rendszer bizonyos fokú útfüggőségére is utalnak, mivel a korábban erősebb pénzügyi és infrastruktúrával rendelkező szervezetek nagyobb valószínűséggel tudnak később is jelentősebb támogatási forrásokhoz jutni. Ugyanakkor fontos hangsúlyozni, hogy a változófontosság nem jelent közvetlen oksági kapcsolatot, mivel az XGBoost nem vizsgál kauzalitást. Az eredmények inkább arra utalnak, hogy a támogatási rendszerben ezek a változók erős prediktív mintázatot alkotnak, amelyek együtt jelennek meg a nagyobb támogatási összegekkel.

Az iparági változók közül különösen a 7219 (Research and experimental development in natural sciences and engineering) és a 8542 (Higher education) ágazatok emelkedtek ki, amelyek együttesen a támogatások közel felét koncentrálták. Ez arra utal, hogy a támogatási rendszer elsősorban a magas tudásintenzitású, kutatásorientált és jelentős infrastruktúrával rendelkező szervezetekre épül. Pénzügyi szempontból ez részben racionális allokációs mechanizmusnak tekinthető, mivel a nagyobb kutatási kapacitással rendelkező intézmények általában alacsonyabb projektkockázattal, magasabb abszorpciós képességgel és erősebb projektmenedzsment háttérrel rendelkeznek, ami növelheti a támogatások hatékony felhasználásának valószínűségét.

Ugyanakkor szakpolitikai szempontból az eredmények arra is rámutatnak, hogy a támogatási rendszer bizonyos mértékben koncentrálódhat a már eleve erőforrásokban gazdagabb szereplők körében. Ezek Magyarországon jelenleg a természettudománnyal és orvostudománnyal foglalkozó szervezetek. A nem eszközigenyes kutatási irányokat – mint a gazdaságtudomány, társadalomtudományok – követő intézmények már jóval kisebb eséllyel pályázhatnak KFI-s kutatásokra. Ez hosszabb távon erősítheti az innovációs rendszer strukturális egyenlőtlenségeit, különösen a kisebb tőkeerejű, alacsonyabb árbevételű vagy kevésbé kutatásintenzív vállalkozások esetében. Ennek következtében a támogatási rendszer egyszerre szolgálhatja a magas innovációs potenciállal rendelkező szervezetek nemzetközi versenyképességének erősítését, miközben korlátozhatja az újonnan belépő vagy periférikus szereplők innovációs

felzárkózásának lehetőségét. Ez potenciálisan regionális koncentrációhoz is vezethet, mivel a nagy kutatási infrastruktúrával rendelkező intézmények elsősorban a fejlettebb innovációs központokban található meg, ami tovább növelheti a területi innovációs különbségeket Magyarországon.

Az eredmények alapján ezért a jövőbeli KFI-szakpolitikák számára fontos kérdés lehet annak mérlegelése, hogy a támogatások allokációja milyen mértékben támogassa továbbra is a magas teljesítményű, stabil kutatási infrastruktúrával rendelkező intézményeket, illetve milyen eszközökkel lehetne javítani a kisebb innovatív vállalkozások és regionális szereplők forrásbevonási lehetőségeit. Ez attól függ, hogy Magyarország jövőbeli innovációs politikája az országhatárokon belüli versenyt akarja jobban fokozni, vagy a nemzetközi versenyben szeretne nagyobb eséllyel helytállni.

Összegzés

Jelen tanulmány célja az volt, hogy azonosítsa a magyarországi KFI-s pályázatok nyerteseinek legfontosabb jellemzőit, amelyek alapján feltehetően elnyerték a pályázati összegeket a 2020-2025 években. Az adatokat ismert hazai és nemzetközi adatbázisokból gyűjtöttük össze, majd megfelelő feldolgozás során egy Bayesi optimalizációval hiperparaméterezett XGBoost modellt tanítottunk be rajtuk. Az eredmények összességében arra utalnak, hogy a magyar KFI-támogatási rendszer jelenleg elsősorban a kutatási és pénzügyi kapacitások mentén allokálja a forrásokat, ahol sokat számít a szervezetek iparági tevékenysége. Ez rövid távon növelheti a támogatások hatékonyságát és nemzetközi versenyképességi potenciálját, hosszabb távon azonban fennáll annak a veszélye, hogy az innovációs rendszerben meglévő strukturális különbségek tovább erősödnek. Ez pozitív hatással lehet a nemzetközi jelenlétben, de negatívan hat az országhatáron belüli versenyre.

A jövőbeli kutatásokban érdemes lehet kooperatív játékelméleti interpretációs módszereket is alkalmazni annak pontosabb feltárására, hogy az egyes pénzügyi és strukturális változók milyen irányban és milyen mértékben befolyásolják a támogatási összegek alakulását. Emellett érdemes lenne erősíteni a most feltanított modell gyakorlati alkalmazhatóságát a következő pályázati időszakok előrejelzéséhez.

Jelen kutatás a Kulturális és Innovációs Minisztérium 2025-2.1.1-EKÖP kódszámú Egyetemi Kutatói Ösztöndíj Programjának a Nemzeti Kutatási, Fejlesztési és Innovációs Alapból finanszírozott szakmai támogatásával készült.

Hivatkozások

- Ayad, F. (2024). Lessons of the "Vergangenheit": Optimal policy learning of innovation subsidies. *National Higher School of Statistics and Applied Economics*.
- Banai, Á., Lang, P., Nagy, G., & Stancsics, M. (2017). A gazdaságfejlesztési célú EU-támogatások hatásvizsgálata a magyar kkv-szektorra. *Közgazdasági Szemle, vol. 0(10)*, 997-1029.
- Barta, G. (2002). *a magyar ipar területi folyamatai, 1945–2000*. Budapest–Pécs: Dialóg campus Kiadó.
- Bódis, L., & Kiss, Á. (2025). Innovációvezérelt gazdasági növekedés – Így lesz Magyarország az innovatív vállalkozók és vállalatok hazája. *Hitelintézeti Szemle, 24. évf. 1. szám*, 105-135.
- Cai, Y., & Etkowitz, H. (2021). Theorizing the Triple Helix model: Past, present, and future. *Triple Helix, 7*, 189-226.
- Caravaggio, N., Resce, G., & Vaquerp-Pineiro, C. (2025). Predicting policy funding allocation with Machine Learning. *Socio-Economic Planning Sciences, 98*.
- Chen, T., & Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System., (old.: 785-794).
- Chen, T., & He, T. (2020). xgboost: eXtreme Gradient Boosting.
- Csath, M., & Nagy, B. (2023). *Innovációs sikerfeltételek a kis- és közepes vállalkozások (mkkv-k) körében*. Budapest: Pázmány Péter Katolikus Egyetem .
- Espinosa-Blasco, M., Penagos-Londoño, G., & Ruiz-Moreno, F. (2023). New Insights on the Allocation of Innovation Subsidies: A Machine Learning Approach. *Journal of the Knowledge Economy, 2704–2725*.
- Etkowitz, H., & Leydesdorff, L. (2000). The Dynamics of Innovation: From National Systems and "Mode 2" to a Triple Helix of University–Industry–Government Relations. *Research Policy, 29(2)*, 109-123.
- EUIPO. (2025). EUIPO. Forrás: <https://euipo.europa.eu/eSearch/#advanced/trademarks>
- Falk, M., & Svensson, R. (2018). Allocation of R&D Grants in the Business Sector. *IFN Working Paper, 1231*.
- Goel, T., Láng, P., Balogh, E., Banai, Á., Stancsics, M., Takáts, E., & Telegdy, Á. (2021). Credit Constrained Firms and Government Subsidies:Evidence from a European Union Program. *MNB*.
- Győri, Á., & Czakó, Á. (2019). Innováció és pénzügyi-gazdálkodói kultúra Az innovációs aktivitás egyes magyarázó tényezői a kkv-szektorban. *Szociológiai Szemle, 29(1)*, 85-116.

- Halmosi, P. (2021). A kormányzati támogatások hatása a járműipari vállalatok pénzügyi teljesítményére az Ipar 4.0 korában Magyarországon. *Köz-Gazdaság*.
- Halpern, L. (2020). *Termelékenység, innováció és külkereskedelem magyar vállalati adatok alapján. Műhelytanulmányok*. Budapest: KRTK KTI.
- Innovációs és Technológiai Minisztérium. (2021). *Magyarország kutatási, fejlesztési és innovációs stratégiája 2021-2030*. Budapest.
- Kátay, G., Filep, P., & Tucci, M. F. (2025). The Impact of EU Grants for Research and Innovation on Firms' Performance. *MNB*.
- Klodt, H. (2000). Industrial policy and the east german productivity puzzle. *German Economic Review*, 1. évf. 3. sz., 315–333.
- Mashhadi, S., Saghezchi, A., & Kashani, V. G. (2025). Interpretable Machine Learning for Predicting Startup Funding, Patenting, and Exits. *arXiv*.
- McDonald, R., & Theater, G. (2000). Measurement of S&T Performance in the Government of Canada: From Outputs to Outcomes. *The Journal of Technology Transfer*, 223–236.
- MNB. (2024). *Termelékenységi jelentés*. Budapest: Magyar Nemzeti Bank.
- MOODY'S. (2025). ORBIS. Forrás: <https://www.moody's.com/web/en/us/capabilities/company-reference-data/orbis.html>
- Mulligan, K. L. (2019). More subsidies More innovation? Evaluating whether a mix of subsidies from regional, national and EU sources crowds out firm-level innovation. *Regional Studies*, 6(1), 130–138.
- NKFIH. (2025). *A Nemzeti Kutatási, Fejlesztési és Innovációs Alap 2025. évi Programstratégiája*. Budapest: NKFIH.
- NKFIH. (2026). *NKFIH*. Forrás: NKFIH: <https://nkfi.gov.hu/palyazoknak>
- Schumpeter, J. A. (1980). *A gazdasági fejlődés elmélete. Vizsgálódás a vállalkozói profitról, a tőkéről, a hitelről, a kamatról és a konjunktúraciklusokról*. Budapest: Közgazdasági és Jogi Könyvkiadó.
- Seong-Won, K., & Hee-Chan, K. (2020). Analysis of Determinants of SME R&D Funding Using the Gradient Boosting Model. *Journal of the Korean Society of Digital Industry*, 25(4), 77–109.
- Snoek, J., Larochelle, H., & Adams, R. P. (2012). *Practical Bayesian Optimization of Machine Learning Algorithms*.
- Solow, R. M. (1957). Technical Change and the Aggregate Production Function. *The Review of Economics and Statistics*, 312–320.

- Stiglitz, J. E., & Greenwald, B. C. (2014). *Creating a learning society: a new approach to growth development and social progress*. New York: Columbia University.
- SZTNH. (2025). SZTNH. Forrás: <https://epub.sztnh.gov.hu/e-nyilvantartas/?lang=HU>
- Varga, A., & Farkas, R. (2021). A GMR-magyarország gazdasági hatáselemző modell TFP-blokkja. *Sigma*, 52. évf. 3. sz., 187–211 o.
- Wu, J., Chen, X.-Y., Zhang, H., Xiong, L.-D., Lei, H., & Deng, S.-H. (2019). Hyperparameter Optimization for Machine Learning Models Based on Bayesian Optimization. *Journal of Electronic Science and Technology*, 17, 26-40.
- Yan, Y. (2026). Package 'rBayesianOptimization'.
- Yu, H., Zhang, M., & Zhu, R. (2025). A reevaluation on the effectiveness of subsidies on firm's innovation: Evidence from newly categorized subsidy data. *Technological Forecasting and Social Change*, 219.

A PÉNZÜGYI MENEDZSMENT ÉS A STRATÉGIAI BESZERZÉS INTEGRÁCIÓJA A DIGITALIZÁCIÓ KORÁBAN: MESTERSÉGES INTELLIGENCIA ÉS GÉPI TANULÁS ALKALMAZÁSI LEHETŐSÉGEI

KOMLÓSI Attila

Neumann János Egyetem Gazdálkodás- és Szervezéstudományok Doktori Iskola
attila.komlosi@icloud.com

<https://doi.org/10.15170/XVIIPPN-Tk-KTK-2026-09>

Absztrakt

A kutatás célja annak feltárása, hogy a digitalizáció, valamint a mesterséges intelligencia (AI) és a gépi tanulás (ML) miként alakítja át a pénzügyi menedzsment és a stratégiai beszerzés kapcsolatát. A téma aktualitását az adja, hogy a pénzügyi menedzsment funkciója az utóbbi években a hagyományos, múltorientált riportálástól egyre inkább a valós idejű, prediktív és adatvezérelt döntéstámogatás irányába mozdult el, miközben a stratégiai beszerzés a vállalati költségstruktúra, a cash-flow és a kockázatkezelés meghatározó tényezőjévé vált (Balkan és Akyuz, 2025; Guida, Caniato és Maretto, 2025). A szakirodalom ugyan részletesen foglalkozik az AI pénzügyi és procurement alkalmazásaival, azonban kevés kutatás vizsgálja azok integrált vállalatirányítási és controlling-hatásmechanizmusait. A tanulmány konceptuális és összehasonlító módszertant alkalmaz. A platformok összehasonlítása integrációs képesség, spend-analitikai funkcionalitás, AI-érettség és pénzügyi döntéstámogatási potenciál alapján történt.

A strukturált szakirodalmi áttekintés három fő területre fókuszál: a pénzügyi menedzsment digitalizációjára, az AI/ML beszerzési alkalmazásaira, valamint a pénzügyi és beszerzési funkció integrációs mechanizmusaira. Ezt kiegészíti négy AI-alapú beszerzési és spend-analitikai platform – SAP Ariba, Coupa, Ivalua és Sievo – összehasonlító értékelése. Az eredmények azt mutatják, hogy a digitalizáció a pénzügyi menedzsmentet három fő dimenzió mentén alakítja át: adatintegráció, folyamatautomatizálás és döntéstámogatás. Az AI-alapú beszerzési rendszerek javítják a költségtranszparenciát, növelik az adatok részletezettségét, és támogatják a pontosabb pénzügyi tervezést, előrejelzést és kockázatkezelést. A gépi tanulási alkalmazások közvetlen és közvetett pénzügyi értéket teremtenek.

A következtetések szerint a valódi pénzügyi érték nem az egyes technológiák elszigetelt alkalmazásából, hanem azok integrált döntéstámogatási architektúrába való beágyazásából származik. A siker kulcstényezői a magas adatminőség, a világos üzleti célok, az átlátható AI-modellek és a szervezeti felkészültség.

Kulcsszavak: digitalizáció, pénzügyi menedzsment, stratégiai beszerzés, mesterséges intelligencia, gépi tanulás, beszerzési költsélemzés

Bevezetés

A digitalizáció és a mesterséges intelligencia fejlődése az elmúlt évtizedben alapvetően átalakította a vállalatok működését, döntéshozatali mechanizmusait és információs rendszereit. A pénzügyi menedzsment hagyományos szerepe – amely korábban elsősorban tranzakciófeldolgozásra, pénzügyi riportálásra és retrospektív controllingtevékenységekre épült – fokozatosan stratégiai, adatvezérelt döntéstámogató funkcióvá alakult át. A modern vállalatok esetében a pénzügyi menedzsment már nem kizárólag a múltbeli teljesítmény értékelésére szolgál, hanem valós idejű adatelemzésre, prediktív előrejelzésre és kockázatkezelésre is épül (Appelbaum et al., 2017; Bhimani & Willcocks, 2014).

A digitális transzformáció egyik legfontosabb következménye a vállalati funkciók közötti integráció erősödése. Különösen jelentős a pénzügyi menedzsment és a stratégiai beszerzés konvergenciája, mivel a procurement-folyamatok közvetlenül befolyásolják a vállalat költségstruktúráját, likviditását, cash-flow folyamatait és működési kockázatait. A globális ellátási láncok sérülékenysége, az inflációs nyomás és a geopolitikai bizonytalanság következtében a beszerzés szerepe jelentősen felértékelődött, és a korábbi operatív támogató funkcióból fokozatosan stratégiai vállalatirányítási területté vált (McKinsey & Company, 2024). A modern vállalatokban a pénzügyi menedzsment és a procurement egyre inkább közös adatplatformokra, integrált ERP-rendszerekre és AI-alapú döntéstámogatósi megoldásokra épül.

A mesterséges intelligencia (Artificial Intelligence – AI) és a gépi tanulás (Machine Learning – ML) alkalmazása új lehetőségeket nyitott a pénzügyi és beszerzési folyamatok integrációjában. Az intelligens rendszerek képesek nagy mennyiségű strukturált és strukturálatlan adat feldolgozására, a költségstruktúrák elemzésére, valamint a beszállítói és pénzügyi kockázatok előrejelzésére. A Deloitte (2025) és a Gartner (2025) elemzése szerint a vállalatok fokozatosan „intelligent finance” modellek felé mozdulnak el, ahol a pénzügyi menedzsment és a stratégiai beszerzés közös digitális ökoszisztémában működik.

A digitalizáció fejlődése ugyanakkor nem tekinthető kizárólag technológiai innovációnak. Brynjolfsson és McAfee (2014) szerint a digitális technológiák és az automatizáció a vállalatok működési logikáját és versenystruktúráját is módosítják. Porter és Heppelmann (2015) rámutattak arra, hogy az intelligens és összekapcsolt rendszerek új típusú vállalatirányítási modelleket hoznak létre, amelyekben az adat és az elemzési képesség stratégiai erőforrássá válik. Quattrone (2016) szerint a digitalizáció a controlling- és számviteli rendszerek működését is újradefiniálja, mivel az adatvezérelt vállalatirányítás fokozatosan átalakítja a kontrollmechanizmusokat és a vezetői döntéshozatalt.

A stratégiai beszerzés területén az AI és ML technológiák elsősorban a spend-analitika, a beszállítói intelligencia és a szerződésmenedzsment fejlődését

gyorsították fel. A modern procurement-platformok – például a SAP Ariba, Coupa, Ivalua és Sievo – fejlett AI-funkciókat integrálnak működésükbe, amelyek támogatják a költségtranszparenciát, a supplier risk managementet és a prediktív döntéstámogatást (SAP, 2024; Sievo, 2025). Davenport és Ronanki (2018) ugyanakkor hangsúlyozzák, hogy az AI-rendszerek vállalati implementációja számos szervezeti és adatkezelési kihívással jár, ezért a sikeres adaptációhoz nem elegendő a technológiai infrastruktúra fejlesztése; szükség van megfelelő adatgovernance-re, szervezeti felkészültségre és keresztfunkcionális együttműködésre is.

A szakirodalom jelentős része külön vizsgálja az AI pénzügyi vagy procurement alkalmazásait, azonban továbbra is korlátozott azoknak a kutatásoknak a száma, amelyek integrált módon elemzik a pénzügyi menedzsment, a stratégiai beszerzés és az AI-alapú döntéstámogatás vállalatirányítási összefüggéseit. A jelen tanulmány ehhez kíván hozzájárulni azáltal, hogy egységes keretben vizsgálja a pénzügyi menedzsment és stratégiai beszerzés digitális konvergenciáját, valamint az AI-alapú procurement-rendszerek pénzügyi és vállalatirányítási hatásait.

A kutatás strukturált szakirodalmi áttekintésre és összehasonlító konceptuális elemzésre épül. A vizsgálat során a vezető AI-alapú procurement-platformok összehasonlítása ERP-integrációs képesség, spend-analitikai funkcionalitás, AI-érettség, supplier risk management és pénzügyi döntéstámogatási potenciál alapján történt. A tanulmány célja annak feltárása, hogy a digitalizáció és a mesterséges intelligencia miként alakítja át a pénzügyi menedzsment és stratégiai beszerzés kapcsolatát, valamint hogyan járul hozzá a vállalati értékteremtéshez, a controlling fejlődéséhez és a stratégiai vállalatirányításhoz.

A pénzügyi menedzsment digitalizációs dimenziói

A pénzügyi menedzsment digitalizációja napjainkra jóval túlmutat az ERP-rendszerek fejlesztésén vagy az automatizált riportálási megoldások alkalmazásán. A folyamat olyan komplex szervezeti és technológiai transzformációként értelmezhető, amely alapvetően módosítja a vállalati adatkezelést, a controlling működését és a döntéstámogatási mechanizmusokat. A hagyományos pénzügyi rendszerek elsősorban múltorientált riportálásra és periodikus elemzésekre épültek, míg a modern digitális pénzügyi környezet valós idejű adatfeldolgozást, prediktív analitikát és integrált üzleti döntéstámogatást alkalmaz (Bhimani & Willcocks, 2014). A digitalizáció fejlődése következtében a pénzügyi menedzsment egyre inkább adatvezérelt stratégiai funkcióvá válik, amely közvetlen kapcsolatban áll a vállalat működési és beszerzési folyamataival.

A digitális transzformáció egyik legfontosabb következménye a vállalati adatvagyon jelentős bővülése. A pénzügyi menedzsment számára ma már nemcsak a számviteli és főkönyvi információk relevánsak, hanem a beszerzési, logisztikai és beszállítói adatok is. A procurementból származó információk – például a szerződéses feltételek, a beszállítói teljesítmény vagy az árkockázatok – közvetlenül befolyásolják a költségstruktúrát, a cash-flow folyamatokat és a vállalati kockázatokat. Az integrált adatplatformok ezért lehetővé teszik a költségek részletesebb elemzését és a pontosabb pénzügyi előrejelzést (Appelbaum et al., 2017). Porter és Heppelmann

(2015) szerint az intelligens és összekapcsolt vállalati rendszerek fejlődése új típusú adatvezérelt vállalatirányítási modelleket hoz létre, amelyekben az információ stratégiai erőforrássá válik.

A pénzügyi digitalizáció másik meghatározó területe a folyamatautomatizálás. A robotic process automation, az intelligens dokumentumfeldolgozás és az elektronikus számlakezelés jelentősen csökkentik a manuális adminisztrációt és a működési hibák számát. A purchase-to-pay folyamatok automatizálása különösen fontos a pénzügyi és beszerzési funkciók integrációjában, mivel támogatja a working capital menedzsmentet és javítja a likviditási folyamatok átláthatóságát. A McKinsey & Company (2024) szerint az AI-alapú automatizáció nemcsak költségcsökkentést eredményez, hanem lehetővé teszi, hogy a pénzügyi szakemberek nagyobb hangsúlyt helyezzenek az elemző és stratégiai tevékenységekre.

A controlling és pénzügyi döntéstámogatás szintén jelentős átalakuláson megy keresztül. A modern AI-rendszerek képesek azonosítani a szokatlan költési mintázatokat vagy a potenciális pénzügyi anomáliákat is, ami támogatja a gyorsabb vezetői beavatkozást és a kockázatkezelést. A controlling és vezetői számvitel fejlődése már a digitális transzformáció előtt is a stratégiai döntéstámogatás irányába mozdult el. Kaplan és Atkinson (1998) szerint a modern vezetői számvitel alapvető célja nem csupán a költségek nyomon követése, hanem a stratégiai értékteremtés és a vezetői döntéshozatal támogatása. Quattrone (2016) szerint a digitalizáció következtében a controlling és számviteli rendszerek működése is újradefiniálódik, mivel az adatvezérelt vállalatirányítás fokozatosan átalakítja a kontrollmechanizmusokat és a vezetői döntéshozatalt. Az OECD (2021) ugyanakkor hangsúlyozza, hogy az AI pénzügyi alkalmazása új szabályozási és governance-kihívásokat is létrehoz, ezért az algoritmusok átláthatósága és auditálhatósága kiemelt jelentőségűvé válik.

A kontroll- és irányítási rendszerek digitalizációja különösen fontos a stratégiai beszerzés területén, ahol a beszállítói teljesítmény, a szerződéses megfelelés és az ellátási láncok stabilitása közvetlen pénzügyi következményekkel járhat. Az AI-alapú monitoring és kockázatelemzés támogatja a problémák korai felismerését, ugyanakkor a szakirodalom szerint az automatizált modellek alkalmazása adatminőségi és algoritmikus torzítási kockázatokat is hordozhat (Davenport & Ronanki, 2018). Ez különösen problémás lehet fragmentált ERP-környezetben vagy nem megfelelő adatgovernance mellett.

A digitalizáció végső soron a pénzügyi menedzsment stratégiai szerepét is újradefiniálja. A CFO és controlling-funkció egyre inkább adatvezérelt üzleti partnerként jelenik meg, amely aktívan támogatja a stratégiai döntéshozatalt és a vállalati értékteremtést. Ebben a folyamatban a stratégiai beszerzés integrációja kulcsszerepet játszik, mivel a procurement-folyamatokból származó adatok közvetlenül hozzájárulnak a vállalati versenyképesség, pénzügyi stabilitás és hosszú távú rugalmasság javításához (Deloitte, 2025; Gartner, 2025).

A pénzügyi menedzsment és a stratégiai beszerzés konvergenciája

A vállalati működés digitalizációja jelentősen átalakította a pénzügyi menedzsment és a stratégiai beszerzés kapcsolatát. Korábban a két funkció eltérő szervezeti logika szerint működött: a pénzügyi menedzsment elsősorban a likviditás, a pénzügyi kontroll és a beszámolási kötelezettségek kezelésére koncentrált, míg a beszerzés főként operatív támogató szerepet töltött be. A globalizált ellátási láncok sérülékenysége, az inflációs környezet és az adatvezérelt vállalatirányítás fejlődése azonban fokozatosan megszüntette ezt az elkülönülést. A stratégiai beszerzés napjainkra a vállalati értékteremtés, a költségoptimalizálás és a kockázatkezelés egyik meghatározó elemévé vált (McKinsey & Company, 2024). A beszerzési döntések közvetlenül hatnak a vállalati eredményességre, mivel a működési költségek jelentős része a procurement-folyamatokhoz kapcsolódik. A beszerzési árak, a szerződéses feltételek, a fizetési határidők és a szállítói teljesítmény közvetlenül befolyásolják a cash-flow folyamatokat, a working capital mutatókat és a jövedelmezőséget. Emiatt a pénzügyi menedzsment és a stratégiai beszerzés integrációja egyre inkább stratégiai szükségszerűségként jelenik meg a vállalatok működésében (Deloitte, 2025).

A digitális transzformáció egyik legfontosabb következménye az integrált adatplatformok megjelenése. A modern ERP-rendszerek, cloud-alapú Source-to-Pay megoldások és AI-alapú spend-analitikai rendszerek lehetővé teszik, hogy a pénzügyi és beszerzési adatok közös architektúrában kerüljenek feldolgozásra. Ez jelentősen javítja a controlling pontosságát, támogatja a stratégiai sourcingot és elősegíti a valós idejű pénzügyi döntéstámogatást. A Balkan et al. (2025), Guida et al. (2025) és Sievo (2025) által bemutatott integrációs modellek szerint a jövő vállalatirányítási rendszerei egységes adatvezérelt ökoszisztémákra épülnek, amelyekben a pénzügyi és beszerzési információk közösen támogatják a stratégiai döntéshozatalt.

A stratégiai beszerzés szerepe ezzel párhuzamosan jelentősen átalakult. A hagyományos beszerzési funkció elsősorban az operatív megrendelések kezelésére és az áralkura koncentrált, míg a modern procurement-rendszerek már komplex elemző és döntéstámogató szerepkört töltenek be. A spend-analitika, a supplier scoring, a szerződésmenedzsment és a prediktív sourcing modellek lehetővé teszik a költségstruktúra részletesebb elemzését és a vállalati kockázatok korai felismerését. A COVID-19 járvány és az ellátási láncok zavarai tovább erősítették ezt a szemléletváltást, mivel a vállalatok számára stratégiai kérdéssé vált a szállítói hálózatok stabilitása és az ellátási lánc rezilienciája (World Economic Forum, 2025).

A pénzügyi és beszerzési adatok integrációja különösen fontos a working capital menedzsment és a likviditás területén. A modern AI-alapú rendszerek képesek valós időben elemezni a készletszinteket, a rendelési ciklusokat, a szállítói szerződéseket és a fizetési feltételeket, ami támogatja a pontosabb pénzügyi tervezést és előrejelzést. Guida, Caniato és Maretto (2025) rámutatnak arra, hogy az AI-alapú spend-klasszifikáció jelentősen javítja a költségtranszparenciát és a pénzügyi elemzések pontosságát.

1. ábra. A pénzügyi menedzsment és stratégiai beszerzés digitális integrációs modellje



Forrás: Balkan et al. (2025), Guida et al. (2025) és Sievo (2025) alapján saját szerkesztés

Az 1. ábra alapján megállapítható, hogy a modell legkritikusabb kapcsolata az integrált adatplatform és az AI-alapú döntéstámogatási réteg közötti összeköttetés. Az adatforrásokból – ERP-rendszerekből, procurement-platformokból, beszállítói portálokból és külső piaci adatbázisokból – származó információk csak megfelelő adat-harmonizáció és normalizáció után válhatnak stratégiai döntéstámogatás alapjává. Ezért az adatminőség és az adatgovernance a teljes modell egyik legfontosabb kritikus sikertényezőjeként jelenik meg (Balkan et al., 2025; Sievo, 2025).

A legfontosabb adatáramlás a beszerzési és pénzügyi rendszerek közötti kétirányú információcsere, amely lehetővé teszi a költségstruktúrák, beszállítói teljesítmények és cash-flow folyamatok valós idejű elemzését. Az ábra alapján az AI és ML motor központi szerepet tölt be, mivel ezen keresztül kapcsolódik össze a spend-analitika, a beszállítói kockázatelemzés, az ár-előrejelzés és a scenáriómodellezés a pénzügyi döntéstámogatással. Ez támogatja a gyorsabb controllingot, a prediktív forecastingot és a stratégiai sourcing döntéseket (Guida et al., 2025).

Az AI-alapú értékteremtés elsősorban a modell harmadik és ötödik szintjén jelenik meg. A közös döntéstámogatási mechanizmusok révén az AI közvetlenül hozzájárul a költségoptimalizáláshoz, a working capital menedzsmenthez, a beszállítói kockázatok csökkentéséhez és az ellátási lánc rezilienciájának növeléséhez. Az ábra szerint az AI-value creation végső eredménye az alacsonyabb teljes költség szint, a nagyobb transzparencia, a fenntarthatóbb működés és a hosszú távú vállalati versenyelőny kialakulása (Deloitte, 2025; Gartner, 2025).

Mesterséges intelligencia és gépi tanulás a stratégiai beszerzésben

Az AI-technológiák gyors terjedését jelentősen ösztönözte az ERP-rendszerek, elektronikus számlázási megoldások és e-sourcing platformok fejlődése, amelyek következtében a vállalatok beszerzési adatbázisa drasztikusan megnőtt. Ezzel párhuzamosan az ellátási láncok sérülékenysége, az inflációs nyomás és a geopolitikai bizonytalanság miatt a vállalatok számára egyre fontosabbá vált a gyorsabb és pontosabb döntéshozatal. A hagyományos elemzési módszerek azonban gyakran nem képesek hatékonyan kezelni a nagy mennyiségű és heterogén adatot, ezért az AI és ML technológiák alkalmazása stratégiai szükségszerűséggé vált (McKinsey & Company, 2024).

A gépi tanulási modellek képesek automatikusan harmonizálni és kategorizálni a beszerzési adatokat, valamint azonosítani a költségi mintázatokat, a duplikált tranzakciókat és a potenciális megtakarítási lehetőségeket. A modern rendszerek már nemcsak elemzik az adatokat, hanem konkrét optimalizálási javaslatokat is generálnak, ami közvetlen pénzügyi előnyöket eredményezhet.

A beszállítói intelligencia és kockázatelemzés szintén kiemelt szerepet kapott a digitális procurement-rendszerekben. Az AI-modellek képesek különböző adatforrások – például pénzügyi beszámolók, piaci adatok, ESG-ratingek és hírelemzések – integrált feldolgozására, amely alapján dinamikus beszállítói kockázati scoring alakítható ki. Ez különösen fontos a pénzügyi menedzsment számára, mivel a beszállítói problémák közvetlenül befolyásolhatják a készletszinteket, a cash-flow folyamatokat és a vállalati jövedelmezőséget. A Gartner (2025) és a McKinsey & Company (2024) szerint a következő években az AI-alapú supplier risk management a procurement-funkció egyik legfontosabb fejlődési iránya lesz.

A mesterséges intelligencia a stratégiai sourcing és beszállító-kiválasztás területén is egyre jelentősebb szerepet tölt be. A modern AI-rendszerek képesek több ezer potenciális beszállító összehasonlítására, előrejelzésen alapuló teljesítményértékelésre és komplex optimalizációs modellek futtatására. Az olyan platformok, mint a Coupa, a SAP Ariba vagy az Ivalua, már fejlett supplier discovery és AI-alapú sourcing funkciókat alkalmaznak, amelyek nemcsak a költségeket, hanem a beszállítói stabilitást, az ESG-kompatibilitást és a logisztikai kockázatokat is figyelembe veszik (SAP, 2024; Ivalua, 2025).

A természetesnyelv-feldolgozás (NLP) fejlődése szintén jelentős változásokat eredményezett a stratégiai beszerzésben. A vállalati szerződések és beszállítói dokumentumok nagy mennyiségű strukturálatlan adatot tartalmaznak, amelyek hagyományos módon nehezen elemezhetők. Az NLP-alapú rendszerek képesek automatikusan azonosítani a kritikus szerződéses feltételeket, a compliance-kockázatokat és a fizetési feltételekhez kapcsolódó pénzügyi kockázatokat. A generatív AI alkalmazása tovább növeli ezeknek a rendszereknek a hatékonyságát, mivel lehetővé teszi szerződésösszefoglalók, tárgyalási javaslatok és automatizált dokumentumtervezetek létrehozását is (Hackett Group, 2025).

Az AI és ML technológiák alkalmazása ugyanakkor jelentős kihívásokat is hordoz. Az adatminőségi problémák, az ERP-rendszerek közötti integrációs nehézségek, az algoritmikus torzítások és az úgynevezett „black box” modellek komoly kockázatot jelenthetnek a vállalatok számára. Az OECD (2025) hangsúlyozza, hogy az AI-rendszerek sikeres implementációjához megfelelő governance-struktúrára, átlátható adatkezelésre és fejlett szervezeti kompetenciákra van szükség. A pénzügyi, beszerzési és IT-funkciók közötti együttműködés ezért kulcsfontosságúvá válik a digitális procurement-rendszerek hatékony működtetésében.

AI-alapú stratégiai beszerzési és spend-analitikai rendszerek összehasonlító elemzése

A szakirodalom szerint a procurement-rendszerek fejlődése szorosan összekapcsolódik a pénzügyi menedzsment digitalizációjával (Guida et al., 2025; SAP, 2024). A beszerzési költségek, a beszállítói kockázatok és a szerződéses feltételek ma már nem kizárólag operatív kérdések, hanem a jövedelmezőség, a cash-flow és a vállalati reziliencia meghatározó tényezői. Ennek következtében a modern procurement-platformok egyre inkább integrált pénzügyi és beszerzési adatarchitektúrára épülnek.

A SAP Ariba elsősorban a mély ERP-integráció és a nagyvállalati skálázhatóság révén vált meghatározó szereplővé. A platform szorosan kapcsolódik a SAP S/4HANA környezethez, így a beszerzési tranzakciók, szerződések és számlák közvetlenül integrálhatók a controlling- és pénzügyi rendszerekkel. A SAP AI Procurement fejlett spend-klasszifikációs, supplier risk management és automatizált compliance-funkciókat kínál, amelyek támogatják a költségkontrollt és a working capital menedzsmentet (SAP, 2024). A rendszer ugyanakkor elsősorban nagyvállalati környezetben működik hatékonyan, mivel implementációja gyakran összetett és költséges.

A Coupa ezzel szemben a mesterséges intelligenciára épülő (AI-native) spend management platformként pozicionálja magát, ahol az AI nem kiegészítő funkció, hanem a rendszer alapvető működési logikája. A platform intelligens spend-analitikát, előzetes költségelemzést, anomáliadetektálást és AI-alapú supplier discovery megoldásokat alkalmaz. A cloud-native architektúra előnye, hogy különböző ERP-rendszerekkel is integrálható, ami gyorsabb implementációt és nagyobb rugalmasságot biztosít (Coupa, 2024). A rendszer különösen erős a valós idejű spend-transzparencia és a megtakarítási lehetőségek azonosítása terén.

Az Ivalua elsősorban rugalmas Source-to-Pay megközelítésével és fejlett contract management funkcióival emelkedik ki. A platform magas konfigurálhatósága lehetővé teszi komplex vállalati struktúrák és beszállítói hálózatok kezelését. Pénzügyi menedzsment szempontból az Ivalua különösen előnyös összetett compliance- és kockázatkezelési környezetben, ugyanakkor a rendszer nagy rugalmassága hosszabb implementációs folyamatot eredményezhet.

A Sievo eltérő stratégiát követ, mivel elsősorban procurement analytics és spend-analitikai platformként működik. A rendszer fókusza nem a teljes Source-to-Pay

folyamat lefedése, hanem a beszerzési adatok harmonizálása, elemzése és üzleti értelmezése. AI-alapú spend-klasszifikációs, supplier risk analytics és benchmarking megoldásai elsősorban a CFO- és controlling-funkció számára teremtenek értéket (Sievo, 2025). A „data-to-action” megközelítés révén a platform nemcsak adatokat jelenít meg, hanem konkrét optimalizálási és megtakarítási javaslatokat is biztosít.

A vizsgált platformok eltérő technológiai és stratégiai megközelítést képviselnek, ugyanakkor közös bennük, hogy az AI és gépi tanulás segítségével növelik a pénzügyi és beszerzési folyamatok transzparenciáját, automatizáltságát és prediktív képességeit. A különböző platformok jellemzőit foglalja össze az 1. táblázat.

1. táblázat. AI-alapú procurement-platformok összehasonlító értékelése pénzügyi menedzsment szempontból

Platform	ERP-integráció	AI-érettség	Spend analitika	Szállítói kockázat	CFO támogatás
SAP Ariba	Nagyon magas; natív SAP S/4HANA integráció, erős enterprise kompatibilitás	Magas; AI Procurement, automatizált compliance és workflow támogatás	Fejlett spend-kategorizáció és költségtranszparencia	Integrált szállítói kockázat monitoring és ESG-funkciók	Erős controlling, cash-flow és working capital támogatás
Coupa	Magas; több ERP-rendszerrel integrálható cloud-native architektúra	Nagyon magas; AI-native spend management és prediktív modellek	Kiemelkedő valós idejű spend analitika és megtakarítás-azonosítás	Fejlett supplier intelligence és anomáliadetektálás	Erős CFO dashboardok és prediktív pénzügyi támogatás
Ivalua	Rugalmas integráció komplex vállalati struktúrákhoz	Magas; generatív AI és szerződés elemzési támogatás	Erős Source-to-Pay elemzési funkcionalitás	Kiemelkedő compliance- és beszállítói kockázat management	Közepesen erős; inkább procurement-orientált pénzügyi támogatás
Sievo	Közepes–magas; elsősorban adataggregációs és analitikai integráció	Közepesen magas; AI-alapú spend harmonizáció és benchmarking	Kiemelkedő procurement analytics és dashboard funkcionalitás	Fejlett szállítói kockázat analitika és benchmarking	Erős CFO és controlling fókusz, stratégiai reporting támogatás

Forrás: Saját szerkesztés SAP (2024), Coupa (2024), Ivalua (2025), Sievo (2025), Deloitte (2025) és Gartner (2025) alapján.

A szakirodalom alapján azok a rendszerek tekinthetők stratégiaileg legértékesebbnek, amelyek képesek integrálni a pénzügyi és procurement-adatokat, valós idejű döntéstámogatást biztosítanak, valamint támogatják a kockázatkezelést és a vállalati rezilienciát (Deloitte, 2025; Gartner, 2025). A procurement-platformok fejlődése egyértelműen azt mutatja, hogy a pénzügyi menedzsment és stratégiai beszerzés közötti határvonal fokozatosan elmosódik, és helyét integrált, AI-támogatott vállalatirányítási ökoszisztémák veszik át.

A digitalizáció pénzügyi hatásmechanizmusai és értékteremtési dimenziói

A digitalizáció és a mesterséges intelligencia vállalati alkalmazásának egyik legfontosabb kérdése, hogy az új technológiák milyen módon képesek mérhető pénzügyi értéket teremteni. A magas automatizáció ugyan növeli a hatékonyságot, ugyanakkor növelheti az algoritmikus függőséget és az IT-kitettséget. A pénzügyi menedzsment és stratégiai beszerzés integrációja önmagában még nem jelent versenyelőnyt, a valódi érték abból származik, hogy a vállalat miként képes az adatvezérelt rendszereket a döntéstámogatási és vállalatirányítási folyamatokba integrálni (Balkan et al., 2025; Deloitte, 2025).

A szakirodalom szerint a digitalizáció pénzügyi hatásai több, egymással összefüggő területen jelennek meg. Az intelligens algoritmusok különösen fontos szerepet

töltenek be a nagy mennyiségű pénzügyi és beszerzési adat feldolgozásában, mivel képesek olyan összefüggések felismerésére, amelyek hagyományos controlling-eszközökkel nehezen azonosíthatók. Az AI-alapú spend-analitikai rendszerek lehetővé teszik a vállalatok számára a nem hatékony folyamatok, duplikált tranzakciók és rejtett megtakarítási lehetőségek gyors azonosítását. Az automatizált kategorizáció, az intelligens workflow-rendszerek és a robotic process automation jelentősen csökkentik az adminisztratív terheket és az átfutási időket. A Coupa (2024) és Guida et al. (2025) szerint a modern procurement-platformok nemcsak a költségkontrollt javítják, hanem közvetlenül támogatják a stratégiai sourcingot és a pénzügyi döntéshozatalt is. A költségtranszparencia fejlődése szintén meghatározó pénzügyi hatásmechanizmus. A hagyományos controlling-rendszerek gyakran aggregált adatokkal dolgoztak, amelyek korlátozott elemzési lehetőségeket biztosítottak. Az AI-alapú procurement-platformok ezzel szemben részletes, valós idejű információkat nyújtanak a költségekről beszállítói, kategória- vagy üzleti egység szinten. Ez jelentősen javítja a controlling pontosságát és támogatja a gyorsabb vezetői reakciókat, különösen volatilis gazdasági környezetben (SAP, 2024; Sievo, 2025). A prediktív döntéstámogatás fejlődése a pénzügyi menedzsment egyik legfontosabb digitális átalakulási területe. A beszerzési adatok – például az alapanyagárak, a beszállítói teljesítmény vagy a logisztikai kockázatok – közvetlenül beépülnek ezekbe a modellekbe, ezáltal pontosabb és gyorsabban frissülő pénzügyi előrejelzések készíthetők (Deloitte, 2025; Gartner, 2025). A digitalizáció stratégiai jelentősége különösen erősen jelenik meg a kockázatkezelés és az ellátási lánc-reziliencia területén. A globális ellátási láncok sérülékenysége rámutatott arra, hogy a beszállítói és logisztikai problémák közvetlen pénzügyi következményekkel járnak.

Az AI-alapú pénzügyi és procurement rendszerek implementációs és szervezeti kihívásai

A mesterséges intelligencia és a digitalizáció vállalati alkalmazása az elmúlt években stratégiai prioritássá vált a pénzügyi menedzsment és stratégiai beszerzés területén. Az AI-alapú rendszerek ugyanakkor nem csupán technológiai fejlesztést jelentenek, hanem mélyreható szervezeti, adatkezelési és irányítási transzformációt is igényelnek. A szakirodalom szerint a digitális transzformáció sikerét nem kizárólag az alkalmazott technológia fejlettsége határozza meg, hanem az implementáció minősége, az adatarcitektúra stabilitása és a szervezeti adaptáció képessége is (Deloitte, 2025; Gartner, 2025). A vállalatok jelentős része még az AI-adaptáció korai szakaszában tart, ezért az implementáció során számos technológiai és szervezeti probléma merül fel. Az egyik legfontosabb kihívás az adatminőség és adatgovernance kérdése. Az AI-modellek működése közvetlenül függ az inputadatok pontosságától és konzisztenciájától, ezért a hibás vagy hiányos adatok megbízhatatlan előrejelzéseket eredményezhetnek. A multinacionális vállalatok esetében különösen problémás lehet az eltérő ERP-rendszerek, kategorizációs logikák és lokális beszállítói adatbázisok integrációja. A SAP (2024), valamint a Sievo és Coupa megoldásai ezért kiemelt hangsúlyt helyeznek az automatizált adatharmonizációra és spend-klasszifikációra.

Az ERP-rendszerek és AI-platformok integrációja szintén jelentős kihívást jelent a vállalatok számára. A legtöbb szervezet heterogén IT-környezetben működik, ahol

egyszerre vannak jelen a hagyományos rendszerek, a cloud-platformok és a külső AI-szolgáltatások. Ez gyakran nehezíti a valós idejű adatkapcsolatok és standardizált interfészek kialakítását. A Gartner (2025) szerint az AI-transzformációs projektek egyik leggyakoribb kudarctényezője az elégtelen rendszerintegráció és az egységes adatarchitektúra hiánya. Az AI-alapú pénzügyi döntéstámogatás másik kritikus kérdése az algoritmusok átláthatósága és auditálhatósága. A pénzügyi menedzsment hagyományosan erősen szabályozott terület, ahol alapvető követelmény a döntések visszakövethetősége. A modern gépi tanulási modellek azonban gyakran „black box” jellegűek, ezért nehezen értelmezhető, hogy az algoritmus milyen logika alapján hozott döntést. Az OECD (2025) és a World Economic Forum (2025) elemzése alapján a jövő AI-rendszereinek egyik legfontosabb követelménye az explainable AI (XAI) megközelítés alkalmazása lesz, amely biztosítja az algoritmusok nagyobb fokú magyarázhatóságát és auditálhatóságát. Az AI-alapú pénzügyi és procurement rendszerek főbb bevezetésének, alkalmazásának kihívásait mutatja be az 1. táblázat.

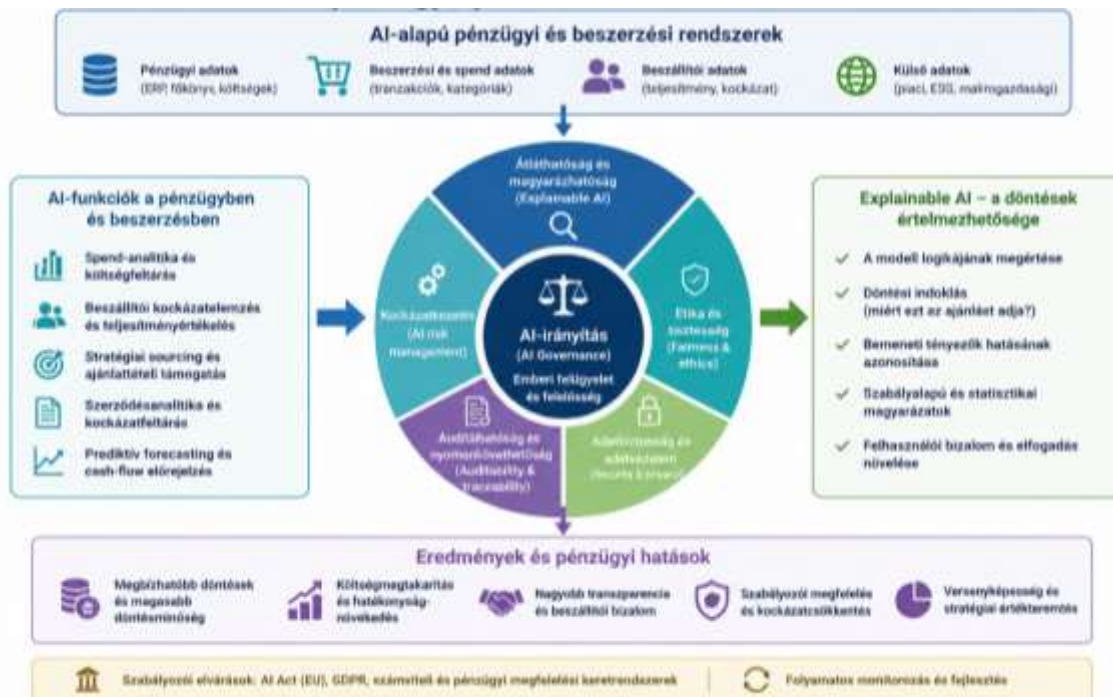
2. táblázat. Az AI-alapú pénzügyi és procurement rendszerek főbb implementációs kihívásai

Terület	Főbb kihívások	Lehetséges következmények
Adatminőség	Fragmentált és inkonzisztens adatok	Hibás forecastok és döntések
ERP-integráció	Heterogén rendszerek	Magas integrációs költségek
AI-transzparencia	„Black box” modellek	Auditálhatósági problémák
Compliance	GDPR és AI-szabályozás	Szabályozási kockázatok
Kompetenciák	Digitális tudáshiány	Lassú adaptáció
Szervezeti együttműködés	Funkcionális széttagoltság	Gyenge döntéstámogatás

Forrás: Saját szerkesztés Deloitte (2025), Gartner (2025), OECD (2025) és SAP (2024) alapján.

A compliance és adatbiztonság szintén meghatározó kérdéssé vált az AI-alapú rendszerek esetében. A cloud-alapú procurement-platformok nagy mennyiségű érzékeny pénzügyi és szerződéses adatot kezelnek, ezért a kibertámadások, az adatvesztés és a GDPR-megfelelés kiemelt kockázatot jelent. Az Európai Unió AI Act szabályozása várhatóan tovább erősíti az AI-governance és adatbiztonság szerepét, különösen a magas kockázatú pénzügyi alkalmazások esetében (World Economic Forum, 2025). Ezt a komplex összefüggési rendszert mutatja be a 2. ábra.

2. ábra. Az AI-governance szerepe a pénzügyi–procurement rendszerekben



Forrás: OECD (2025), Gartner (2025) és Deloitte (2025) alapján saját szerkesztés.

A technológiai kihívások mellett a kompetenciahiány és szervezeti ellenállás is jelentős akadályt jelenthet. A pénzügyi és procurement-szakemberek hagyományos controlling- és beszerzési szemlélete gyakran nehezen alkalmazkodik az AI-alapú működéshez, amely fejlett adatértelmezési és digitális analitikai kompetenciákat igényel. A Deloitte (2025) szerint a sikeres AI-implementáció egyik legfontosabb feltétele a szervezeti kultúra fejlesztése, a képzési programok és a megfelelő change management kialakítása.

A szakirodalom alapján a sikeres digitális transzformáció kulcsa a pénzügyi, beszerzési és IT-funkciók integrált együttműködése. A modern vállalatokban ezek a területek egyre inkább közös adatplatformokra és összehangolt döntéstámogatási mechanizmusokra épülnek. A McKinsey & Company (2024) szerint azok a vállalatok képesek valódi versenyelőnyt kialakítani, amelyek az AI-transzformációt nem izolált IT-projektként, hanem integrált vállalatirányítási és stratégiai programként kezelik.

A digitalizáció és mesterséges intelligencia jövőbeli fejlődési irányjai a pénzügyi menedzsmentben és stratégiai beszerzésben

A pénzügyi menedzsment és stratégiai beszerzés digitalizációja az elmúlt években a vállalati transzformáció egyik legfontosabb hajtóerejévé vált. A mesterséges intelligencia, a gépi tanulás, a cloud-alapú vállalatirányítás és a prediktív analitika fejlődése azonban még korántsem érte el végső állapotát. A jelenlegi rendszerek többsége elsősorban döntéstámogató és elemző szerepet tölt be, ugyanakkor a technológiai trendek arra utalnak, hogy a jövő pénzügyi és procurement-rendszerei fokozatosan autonómabbá, valós idejűvé és hálózatalapúvá válnak. A szakirodalom

szerint a következő évtizedben a pénzügyi menedzsment és stratégiai beszerzés fejlődését három meghatározó trend fogja alakítani. Az első az autonóm és generatív AI-rendszerek megjelenése, amelyek képesek lesznek komplex döntéstámogatási és részben önálló folyamatirányítási feladatok végrehajtására. A második trend az ESG- és fenntarthatósági szempontok integrációja a pénzügyi és beszerzési rendszerekbe. A harmadik pedig a CFO- és controlling-funkció stratégiai újrapozicionálása, amelyben a pénzügyi menedzsment fokozatosan adatvezérelt üzleti partneri szerepkört vesz át (Deloitte, 2025; Gartner, 2025). A digitalizáció jövőbeli fejlődése ugyanakkor nem kizárólag technológiai kérdés. A vállalatok számára egyre fontosabbá válik az AI-governance, az adatbiztonság, az algoritmikus átláthatóság és a humán döntéshozatal szerepének újradefiniálása is. A jövő pénzügyi és procurement-rendszereinek versenyképessége így nem pusztán az automatizáció szintjétől, hanem a technológiai, szervezeti és stratégiai integráció minőségétől függ majd.

A generatív AI fejlődési trendjei a procurement-folyamatokban

A generatív mesterséges intelligencia megjelenése új korszakot nyitott a pénzügyi menedzsment és stratégiai beszerzés digitalizációjában. A korábbi AI-rendszerek elsősorban adatfeldolgozó és elemző szerepet töltek be, míg a generatív AI képes új tartalmak, ajánlások, döntési alternatívák és automatizált üzleti válaszok létrehozására is. A procurement-funkció különösen alkalmas a generatív AI alkalmazására, mivel jelentős mennyiségű strukturálatlan adatot (szerződések, ajánlatkérések, beszállítói kommunikációk, ESG-jelentések, piaci elemzések) kezel. A generatív AI-rendszerek képesek ezek automatikus feldolgozására, értelmezésére és üzleti szempontú összegzésére. A Hackett Group (2025) kutatása szerint a generatív AI a következő években alapvetően átalakíthatja a procurement-funkció működését. A vállalatok egyre inkább autonóm AI-agenteket alkalmaznak majd a beszállítók előszűrésére, az ajánlatkérések generálására, a tárgyalási forgatókönyvek előkészítésére, valamint költségoptimalizálási javaslatok készítésére. A pénzügyi menedzsment számára ez különösen fontos, mivel a generatív AI-rendszerek jelentősen gyorsíthatják a döntéshozatalt és csökkenthetik a tranzakciós költségeket. A modern AI-agentek már képesek különböző scenáriókat modellezni, összehasonlítani azok pénzügyi hatásait, és optimalizációs javaslatokat készíteni a vezetők számára. Az autonóm procurement-rendszerek fejlődése a következő évek egyik legjelentősebb trendje lehet. A jelenlegi AI-rendszerek többsége még emberi jóváhagyáshoz kötött, azonban az autonóm AI-agentek képesek lehetnek bizonyos döntések önálló végrehajtására. Az ilyen rendszerek például automatikusan kiválaszthatják az optimális beszállítót, előre definiált keretek között tárgyalhatnak, valós időben optimalizálhatják a rendelési mennyiségeket, valamint dinamikusan módosíthatják a sourcing-stratégiát. A Gartner (2025) szerint az autonóm procurement-rendszerek különösen a rutin és standardizált beszerzési folyamatokban jelenhetnek meg gyorsan. A stratégiai és nagy értékű döntések esetében ugyanakkor továbbra is meghatározó marad az emberi kontroll és jóváhagyás szerepe.

A jövő pénzügyi és procurement-rendszerei várhatóan fokozatosan áttérnek a valós idejű vállalatirányítási modellekre. A hagyományos havi vagy negyedéves riportálási logika helyett egyre inkább folyamatos adatfrissítésre és AI-alapú forecastingra

épülő működés válik dominánssá. A modern prediktív rendszerek képesek valós időben monitorozni a költségstruktúrát, előre jelezni a likviditási problémákat, elemezni a beszállítói kockázatokat és scenárióalapú pénzügyi modelleket készíteni. A Deloitte (2025) ezt a folyamatot „continuous finance” vagy „always-on controlling” modellként írja le. A controlling szerepe így fokozatosan eltolódik a múltbeli teljesítmény mérésétől a jövőbeli események modellezése felé.

ESG, fenntarthatóság és digitális procurement

A fenntarthatósági és ESG-szemponatok integrációja a pénzügyi menedzsment és stratégiai beszerzés egyik legfontosabb jövőbeli fejlődési iránya. A vállalatok egyre nagyobb nyomás alatt állnak a szabályozói megfelelés, a befektetői elvárások, valamint a fenntarthatósági jelentéstételi kötelezettségek miatt. A World Economic Forum (2025) szerint a következő években a pénzügyi és procurement-rendszerek egyik legfontosabb versenyképességi tényezője az ESG-adatok integrált kezelése lesz. A jövő vállalati irányítási rendszerei várhatóan egyre inkább egységes adatplatformokra épülnek majd, amelyek egyszerre kezelik a pénzügyi adatokat, a procurement-információkat, valamint az ESG-mutatókat. Ez lehetővé teszi, hogy a pénzügyi menedzsment ne kizárólag költség- és profitoldalról értékelje a beszállítókat, hanem fenntarthatósági és reputációs szempontokat is figyelembe vegyen. A hagyományos beszállítóértékelési rendszerek jellemzően az árra, a minőségre, a szállítási teljesítményre, valamint a költséghatékonyságra koncentráltak. A modern AI-alapú rendszerek ezzel szemben már komplex ESG- és fenntarthatósági indikátorokat is integrálnak. A beszállítók értékelése így fokozatosan multidimenzionális modellé válik.

A digitális pénzügyi menedzsment stratégiai transzformációja

A digitalizáció és mesterséges intelligencia fejlődése alapvetően átalakítja a pénzügyi menedzsment szervezeti szerepét is. A CFO és controlling-funkció hagyományosan riportálási, kontroll-, valamint szabályozási szerepkörökre épült. A digitális vállalatban azonban a pénzügyi menedzsment egyre inkább stratégiai üzleti partnerként jelenik meg. A KPMG (2025) szerint a jövő pénzügyi vezetői egyre inkább adatvezérelt döntéshozók, AI-governance szereplők, valamint stratégiai transzformációs vezetők lesznek. A CFO szerepkör fejlődése szorosan összekapcsolódik az AI-alapú döntéstámogatással. A pénzügyi vezetőknek már nem elegendő a számviteli és pénzügyi ismeretek birtoklása, egyre fontosabbá válik az adatértelmezési képesség, az AI-rendszerek működésének megértése, valamint a digitális transzformáció irányítása. A controlling-funkció fejlődésének egyik legfontosabb iránya a folyamatos forecasting és a valós idejű controlling kialakulása. A hagyományos éves költségtervezési és forecast-rendszerek fokozatosan háttérbe szorulnak, helyüket dinamikusan frissülő AI-modellek veszik át. Ez lehetővé teszi a gyorsabb reakcióidőt, a pontosabb pénzügyi előrejelzést, valamint a valós idejű üzleti döntéstámogatást. A digitális transzformáció végső következménye, hogy a pénzügyi menedzsment fokozatosan stratégiai üzleti partneri szerepkörbe kerül. A procurement és pénzügyi rendszerek integrációja lehetővé teszi, hogy a controlling ne csupán utólagos riportálási funkcióként működjön, hanem aktívan támogassa a

stratégiai sourcingot, a beruházási döntéseket, a kockázatkezelést, valamint a vállalati értékteremtést.

Következtetések

A digitalizáció, a mesterséges intelligencia és a gépi tanulás fejlődése alapvetően átalakítja a vállalati pénzügyi menedzsment és stratégiai beszerzés működését. A tanulmány rámutatott arra, hogy az AI-alapú procurement-rendszerek ma már nem pusztán tranzakciókezelő megoldások, hanem integrált, adatvezérelt döntéstámogatási platformok, amelyek szoros kapcsolatban állnak a controllinggal, a treasury-funkcióval és a stratégiai vállalatirányítással. A procurementből származó adatok egyre inkább a pénzügyi menedzsment meghatározó inputjaivá válnak, ami fokozatosan megszünteti a pénzügyi és beszerzési funkciók hagyományos elkülönülését (Deloitte, 2025; McKinsey & Company, 2024).

A kutatás arra is rámutatott, hogy az AI-alapú rendszerek implementációja nem tekinthető kizárólag technológiai innovációnak. A sikeres alkalmazás feltétele a megfelelő adatarchitektúra, az ERP-integráció, az AI-governance kialakítása, valamint a pénzügyi, beszerzési és IT-funkciók együttműködése. A vállalatok számára ezért a legnagyobb kihívást nem maga a technológia, hanem annak stratégiai és szervezeti integrációja jelenti.

A kutatás legfontosabb eredményei

A kutatás egyik legfontosabb megállapítása, hogy a pénzügyi menedzsment és a stratégiai beszerzés konvergenciája a digitalizáció egyik meghatározó vállalatirányítási következménye. Az integrált adatplatformok révén a vállalatok pontosabb költségelemzést, cash-flow forecastingot és working capital optimalizálást valósíthatnak meg, miközben az AI-rendszerek támogatják a beszállítói és ellátási lánc kockázatok prediktív elemzését is (Deloitte, 2025; Gartner, 2025).

A mesterséges intelligencia fejlődése alapvetően átalakítja a controlling és pénzügyi döntéstámogatás működését. A retrospektív elemzések helyét fokozatosan prediktív és scenárióalapú modellek veszik át, amelyek valós idejű adatfeldolgozásra épülnek. A SAP Ariba, Coupa, Ivalua és Sievo rendszerek összehasonlítása alapján megállapítható, hogy a modern procurement-platformok növelik a spend-transzparenciát, támogatják a controllingot és közvetlenül hozzájárulnak a pénzügyi értékteremtéshez (Guida et al., 2025; Sievo, 2025).

A digitalizáció pénzügyi hatásai elsősorban a működési hatékonyság javulásában, az adminisztratív folyamatok automatizálásában és a controlling pontosságának növekedésében jelennek meg. Az AI-alapú rendszerek támogatják a likviditásmenedzsmentet, a cash-flow forecastingot és a stratégiai sourcingot, miközben gyorsabb reakciót tesznek lehetővé az ellátási lánc zavaraira és a piaci bizonytalanságokra (Appelbaum et al., 2017; Bhimani & Willcocks, 2014). A digitalizáció legfontosabb pénzügyi és vállalatirányítási hatásait a 2. táblázat foglalja össze.

3. táblázat. A digitalizáció legfontosabb pénzügyi és vállalatirányítási hatásai

Terület	Hagyományos működés	AI-alapú digitális működés
Controlling	Retrospektív riportálás	Prediktív döntéstámogatás
Procurement	Operatív beszerzés	Stratégiai sourcing
Forecasting	Periodikus tervezés	Valós idejű forecasting
Kockázatkezelés	Reaktív megközelítés	Prediktív risk analytics
Beszállítói értékelés	Statikus KPI-rendszer	Dinamikus AI-scoring
Working capital	Manuális optimalizálás	AI-alapú cash-flow menedzsment

Forrás: Saját szerkesztés Deloitte (2025), Gartner (2025), SAP (2024) és McKinsey & Company (2024) alapján.

A pénzügyi menedzsment és stratégiai beszerzés integrációja a modern vállalatirányítás egyik kulcstényezőjévé vált. Az integrált adatplatformok és AI-rendszerek támogatják a valós idejű döntéshozatalt, a gyorsabb controllingot és az összehangolt stratégiai tervezést. A procurement-funkció fokozatosan stratégiai üzleti partneri szerepkörbe kerül, amely közvetlenül hozzájárul a vállalati értékteremtéshez és versenyképességhez (McKinsey & Company, 2024; Deloitte, 2025).

Gyakorlati és vállalatirányítási következtetések

A kutatás gyakorlati szempontból is jelentős következtetéseket fogalmaz meg a vállalatok számára. Az AI-alapú pénzügyi és procurement-rendszerek implementációja ugyanis nem értelmezhető pusztán technológiai fejlesztésként, hanem komplex szervezeti és stratégiai transzformációként jelenik meg. A szakirodalom alapján a sikeres digitális átállás alapfeltétele az adatvezérelt működés kialakítása, az integrált vállalatirányítási architektúra fejlesztése, valamint a pénzügyi, beszerzési és informatikai funkciók közötti együttműködés erősítése (Deloitte, 2025; Gartner, 2025). A vállalatok számára különösen fontos az adatminőség javítása és az ERP-rendszerek megfelelő integrációja, mivel az AI-alapú döntéstámogatás csak megbízható és konzisztens adatstruktúrák mellett működtethető hatékonyan. Emellett egyre nagyobb jelentősége van az AI-governance kialakításának is, amely biztosítja az algoritmusok átláthatóságát, az auditálhatóságot és a szabályozási megfelelést. A pénzügyi menedzsment és a procurement közös digitális platformjai lehetővé teszik a controlling- és sourcing-folyamatok összehangolását, ami különösen volatilis gazdasági környezetben jelenthet versenyelőnyt a vállalatok számára.

A kutatás eredményei arra utalnak, hogy a vállalatoknak célszerű fokozatos AI-transzformációs stratégiát alkalmazniuk. A nemzetközi gyakorlat azt mutatja, hogy a pilotprojektekre és fokozatos implementációra épülő megközelítés jelentősen csökkenti a technológiai és szervezeti kockázatokat. Az AI-rendszerek bevezetése során az adatgovernance fejlesztése és a munkavállalói kompetenciák erősítése ugyanolyan fontos tényező, mint maga a technológiai infrastruktúra. A gyors technológiai adaptáció önmagában nem garantálja a sikeres transzformációt; a vezetői támogatás, a szervezeti kultúra és a megfelelő change management legalább ilyen meghatározó szerepet játszik (McKinsey & Company, 2024). A pénzügyi menedzsment és controlling területén a legfontosabb fejlődési irány a valós idejű és prediktív működési modellek kialakulása. A controlling-funkció fokozatosan eltávolodik a hagyományos retrospektív riportálási logikától, és egyre inkább adatvezérelt, előrejelző és stratégiai döntéstámogató szerepkört vesz fel. Ez megköveteli a data-driven controlling modellek alkalmazását, a folyamatos forecasting rendszerek fejlesztését, valamint az AI-alapú döntéstámogatási mechanizmusok integrációját. A pénzügyi szakemberek számára emiatt egyre fontosabbá válnak az adatértelmezési, digitális analitikai és AI-governance kompetenciák is (Appelbaum et al., 2017; Bhimani, 2020). A procurement-funkció stratégiai szerepe szintén jelentős átalakuláson megy keresztül. A tranzakcióközpontú működés helyét fokozatosan a stratégiai sourcing és supplier intelligence megközelítések veszik át, amelyekben az AI-rendszerek központi szerepet töltenek be. A modern procurement-platformok nem csupán a beszerzési folyamatok automatizálását támogatják, hanem fejlett spend-analitikai, supplier risk management és ESG-monitoring funkciókat is biztosítanak. Emellett a szerződésanalitika és generatív AI alkalmazása lehetővé teszi a szerződéses kockázatok gyorsabb azonosítását és a döntéshozatal hatékonyságának növelését (Guida et al., 2025; Sievo, 2025).

A pénzügyi menedzsment és a stratégiai beszerzés integrációja hosszú távon jelentős vállalati értéket teremthet. Az összehangolt digitális rendszerek nemcsak a költségtranszparencia és működési hatékonyság javulását eredményezhetik, hanem hozzájárulhatnak a vállalati reziliencia, a stratégiai rugalmasság és a fenntartható versenyképesség erősítéséhez is. A kutatás eredményei alapján megállapítható, hogy a jövő sikeres vállalatai azok lesznek, amelyek képesek a pénzügyi és procurement-funkciókat integrált, AI-támogatott és adatvezérelt vállalatirányítási ökoszisztémaként működtetni.

Korlátok és további kutatási irányok

A kutatás elsősorban szekunder szakirodalmi forrásokra és konceptuális elemzésre épült, ezért az eredmények általánosíthatósága korlátozott lehet, különösen a kisebb vállalatok vagy eltérő iparági környezetek esetében. A technológiai fejlődés gyors üteme szintén nehezíti a hosszú távú következtetések levonását, különösen a generatív AI és autonóm vállalatirányítási rendszerek területén (OECD, 2025; World Economic Forum, 2025).

A jövőbeni kutatások számára fontos irány lehet az AI-alapú pénzügyi és procurement-rendszerek empirikus vizsgálata, különösen a pénzügyi megtérülés, a

working capital menedzsment és az autonóm AI-agentek szervezeti hatásainak elemzése területén. A digitalizáció és a mesterséges intelligencia hosszú távon a pénzügyi menedzsment és stratégiai beszerzés egyik legjelentősebb vállalatiirányítási transzformációját alakíthatja ki, amelyben az integrált, adatvezérelt döntéstámogatási rendszerek válnak a vállalati versenyképesség meghatározó elemévé (KPMG, 2025).

Hivatkozások

- Abdel-Kader, M., & Luther, R. (2008). The impact of firm characteristics on management accounting practices: A UK-based empirical analysis. *The British Accounting Review*, 40(1), 2–27. <https://doi.org/10.1016/j.bar.2007.11.003>
- Appelbaum, D., Kogan, A., Vasarhelyi, M., & Yan, Z. (2017). Impact of business analytics and enterprise systems on managerial accounting. *International Journal of Accounting Information Systems*, 25, 29–44. <https://doi.org/10.1016/j.accinf.2017.03.003>
- Balkan, B., & Akyuz, G. A. (2025). Artificial intelligence in procurement: A systematic literature review and future research agenda. *Artificial Intelligence Review*, 58, Article 233. <https://doi.org/10.1007/s10462-025-11336-1>
- Bhimani, A. (2020). Digital data and management accounting: Why we need to rethink research methods. *Journal of Management Control*, 31(1–2), 9–23. <https://doi.org/10.1007/s00187-020-00295-z>
- Bhimani, A., & Willcocks, L. (2014). Digitisation, 'Big Data' and the transformation of accounting information. *Accounting and Business Research*, 44(4), 469–490. <https://doi.org/10.1080/00014788.2014.910051>
- Brynjolfsson, E., & McAfee, A. (2014). *The second machine age: Work, progress, and prosperity in a time of brilliant technologies*. W. W. Norton & Company.
- Coupa. (2024). *AI in procurement: Exploring its growing impact*. Coupa Software Inc. <https://www.coupa.com/blog/ai-in-procurement/>
- Davenport, T. H., & Ronanki, R. (2018). Artificial intelligence for the real world. *Harvard Business Review*, 96(1), 108–116.
- Deloitte. (2025). *Future of finance: AI-driven transformation in procurement and finance*. Deloitte Insights. <https://www2.deloitte.com/us/en/insights/focus/cognitive-technologies/artificial-intelligence-financial-services.html>
- Gartner. (2025). *Top technology trends in procurement and finance*. Gartner Research. <https://www.gartner.com/en/articles/top-technology-trends-in-procurement>
- Guida, M., Caniato, F., & Moretto, A. (2025). AI meets spend classification: A new frontier in procurement information processing. *Journal of Purchasing and Supply Management*, 31(2), 100993. <https://doi.org/10.1016/j.pursup.2025.100993>

- Hackett Group. (2025). *Generative AI and the future of procurement*. The Hackett Group Research. <https://www.thehackettgroup.com/insights/embracing-the-future-how-generative-ai-is-revolutionizing-procurement-in-2025/>
- Ivalua. (2025). *AI in procurement: Automation, governance and supplier intelligence*. Ivalua White Paper. <https://www.ivalua.com/resources/>
- Kaplan, R. S., & Atkinson, A. A. (1998). *Advanced management accounting* (3rd ed.). Prentice Hall.
- KPMG. (2025). *The future of finance with AI*. KPMG International. <https://kpmg.com/xx/en/home/insights/2024/01/future-of-finance.html>
- McKinsey & Company. (2024). *The state of AI in procurement and finance*. McKinsey Insights. <https://www.mckinsey.com/capabilities/operations/our-insights/generative-ai-and-the-future-of-procurement>
- OECD. (2021). *Artificial intelligence, machine learning and big data in finance: Opportunities, challenges, and implications for policy makers*. OECD Publishing. <https://doi.org/10.1787/7ebe77c7-en>
- OECD. (2025). *Governing with artificial intelligence: The state of play and way forward in core government functions*. OECD Publishing. <https://doi.org/10.1787/795de142-en>
- Porter, M. E., & Heppelmann, J. E. (2015). How smart, connected products are transforming companies. *Harvard Business Review*, 93(10), 96–114.
- Quattrone, P. (2016). Management accounting goes digital: Will the move make it wiser? *Management Accounting Research*, 31, 118–122. <https://doi.org/10.1016/j.mar.2016.01.003>
- SAP. (2024). *AI in procurement: Intelligent spend management and finance integration*. SAP SE. <https://www.sap.com/products/financial-management/artificial-intelligence.html>
- Sievo. (2025). *The ultimate guide for AI in procurement*. Sievo Oy. <https://sievo.com/resources/guide-ai-in-procurement/>
- Srai, J. S., Kumar, M., Graham, G., Phillips, W., Tooze, J., Ford, S., Beecher, P., Raj, B., Gregory, M., Tiwari, M. K., Ravi, B., Neely, A., Shankar, R., Charnley, F., & Tiwari, A. (2016). Distributed manufacturing: Scope, challenges and opportunities. *International Journal of Production Research*, 54(23), 6917–6935. <https://doi.org/10.1080/00207543.2016.1192302>
- Van der Aalst, W. (2016). *Process mining: Data science in action* (2nd ed.). Springer. <https://doi.org/10.1007/978-3-662-49851-4>
- World Economic Forum. (2025). *Artificial intelligence in financial services and procurement ecosystems*. World Economic Forum Report. <https://www.weforum.org/reports/>
- Zhang, Z. (2023). Analysis of digital transformation of financial management in the era of artificial intelligence. *Highlights in Business, Economics and Management*, 23, 876–882. <https://doi.org/10.54097/v4nj7935>

Zhang, Y., & Wang, H. (2024). Digital transformation and corporate finance: A bibliometric and systematic review. *Finance Research Letters*, 65, 105412.
<https://doi.org/10.1016/j.frl.2024.105412>

ADATVEZÉRELT MŰKÖDÉSI MODELLEK ÉS A DIGITÁLIS TRANSZFORMÁCIÓ ELMÉLETI KIHÍVÁSAI A PÉNZÜGYI SZÉKTORBAN

LOVÁSZ Zoltán

*Neumann János Egyetem, Gazdálkodás- és Szervezéstudományok Doktori Iskola
Pénzügyi Digitalizációs Alprogram*

lovasz.zoltan@gmail.com

<https://doi.org/10.15170/XVIIPPN-Tk-KTK-2026-10>

Absztrakt

Az Ipar 4.0 és az emberközpontú Ipar 5.0 technológiai paradigmái alapjaiban írják felül a vállalati működés hagyományos kereteit, különösen a nemzetgazdasági szempontból kritikus infrastruktúrát jelentő pénzügyi szektorban. A „Digitális Darwinizmus” korszakában az adat a pusztán adminisztratív melléktermék státuszából a legkritikusabb erőforrássá, egyfajta stratégiai vagyonelemmé lépett elő. Ugyanakkor a digitális átalakulás a gyakorlatban gyakran ütközik strukturális és szervezeti korlátokba, amelyet a szervezeti tehetetlenség is felerősít. Jelen tanulmány átfogóan vizsgálja, hogy a modern szervezetelméleti, informatikai és szociológiai kutatások hogyan járulnak hozzá a banki digitális transzformáció és a technológiai innovációk mélyebb megértéséhez.

Kulcsszavak: Ipar 4.0, Működési Reziliencia, AI Modellkockázat, Adatvagyon-gazdálkodás, Technológiai Determinizmus, Ügynökelmélet, DORA, Infonomics

Bevezetés

A 21. század gazdaságtörténetének egyik legmeghatározóbb fordulata az adat szerepének radikális átértékelődése. Míg a klasszikus közgazdaságtan a földet, a munkát és a tőkét tekintette a termelés elsődleges tényezőinek, addig az Infonómia (Infonomics) elméletének térnyerésével nyilvánvalóvá vált, hogy az információs vagyon mára a vállalatok legértékesebb, bár a hagyományos mérlegekben gyakran láthatatlan eszközévé (Asset) vált (Laney, 2018). Ez a paradigmaváltás a bankrendszerben különösen markánsan jelentkezik, hiszen a modern pénzintézetek ma már alapvetően komplex „adatfeldolgozó üzemekké” váltak.

A 2008-as globális pénzügyi válság (GFC) brutális módon világított rá a bankrendszer információs architektúrájának fundamentális hiányosságaira. A Lehman Brothers összeomlása bizonyította, hogy a bankok informatikai rendszerei és adatarcitektúrái nem voltak képesek a kockázati kitettségek gyors, pontos és

aggregált megjelenítésére válsághelyzetben (Basel Committee on Banking Supervision, 2013). Az átláthatatlanság miatt a döntéshozók és a prudenciális hatóságok információs deficitbe kerültek, és nem érzékelték a toxikus eszközök felhalmozódását, amit a szakirodalom a „bankárok új ruhája” effektusként tart számon (Admati & Hellwig, 2013). A poszt-krízis szabályozási hullám – élén a Bázeli Bankfelügyeleti Bizottság (BCBS) 239-es ajánlásával – az adatot kritikus infrastruktúrává emelte, egyértelművé téve, hogy a modern prudenciális megfelelés alapfeltétele a tőke megfelelés mellett az „adatmegfelelés” (Data Adequacy) (Basel Committee on Banking Supervision, 2013).

Ugyanakkor a digitális adaptáció – a „Digitális Darwinizmus” – korszakában a pusztai technológiai beruházások és az általános, iparág-független adatmenedzsment modellek mechanikus alkalmazása elégtelennek bizonyul. Jelen tanulmány célja, hogy túllépjen a banki adatvagyon-gazdálkodás pusztán leíró jellegű (deskriptív) vizsgálatán, és kritikai górcső alá vegye a felügyeleti gyakorlatban dogmaként kezelt, de a prudenciális rögválóságban gyakran csődöt mondó elméleteket. A kutatás egyrészt azonosítja a generikus keretrendszerek (például a DAMA) episztemológiai vakfoltjait, másrészt rámutat a „Három Védelmi Vonal” (3LoD) modelljén belüli ágencia-problémákra és a forrásoldali adatrögzítés erkölcsi kockázataira (Moral Hazard). A tanulmány feltárja a Conway-törvényt és a „decoupling” (szétcsatolás) dialektikáját, igazolva, hogy a technológiai elmaradottság miként szolgál a ceremoniális megfelelés alibijeként a szervezetek számára (Leonardi & Barley, 2010; Orlikowski & Scott, 2008). Végül bemutatja, hogy ez az előregedő architektúrák örökség miként transzformálódik a bemeneti adathibák (GIGO) keresztül a mesterséges intelligencia modellek korában felbecsülhetetlen rendszerskockázattá, és hogyan válaszolnak erre az új európai reziliencia-szabályozások (DORA) által támogatott architektúrák stressztesztjei.

1. A folyamatoptimalizálás rejtett akadályai

A banki adatkezelés és digitális transzformáció hatékonyságának vizsgálatakor elengedhetetlen a technológiai architektúra és a szervezeti struktúra közötti mélyreható elemzés. A szakirodalom konszenzusa szerint az adatarchitektúra nem értelmezhető csupán informatikai infrastrukturális kérdéseként, hanem sokkal inkább egy szervezeti lenyomatként funkcionál.

1.1. A Conway-törvény és az adatarchitektúrák evolúciós kényszerpályája

Ezt a szocio-technikai jelenséget írja le Melvin Conway törvénye, amely posztulálja, hogy a rendszereket tervező szervezetek kényszerűen olyan technológiai terveket hoznak létre, amelyek a szervezet belső kommunikációs struktúrájának másolatai (Conway, 1968). Ez a szociológiai törvényszerűség magyarázza a banki adattárház-építések gyakori kudarcát: a funkcionálisan silósodott – például a Hitelezés, Kockázatkezelés, Pénzügy és Treasury területekre tagozódott –, egymással alig kommunikáló szervezeti egységek szükségszerűen silósodott, inkompatibilis adatrendszereket eredményeznek.

A tradicionális banki válasz erre a kihívásra évtizedekig a Vállalati Adattárház (Enterprise Data Warehouse - EDW) volt, amely a „Single Source of Truth” (SSOT) megteremtését ígérte egy radikálisan centralizált, szigorú sémákra (Schema-on-Write) épülő relációs adatbázison keresztül (Inmon, 2005; Kimball & Ross, 2013). A banki környezetben azonban az EDW merevsége vált a legfőbb akadállyá: minden új üzleti igény hosszas fejlesztést igényelt, ami a központi IT osztályt szűk keresztmetszetté (bottleneck) tette, drasztikusan rontva az üzleti agilitást (Devlin, 2013).

A Big Data korszak kihívásaira reagálva az iparág az Adattó (Data Lake) felé fordult, de a megfelelő kormányzás hiánya miatt ezek a tárolók gyakran „Adatmocsárrá” (Data Swamp) degradálódtak, ahol az adatok minősége ellenőrizhetetlenné vált (Stein & Morrison, 2014). Erre válaszul született meg a Data Lakehouse koncepció, amely biztosítja az ACID tulajdonságokat, de a szervezeti centralizációból fakadó strukturális problémákat alapjaiban nem oldja meg (Armbrust et al., 2021). A valódi paradigmaváltást a Data Mesh koncepciója hozta el, amely szakít a technológiai centralizáció dogmájával, és a Conway-törvény realitásaihoz jobban illeszkedő decentralizált, domén-orientált megközelítést javasol az „Adat mint Termék” elve mentén (Dehghani, 2020, 2022). Ugyanakkor az elosztott környezet új kockázatot generál: ha a bank nem képes garantálni a domének közötti „szemantikai interoperabilitást”, a decentralizált hálózat képtelen lesz megfelelni a kockázati aggregációs elvárásoknak (AWS, 2025).

1.2. End-User Computing (EUC) és a "Rejtett Gyárak" kockázata

A megkövesedett technológiai architektúrák és a silósodott szervezet legveszélyesebb tünete az End-User Computing (EUC), vagyis az Excel-alapú árnyékinformatika burjánzása. Amikor az IT-fejlesztések lassúak, az üzleti területek a hivatalos rendszereket megkerülve, táblázatkezelőkben („rejtett gyárakban”) tartják fenn a jelentéstételt. Panko empirikus kutatásai rávilágítottak, hogy a manuális táblázatkezelő alapú folyamatok mintegy 88%-a tartalmaz szubsztanciális hibát (Panko, 2008). A „Data Provenance” elmélete rámutat: az adatok megbízhatósága csak akkor garantálható, ha transzformációjuk és eredetük dokumentált (Buneman et al., 2001). A manuális beavatkozások fizikailag megszakítják az automatizált adatszámaztatási láncot (Data Lineage), átláthatatlan „Fekete Dobozokat” hozva létre, amelyek gátolják az eredetismeretet.

1.3. Intézményi izomorfizmus és a „decoupling” (szétcsatolás) jelensége

A bankok technológiai és szervezeti reakcióit a szabályozói nyomásra legkifejezőbbben az Új Intézményi Elmélet magyarázza. A bizonytalan és erősen szabályozott környezetben a szervezetek az intézményi izomorfizmus (homogenizáció) felé mozdulnak el, amely elsősorban a legitimitás megőrzését, és nem feltétlenül a piaci hatékonyság növelését szolgálja (DiMaggio & Powell, 1983).

A kényszerítő izomorfizmus (coercive isomorphism) hatására a bankok gyakran szétválasztják a formális struktúrát a tényleges napi működéstől. Ez az úgynevezett „decoupling” (szétcsatolás) jelensége, ahol a pozíciók létrehozása – például a Chief

Data Officer (CDO) vagy az Adatgazdák kinevezése – gyakran csak egy „ceremoniális” aktus, amely a szabályozó felé a megfelelőséget szimbolizálja, de valós vétőjogok és költségvetési kontroll hiányában a belső hatalmi struktúrákat nem bolygatja meg (Meyer & Rowan, 1977).

A mimetikus izomorfizmus (mimetic isomorphism) a technológiai bizonytalanság redukcióját szolgálja: a bankok hajlamosak kritika nélkül másolják a sikeresnek vélt versenytársakat vagy tanácsadó cégek (Big4) modelljeit, mivel a „Best Practice” másolása kockázatcsökkentő, hiszen „tévedni társaságban biztonságosabb” (Teo, Wei, & Benbasat, 2003; Tingling & Parent, 2002). A normatív izomorfizmus (normative isomorphism) pedig a professzionalizálódásból fakad: a szakmai szervezetek (pl. DAMA) „episztemikus közösségeket” hoznak létre, amelyek homogenizálják a banki belső szabályzatokat és gondolkodásmódot (Scott, 2014; King et al., 1994).

1.4. A technológiai determinizmus és a szervezeti ellenállás dialektikája

A Conway-törvény és a szociológiai izomorfizmus vizsgálata rávilágít, hogy a banki „decoupling” és az elavult (legacy) informatikai rendszerek dominanciája között egymást erősítő, dialektikus viszony áll fenn. A technológiai örökség a „ceremoniális megfelelés” anyagi bázisaként (material substrate) funkcionál: a banki menedzsment gyakran a régi rendszerek rigiditására hivatkozva legitimálja a manuális Excel-kerülőutak fenntartását és az Adatgazdák formális szerepben tartását. A technológia alkalmazkodása és a működési gyakorlat szétválása a digitális transzformáció elsődleges akadály, fenntartva az inkonzisztenciákat (Leonardi & Barley, 2010; Orlikowski & Scott, 2008).

2. AI modellkockázat, a GIGO-mechanizmus és a Magyarázható AI (XAI) imperatívusza

A mesterséges intelligencia (AI) és a gépi tanulás (ML) alkalmazása a banki prudenciális modellezésben – különös tekintettel a nemteljesítési valószínűség (PD) vagy a hitelbedőlések (LGD) becslésére – történelmi léptékű paradigmaváltást ígér a pénzügyi döntéstámogatásban. Ez a technológiai ugrás azonban a kockázatkezelési architektúrák fundamentális újraértékelését is kikényszeríti, mivel az új algoritmusok a hagyományos statisztikai módszerektől eltérő, sajátos rendszerkockázatokat generálnak.

2.1. A GIGO-mechanizmus és az ontológiai előfeltételek

A működési kockázati modellek megbízhatóságának vizsgálatokor a validációs eljárások nem korlátozódhatnak pusztán a kimeneti eredmények statisztikai tesztelésére. A Modellkockázat-kezelésnek (Model Risk Management - MRM) proaktívan ki kell terjednie a bemeneti adatok minőségének folyamatos ellenőrzésére is (Scandizzo, 2011). Az algoritmusok ontológiai előfeltétele az adatminőség: a „Garbage In, Garbage Out” (GIGO) mechanizmusán keresztül a hibás bemeneti adat torzítja a legkifinomultabb mélytanulási modellek és a tőkeszámítások végeredményét is, ami közvetlenül szuboptimális tőkeallokációhoz vezet (Cai & Zhu, 2015).

2.2. A „Fekete Doboz” probléma és a validációs vákuum

Míg a klasszikus statisztikai modellek átláthatóak voltak, a modern gépi tanulási algoritmusok döntési mechanizmusa gyakran átláthatatlan, vagyis „Fekete Dobozként” (Black Box) funkcionál. A vállalati kormányzás (Governance) szintjén ez felerősíti a harmadik védelmi vonal, azaz a Belső Ellenőrzés kompetenciahiányát. Amennyiben a belső ellenőrzés csak interjúokra és dokumentumokra épít, és nem képes technikai, SQL-szintű adatelemzéssel vizsgálni az AI modellek bemeneti adatait, úgy kialakul az „Audit Expectation Gap”. Ebben az audit elvárási résben a felsővezetés abban a hamis illúzióban hoz döntéseket, hogy az AI által generált kockázati profil validált és biztonságos, holott az adathibákon alapulhat (Marcella & Stucki, 2015; Vasarhelyi et al., 2004).

2.3. A Magyarázható AI (XAI) prudenciális imperatívusza

A „Fekete Doboz” jelenség feloldására a szakirodalom a Magyarázható AI (Explainable AI - XAI) alkalmazását teszi kötelezővé (Gunning et al., 2019). Ennek egyik legígéretesebb technológiai megvalósítása a játékelméleti alapokon nyugvó SHAP (Shapley Additive exPlanations) értékek alkalmazása, amely képes egzakt módon számszerűsíteni az egyes bemeneti változók hozzájárulását a modell végső kimeneteléhez.

A szigorúan szabályozott pénzügyi szektorban a magyarázhatóság (explainability) messze túlmutat az etikai kérdéseken (Bracke et al., 2019; Doshi-Velez & Kim, 2017). Az XAI alapvető prudenciális követelmény: megfelelő átláthatóság, visszakövethetőség és auditálhatóság nélkül a prediktív AI modellek nem emelhetők be az „éles” (Production) banki folyamatokba. Az átláthatatlan rendszerek alkalmazása frontálisan sértené a szabályozók (például a BCBS 239 ajánlás) által is megkövetelt átlátható belső vállalatirányítási elveket és a kockázati jelentések megbízhatóságát (Basel Committee on Banking Supervision, 2013).

3. Ügynökelmélet, Moral Hazard és a „Három Védelmi Vonal” korlátai az adatminőség-menedzsmentben

A banki vállalatirányításban és kockázatkezelésben globális sztenderdek tekintett, a felügyeleti hatóságok által is megkövetelt „Három Védelmi Vonal” (Three Lines of Defense - 3LoD) modell alkalmazása az adatminőség-menedzsment területére elméletben logikus lépés. A gyakorlati implementáció során azonban a modell súlyos strukturális korlátokba ütközik, amelyek leginkább a közgazdaságtani Megbízó-Ügynök Elmélet (Principal-Agent Theory) keretrendszerében értelmezhetők. Jensen és Meckling (1976) klasszikus elmélete rávilágít a szervezeti szereplők – a banki felsővezetés és az operatív munkavállalók – közötti érdekellentétekre, valamint az információs aszimmetriából fakadó hatékonyságvesztésre (Jensen & Meckling, 1976; Institute of Internal Auditors, 2013).

3.1. Az első védelmi vonal: Ösztönzők inkoherenciája és az Erkölcsi Kockázat (Moral Hazard)

Az adatvagyon keletkezésének és rögzítésének helyén, az első védelmi vonalat jelentő üzleti területeken (Business Operations) dolgozó munkavállalók töltik be az „Ügynök” szerepét. A banki javadalmazási rendszerek és a kulcsfontosságú teljesítménymutatók (KPI-k) azonban tradicionálisan az értékesítési volumenre, a hitelfolyósítás gyorsaságára és a bevételgenerálásra fókuszálnak, miközben az adatminőségi célok marginális súllyal szerepelnek a teljesítményértékelésben.

Ebben a konstellációban a munkavállaló racionális gazdasági döntése az, hogy a munkaidejét a bevételt termelő tevékenységekre optimalizálja. Ez a struktúra klasszikus Erkölcsi Kockázatot (Moral Hazard) teremt az adatrögzítés szintjén: az ügynök abban válik érdekeltté, hogy a hitelezési vagy számlanyitási folyamatokat – akár kötelező mezők fiktív adatokkal történő feltöltésével vagy a minőségügyi lépések megkerülésével – felgyorsítsa. A „Megbízó” (a felsővezetés vagy a Kockázatkezelés) ezzel információs aszimmetriába kerül, mivel a hibák rejtve maradnak a rendszerekben (latent defect). Ezek az adathibák sokszor csak évekkel később, egy portfólió-tisztítás, egy szigorú felügyeleti adatszolgáltatás (pl. HITREG), vagy egy nem teljesítő hitel (NPL) esemény kapcsán manifesztálódnak, amikor a korrekció költsége már exponenciálisan magasabb, az eredeti adatfelelős számonkérése pedig lehetetlen (Luburić, 2017; Redman, 2016).

3.2. A második védelmi vonal: Hatalmi aszimmetria és a „fogatlan oroszlán” szindróma

A második védelmi vonal funkcióit ellátó szereplők (Kockázatkezelés, Compliance, Chief Data Officer, Adatgazdák) feladata az adatkormányzási keretrendszer működtetése és a független monitorozás. A gyakorlatban azonban éles ellentét feszül a formális „Data Governance” (irányítás) és a valós „Data Management” (végrehajtás) között. A második vonal szereplői gyakran válnak „fogatlan oroszlánokká”: bár formálisan ők felelnek az adatminőségért, nem rendelkeznek tényleges költségvetési kontrollal vagy vétőjoggal az IT-fejlesztések felett (Khatri & Brown, 2010).

Szervezetpszichológiai szempontból ezen a ponton egy súlyos Hatalmi Aszimmetria figyelhető meg. A profitorientált banki kultúrában a bevételtermelő egységek (Front Office) lobbijereje jellemzően lényegesen nagyobb, mint a kontroll funkcióké. Konfliktushelyzetben – például amikor egy adatminőségi ellenőrzés lassítaná vagy megállítaná egy új hiteltermék piacra lépését (Time-to-Market) – a rövid távú üzleti érdek rendre felülírja a prudenciális megfontolásokat. Ezt a jelenséget tovább súlyosbítja a CDO pozíció gyakori gyenge szervezeti beágyazottsága (például ha az IT alá rendelve működik), ami lehetetlenné teszi, hogy a funkció stratégiai partnerként és egyenrangú kontrollként lépjen fel az üzleti vezetőkkel szemben (Seiner, 2014; Weber, Otto, & Österle, 2009).

3.3. A harmadik védelmi vonal: Kompetenciahiány és az „Audit Expectation Gap”

A Belső Ellenőrzés (Internal Audit), mint a harmadik védelmi vonal feladata, hogy független bizonyosságot (assurance) nyújtson a kontrollkörnyezet, így az adatelőállítás hatékonyságáról is. A prudenciális adatvagyon ellenőrzése terén azonban drasztikus kompetenciahiány (Skills Gap) és módszertani elmaradás tapasztalható. A hagyományos banki audit módszertanok alapvetően folyamatorientáltak: interjúkra, szabályzatok formai ellenőrzésére és statisztikailag kis elemszámú mintavételre építenek.

Egy több tízmillió rekordot tartalmazó, szerződés szintű granularitást megkövetelő rendszer (például a HITREG vagy az IReF) ellenőrzéséhez azonban a manuális mintavételes eljárás teljesen alkalmatlan. A prudenciális megfelelés validálásához elengedhetetlen lenne az auditorok technológiai transzformációja: az interjúk mellett a Folytonos Auditálás (Continuous Auditing) és az adatbázis-szintű (SQL/Python alapú) elemzések alkalmazása. Ezen képességek hiányában óhatatlanul kialakul a szakirodalomban „Audit Expectation Gap”-nek (audit elvárási rés) nevezett jelenség. Ebben az inkonzisztens állapotban a banki felsővezetés abban a hamis illúzióban hoz döntéseket, hogy a rendszerek biztonságosak és az adatok pontosak – hiszen a folyamataudit „megfelelő” minősítést adott –, holott a felszínes vizsgálat képtelen volt feltárni a mögöttes adatbázisok mélystrukturális hibáit és a manuális árnyékinformatikai beavatkozások (End-User Computing) okozta torzításokat (Marcella & Stucki, 2015; Vasarhelyi et al., 2004).

4. Működési reziliencia (DORA) és az architektúrális stresszteszt

A digitális transzformáció sikerességének és az adatvagyon-gazdálkodási keretrendszerek érettségének végső fokmérője a rendszer ellenállóképessége, azaz rezilienciája. A pénzügyi szektor szabályozási környezete az elmúlt években fundamentális paradigmaváltáson ment keresztül: a pusztán technológiai megfelelés (Compliance) és a tőkeellátottság biztosításának fókuszából a hangsúly a válsághelyzeti működés-fenntartás és a szanalhatóság (Resolvability) felé tolódott el.

4.1. A DORA rendelet és a működési reziliencia (Safety-II) paradigmája

A prudenciális architektúrák szabályozásának legújabb, meghatározó pillére az Európai Unió DORA (Digital Operational Resilience Act) rendelete (Európai Parlament és a Tanács, 2022). Míg a korábbi szabályozások (pl. a BCBS 239 alapelvek) dominánsan az adatok tartalmi pontosságára és aggregálhatóságára fókuszáltak, a DORA a technológiai infrastruktúra mint hordozó közeg ellenálló képességét helyezi a középpontba. A rendelet elméleti alapját a hagyományos, védelem-orientált IT-biztonsági szemlélet („Safety-I” – hibamentességre törekvés) felváltása adja a Hollnagel-féle „Safety-II”, azaz a működési reziliencia (Operational Resilience) koncepciójával. Ez a megközelítés elismeri, hogy a komplex, összekapcsolt rendszerekben a kiberincidensek vagy a hardveres leállások elkerülhetetlenek, ezért a cél a kritikus funkciók és az adatelérés folyamatosságának minden áron történő fenntartása (Hollnagel, 2011).

A banki adatarchitektúrák modernizációja során egyre hangsúlyosabb a felhőszolgáltatások (Cloud Computing) igénybevétele a mesterséges intelligencia (AI) és a Big Data analitika hatalmas számítási igénye miatt. A DORA ezen a téren szigorú szabályokat vezet be a harmadik feles szolgáltatókra (Third-party Risk) vonatkozóan. A szakirodalom rámutat, hogy ez közvetlenül érinti az adatszuverenitás kérdését: a bankoknak (és az adatgazdáknak) garantálniuk kell, hogy a kiszervezett adatok feletti kontroll, a fizikai lokalizáció feletti rendelkezés, valamint a kilépési stratégia (exit strategy) egy esetleges szolgáltatói krízis esetén is fennmaradjon (Al-Ruithe et al., 2019). A rendelet megköveteli a rendszeres és technikailag mély tesztelést (pl. Threat-Led Penetration Testing), amely során a banknak auditálható módon bizonyítania kell, hogy egy esetleges zsarolóvírus-támadás esetén a visszaállítási (Backup & Restore) folyamatok biztosítják az adatok integritását és előírt időablakon belüli rendelkezésre állását (Marcella & Stucki, 2015).

4.2. A BRRD és a „Resolution Weekend” időkritikus döntéshozatala

Az informatikai rendszerek legszigorúbb reziliencia-tesztje – egyfajta „architekturális stresszteszt” – a banki szanalási (Resolution) eljárás adatigénye. A 2008-as válság tapasztalataira reagálva a BRRD (Bank Recovery and Resolution Directive) irányelv szakított az adófizetői pénzből történő kimentés (bail-out) erkölcsi kockázatot (moral hazard) növelő gyakorlatával, és helyette a hitelezői feltőkésítés (bail-in) elvét vezette be (Európai Parlament és a Tanács, 2014; Avgouleas & Goodhart, 2015).

Egy valószínűsíthetően fizetéseképtelenné váló intézmény (Failing or Likely to Fail - FOLTF) szanalása a gyakorlatban extrém időnyomás alatt, jellemzően a péntek esti piacbezárás és a hétfő reggeli nyitás közötti, úgynevezett „Resolution Weekend” (szanalási hétvége) szűk, 48-72 órás időablakában történik. A szanalási hatóságoknak (mint az európai SRB vagy a hazai MNB) ezalatt az idő alatt kell bizonyosságot szerezniük a bank eszközeinek és forrásainak valós értékéről, biztosítva a „No Creditor Worse Off” (NCWO – Egy hitelező sem járhat rosszabbul) elv sérthetlenségét. Az információhiány ebben a szakaszban végzetes: a hibás vagy hiányos adatokon alapuló szanalási döntés peres eljárásokhoz, a befektetői bizalom összeomlásához, és végső soron piaci pánikhoz, azaz pénzügyi fertőzéshez (contagion) vezethet (Binder, 2016; World Bank, 2016).

4.3. A Valuation 2 adatparadoxona és a „Buffers for Uncertainty”

A szanalási tervezés adatvagyon-gazdálkodási szempontból legkritikusabb fázisa a szanalás alatti értékelés (Valuation in Resolution – ViR), ezen belül is az úgynevezett „Valuation 2” eljárás. Ez az értékelés egy sajátos „Adatparadoxont” teremt: a banki alaprendszerek (Core Banking Systems) a normál üzletmenet („going concern”) elvei alapján – például amortizált bekerülési értéken – működnek, miközben a Valuation 2 egy csődhelyzeti („gone concern”), kényszerértékesítési logikát követel meg (EBA, 2019).

A Valuation 2 elvégzéséhez a banknak 24 órán belül kell előállítania a teljes mérlegét lefedő Értékelési Adatkészletet (Valuation Data Set – VDS) tranzakciós szintű, elemi

granularitással (Single Resolution Board, 2024). Ez megköveteli a szerződéses feltételek, a biztosítékok, a beszámítási jogok és a kötelezettségi hierarchia (MREL) azonnali, adatbázis-szintű lekérdezhetőségét (SRB, 2020).

A Galbraith-féle információfeldolgozási elmélet (Information Processing View) alapján krízishelyzetben a bizonytalanság csökkentésének egyetlen módja az információáramlás felgyorsítása (Galbraith, 1974). Ha a bank adatarchitektúrája (a legacy rendszerek rugalmatlansága vagy a manuális Excel-feldolgozások dominanciája miatt) nem képes ezt az időkritikus adatszolgáltatást 24 órán belül teljesíteni, a független értékelő konzervatív becsléseket, úgynevezett „bizonytalansági puffereket” (buffers for uncertainty) kénytelen alkalmazni. Ezek a pufferek mesterségesen rontják az eszközök értékét, ami indokolatlanul magas veszteséget (haircut) okoz a hitelezőknek. A rossz információs rendszer tehát kilép az informatika köréből, és közvetlen vagyoni kárt okozó tényezővé, a szanálhatóság legfőbb akadályává (impediment to resolvability) válik. Azon intézmény, amely informatikailag képes a „Gone Concern” állapot 24 órás adatigényét teljesíteni, definíció szerint rendelkezik a normál üzletmenethez („Going Concern”) és a BCBS 239 megfeleléshez szükséges adatvagyon-gazdálkodási érettséggel is.

Összegzés

A kutatás megállapítja, hogy a bankrendszer digitális transzformációja és a prudenciális adatvagyon stratégiai menedzsmentje nem redukálható pusztán szoftveres vagy infrastrukturális beruházásokra (Laney, 2018). A tanulmány rámutat a hagyományos adatmenedzsment keretrendszerek (például a DAMA-DMBOK) prudenciális vakfoltjaira: ezek az általános modellek episztemológiai értelemben egyenrangúként kezelik a tudásterületeket, és hiányzik belőlük a banki működési engedély (licenc) szempontjából kritikus, kockázatalapú súlyozás.

A kutatás kritikával illeti a felügyeleti gyakorlatban dogmaként kezelt „Három Védelmi Vonal” (3LoD) modellt is. Az adatminőség kontextusában a modell gyakran csődöt mond az első vonal értékesítés-vezérelt ösztönzőrendszereiből fakadó Erkölcsi Kockázat (Moral Hazard) miatt, amely a második védelmi vonalat valós vétójogok nélküli „fogatlan oroszlánná” degradálja.

A feltárt összefüggések rávilágítanak a Conway-törvény és a „decoupling” (szétcsatolás) dialektikájára: a megkövesedett technológiai örökség (Legacy) ma már nem csupán IT-probléma, hanem a ceremonialis megfelelés anyagi bázisa, amellyel a szervezetek legitimálják az End-User Computing (EUC) rejtett kockázatait és a manuális kerülőutakat. Ez a strukturális hiányosság az AI térnyerésével exponenciális veszélyt jelent. Ha az adatrögzítés szintjén jelenlévő Erkölcsi Kockázat miatt a bemeneti adat hibás, a „Garbage In, Garbage Out” (GIGO) mechanizmusán keresztül a legfejlettebb, „Fekete Doboz” AI algoritmusok is torzított tőke- és kockázatszámításokat fognak generálni.

A BCBS 239 elveknek (Basel Committee on Banking Supervision, 2013), a szanálhatósági stresszteszteknek (ViR) és a DORA rendeletnek (Európai Parlament és a Tanács, 2022) való megfelelés egyaránt igazolja, hogy a tartós prudenciális

megfelelés eléréséhez radikális paradigmaváltásra van szükség. Elengedhetetlen az emberi teljesítménymérési ösztönzők újrhangolása a forrásoldali minőség (Quality at Source) javára, a gépi tanulási modellek magyarázhatóvá tétele (XAI) (Bracke et al., 2019; Doshi-Velez & Kim, 2017), valamint az árnyékinformatika felszámolása. A jövőben csak a technológiai interoperabilitást megteremtő, és valós költségvetési, illetve vétőjogokkal felruházott adatkormányzás képes áthidalni a formális szabályozás absztrakciója és az operatív rögzülés közötti szakadékot (Khatri & Brown, 2010).

Hivatkozások

- Admati, A. R., & Hellwig, M. F. (2013). *The bankers' new clothes: What's wrong with banking and what to do about it*. Princeton University Press.
- Al-Ruithe, M., Benkhelilfa, E., & Hameed, K. (2019). A systematic literature review of data governance and cloud data governance. *Personal and Ubiquitous Computing*, 23, 839-859.
- Armbrust, M., Ghodsi, A., Xin, R., & Zaharia, M. (2021). Lakehouse: A new generation of open platforms that unify data warehousing and advanced analytics. *CIDR 2021 Conference Proceedings*.
- Avgouleas, E., & Goodhart, C. (2015). Critical reflections on bank bail-ins. *Journal of Financial Regulation*, 1(1), 3-29.
- AWS. (2025). How cloud-based data mesh technology can enable financial regulatory data collection. *AWS for Industries Blog*.
- Basel Committee on Banking Supervision. (2013). *Principles for effective risk data aggregation and risk reporting (BCBS 239)*. Bank for International Settlements.
- Binder, J. H. (2016). *Bank resolution: The European regime*. Oxford University Press.
- Bracke, P., Datta, A., Jung, C., & Sen, S. (2019). Machine learning explainability in finance: An application to default risk analysis. *Bank of England Staff Working Paper*, No. 816.
- Buneman, P., Khanna, S., & Tan, W. C. (2001). Why and where: A characterization of data provenance. In *International Conference on Database Theory*. Springer.
- Cai, L., & Zhu, Y. (2015). The challenges of data quality and data quality assessment in the big data era. *Data Science Journal*, 14.
- Conway, M. E. (1968). How do committees invent? *Datamation*, 14(4), 28-31.
- Dehghani, Z. (2020). *Data mesh principles and logical architecture*. MartinFowler.com.
- Dehghani, Z. (2022). *Data mesh: Delivering data-driven value at scale*. O'Reilly Media.
- Devlin, B. (2013). *Business unIntelligence: Insight and innovation beyond analytics and big data*. Technics Publications.

- DiMaggio, P. J., & Powell, W. W. (1983). The iron cage revisited: Institutional isomorphism and collective rationality in organizational fields. *American Sociological Review*, 48(2), 147-160.
- Doshi-Velez, F., & Kim, B. (2017). *Towards a rigorous science of interpretable machine learning*. arXiv preprint arXiv:1702.08608.
- EBA. (2019). *Handbook on valuation for purposes of resolution*. European Banking Authority.
- Európai Parlament és a Tanács. (2014). 2014/59/EU irányelve a hitelintézetek és befektetési vállalkozások helyreállítását és szanálását célzó keretrendszer létrehozásáról (BRRD). *Az Európai Unió Hivatalos Lapja*, L 173.
- Európai Parlament és a Tanács. (2022). Az Európai Parlament és a Tanács (EU) 2022/2554 rendelete a pénzügyi ágazat digitális működési rezilienciájáról (DORA). *Az Európai Unió Hivatalos Lapja*, L 333.
- Galbraith, J. R. (1974). Organization design: An information processing view. *Interfaces*, 4(3), 28-36.
- Gunning, D., Stefik, M., Choi, J., Miller, T., Stumpf, S., & Yang, G. Z. (2019). XAI—Explainable artificial intelligence. *Science Robotics*, 4(37), eaay7120.
- Hollnagel, E. (2011). *Resilience engineering in practice: A guidebook*. Ashgate Publishing.
- Inmon, W. H. (2005). *Building the data warehouse* (4th ed.). John Wiley & Sons.
- Institute of Internal Auditors. (2013). *The three lines of defense in effective risk management and control*. IIA Position Paper.
- Jensen, M. C., & Meckling, W. H. (1976). Theory of the firm: Managerial behavior, agency costs and ownership structure. *Journal of Financial Economics*, 3(4), 305-360.
- Khatri, V., & Brown, C. V. (2010). Designing data governance. *Communications of the ACM*, 53(1), 148-152.
- Kimball, R., & Ross, M. (2013). *The data warehouse toolkit: The definitive guide to dimensional modeling* (3rd ed.). John Wiley & Sons.
- King, J. L., Gurbaxani, V., Kraemer, K. L., McFarlan, F. W., Raman, K. S., & Yap, C. S. (1994). Institutional factors in information technology innovation. *Information Systems Research*, 5(2), 139-169.
- Laney, D. B. (2018). *Infonomics: How to monetize, manage, and measure information as an asset for competitive advantage*. Bibliomotion.
- Leonardi, P. M., & Barley, S. R. (2010). What's under construction here? Social action, materiality, and power in constructivist studies of technology and organizing. *The Academy of Management Annals*, 4(1), 1-70.

- Luburić, G. (2017). Quality of data in the context of the three lines of defense model. *Journal of Central Banking Theory and Practice*, 6(1), 37-53.
- Marcella, A. J., & Stucki, C. (2015). *Business continuity, risk and audit: The audit of business continuity management*. CRC Press.
- Meyer, J. W., & Rowan, B. (1977). Institutionalized organizations: Formal structure as myth and ceremony. *American Journal of Sociology*, 83(2), 340-363.
- Orlikowski, W. J., & Scott, S. V. (2008). Sociomateriality: Challenging the separation of technology, work and organization. *The Academy of Management Annals*, 2(1), 433-474.
- Panko, R. R. (2008). What we know about spreadsheet errors. *Journal of Organizational and End User Computing*, 10(2), 15-25.
- Redman, T. C. (2016). Bad data costs the U.S. \$3 trillion per year. *Harvard Business Review*.
- Scandizzo, H. (2011). Validation of operational risk models and the role of key risk indicators. *The Journal of Operational Risk*, 6(2), 23-41.
- Scott, W. R. (2014). *Institutions and organizations: Ideas, interests, and identities* (4th ed.). SAGE Publications.
- Seiner, R. (2014). *Non-invasive data governance: The path of least resistance and greatest success*. Technics Publications.
- Single Resolution Board. (2024). *Expectations for banks*. Single Resolution Board.
- SRB. (2020). *Minimum requirement for own funds and eligible liabilities (MREL) policy under the banking package*. Single Resolution Board.
- Stein, B., & Morrison, A. (2014). The enterprise data lake: Better integration and deeper analytics. *PwC Technology Forecast*, 1, 1-9.
- Teo, H. H., Wei, K. K., & Benbasat, I. (2003). Predicting intention to adopt interorganizational linkages: An institutional perspective. *MIS Quarterly*, 27(1), 19-49.
- Tingling, P., & Parent, M. (2002). Mimetic isomorphism and technology evaluation: Does imitation mean success? *Communications of the ACM*, 45(5), 113-117.
- Vasarhelyi, M. A., Alles, M. G., & Kogan, A. (2004). Principles of analytic monitoring for continuous assurance. *Journal of Emerging Technologies in Accounting*, 1(1), 1-21.
- Weber, K., Otto, B., & Österle, H. (2009). One size does not fit all - A contingency approach to data governance. *Journal of Data and Information Quality*, 1(1), 1-27.
- World Bank. (2016). *Bank resolution and bail-in in the EU: Selected case studies pre and post BRRD*. FinSAC.

MESTERSÉGES INTELLIGENCIA ALKALMAZÁSA A VÁLLALATI ÉRTÉKTEREMTÉST TÁMOGATÓ BESZÁMOLÓELEMZÉSBEN

M. HORVÁTH Gábor

ORCID: 0009-0008-8419-7563

Pécsi Tudományegyetem Közgazdaságtudományi Kar

horvath.gabor@ktk.pte.hu

<https://doi.org/10.15170/XVIIPPN-Tk-KTK-2026-11>

Absztrakt

A tanulmány célja annak vizsgálata, hogy a generatív mesterséges intelligencia milyen módon alkalmazható a vállalati értékteremtést támogató beszámolóelemzésben, különös tekintettel a vezetői döntéstámogatási funkciókra. A kutatás abból indul ki, hogy a számviteli beszámolók nem kizárólag múltorientált pénzügyi információkat tartalmaznak, hanem megfelelő elemzési keretrendszer mellett alkalmasak lehetnek a vállalatok növekedési potenciáljának, működési hatékonyságának, pénzügyi stabilitásának, beruházási aktivitásának és hosszú távú értékteremtési képességének előzetes értelmezésére is. A tanulmány módszertana feltáró, proof-of-concept jellegű empirikus vizsgálatra épül, amelyben öt magyar vállalkozás 2019-2023 közötti beszámolóit, kiegészítő mellékleteit és kapcsolódó dokumentumait kerültek feldolgozásra. Az AI alkalmazása két szakaszban történt: egyrészt az adatelőkészítésben, a beszámolóadatok strukturálásában és mutatószámítások előkészítésében, másrészt standardizált prompt alapján, öt értékelési dimenzió mentén történő vállalati értékelésben. Az eredmények alapján a generatív AI képes lehet nagy mennyiségű beszámolóanyag gyors feldolgozására, az adatok egységes szerkezetbe rendezésére, valamint eltérő vállalati értékteremtési profilok előzetes azonosítására. A vizsgálat ugyanakkor rámutat arra is, hogy az AI-alapú értékelés nem helyettesíti a hagyományos pénzügyi mutatóelemzést, mivel az AI-score-ok részben black-box jellegűek, és csak előre definiált értékelési keret, standardizált promptolás, valamint számviteli szakértői kontroll mellett értelmezhetők megbízhatóan. A tanulmány gyakorlati következtetése, hogy az AI a számviteli és kontrollingfolyamatokban elsősorban adatelőkészítési, előszűrési és értelmezéstámogatási eszközként alkalmazható, miközben a végső szakmai megítélés és az adatminőség biztosítása továbbra is emberi kontrollt igényel.

Kulcsszavak: mesterséges intelligencia, beszámolóelemzés, vállalati értékteremtés, vezetői számvitel, döntéstámogatás

Bevezetés

A vállalati döntéshozatal és értékteremtés folyamatai az elmúlt években jelentős átalakuláson mentek keresztül a digitalizáció, az adatalapú menedzsment és a

mesterséges intelligencia fejlődésének következtében. A vállalatok működése során keletkező pénzügyi és nem pénzügyi információk mennyisége folyamatosan növekszik, miközben a menedzsment részéről egyre erősebb igény jelentkezik a gyorsabb, pontosabb és előretékintőbb döntéstámogatási rendszerek iránt. A számviteli beszámolók szerepe ennek megfelelően fokozatosan átalakul: a hagyományos múltorientált információszolgáltatás mellett egyre nagyobb hangsúly kerül a jövőbeli teljesítmény, a növekedési potenciál és a vállalati értékteremtés támogatására.

A mesterséges intelligencia (Artificial Intelligence – AI) számviteli alkalmazása az elmúlt évek egyik legdinamikusabban fejlődő kutatási területévé vált. Az AI-alapú rendszerek képesek strukturált és strukturálatlan adatok integrált feldolgozására, pénzügyi mintázatok felismerésére, valamint prediktív vállalatelemzési feladatok támogatására. A generatív AI-modellek és a nagy nyelvi modellek (Large Language Models – LLM-ek) megjelenése különösen jelentős előrelépést eredményezett a vállalati beszámolók szöveges elemeinek értelmezésében és automatizált elemzésében (Abbas, 2026).

A szakirodalom alapján az AI nem pusztán automatizációs eszközként jelenik meg a számvitelben, hanem stratégiai döntéstámogató mechanizmusként is. Az AI-rendszerek alkalmasak lehetnek a vállalat jövőbeli pénzáram-termelő képességének, növekedési potenciáljának, működési stabilitásának és hosszú távú értékteremtő képességének értelmezésére. A vezetői számvitel fejlődése következtében a számvitel egyre inkább prediktív és stratégiai irányba mozdul el, amelyben az AI meghatározó szerepet tölthet be (Stratopoulos & Wang, 2025).

A tanulmány célja annak feltárása, hogy a generatív AI milyen módon illeszthető be a vállalati beszámolóelemzés és vezetői döntéstámogatás folyamatába, különös tekintettel az adatelőkészítésre, az értékteremtési profilok azonosítására és a hagyományos pénzügyi mutatóelemzéssel való kiegészítő kapcsolatára. Ennek megfelelően a tanulmány három kutatási kérdésre keresi a választ. Egyrészt vizsgálja, hogy a generatív AI milyen mértékben képes támogatni a számviteli beszámolók adatelőkészítési és rendszerezési folyamatait. Másrészt azt elemzi, hogy standardizált értékelési keret mellett az AI képes-e eltérő vállalati értékteremtési profilok azonosítására. Harmadrészt arra keresi a választ, hogy az AI által generált értékelések milyen viszonyban állnak a hagyományos, transzparensten számítható pénzügyi mutatókkal.

A tanulmány hozzájárulása három területen ragadható meg. Először, a generatív AI alkalmazását nem önálló döntéshozó rendszerként, hanem kontrollált vezetői döntéstámogatási eszközként értelmezi. Másodsor, a beszámolóelemzési folyamatot nem kizárólag az értékelés, hanem az adatelőkészítés, adatellenőrzés és értelmezés egymásra épülő munkafázisaként kezeli. Harmadszor, az AI által generált értékeléseket klasszikus pénzügyi mutatókkal veti össze, ezáltal hangsúlyozva, hogy az AI-score-ok nem helyettesítik, hanem kiegészítik a hagyományos pénzügyi elemzést.

Irodalmi áttekintés

A mesterséges intelligencia szerepe a számvitel és a vezetői számvitel fejlődésében

A számviteli rendszerek digitalizációja alapvetően változtatta meg a pénzügyi információk előállításának és feldolgozásának folyamatát. A hagyományos számviteli rendszerek elsősorban múltbeli tranzakciók rögzítésére és riportálására fókuszáltak, míg a modern AI-alapú rendszerek hatékonyan képesek prediktív elemzések és stratégiai döntéstámogatási funkciók ellátására is. A szakirodalom szerint a mesterséges intelligencia számviteli alkalmazásai elsősorban az automatizált adatfeldolgozás, a pénzügyi és vezetői elemzés, a prediktív vállalatelemzés, valamint a kontroll- és auditfolyamatok támogatása köré szerveződnek.

Fallatah (2021) szerint a gépi tanulási megoldások a számvitel és könyvvizsgálat területén különösen hatékonyan alkalmazhatók az ismétlődő elemzési feladatok automatizálásában, a mintázatfelismerésben és az anomáliák azonosításában, amely jelentősen növelheti a pénzügyi elemzések gyorsaságát és pontosságát.

Abbas (2026) szerint a vezetői számvitel egyik legjelentősebb átalakulási iránya az AI által támogatott döntéstámogatási rendszerek térnyerése. A szerző hangsúlyozza, hogy az AI lehetővé teszi a pénzügyi és működési információk integrált elemzését, ezáltal támogatva a hosszú távú vállalati értékteremtést és stratégiai tervezést. A generatív mesterséges intelligencia megjelenése tovább erősítette ezt a folyamatot, mivel a nagy nyelvi modellek képesek szövegek – például üzleti jelentések, kiegészítő mellékletek vagy menedzsment-kommentárok – értelmezésére és összegzésére, amely új lehetőségeket teremt a vezetői döntéstámogatásban (Jejenywa et al., 2024).

A hazai szakirodalomban szintén megjelent a digitalizáció és az AI hatásának vizsgálata. Szukits és szerzőtársai (2024) rámutatnak arra, hogy a digitális technológiák következtében a kontrolleri és vezetői számviteli szerepkör jelentősen átalakul. A rutinjellegű adatfeldolgozási feladatok automatizálódnak, miközben egyre nagyobb hangsúly kerül az elemzői, stratégiai és döntéstámogató kompetenciákra. Ez a folyamat összhangban áll a nemzetközi szakirodalom megállapításaival, amelyek szerint a jövő számviteli szakembereinek szerepe egyre inkább az adatok értelmezésére, a prediktív elemzések validálására és a stratégiai döntések támogatására épül.

Polyák (2024) hangsúlyozza, hogy a mesterséges intelligencia számviteli alkalmazásai különösen fontos szerepet tölthetnek be az adatelemzés, előrejelzés és pénzügyi értékelés területén. Az AI-alapú rendszerek képesek gyorsabban és nagyobb pontossággal feldolgozni a vállalati beszámolókból szereplő információkat, mint a hagyományos manuális elemzési módszerek. Ez különösen releváns a vállalati értékteremtés szempontjából, mivel a vezetői döntéshozatal egyre inkább előretekintő információkra épül.

Hasan (2022) átfogó szakirodalmi áttekintése szerint a mesterséges intelligencia alkalmazása a számvitelben és könyvvizsgálatban egyre inkább túlmutat az

automatizáción, és stratégiai döntéstámogatási funkciókat is betölt, különösen a pénzügyi előrejelzés, kockázatelemzés és teljesítményértékelés területén.

AI-alapú beszámolóelemzés és vállalati értékteremtés

A vállalati értékteremtés a modern vállalatirányítás egyik központi fogalmává vált. A hagyományos részvényesi értékmaximalizálási megközelítést fokozatosan felváltják azok a szemléletek, amelyek a hosszú távú fenntartható teljesítményt, a növekedési potenciált és a működési stabilitást helyezik előtérbe. Dorgai (2004) szerint a vállalati értékmaximalizálás a modern vállalatirányítás egyik alapvető célrendszere, amely a vállalat jövőbeli pénzáramainak és teljesítményének optimalizálására épül. A szerző hangsúlyozza, hogy a vállalati értékteremtés nem kizárólag rövid távú profitmaximalizálást jelent, hanem hosszú távú stratégiai szemléletet igényel.

Jelen tanulmányban a vállalati értékteremtés fogalma nem szűk értelemben vett vállalatértékelési, diszkontált cash-flow alapú érték meghatározást jelent. A fogalom tágabb vezetői és teljesítménymenedzsment-szempontról kerül alkalmazásra: arra utal, hogy a beszámolók alapján milyen előzetes következtetések vonhatók le a vállalat növekedési képességéről, működési hatékonyságáról, pénzügyi stabilitásáról, beruházási aktivitásáról és hosszabb távú fenntartható teljesítménypotenciáljáról. Ez a megközelítés illeszkedik a vezetői döntéstámogatási logikához, mivel nem a vállalat pontos piaci értékének meghatározását, hanem az értékteremtési karakter előzetes értelmezését célozza.

Az AI-alapú beszámolóelemzés különösen jelentős lehet ezen a területen, mivel a mesterséges intelligencia képes integrálni a pénzügyi mutatókat, cash-flow információkat, beruházási adatokat, működési trendeket és szöveges menedzsmentkommunikációt. Shi (2025) szerint az AI egyik legfontosabb előnye, hogy komplex vállalati mintázatok azonosítására képes, amelyeket a hagyományos pénzügyi elemzési módszerek sok esetben nem tudnak megfelelően kezelni. Az AI-modellek lehetővé teszik a vállalati növekedési potenciál, működési hatékonyság és pénzáram-stabilitás előrejelzését.

Heaton és szerzőtársai (2017) rámutatnak arra, hogy a deep learning alapú pénzügyi modellek képesek összetett, nemlineáris pénzügyi mintázatok felismerésére, amely különösen alkalmassá teszi őket a prediktív vállalatelemzés és jövőbeli teljesítménybecslés támogatására. Huang és szerzőtársai (2020) szerint a mélytanulási modellek a pénzügyi és banki szektorban különösen eredményesen alkalmazhatók előrejelzési és osztályozási feladatokra, mivel képesek nagy mennyiségű strukturált és strukturálatlan adat együttes feldolgozására.

A szakirodalom egyre gyakrabban használja az „AI-derived indicators” vagy „AI-generated managerial assessment variables” fogalmát. Ezek olyan AI által generált összetett indikátorok, amelyek a vállalat jövőbeli teljesítményére, növekedési lehetőségeire és értékteremtő képességére vonatkozó becsléseket tartalmaznak (Stratopoulos & Wang, 2025). Az AI-rendszerek ilyen módon nem csupán numerikus elemzést végeznek, hanem képesek kvalitatív és kvantitatív információk integrált értelmezésére is.

A vállalati értékteremtés szempontjából különösen releváns lehet a növekedési potenciál, a működési hatékonyság, a pénzáram-stabilitás vagy a beruházási aktivitás AI-alapú értékelése. Sági-Duduk és Csugány (2025) szerint a vállalatértékelési modellek fejlődése egyre inkább az összetett teljesítménymérési rendszerek irányába mutat, amelyek nem csupán múltbeli pénzügyi teljesítményt, hanem jövőbeli értékteremtési potenciált is figyelembe vesznek. Ez a szemlélet jól kapcsolható az AI-alapú vállalatelemzési rendszerekhez.

AI és menedzseri döntéstámogatás

A vezetői számvitel egyik legfontosabb funkciója a menedzsment stratégiai döntéseinek támogatása releváns és időben rendelkezésre álló információkkal. Az AI-rendszerek megjelenése jelentősen kibővítette a döntéstámogatás lehetőségeit. A szakirodalom alapján az AI különösen alkalmas jövőbeli pénzáramok előrejelzésére, növekedési lehetőségek azonosítására, működési teljesítmény elemzésére és stratégiai tervezés támogatására. Liaras és szerzőtársai (2024) szakirodalmi áttekintése alapján a gépi tanulási modellek alkalmazása a számviteli és pénzügyi kutatásokban egyre inkább a prediktív vállalatelemzés, teljesítménybecslés és döntéstámogatás irányába mozdul el.

Lehner, Harrer és Stockinger (2022) szerint az AI-alapú döntéstámogatás egyik legfontosabb előnye, hogy képes strukturált és strukturálatlan információk integrált értelmezésére. Az AI-modellek nem kizárólag numerikus mutatókat elemeznek, hanem képesek a vállalati kommunikáció, menedzsment-kommentárok és üzleti jelentések interpretációjára is. A természetesnyelv-feldolgozó technológiák alkalmazása különösen fontos szerepet játszik ebben a folyamatban, mivel lehetővé teszi a menedzsment kommunikációjában megjelenő stratégiai irányok, növekedési orientációk és működési prioritások azonosítását.

A hazai szakirodalom alapján a digitális technológiák fejlődése a kontrollingszisztemek szerepét is átalakítja. Szukits és szerzőtársai (2024) szerint a jövő kontrollerének egyre inkább stratégiai partnerként kell működnie, amelyben az AI-alapú elemző rendszerek meghatározó szerepet kapnak. Ez különösen releváns a vállalati értékteremtés szempontjából, hiszen a menedzsment számára egyre fontosabbá válik a jövőorientált, adatvezérelt döntéstámogatás.

AI-governance és kontrollfolyamatok

A mesterséges intelligencia számviteli és döntéstámogatási alkalmazása ugyanakkor jelentős kontroll- és governance-kockázatokat is felvet. A szakirodalom hangsúlyozza, hogy az AI-rendszerek csak megfelelő kontrollmechanizmusok mellett tekinthetők megbízhatónak. A legfontosabb kockázatok közé tartozik az algoritmikus torzítás, az adatminőségi problémák, a modellkockázat, valamint a transzparenciahiány.

Mökander (2023) szerint az AI-governance új multidiszciplináris kutatási területté vált, amely összekapcsolja a számviteli kontrollokat, az IT-governance rendszereket

és az etikai szabályozási mechanizmusokat. A generatív AI-modellek alkalmazása esetén különösen fontos a standardizált prompting, az egységes értékelési keretrendszerek kialakítása, valamint az emberi kontroll fenntartása.

Lehner et al. (2022) hangsúlyozzák, hogy az AI-rendszerek nem helyettesítik a menedzsment szakmai ítélőképességét, hanem annak támogatására szolgálnak. Az AI által generált értékelések ezért csak megfelelő szakmai kontroll mellett használhatók stratégiai döntéshozatalban. A management accounting jövőjével foglalkozó kutatások szerint a számviteli szakemberek szerepe fokozatosan elmozdul az adat-előállítástól az AI-alapú elemzések interpretálása és kontrollja irányába.

Empirikus kutatás

A tanulmány empirikus része feltáró, demonstrációs jellegű vizsgálatként készült. A kutatás célja nem egy általánosítható prediktív modell felépítése vagy nagy mintás statisztikai validáció elvégzése volt, hanem annak szemléltetése, hogy a generatív mesterséges intelligencia milyen módon alkalmazható a vállalati beszámolók strukturált, vezetői döntéstámogatási célú feldolgozására és értelmezésére. Ennek megfelelően az empirikus vizsgálat proof-of-concept jellegű elemzésként értelmezhető, amely a módszertani lehetőségek bemutatására, nem pedig végleges modellkövetkeztetések levonására irányul.

A módszertani demonstráció egyik kiindulópontja az volt, hogy a generatív AI nem csupán a végső értékelési megállapítások előállítására használható, hanem a beszámolóelemzési folyamat korábbi, időigényesebb szakaszaiban is. A számviteli beszámolók feldolgozása jelentős mennyiségű ismétlődő, részben mechanikus munkát igényel: a mérleg- és eredménykimutatás-adatok kinyerését, többéves idősorok összeállítását, a kiegészítő mellékletek áttekintését, valamint az adatok egységes elemzési szerkezetbe rendezését. Az AI ebben a folyamatban elsősorban adatelőkészítési asszisztensként értelmezhető, amely rövid idő alatt képes nagy mennyiségű dokumentum előzetes feldolgozására, ezáltal csökkentheti az elemzői munka repetitív, alacsony hozzáadott értékű részét. Ez azonban nem jelenti az ellenőrzési felelősség megszűnését, mivel a beszámolóadatok pontossága továbbra is szakértői kontrollt igényel.

A vizsgálat egyik fontos módszertani sajátossága, hogy az AI alkalmazása nem kizárólag a vállalatok múltbeli és várható teljesítményének értékelésére korlátozódott, hanem az adatelőkészítés folyamatában is szerepet kapott. A beszámolók feldolgozása során az AI-t a mérleg, az eredménykimutatás és a kiegészítő melléklet adatainak strukturált táblázatos rendszerezésére is felhasználtam. Ez a lépés azért lényeges, mert a számviteli beszámolók AI-alapú elemzésének gyakorlati alkalmazhatósága nem pusztán azon múlik, hogy a modell képes-e értékelő megállapításokat tenni, hanem azon is, hogy mennyiben tudja támogatni az elemzéshez szükséges adatok kinyerését, egységesítését és előkészítését.

Az adatrendszerelési folyamat tapasztalatai alapján az AI érdemi támogatást nyújthat a beszámolókból történő adatkinyerésben, különösen akkor, ha előzetesen meghatározott sablont, egységes mutatószámstruktúrát és ellenőrzési logikát alkalmaz. A beszámolók Excel-alapú rendszerzése során az AI képes volt a mérleg- és eredménykimutatás-adatok több évre kiterjedő összegyűjtésére, a mutatószámok előkészítésére, valamint az eszköz–forrás egyezőség és az adózott eredmény egyezőségének ellenőrzésére. A folyamat során ugyanakkor több olyan probléma is megjelent, amely rámutat az AI-alapú adatelőkészítés korlátaira. Előfordult, hogy a sablonban korábbi mintaadatok vagy statikus elemek maradtak bent, illetve egyes foglalkoztatotti létszámadatok csak utólagos ellenőrzés és korrekció után kerültek megfelelően rögzítésre. Ez különösen fontos tanulság, mert a beszámolókból kinyert adatok pontossága alapvetően meghatározza a későbbi mutatószámítások és AI-alapú értékelések megbízhatóságát.

A módszertani demonstráció ezért két egymásra épülő szakaszból állt. Az első szakasz az adatelőkészítés volt, amelyben a beszámolók adatai egységes struktúrába kerültek. A második szakaszban az AI a rendszerezett beszámolóinformációk és a kiegészítő mellékletek szöveges tartalma alapján vállalati értékelést készített. Ez a kettős megközelítés jobban közelíti a gyakorlati számviteli és kontrollingmunkát, mivel a vezetői döntéstámogatás nem közvetlenül az értékeléssel kezdődik, hanem az adatok előkészítésével, ellenőrzésével és értelmezhető formába rendezésével.

A vizsgálatba bevont vállalkozások az ANDA Kereskedelmi Kft., a MATRO Kft., a Szamos Marcipán Kft., a 77 Elektronika Műszeripari Kft. és a Zsolnay Porcelánmanufaktúra Zrt. voltak – mindegyik hazai középvállalkozás. A vállalkozások kiválasztásának célja nem reprezentatív minta kialakítása volt, hanem eltérő vállalati értékteremtési karakterek bemutatása. A mintában szerepelt stabil kereskedelmi vállalkozás, ipari növekedési vállalat, érett márkaalapú vállalkozás, technológiai és innovációorientált vállalat, valamint pénzügyileg és működésileg volatilisabb, átalakulási helyzetben lévő vállalat is. Ez a kiválasztási logika lehetővé tette annak vizsgálatát, hogy az AI-alapú beszámolóelemzés képes-e eltérő vállalati élethelyzeteket és értékteremtési mintázatokat elkülöníteni.

Az értékelés standardizált prompt alkalmazásával történt. A modell minden vállalat esetében azonos instrukciót kapott: kizárólag a rendelkezésre bocsátott beszámolókból és kapcsolódó dokumentumokból dolgozhatott, külső piaci vagy céginformációs adatokat nem használhatott. Az értékelés öt előre definiált dimenzió mentén történt: növekedési potenciál, működési hatékonyság, pénzáram-stabilitás, beruházási aktivitás és hosszú távú értékteremtési potenciál. A modellnek minden dimenziót 1–10 skálán kellett értékelnie, és minden pontszámhoz rövid szakmai indoklást kellett kapcsolnia. A prompt kifejezetten kérte, hogy az értékelés során a pénzügyi adatok mellett a kiegészítő mellékletekben és kapcsolódó dokumentumokban szereplő kvalitatív információkat is vegye figyelembe. A standardizált prompt alkalmazása azért volt lényeges, mert csökkentti az értékelési eltérések promptolásból eredő torzulását, és összehasonlíthatóvá teszi az egyes vállalatokra adott AI-válaszokat.

Az AI-alapú pontozás a ChatGPT GPT-5.5 Thinking modell alkalmazásával készült. A modellválasztás módszertani szempontból lényeges tényező, mivel az egyes generatív AI-modellek eltérhetnek a dokumentumfeldolgozási képesség, a pénzügyi-számviteli szövegértelmezés, a következtetési mélység és az értékelési konzisztencia tekintetében. Emiatt az eredmények nem tekinthetők modelltől függetlennek: más AI-rendszer vagy modellverzió alkalmazása eltérő pontszámokat és indoklásokat eredményezhet. A későbbi kutatásokban ezért indokolt lehet több AI-modell összehasonlítása, valamint az értékelések modellfüggőségének vizsgálata.

Az értékelési folyamat tapasztalatai alapján az AI alkalmazásának egyik kulcsfeltétele az értékelési viszonyrendszer előzetes meghatározása. A modell önmagában is képes szöveges összefoglalót készíteni egy beszámolóról, azonban vezetői döntéstámogatási célú értékeléshez szükséges rögzíteni, hogy milyen dimenziók mentén, milyen skálán és milyen értelmezési logika alapján történjen a minősítés. Ebben az értelemben az AI alkalmazása nem klasszikus gépi tanulási értelemben vett modellbetanítást, hanem feladatspecifikus instrukcionálást és értékelési keret kialakítását igényli. A promptban megadott dimenziók, skálák és értelmezési szempontok kvázi „elemzési tanításként” működnek: kijelölik, hogy a modell mit tekintsen releváns információnak, és milyen szempontok alapján rendezze értékelési struktúrába a beszámolók adatait.

Ugyanakkor a több vállalatra egymást követően alkalmazott azonos értékelési keretrendszer további gyakorlati előnyt jelent. Amikor az AI több vállalkozás beszámolóit azonos dimenziók mentén dolgozza fel, az értékelés nem teljesen izoláltan történik, hanem a modell válaszaiban fokozatosan megjelenhet az egymáshoz viszonyított értelmezés is. Ez nem jelent statisztikailag validált tanulást, de a gyakorlati elemzés szintjén hozzájárulhat ahhoz, hogy a modell következetesebben különböztesse meg például a stabil, érett, a beruházásvezérelt növekedési vagy a pénzügyileg volatilisabb vállalati profilokat. Emiatt a módszer különösen alkalmas lehet vállalati portfóliók előzetes szűrésére vagy összehasonlító vezetői elemzések támogatására.

Fontos módszertani korlát, hogy az AI által adott pontszámok nem tekinthetők objektív, validált pénzügyi mutatóknak. Ezek sokkal inkább AI által generált összetett értékelési indikátorokként értelmezhetők, amelyek a pénzügyi adatok, a kiegészítő mellékletben szereplő kvalitatív információk és a beszámolóban megjelenő menedzsmentkommunikáció együttes értelmezésére épülnek. A vizsgálat ezért nem azt állítja, hogy az AI önállóan képes a vállalat jövőbeli teljesítményének megbízható előrejelzésére, hanem mindössze azt vizsgálja, hogy az AI alkalmas lehet-e strukturált, vezetői szempontból értelmezhető előzetes vállalati értékelés készítésére.

Az AI-alapú értékelés egyik további korlátja a modell működésének részben black-box jellege. Bár a generatív AI képes szöveges indoklást adni az egyes pontszámokhoz, ez az indoklás nem azonos a klasszikus pénzügyi mutatók transzparens számítási logikájával. Egy likviditási ráta, saját tőke arány vagy árbevétel-arányos eredménymutató esetében a számítás módja egyértelműen visszakövethető, és a mutató értelmezése közvetlenül kapcsolódik a beszámoló

konkrét számsoraihoz. Ezzel szemben az AI által adott értékelési pontszám több tényező együttes, részben nem teljesen rekonstruálható súlyozásán alapul. Ezért az AI-score-ok nem helyettesíthetik a hagyományos pénzügyi mutatóelemzést, hanem annak kiegészítő, értelmező jellegű eszközöként használhatók.

Az AI-alapú értékelés eredményei

Az AI által adott pontszámok alapján a vizsgált vállalatok között jól elkülöníthető értékteremtési profilok rajzolódtak ki. Az eredmények összesítését az 1. táblázat mutatja be.

1. táblázat: A vizsgált vállalkozások AI-alapú értékelése

Vállalkozás	Növekedési potenciál	Működési hatékonyság	Pénzáram-stabilitás	Beruházási aktivitás	Hosszú távú értékteremtés	Átlag
77 Elektronika Műszeripari Kft.	7	7	9	8	8	7,8
MATRO Kft.	8	7	6	9	8	7,6
Szamos Marcipán Kft.	7	8	8	6	8	7,4
ANDA Kereskedelmi Kft.	7	7	7	7	8	7,2
Zsolnay Porcelán-manufaktúra Zrt.	5	4	4	7	5	5,0

Forrás: saját szerkesztés a beszámolók AI-alapú elemzése alapján

Az AI-alapú értékelések értelmezhetősége érdekében az egyes értékelési dimenziókhöz hagyományos pénzügyi mutatókat is társítottam. Ennek célja nem az AI által adott pontszámok közvetlen igazolása, hanem annak bemutatása, hogy az AI-score-ok milyen transzparensten számítható pénzügyi információk mellett értelmezhetők. Ez különösen fontos, mert míg a klasszikus pénzügyi mutatók számítási módja egyértelműen visszakövethető, addig az AI által adott pontszámok több pénzügyi és szöveges információ együttes, részben black-box jellegű értelmezésén alapulnak. A növekedési potenciálhoz az árbevétel-növekedés, a működési hatékonysághoz az üzemi eredményhányad, a pénzáram- és likviditási stabilitáshoz a folyórata, a beruházási aktivitáshoz a befektetett eszközök változása, míg a hosszú távú értékteremtési potenciálhoz a saját tőke aránya került társításra. E mutatók nem fedik le az AI által értékelt dimenziókat, de alkalmasak arra, hogy a beszámolóelemzés hagyományos, számviteli-logikai kontrollpontjait megjelenítsék.

2. táblázat: A vizsgált vállalkozások klasszikus pénzügyi mutatóinak átlaga

Vállalkozás	Átlagos árbevétel-változás	Átlagos üzemi eredmény-hányad	Átlagos folyórata	Befektetett eszközök változásának átlagos értéke	Átlagos saját tőke-arány
77 Elektronika Műszeripari Kft.	4,3%	11,4%	7,59	-1,3%	83,0%
ANDA Kereskedelmi Kft.	11,9%	10,3%	6,59	21,8%	80,6%
MATRO Kft.	23,1%	6,5%	1,00	25,7%	22,3%
Szamos Marcipán Kft.	8,2%	2,6%	1,81	-4,7%	45,9%
Zsolnay Porcelán-manufaktúra Zrt.	1,0%	4,3%	1,83	22,7%	49,7%

Forrás: saját szerkesztés a beszámolók alapján

Az árbevétel-növekedés és a befektetett eszközök változása esetében az átlag a 2020–2023 közötti éves változások számtani átlaga, mivel 2019-hez nem áll rendelkezésre előző évi bázisadat. Az üzemi eredményhányad, a folyórata és a saját tőke aránya esetében az átlag a 2019–2023 közötti évek értékeinek számtani átlaga.

A hagyományos mutatók alapján látható, hogy az AI által adott értékelések több esetben összhangban állnak a klasszikus pénzügyi elemzés következtetéseivel, ugyanakkor nem vezethetők vissza mechanikusan egyetlen mutatóra. A 77 Elektronika Műszeripari Kft. és az ANDA Kereskedelmi Kft. esetében például a magas saját tőke arány és a kedvező likviditási pozíció alátámasztja a hosszú távú értékteremtési és stabilitási értékelést. A MATRO Kft. esetében az átlagos árbevétel-növekedés és a befektetett eszközök növekedése összhangban áll a növekedési és beruházási profil azonosításával, miközben az alacsonyabb folyórata a pénzügyi stabilitás óvatosabb értékelését indokolja. A Zsolnay esetében a mérsékelt árbevételi dinamika és az alacsonyabb likviditási mutatók összhangban vannak az AI által adott visszafogottabb működési és értékteremtési pontszámokkal.

Mindez azt is szemlélteti, hogy az AI-alapú értékelés a klasszikus mutatóknál szélesebb információs bázisra épülhet. A pénzügyi mutatók önmagukban jól értelmezhetők és ellenőrizhetők, de kevésbé képesek megragadni például a kiegészítő mellékletben megjelenő stratégiai utalásokat, K+F-tevékenységet, beruházási narratívát vagy márkaalapú értékpotenciált. Ezért az AI-score-ok a hagyományos mutatóelemzés kiegészítőiként értelmezhetők: a mutatók biztosítják a transzparens pénzügyi kontrollpontokat, míg az AI az adatok és szöveges információk integrált értelmezésében nyújthat többletet.

Az AI-alapú értékelés eredményei alapján a vizsgált vállalatok eltérő értékteremtési profilokba rendezhetők. A 77 Elektronika Műszeripari Kft. esetében az AI elsősorban a technológiai, K+F-alapú és likviditásában erős működést azonosította, míg a MATRO Kft.-nél a beruházásvezérelt növekedési karakter jelent meg hangsúlyosan. A Szamos Marcipán Kft. és az ANDA Kereskedelmi Kft. esetében az értékelés inkább

stabil, érett, pénzügyileg kiegyensúlyozott vállalati profilt mutatott, eltérő iparági és működési háttér mellett. A Zsolnay Porcelánmanufaktúra Zrt. ezzel szemben alacsonyabb működési és pénzáram-stabilitási pontszámokat kapott, miközben a beruházási aktivitás és a márkaalapú értékpotenciál az AI-értékelésben továbbra is megjelent.

Az eredmények legfontosabb tanulsága nem az egyes vállalatok sorrendje, hanem az, hogy a standardizált prompt alapján a generatív AI képes volt a beszámolók pénzügyi és szöveges információit egységes értékelési keretbe rendezni. Az értékelés így nemcsak pontszámokat eredményezett, hanem a vállalatok eltérő értékteremtési karakterét is azonosíthatóvá tette. Ez arra utal, hogy az AI-alapú beszámolóelemzés vezetői döntéstámogatási környezetben elsősorban előszűrő, strukturáló és értelmezéstámogató eszközként lehet hasznos. Vezetői szempontból a módszer fő értéke nem az, hogy önálló döntési javaslatot ad, hanem hogy rövid idő alatt képes azonosítani azokat a vállalati dimenziókat, amelyek további menedzsmentfigyelmet igényelnek. Ilyen lehet például a növekedési dinamika lassulása, a likviditási tartalékok csökkenése, a beruházási aktivitás és pénztermelés közötti feszültség, vagy a magas immateriális értékpotenciál mellett megjelenő gyenge működési teljesítmény. Az AI-alapú elemzés ezért a döntéshozatal korai szakaszában, előzetes diagnosztikai eszközként lehet különösen hasznos.

Az adatelőkészítési tapasztalatok tanulságai

Az empirikus vizsgálat egyik fontos gyakorlati tanulsága, hogy az AI nemcsak a beszámolók értékelésére, hanem az elemzést megelőző adat-előkészítési folyamat támogatására is alkalmazható. Ez a funkció különösen releváns a számviteli és kontrolling gyakorlatban, ahol az elemzési munka jelentős része nem az értelmezéssel, hanem az adatok összegyűjtésével, tisztításával, egységesítésével és ellenőrzésével telik. A vizsgálat során az AI képes volt beszámolási adatok rendszerezésére, többéves idősorok előállítására és a mutatószámítások alapadatainak előkészítésére.

A vizsgálat gyakorlati tapasztalata szerint az AI egyik legközvetlenebb haszna éppen az adatelőkészítés gyorsításában jelentkezik. Több év beszámolóinak, kiegészítő mellékleteinek és kapcsolódó határozatainak áttekintése hagyományos módon jelentős időráfordítást igényel, különösen akkor, ha az adatok eltérő dokumentumstruktúrában, PDF-formátumban vagy nem egységesen szerkesztett táblázatokban állnak rendelkezésre. Az AI ebben a folyamatban képes lehet az elsődleges adatkinyerés, rendszerezés és előzetes mutatószám-előkészítés felgyorsítására. Ez a számviteli és kontrollinggyakorlatban azért különösen releváns, mert az elemzői munka jelentős része gyakran nem a szakmai értelmezéshez, hanem az adatok manuális előkészítéséhez kapcsolódik.

Az adatelőkészítés automatizálása ugyanakkor nem értelmezhető teljes körű kiváltásként. A tapasztalatok alapján az AI alkalmas lehet az előkészítő munka jelentős részének támogatására, de az elkészült adatstruktúra csak ellenőrzés után használható elemzési alapként. A módszer ezért leginkább úgy értelmezhető, mint amely a szakértői munka fókuszát az adatmásolásról, táblázatrendezésről és

elsődleges rendszerezésről az ellenőrzésre, értelmezésre és következtetés levonására helyezi át.

Ugyanakkor az adatelőkészítési tapasztalatok arra is rámutattak, hogy az AI alkalmazása ezen a területen csak szigorú emberi kontroll mellett tekinthető megbízhatónak. A sablonban bent maradó mintaadatok, a hibás foglalkoztatotti létszámok vagy az eredménykimutatás-sorok korrekciójának szükségessége azt mutatja, hogy az AI által létrehozott adatstruktúra első változata nem feltétlenül alkalmas közvetlen elemzésre. A módszer gyakorlati alkalmazása ezért ellenőrző lépéseket igényel: szükséges az eszköz–forrás egyezőség, az adózott eredmény mérleg és eredménykimutatás közötti egyezősége, valamint az egyes kiemelt inputadatok, például a foglalkoztatotti létszám, a pénzeszközök, a saját tőke vagy a működési eredmény manuális visszaellenőrzése.

Ez a tapasztalat számviteli szempontból különösen lényeges. Az AI gyorsíthatja az adatelőkészítést, de nem mentesíti az elemzőt az ellenőrzési felelősség alól. A beszámolókból származó adatok esetében már egyetlen hibásan átvett létszám-, eredmény- vagy mérlegsor is torzíthatja a mutatószámokat és az ezekre épülő AI-alapú értékelést. Az AI ezért az adatelőkészítésben nem önálló adatminőségi garanciaként, hanem asszisztensként értelmezhető: képes támogatni az adatgyűjtést és a rendszerezést, de az adatok hitelességét számviteli szakértői ellenőrzéssel kell biztosítani. A gyakorlati alkalmazás szempontjából ezért kiemelt jelentőségű az ellenőrzési nyomvonal fenntartása. Az AI által előállított táblázatok és mutatószámok csak akkor használhatók megbízható vezetői döntéstámogatási inputként, ha az adatok forrása, a beszámoló megfelelő sora, az alkalmazott számítási logika és az esetleges manuális korrekció egyaránt visszakövethető. Ez különösen fontos számviteli környezetben, ahol az adatfeldolgozás gyorsítása nem járhat együtt az adatminőség, az ellenőrizhetőség vagy a felelősségi rend gyengülésével.

Az empirikus vizsgálat értelmezése és korlátai

Az empirikus vizsgálat eredményei alapján a generatív AI alkalmas lehet arra, hogy a számviteli beszámolókból vezetői döntéstámogatásra használható, strukturált vállalati értékelést állítson elő. A módszer előnye, hogy nem csupán pénzügyi mutatók mechanikus elemzésére épül, hanem figyelembe veszi a beszámolók szöveges részeit, a kiegészítő mellékletekben megjelenő magyarázatokat, valamint a vállalat működésére és jövőbeli kilátásaira vonatkozó kvalitatív információkat is. Ezáltal az AI-alapú beszámolóelemzés kiegészítheti a hagyományos pénzügyi elemzést, különösen olyan helyzetekben, amikor a cél a vállalati értékteremtési potenciál előzetes értelmezése.

A vizsgálat ugyanakkor több korláttal rendelkezik. Egyrészt a minta elemszáma alacsony, ezért az eredmények nem általánosíthatók a magyar vállalkozások teljes körére. Másrészt az AI által adott pontszámok nem tekinthetők validált pénzügyi előrejelzéseknek, hanem értelmező jellegű, beszámolóalapú értékelések. A jelen kutatásban ezért az AI-score-ok nem prediktív teljesítménymutatóként, hanem feltáró jellegű, döntéstámogatási indikátorként értelmezhetők. A pontszámok célja nem a későbbi vállalati teljesítmény előrejelzése, hanem annak bemutatása, hogy az

AI képes-e a rendelkezésre álló beszámolóinformációkat egységes, összehasonlítható értékelési struktúrába rendezni. A prediktív érvényesség vizsgálata nagyobb mintát, többéves utókövetést és statisztikai validációt igényelne. Harmadrészt az AI-modellek működése részben black-box jellegű, ezért az értékelések megbízhatósága csak standardizált promptolással, szakértői kontrollal és további validációval növelhető.

A black-box jelleg még akkor is fennáll, ha az AI szöveges indoklást ad az értékeléshez. A szöveges magyarázat növeli az értelmezhetőséget, de nem teszi teljesen transzparenssé a modell belső súlyozási és döntési mechanizmusát. Ez különbséget jelent a hagyományos pénzügyi mutatókhoz képest. A pénzügyi mutatók önmagukban gyakran szűkebb információtartalmúak, de számítási módjuk és értelmezésük világosan rekonstruálható. Az AI-score ezzel szemben komplexebb, több információforrást integrálhat, de kevésbé átlátható. Emiatt az AI-alapú értékelést célszerű a hagyományos mutatóelemzés mellett, nem pedig annak helyettesítéseként alkalmazni.

A módszer jövőbeli továbbfejlesztése több irányban is lehetséges. Nagyobb vállalati mintán vizsgálható lenne, hogy az AI által generált növekedési, likviditási vagy értékteremtési score-ok milyen kapcsolatban állnak a későbbi tényleges pénzügyi teljesítménnyel. Emellett több AI-modell összehasonlításával mérhető lenne az értékelések stabilitása és modellfüggősége. További kutatási irányt jelenthet a humán szakértői értékelések és az AI által adott pontszámok összevetése, valamint az adatelőkészítés pontosságának szisztematikus vizsgálata. Ez utóbbi különösen fontos, mert a jelen pilot alapján az AI egyik leggyakorlatiasabb hasznosulási területe nem feltétlenül a végső döntési javaslat megfogalmazása, hanem az elemzést megelőző adat-előkészítési munka gyorsítása lehet.

Összességében az empirikus vizsgálat azt mutatja, hogy az AI-alapú beszámolóelemzés a vállalati értékteremtést támogató vezetői döntéstámogatás ígéretes, de kontrollált alkalmazást igénylő eszköze lehet. A módszer különösen alkalmas arra, hogy a beszámolókból szereplő pénzügyi és kvalitatív információkat egységes értékelési keretbe rendezze, valamint előzetes képet adjon a vállalat növekedési, pénztermelési, beruházási és hosszú távú értékteremtési karakteréről. A gyakorlati alkalmazás szempontjából ugyanakkor legalább ilyen fontos, hogy az AI az adat-előkészítési folyamatban is hasznosítható, de csak akkor, ha az eredményeket számviteli szakértő ellenőrzi, és a modell által előállított strukturált adatok nem kerülnek automatikusan elfogadásra.

A kutatás egyik lényeges következtetése, hogy az AI-alapú beszámolóelemzés gyakorlati haszna nem kizárólag a vállalatok értékelésében, hanem az értékelést megelőző adat-előkészítési folyamat támogatásában is megjelenik. A generatív AI rövid idő alatt képes nagy mennyiségű beszámolóanyag áttekintésére, rendszerezésére és előzetes elemzési struktúrába rendezésére, ami jelentősen csökkentheti a manuális adatelőkészítési terhet. Ugyanakkor az AI alkalmazása csak előre definiált értékelési keret, standardizált promptolás és számviteli szakértői kontroll mellett tekinthető megbízhatónak. A módszer ezért nem a hagyományos pénzügyi mutatóelemzés helyettesítőjeként, hanem annak kiegészítőjeként

értelmezhető: gyorsítja az adatfeldolgozást, támogatja a vállalati profilok azonosítását, de az értékelések végső szakmai megítélése továbbra is emberi kontrollt igényel.

A tanulmány hozzájárulása nem egy új prediktív pénzügyi modell validálása, hanem annak bemutatása, hogy a generatív AI miként alkalmazható kontrollált, standardizált keretben a beszámolóadatok előkészítésére és vezetői döntéstámogatási célú értelmezésére.

Összegzés

A tanulmány a mesterséges intelligencia vállalati értékteremtést támogató beszámolóelemzésben betöltött szerepét vizsgálta. A szakirodalmi áttekintés alapján megállapítható, hogy az AI-alapú rendszerek a számvitelben és a vezetői számvitelben nem csupán automatizációs eszközként jelennek meg, hanem egyre inkább stratégiai döntéstámogató funkciót is betöltenek. A generatív AI és a nagy nyelvi modellek különösen azért jelentenek új lehetőséget, mert a strukturált pénzügyi adatok mellett képesek a beszámolók szöveges elemeinek, kiegészítő mellékleteinek és menedzsmentkommunikációjának értelmezésére is. Ezáltal a beszámolóelemzés potenciálisan túlléphet a hagyományos, múltorientált mutatóelemzésen, és támogathatja a vállalatok jövőbeli értékteremtési képességének előzetes értékelését.

Az empirikus vizsgálat feltáró, proof-of-concept jelleggel öt magyar vállalkozás beszámolóanyagára épült. A kutatás egyik fontos eredménye, hogy az AI nemcsak a vállalatok értékelésében, hanem az azt megelőző adatelőkészítési folyamatban is hasznosítható. A beszámolók adatainak rendszerezése, többéves idősorok előállítás, valamint a mutatószámítások alapadatainak előkészítése olyan feladatok, amelyek a számviteli és kontrollgyakorlatban jelentős időráfordítást igényelnek. A vizsgálat alapján az AI képes lehet e repetitív, alacsonyabb hozzáadott értékű munkafázisok gyorsítására, ezáltal az elemzői figyelmet az ellenőrzésre, értelmezésre és következtetéslevonásra irányíthatja át.

A vállalati értékelés során az AI öt dimenzió mentén adott pontszámokat: növekedési potenciál, működési hatékonyság, pénzáram- és likviditási stabilitás, beruházási aktivitás, valamint hosszú távú értékteremtési potenciál. Az eredmények alapján az AI képes volt eltérő vállalati profilok azonosítására, így például technológiai és K+F-alapú, beruházásvezérelt növekedési, stabil érett, illetve pénzügyileg volatilisabb vállalati karakterek elkülönítésére. A klasszikus pénzügyi mutatókkal való összevetés ugyanakkor azt is megmutatta, hogy az AI-score-ok nem vezethetők vissza mechanikusan egyetlen pénzügyi mutatóra. Ez egyszerre jelent előnyt és korlátot: az AI szélesebb információs bázist képes integrálni, ugyanakkor értékelése kevésbé transzparens, mint a hagyományos pénzügyi mutatók számítási logikája.

A kutatás egyik lényeges módszertani tanulsága, hogy az AI-alapú értékelés nem működik megbízhatóan előzetesen definiált viszonyrendszer nélkül. A modell képes ugyan beszámolókat összefoglalni, de vezetői döntéstámogatási célú értékeléshez rögzíteni kell az értékelési dimenziókat, a skálát, az értelmezési logikát és a kontrollpontokat. Ez a feladatspecifikus instrukcionálás kvázi elemzési keretként

működik, amely meghatározza, hogy a modell milyen információkat tekintsen relevánsnak. Több vállalat azonos szempontok szerinti értékelése esetén az AI alkalmas lehet összehasonlító profilalkotásra is, azonban ez nem tekinthető statisztikai értelemben vett modellvalidációnak.

A vizsgálat korlátai közé tartozik az alacsony elemszám, a minta nem reprezentatív jellege, valamint az AI-modellek részben black-box működése. Bár a generatív AI képes szöveges indoklást adni az értékeléshez, ez nem teszi teljesen átláthatóvá a belső súlyozási és döntési mechanizmust. Emiatt az AI-alapú értékelések nem helyettesíthetik a klasszikus pénzügyi mutatóelemzést, hanem annak kiegészítőiként értelmezhetők. A hagyományos pénzügyi mutatók transzparens kontrollpontokat biztosítanak, míg az AI az adatok és szöveges információk integrált értelmezésében nyújthat többletet.

Gyakorlati szempontból a tanulmány arra mutat rá, hogy az AI a számviteli és kontrollingfolyamatokban elsősorban adatelőkészítési, előszűrési és értelmezéstámogató eszközként alkalmazható. A vállalkozások és a számviteli szakemberek számára ez azt jelenti, hogy az AI használata akkor lehet értékteremtő, ha nem önálló döntéshozóként, hanem kontrollált elemzési asszisztensként épül be a munkafolyamatokba. Gazdaságpolitikai és szakmai szabályozási szempontból mindez az AI-literacy, az adatminőség, a standardizált módszertanok és az emberi felülvizsgálat jelentőségére hívja fel a figyelmet. A jövőbeni kutatások nagyobb mintán, több AI-modell összehasonlításával és humán szakértői értékelésekkel való összevetéssel vizsgálhatják tovább az AI-alapú beszámolóelemzés megbízhatóságát, stabilitását és döntéstámogató értékét. A tanulmány fő üzenete ezért az, hogy az AI-alapú beszámolóelemzés nem a számviteli szakmai ítélet kiváltásának, hanem annak kiterjesztésének eszköze lehet. A módszer akkor teremthet valódi hozzáadott értéket, ha a gyors adatfeldolgozási és mintázatfelismerési képesség kontrollált számviteli módszertannal, transzparens pénzügyi mutatókkal és szakértői felülvizsgálattal kapcsolódik össze.

Köszönetnyilvánítás

A tanulmány a TKP2021-NKTA-19 számú projekt keretében az Innovációs és Technológiai Minisztérium Nemzeti Kutatási Fejlesztési és Innovációs Alapból nyújtott támogatásával, a TKP2021-NKTA pályázati program finanszírozásában valósult meg.

Hivatkozások

- Abbas, K. (2026). Management accounting and artificial intelligence: A comprehensive literature review and recommendations for future research. *The British Accounting Review*, 57(2), 101551. <https://doi.org/10.1016/j.bar.2025.101551>
- Dorgai, I. (2004). A részvényesi értékmaximalizálás elméleti háttere. *Vezetéstudomány*, 35(3), 2–18. https://unipub.lib.uni-corvinus.hu/4500/1/VT_2004n3p2.pdf

- Fallatah, R. (2021). Machine learning in accounting and assurance. *Academy of Accounting and Financial Studies Journal*, 25(6), 1–14. <https://www.abacademies.org/articles/Literature-review-Machine-Learning-accounting-and-Assurance-1528-2635-25-6-908.pdf>
- Hasan, A. R. (2022). Artificial intelligence in accounting and auditing: A literature review. *Open Journal of Business and Management*, 10, 440–465. <https://doi.org/10.4236/ojbm.2022.101026>
- Heaton, J. B., Polson, N. G., & Witte, J. H. (2017). Deep learning in finance: Deep portfolios. *Applied Stochastic Models in Business and Industry*, 33(1), 3–12. <https://doi.org/10.1002/asmb.2209>
- Huang, J., Chai, J. & Cho, S. (2020). Deep learning in finance and banking: A literature review and classification. *Frontiers of Business Research in China*, 14, 2–24. <https://doi.org/10.1186/s11782-020-00082-6>
- Jejenywa, T. O., Mhlongo, N. Z., & Jejenywa, T. O. (2024). A comprehensive review of the impact of artificial intelligence on modern accounting practices and financial reporting. *Computer Science and IT Research Journal*, 5(4), 1031–1047. <https://doi.org/10.51594/csitrj.v5i4.1086>
- Lehner, O. M., Ittonen, K., Silvola, H., Ström, E., & Wührleitner, A. (2022). Artificial intelligence based decision-making in accounting and auditing: Ethical challenges and normative thinking. *Accounting, Auditing & Accountability Journal*, 35(9), 109–135. <https://doi.org/10.1108/AAAJ-09-2020-4934>
- Liaras, E., Nerantzidis, M., & Alexandridis, A. (2024). Machine learning in accounting and finance research: a literature review. *Review of Quantitative Finance and Accounting*, 63(4), 1431–1471. <https://doi.org/10.1007/s11156-024-01306-z>
- Mökander, J. (2023). Auditing of AI: Legal, ethical and technical approaches. *Digital Society*, 2(49). <https://doi.org/10.1007/s44206-023-00074-y>
- Polyák, I. (2024). A mesterséges intelligencia alkalmazási területei a számvitelben. *Magyar Tudomány*, 185 (7), 906-919. <https://doi.org/10.1556/2065.185.2024.7.8>
- Sápi-Duduk, I., & Csugány, J. (2025). A magyar tulajdonú cégek vállalati értékfejlődése – A vállalatértékelési teljesítményindex elméleti és módszertani alapjai. *Controller Info*, 13(3), 24-29. <https://doi.org/10.24387/CI.2025.3.5>
- Shi, M. (2025). A literature review on the application of artificial intelligence in financial statement analysis. *Accounting, Marketing and Organization*, 1(1), 1000062. <https://doi.org/10.71204/dd26he23>

- Stratopoulos, T. C., & Wang, V. X. (2025). Artificial intelligence and accounting research: a framework and agenda. *International Journal of Accounting Information Systems*, 56, 100760. <https://doi.org/10.1016/j.accinf.2025.100760>
- Szukits, Á., Sztrida, L., & Szabó, I. A. (2024). Információs folyamatok digitalizációjának hatása a kontrolleri szakmára – szisztematikus irodalomáttekintés. *Vezetéstudomány*, 55(6), 26–40. <https://doi.org/10.14267/VEZTUD.2024.06.03>

FENNTARTHATÓSÁG ÉS PÉNZÜGYI STABILITÁS: ÖSSZEHANGOLT VÁLLALATI STRATÉGIA VAGY KÜLÖN UTAK?

M. HORVÁTH Gábor

ORCID: 0009-0008-8419-7563

Pécsi Tudományegyetem Közgazdaságtudományi Kar

horvath.gabor@ktk.pte.hu

<https://doi.org/10.15170/XVIIPPN-Tk-KTK-2026-12>

Absztrakt

A tanulmány azt vizsgálja, hogy az eredményminőség és a fenntarthatósági teljesítmény kapcsolata szolgálhat-e a hatékony vezetés empirikus indikátoraként. Miközben a korábbi kutatások döntően az ESG-teljesítmény szintjére koncentráltak, továbbra is korlátozottan ismert, hogy a fenntarthatósági teljesítmények miként hatnak a vállalatok alapvető pénzügyi eredményességére és miként épülnek be a stratégiába. A vizsgálat 1 857 tőzsdén jegyzett vállalat 2011 és 2019 közötti mintáján méri az eredményminőséget az eredményperzisztencia alapján, míg a fenntarthatósági teljesítményt az ESG-perzisztencia és a hosszú távú ESG-fejlődés segítségével ragadja meg. A növekedést, a jövedelmezőségi dinamikát és az iparági hatásokat kontrollváltozóként megragadó többváltozós OLS-modell azt elemzi, hogy e dimenziók mutatnak-e összhangot. Az eredmények szerint nincs statisztikailag szignifikáns kapcsolat az eredményperzisztencia, valamint az ESG-perzisztencia vagy az ESG-fejlődés között. Az eredményminőséget elsősorban alapvető gazdasági tényezők, különösen a vállalat növekedése és a jövedelmezőség volatilitása magyarázzák. A megállapítások a stratégiai leválasztási elméletet („strategic decoupling theory”) támasztják alá, jelezve, hogy a fenntarthatósági programok gyakran önálló területként működnek és nem mélyen integráltak a vállalati stratégiába. A tanulmány dinamikus nézőpontot kínál az ESG-integráció értékeléséhez, és hangsúlyozza a hosszú távú illeszkedés vizsgálatának jelentőségét a vállalati reziliencia megítélésében.

Kulcsszavak: eredményminőség, eredményperzisztencia, ESG, ESG-perzisztencia, vezetői szándékosság, stratégiai szinkronizáció, stratégiai leválasztás

Bevezetés

A modern vállalatértékelésben a környezeti, társadalmi és irányítási (ESG) szempontok integrációja túllépett az etikai megfontolásokon, és a hosszú távú kockázatkezelés meghatározó elemévé vált. A tanulmány kiindulópontja, hogy a fenntarthatósági teljesítmény és a pénzügyi eredmények tartóssága közötti kapcsolat a vezetői szándék és a stratégiai összhangoltság lehetséges

indikátoraként értelmezhető. A vizsgálat a valódi stratégiai integráció és a „stratégiai leválasztás” közötti feszültséget elemzi, vagyis azt, hogy a fenntarthatósági eredmények tudatosan kapcsolódnak-e a pénzügyi stabilitáshoz, vagy inkább külső elvárásokra adott reaktív válaszként jelennek meg.

A téma elemzése különösen releváns a fenntarthatósági minősítések körüli bizonytalanság és a „greenwashing” széles körben azonosított kockázata miatt. A korábbi szakirodalom részletesen vizsgálta az ESG-szintek és a jövedelmezőség kapcsolatát, azonban az eredmények nem egységesek: az etikai hipotézis támogatói pozitív összefüggést feltételeznek a fenntarthatóság és az eredményminőség között, míg az opportunisták vagy leválasztási megközelítés szerint az ESG-kommunikáció akár a gyenge pénzügyi fundamentumok elfedésére is szolgálhat.

A tanulmány ehhez a vitához azzal járul hozzá, hogy többváltozós regressziós keretben, 1 857 vállalat adatain keresztül vizsgálja a statikus mutatókat és az időbeli stabilitást, különös tekintettel az eredményperzisztencia és az ESG-perzisztencia kapcsolatára. Az eredmények a stratégiai leválasztással konzisztens bizonyítékokat szolgáltatnak: a pénzügyi stabilitást elsősorban a mögöttes gazdasági fundamentumok magyarázzák, míg a fenntarthatósági programok gyakran az érintetti nyomásra adott reaktív válaszként, nem pedig proaktívan összehangolt stratégiaként működnek. A vizsgálat ezzel a vállalati gyakorlatok egyik fontos hiányosságára mutat rá, és kiemeli, hogy a pénzügyi és nem pénzügyi dimenziók mélyebb, tudatos összehangolása jelentős lehetőséget kínálhat a vállalati értékteremtés és a hosszú távú reziliencia erősítésére.

Irodalmi áttekintés

A vállalati eredményminőség értékelése évtizedek óta a számviteli kutatások központi témája. A szakirodalomban általánosan tekinthető az a megközelítés, hogy az eredményminőség nem egyetlen mutatóval írható le, hanem indikátorok összességéként értelmezhető. Ebben az összefüggésben a konzervatív számviteli gyakorlatok különösen fontosak: Velte (2017) szerint az etikus és megfelelően irányított szervezetek inkább konzervatívabb és transzparensabb beszámolási gyakorlatokat alkalmaznak, ami csökkenti a diszkrecionális beavatkozások lehetőségét, és növeli a jelentések megbízhatóságát. Az ilyen gyakorlatok biztosítják, hogy a közzétett adatok a vállalat tényleges gazdasági teljesítményét, ne pedig vezetői manipulációt tükrözzenek.

Az eredményperzisztencia az eredményminőség egyik legfontosabb és leginkább értelmezhető indikátora. Befektetői szempontból a stabil és előrejelezhető eredménytermelő képesség kiemelt jelentőségű, mivel a vállalatértékelési modellek alapvetően a jövőbeni pénzáramlások becslésére épülnek. A diszkontált cash flow (DCF) megközelítés relevanciáját vizsgáló kutatások rámutatnak arra, hogy a befektetők döntéseiben meghatározó szerepet játszik a jövőbeni teljesítmény megbízható előrejelezhetősége (Ulbert et al., 2017).

Barth et al. (2023) szerint a perzisztencia azt mutatja meg, hogy a jelenlegi eredmény milyen mértékben tartós, illetve mennyiben képes előre jelezni a jövőbeli

teljesítményt. A magas perzisztencia mérsékli a befektetői bizonytalanságot, mivel kevesebb átmeneti vagy zajos elemet tartalmaz (Hou et al., 2012). A perzisztencia hiánya gyakran eredménymenedzsmentre utalhat; Dechow et al. (2010) rámutatnak, hogy a menedzserek diszkrecionális elhatárolásokat alkalmazhatnak a nyereség stabilizálása vagy meghatározott célok elérése érdekében, ami rontja a pénzügyi kimutatások információtartalmát. Eliwa et al. (2021) empirikus kutatása szerint a transzparens és következetes jövedelmezőséget mutató vállalatok lényegesen alacsonyabb finanszírozási költségekkel szembesülnek, mivel a piac a kiszámíthatóságot minőségi prémiummal jutalmazza.

A reálopciók megközelítés szerint a bizonytalan környezetben végrehajtott beruházások és stratégiai kezdeményezések értéke nem kizárólag a jelenlegi pénzügyi teljesítmény alapján ítélt meg, hanem a jövőbeni alkalmazkodási lehetőségek figyelembevételével is (Csapi, 2019). A fenntarthatósági teljesítmény jelentősége a vállalatértékelésben gyorsan növekedett, mivel azt egyre inkább a hosszú távú kockázatok és a jövőbeli reziliencia mérőszámaként kezelik. A hosszú távú vállalatértékelési megközelítések fejlődését jól mutatja, hogy a pénzügyi szakirodalomban egyre nagyobb szerepet kapnak azok a modellek, amelyek a stratégiai rugalmasságot és a jövőbeni döntési lehetőségek értékét is figyelembe veszik. Serafeim (2020) hangsúlyozza, hogy a piac különbséget tesz a „szimbolikus” és a „tényleges” elköteleződés között, utóbbit pedig a pénzügyi célokkal való összhang jellemzi. A következetes fenntarthatósági fejlődés nem pusztán jelentéstételi követelmény: a belső vállalati folyamatok érettségét is tükrözi (Christensen et al., 2021), és egyfajta hosszú távú biztosításként szolgálhat, amely piaci zavarok idején erősíti a működési stabilitást (Attig et al., 2016; Liang & Renneboog, 2017).

A fenntarthatóságot jellemzően ESG-minősítésekkel mérik, ugyanakkor e mutatók megbízhatóságával kapcsolatban továbbra is jelentős viták vannak. Berg et al. (2022) az „aggregate confusion” jelenségével írják le, hogy a különböző minősítő szervezetek eltérő módszertani megközelítéseik miatt jelentősen különböző értékeléseket adhatnak ugyanazon vállalatokról. E bizonytalanság miatt a kutatási fókusz a statikus pontszámokról egyre inkább az ESG-perzisztencia irányába tolódott. Zheng et al. (2022) szerint a fenntarthatósági mérőszámok időbeli következetessége több információt hordoz a vállalat stratégiai irányultságáról, mint egy egyszeri értékelés. Az ESG-pontszámok gyakori és indokolatlan változásai greenwashingra vagy stratégiai fókuszhiányra utalhatnak (Dorfleitner et al., 2020).

Az ESG-teljesítmény és az eredményminőség kapcsolata fontos tudományos vita tárgya. Az etikai hipotézis szerint a magas ESG-teljesítményű vállalatok megbízhatóbb pénzügyi beszámolókat készítenek, és nagyobb eredményperzisztenciát mutatnak (Velte, 2017; Jordaan et al., 2018; Kim et al., 2012). Rezaee és Tuo (2019) szerint a fenntarthatósági közzétételek és a pénzügyi transzparencia egymást erősítő folyamatok. Ezzel szemben a leválasztási elmélet alapján a vezetés az ESG-eredményeket „pajzsként” használhatja: amikor a pénzügyi teljesítmény nem fenntartható, az intenzív ESG-kommunikáció elterelheti a befektetői figyelmet (Tashman et al., 2019; Torelli et al., 2020). A stratégiai leválasztás akkor

valósul meg, amikor a vállalati diskurzus eltér a tényleges teljesítménytől (Hawn & Ioannou, 2016).

E dimenziók összekapcsolása szorosan kapcsolódik a vezetői szándékhoz. Schiehl és Kolahgar (2021) szerint a pénzügyi és nem pénzügyi mutatók integrációja fejlett vezetői képességeket igényel, míg Henri és Journeault (2010) kiemelik, hogy az összehangolt menedzsment akkor válik láthatóvá, ha a jövedelmezőségi és fenntarthatósági KPI-ok nyíltan kapcsolódnak egymáshoz. Az intézményi befektetói elvárások szintén befolyásolják e trendeket: Dyck et al. (2019) és Grewal et al. (2019) szerint a piac bünteti azokat a vállalatokat, amelyek ESG-ígéretei nem rendelkeznek szilárd pénzügyi alapokkal. Végső soron az ESG-perzisztencia stabilabb cash flow-khoz vezethet (Albuquerque et al., 2019), azonban valódi piaci értéknövekedést csak a lényeges ESG-jellemzők következetes javítása eredményez (Khan et al., 2016). A perzisztenciamintázatok közötti eltérés a vezetői kompetenciába vetett bizalmat is gyengítheti (Billio et al., 2021).

Hipotézisek

Az ESG-teljesítmény és az eredményminőség kapcsolata az etikai hipotézis és az opportunist, leválasztási elmélet közötti tudományos vita középpontjában áll. Etikai nézőpontból feltételezhető, hogy a fenntarthatóság iránt erősen elkötelezett vállalatok konzervatívabb és transzparensabb számviteli eljárásokat alkalmaznak, mivel értékrendjük a rövid távú vezetői manipuláció helyett a hosszú távú stabilitást helyezi előtérbe.

H₁: Az ESG-teljesítmény szintje pozitív kapcsolatban áll az eredményperzisztencia mértékével.

E feltevés alapján a magas fenntarthatósági teljesítmény őszinte transzparencia iránti elköteleződést jelez, amely mérsékli a diszkracionális eredménymenedzsmentet, és tartósabb jövedelmezőséget eredményez. Amennyiben azonban az opportunist megközelítés érvényesül, a magas ESG-pontszámok akár „pajzsként” is működhetnek a gyenge pénzügyi fundamentumok elfedésére, ami a két dimenzió közötti gyenge kapcsolatban jelenne meg.

A tanulmány azt is vizsgálja, hogy a fenntarthatósági és pénzügyi teljesítmény időbeli stabilitása szándékolt stratégiai tervezésből, vagyis stratégiai szinkronizációból fakad-e.

H₂: Az ESG-teljesítmény időbeli stabilitása, azaz az ESG-perzisztencia pozitív kapcsolatban áll az eredményperzisztenciával.

Ha a menedzsment sikeresen integrálja a fenntarthatósági célokat az operatív és pénzügyi döntéshozatalba, akkor mindkét területen összehangolt stabilitás várható. A perzisztenciamintázatok eltérése – például amikor az egyik dimenzió stabil, míg a másik volatilis – empirikus bizonyítékot szolgáltat a stratégiai leválasztásra, jelezve, hogy a fenntarthatósági eredmények nem épülnek be a vállalat alapvető pénzügyi realitásába.

Módszertan

A tanulmány a 2011 és 2019 közötti paneladatbázist vizsgálja annak érdekében, hogy elkerülje a 2008 utáni konszolidáció, valamint a 2020-as pandémia okozta strukturális töréseket (Barth et al., 2023; Ding et al., 2021). E „stabilitási ablak” elemzése lehetővé teszi a vezetői szándék és az ESG-fenntarthatóság közötti tartós stratégiai kapcsolat átfogó vizsgálatát. Az adatok az LSEG (Refinitiv Eikon) adatbázisból származnak. A kiinduló minta 8 918, 2019-ben ESG-minősítéssel rendelkező tőzsdén jegyzett vállalatot tartalmazott; a pénzügyi szektor a sajátos számviteli szabályozás miatt kizárásra került.

Az eredményminőség és a fenntarthatósági stabilitás mérésére az időbeli perzisztenciát használja a vizsgálat, elsőrendű autoregresszív AR(1) modellek alapján. Minden vállalatra külön perzisztencia-együtthatók (β_{earn} , β_{ESG}) kerültek becslésre, Newey-West standard hibákkal korrigálva az autokorrelációt és a heteroszkedaszticitást.

Az eredményperzisztencia (β_{earn}) a tárgyévi, skálázott eredmény késleltetett skálázott eredményre történő regressziójával számítható:

$$\frac{NI_{i,t}}{TA_{i,t-1}} = \alpha + \beta_{earn} * \frac{NI_{i,t-1}}{TA_{i,t-2}} + \varepsilon_{t,i} \quad (1)$$

ahol $\frac{NI_{i,t}}{TA_{i,t-1}}$ az i vállalat t időszaki, késleltetett összes eszközzel skálázott eredményét jelöli; $\frac{NI_{i,t-1}}{TA_{i,t-2}}$ a késleltetett skálázott eredmény; α az egyedi konstans; β a perzisztencia-együttható, amely a jelenlegi eredmény jövőbeli időszakokra vonatkozó fenntarthatóságát számszerűsíti; $\varepsilon_{t,i}$ pedig a hibatermék.

Az ESG-perzisztencia (β_{ESG}) azonos autoregresszív logikával, de közvetlenül az összesített ESG-pontszámokra alkalmazva kerül meghatározásra:

$$ESG_{i,t} = \alpha + \beta_{ESG} * ESG_{i,t-1} + \varepsilon_{t,i} \quad (2)$$

Mindkét modellben a β -együttható a jelenlegi kimenetek perzisztenciájának mértékét ragadja meg, és megbízható alapot teremt a jövőbeli teljesítmény előrejelzéséhez. A végső elemzési minta 1 857 vállalatból áll, amelyek esetében a vállalati szintű autoregresszív modellek 5%-os szinten statisztikailag szignifikáns együtthatókat eredményeztek az eredményperzisztenciára és az ESG-perzisztenciára.

Az empirikus kutatás alapját többváltozós OLS-regressziós módszertan adja, amely a pénzügyi stabilitás és a fenntarthatósági eredmények összetett kapcsolatát vizsgálja. Ez a megközelítés lehetővé teszi több stratégiai tényező egyidejű értékelését a vállalatspecifikus jellemzők és az iparági trendek figyelembevételével. A modell fő eszközként szolgál a valódi stratégiai integráció – a pénzügyi és nem pénzügyi eredmények illeszkedése – és a stratégiai leválasztás

megkülönböztetésére, amikor a fenntarthatósági diskurzus és teljesítmény eltér a szervezet pénzügyi realitásától. Az alapmodell a következő:

$$\beta_{earn,i} = \alpha + \gamma_1 \beta_{ESG,i} + \gamma_2 \Delta ESG_i + \gamma_3 \Delta Size_i + \gamma_4 \Delta ROA_i + \sum Industry_FE + \varepsilon_i \quad (3)$$

A változók értelmezése:

- $\beta_{earn,i}$: az eredményperzisztencia mértékét jelölő függő változó;
- $\beta_{ESG,i}$: az ESG-perzisztencia, vagyis a fenntarthatósági teljesítmény időbeli stabilitása;
- ΔESG_i : a 2011 és 2019 közötti ESG-pontszám-változás, amely a stratégiai ESG-fejlődés proxyja;
- $\Delta Size_i$: a vállalatnövekedés, amely az összes eszköz természetes logaritmusának változásaként kerül meghatározásra a megfigyelési időszak első és utolsó éve között;
- ΔROA_i : a jövedelmezőség, azaz az eszközarányos megtérülés változása, amely az eredményvolatilitást kontrollálja;
- $Industry_FE$: pedig az iparági fix hatásokat jelöli, amelyek a szektorspecifikus perzisztenciamintázatokat szűrik ki.

A keresztmetszeti regressziós kialakítás miatt az eredmények asszociatívként, nem pedig okságiként értelmezendők.

Eredmények

A többváltozós OLS-regresszió eredményei empirikus alapot biztosítanak a pénzügyi stabilitás és a fenntarthatósági teljesítmény kapcsolatának elemzéséhez. A vállalati növekedés, a jövedelmezőség változásai és az iparági sajátosságok kontrollváltozóként történő bevonása révén a modell túlmutat az egyszerű korrelációkon, és rendszerszintűbb képet ad a stratégiai integrációról. Az 1. táblázat azt a regressziós modellt mutatja be, amelyben az eredményperzisztencia (β_{earn}) a függő változó. A végső minta 1 857 vállalatot tartalmaz, ezáltal széles szektorális lefedettséget biztosít.

1. táblázat: Többváltozós regressziós eredmények az eredményperzisztenciára

Változók	Együttható	Rob. std. hiba	t-statisztika	P > t	Beta (std.)
ESG-perzisztencia (β_{ESG})	-0,0618	0,0847	-0,73	0,466	-0,0324
ESG-változás (ΔESG)	-0,0002	0,0004	-0,50	0,619	-0,0089
Vállalatnövekedés ($\Delta Size$)	0,0289**	0,0120	2,41	0,016	0,0585
Jövedelmezőség változása (ΔROA)	-0,1367***	0,0440	-3,10	0,002	-0,0619
Iparági fix hatások	Figyelembe véve				
Konstans	0,6730***	0,0765	8,80	0,000	
Modelldiagnosztika					
Megfigyelések	1 857	R2	0,0167	Prob > F	0,000

Forrás: saját számítás LSEG / Refinitiv Eikon adatok alapján (2011–2019)

*Megjegyzés: *** $p < 0,01$, ** $p < 0,05$. A standard hibák robusztusak. A β standardizált együtthatót jelöl.*

A regressziós elemzés azt mutatja, hogy a fenntarthatósági mutatók – mind az időbeli stabilitás (β_{ESG}), mind az abszolút fejlődés (Δ_{ESG}) szempontjából – nem gyakorolnak statisztikailag szignifikáns hatást az eredményperzisztenciára. Az ESG-perzisztencia p-értéke 0,466, az ESG-változás p-értéke pedig 0,619, ami azt jelzi, hogy e dimenziók a vizsgált mintában nem épülnek be a pénzügyi stabilitás meghatározó tényezői közé. Bár statisztikailag nem szignifikánsak, az eredmények gazdasági szempontból informatív bizonyítékot szolgáltatnak arra, hogy a fenntarthatósági teljesítmény a legtöbb vállalatnál önálló stratégiai tartományként működik.

A szignifikancia hiánya erős bizonyítékot kínál a stratégiai leválasztással összhangban. Arra utal, hogy a legtöbb szervezetben a fenntarthatósági teljesítmény elsősorban elkülönült stratégiai terület, amely gyakran kevésbé beágyazott, mintsem teljes mértékben integrált elköteleződést tükröz. Az eredmények szerint a szinkronizált stabilitásban megnyilvánuló vezetői szándékosság sok esetben hiányzik, mivel a fenntarthatósági eredmények leválasztottnak tűnnek azoktól az alapvető pénzügyi mechanizmusoktól, amelyek az eredményperzisztenciát biztosítják.

A fenntarthatósági változókkal szemben az alapvető pénzügyi jellemzők erősebb magyarázóerőt mutatnak. A vállalatnövekedés pozitív és szignifikáns kapcsolatban áll az eredményperzisztenciával ($p=0,016$), ami arra utal, hogy a nagyobb, illetve a stabil növekedést mutató vállalatok tartósabb eredményeket értek el a stabilitási ablakban. A jövedelmezőség változásának szignifikáns negatív kapcsolata ($p=0,002$) azt jelzi, hogy az eszközarányos megtérülés magas volatilitása közvetlenül gyengíti az eredmények időbeli stabilitását. Az iparági hatások szintén azt erősítik meg, hogy a szektorspecifikus jellemzők fontosabb meghatározói a pénzügyi stabilitásnak, mint a vállalat ESG-profilja.

Az alacsony R^2 (0,0167) és az ESG-tényezők inszignifikanciája arra utal, hogy a greenwashing elterjedtsége és a fenntarthatósági minősítések bizonytalansága akadályozhatja e mutatók megbízható vezetői stratégiai koherencia-indikátorként való alkalmazását. Az eredményperzisztenciát számos vállalatspecifikus tényező befolyásolja, ami a keresztmetszeti modellekben gyakran alacsony magyarázóerőt eredményez. A megállapítások összességében azt jelzik, hogy bár a vállalatok ESG-minősítései javulásáról számolhatnak be, ezek a mutatók gyakran inkább „pajzsként”, mintsem a tartós pénzügyi reziliencia integráns részeként működnek.

Összességében a bizonyítékok azt sugallják, hogy a fenntarthatósági teljesítmény nagyrészt önálló stratégiai tartományként, nem pedig az alapvető pénzügyi stabilitásmenedzsment komponenseként működik.

Összegzés

Az empirikus eredmények egyik felállított hipotézist sem támasztják alá. Sem az ESG-teljesítmény szintje (H_1), sem az ESG-perzisztencia (H_2) nem mutat statisztikailag szignifikáns kapcsolatot az eredményperzisztenciával. Ez a mintázat nem illeszkedik az etikai hipotézishez, sokkal inkább a stratégiai leválasztás elméletének előrejelzéseivel konzisztens.

A tanulmány az eredményminőség időbeli stabilitása és a fenntarthatósági teljesítmény kapcsolatát vizsgálta, az eredményminőséget az eredményperzisztencia alapján definiálva. A 2011 és 2019 közötti, válságmentes stabilitási időszak elemzése azt mutatja, hogy nincs erős szinkronizáció a fenntarthatósági stabilitás és a pénzügyi eredmények időbeli stabilitása között. A kezdeti etikai feltevésével szemben a szigorúbb statisztikai elemzés arra utal, hogy a legtöbb szervezetben a pénzügyi stabilitás és a fenntarthatósági teljesítmény külön pályán mozog, ami a stratégiai leválasztással összhangban álló bizonyítékot jelent.

Az eredmények azt jelzik, hogy a vállalati jövedelmezőséget elsősorban fundamentális gazdasági tényezők – a vállalatnövekedés és a nyereséghányad stabilitása – befolyásolják, míg az ESG-teljesítmény lényegében elkülönült területként működik. Ez az elválás arra utal, hogy a fenntarthatósági vállalatok sok vállalatnál párhuzamos stratégiai dimenzióként jelennek meg, nem pedig a pénzügyi döntéshozatal mélyen integrált részeként. A perzisztenciamintázatok közötti érdemi együttmozgás hiánya azt sugallja, hogy a valódi vezetői szándék – amely a pénzügyi és fenntarthatósági eredmények összehangolt stabilitásában lenne megfigyelhető – a vizsgált időszakban inkább kivétel, mint általános gyakorlat volt.

Fontos ugyanakkor felismerni, hogy a kutatás a 2011 és 2019 közötti időszakot vizsgálta, azóta pedig jelentős idő telt el, ami lehetővé tehetette a fenntarthatósági és pénzügyi célok erősebb összehangolását a vállalati stratégiai érettség növekedésével. A frissebb időszakok elemzése azonban módszertanilag nehezebb, mivel számos külső gazdasági hatás és globális sokk – beleértve a módszertanban azonosított strukturális töréseket – megnehezíti a valódi stratégiai koordináció elkülönítését az exogén piaci volatilitástól.

E korlátok ellenére az eredmények fontos érvet szolgáltatnak a környezeti és fenntarthatósági szempontok pénzügyi menedzsmentbe történő mélyebb integrációja mellett. A vállalatvezetők számára a javaslat egyértelmű: a fenntarthatóságot nem elkülönített programként, hanem stratégiai pilléreként kell beépíteni a hosszú távú pénzügyi tervezésbe annak érdekében, hogy mérsékeljék a „shielding” vagy greenwashing kockázatát.

A tanulmány új értékelési nézőpontot kínál a befektetők és intézményi tulajdonosok számára is. Az érintetteknek a statikus ESG-minősítések helyett az ESG-mutatók időbeli stabilitását az eredményminőséggel együtt érdemes vizsgálniuk, hogy azonosítani tudják a valóban integrált, megalapozott elköteleződést mutató vállalatokat. Ez a szemlélet segíthet a befektetőknek és szabályozóknak megkülönböztetni a tényleges ESG-integrációt a szimbolikus megfeleléstől. A

perzisztenciamintázatok eltérése empirikus jelzésként szolgálhat a szabályozók és könyvvizsgálók számára a vállalati jelentésekben megjelenő potenciális stratégiai leválasztás azonosításához.

A jövőbeli kutatásoknak érdemes e megállapításokra építve vizsgálniuk a szektorspecifikus lényegességet és az intézményi tulajdon szerepét a pénzügyi és ESG-teljesítmény közötti stratégiai illeszkedés erősítésében. A tanulmány keretet ad a hosszú távú összehangoltság értékeléséhez, és arra mutat rá, hogy bár a stratégiai leválasztás elterjedt jelenség, a valódi vállalati reziliencia a pénzügyi és fenntarthatósági eredmények koordinált stabilitását igényli.

Korlátok és jövőbeli kutatási irányok

A kutatásnak több korlátja is van. Az elemzés vállalati szintű, időben becsült perzisztencia-együtthatókat alkalmaz, amelyeket keresztmetszeti keretben értékel; mivel az eredményperzisztenciát minden vállalat esetében egyetlen paraméter jelzi, a vállalaton belüli dinamikák nem használhatók ki, az eredmények ezért asszociatívként, nem pedig okságiként értelmezendők, és az endogenitás lehetősége fennmarad. Másodsor, a fenntarthatósági teljesítmény egyetlen szolgáltató, az LSEG / Refinitiv ESG-minősítésein alapul, miközben a minősítő szervezetek közötti bizonyított eltérések korlátozhatják a külső érvényességet. A válságmentes „stabilitási ablak” (2011–2019) növeli a belső konzisztenciát, ugyanakkor csökkenti az általánosíthatóságot jelentős gazdasági sokkok időszakaira.

A modell korlátozott magyarázóereje azt jelzi, hogy az eredményperzisztenciát további vállalati, intézményi és makrogazdasági tényezők is befolyásolják, amelyek nem szerepelnek a modellben. A jövőbeli kutatások további ESG-adatforrásokat vonhatnak be, valamint vizsgálhatják azokat a szektorspecifikus és vállalatiirányítási tényezőket, amelyek a pénzügyi és ESG-illeszkedést alakítják. Emellett az elemzés meghatározott eredményminőségi és fenntarthatósági perzisztencia-mérőszámokra támaszkodik; alternatív proxyk vagy modell-specifikációk eltérő eredményekre vezethetnek, ezért ezek vizsgálata további kutatási irányt jelent.

Köszönetnyilvánítás

A tanulmány a TKP2021-NKTA-19 számú projekt keretében az Innovációs és Technológiai Minisztérium Nemzeti Kutatási Fejlesztési és Innovációs Alapból nyújtott támogatásával, a TKP2021-NKTA pályázati program finanszírozásában valósult meg.

Hivatkozások

Albuquerque, R., Koskinen, Y., & Zhang, C. (2019). Corporate social responsibility and firm risk: Theory and empirical evidence. *Management Science*, 65(10), 4451–4469. doi:10.1287/mnsc.2018.3043

- Attig, N., Boubakri, N., El Ghouli, S., & Guedhami, O. (2016). Firm Internationalization and Corporate Social Responsibility. *Journal of Business Ethics*, 134(2), 171-197. doi:10.1007/s10551-014-2410-6
- Barth, M. E., Li, K., & McClure, C. G. (2023). Evolution in Value Relevance of Accounting Information. *The Accounting Review*, 98(1), 1–28. doi:10.2308/TAR-2019-0521
- Berg, F., Koelbel, J. F., & Rigobon, R. (2022). Aggregate confusion: The divergence of ESG ratings. *Review of Finance*, 26(6), 1315–1344. doi:10.1093/rof/rfac033
- Billio, M., Costola, M., Hristova, I., Latino, C., & Pelizzon, L. (2021). Inside the ESG ratings: (Dis)agreement and performance. *Corporate Social Responsibility and Environmental Management*, 28(5), 1426–1445. doi:10.1002/csr.2177
- Christensen, D. M., Hail, L., & Leuz, C. (2021). Mandatory CSR and Sustainability Reporting: Economic Analysis and Literature Review. *Finance Working Paper*, 623/2019. doi:10.2139/ssrn.3427748
- Csapi, V. (2019). How Real Option Theory Has Gained Space in Research and Practice. *INTERNATIONAL RESEARCH JOURNAL OF FINANCE AND ECONOMICS*, 2019(171), 86–96.
- Dechow, P., Ge, W., & Schrand, C. (2010). Understanding earnings quality: A review of the proxies, their determinants and their consequences. *Journal of Accounting and Economics*, 50(2-3), 344–401. doi:10.1016/j.jacceco.2010.09.001
- Ding, W., Levine, R., Lin, C., & Xie, W. (2021). Corporate immunity to the COVID-19 pandemic. *Journal of Financial Economics*, 141(2), 802–830. doi:10.1016/j.jfineco.2021.03.005
- Dorfleitner, G., Kreuzer, C., & Sparrer, C. (2020). ESG controversies and controversial ESG: about silent saints and small sinners. *Journal of Asset Management*, 21, 393-412. doi:10.1057/s41260-020-00178-x
- Dyck, A., Lins, K. V., Roth, L., & Wagner, H. F. (2019). Do institutional investors drive corporate social responsibility? International evidence. *Journal of Financial Economics*, 131(3), 693–714. doi:10.1016/j.jfineco.2018.08.013
- Eliwa, Y., Aboud, A., & Saleh, A. (2021). ESG practices and the cost of debt: Evidence from EU countries. *Critical Perspectives on Accounting*, 79, 102194. doi:10.1016/j.cpa.2019.102097
- Grewal, J., Riedl, E. J., & Serafeim, G. (2019). Market reaction to mandatory nonfinancial disclosure. *Management Science*, 65(7), 3061-3084. doi:10.1287/mnsc.2018.3099
- Hawn, O., & Ioannou, I. (2016). Mind the gap: The interplay between external and internal actions in the case of corporate social responsibility. *Strategic Management Journal*, 37(13), 2569-2588. doi:10.1002/smj.2464

- Henri, J.-F., & Journeault, M. (2010). Eco-control: The influence of management control systems on environmental and economic performance. *Accounting, Organizations and Society*, 35(1), 63-80. doi:10.1016/j.aos.2009.02.001
- Hou, K., van Dijk, M. A., & Zhang, Y. (2012). The implied cost of capital: A new approach. *Journal of Accounting and Economics*, 53(3), 504-526. doi:10.1016/j.jacceco.2011.12.001
- Jordaan, L. A., de Klerk, M., & de Villiers, C. J. (2018). Corporate social responsibility and earnings management of South African companies. *South African Journal of Economic and Management Sciences*, 21(1), 1-13. doi:10.4102/sajems.v21i1.1849
- Khan, M., Serafeim, G., & Yoon, A. (2016). Corporate sustainability: First evidence on materiality. *The Accounting Review*, 91(6), 1697-1724. doi:10.2308/accr-51383
- Kim, Y., Park, M. S. & Wier, B. (2012). Is earnings quality associated with corporate social responsibility? *The Accounting Review*, 87(3), 761-796. doi:10.2308/accr-10209
- Liang, H., & Renneboog, L. (2017). On the foundations of corporate social responsibility. *The Journal of Finance*, 72(2), 853-910. doi:10.1111/jofi.12487
- Rezaee, Z., & Tuo, L. (2019). Are the Quantity and Quality of Sustainability Disclosures Associated with the Innate and Discretionary Earnings Quality? *Journal of Business Ethics*, 155, 763-786. doi: 10.1007/s10551-017-3546-y
- Schiehll, E., & Kolahgar, S. (2021). Financial materiality in the informativeness of sustainability reporting. *Business Strategy and the Environment*, 30(2), 840-855. doi:10.1002/bse.2657
- Serafeim, G. (2020). Public sentiment and the price of corporate sustainability. *Financial Analysts Journal*, 76(2), 26-46. doi:10.1080/0015198X.2020.1723390
- Tashman, P., Marano, V., & Kostova, T. (2019). Walking the walk or talking the talk? Corporate social responsibility decoupling in emerging market multinationals. *Journal of International Business Studies*, 50, 153-171. doi:10.1057/s41267-018-0171-7
- Torelli, R., Balluchi, F., & Furlotti, K. (2020). The materiality assessment and stakeholder engagement: A content analysis of sustainability reports. *Corporate Social Responsibility and Environmental Management*, 27(2), 470-484. doi:10.1002/csr.1813
- Ulbert, J., Takács, A., & Csapi, V. (2017). *The Relevance of the DCF Valuation Model in Investor Decisions*. Saarbrücken: GlobeEdit.
- Velte, P. (2017). Does ESG performance have an impact on financial performance? Evidence from Germany. *Journal of Global Responsibility*, 8(2), 169-178. doi:10.1108/JGR-11-2016-0029

Zheng, Y., Wang, B., Sun, X. & Li, X. (2022). ESG performance and corporate value: Analysis from the stakeholders' perspective. *Frontiers in Environmental Science*, 10, 1084632. doi:10.3389/fenvs.2022.1084632

Fenntartható számvitel 2.0

Dr. SISA Krisztina Andrea

Budapesti Gazdaságtudományi Egyetem

sis.krisztina@uni-bge.hu

Dr. SIKLÓSI Ágnes

Budapesti Gazdaságtudományi Egyetem

siklosi.agnes@uni-bge.hu

<https://doi.org/10.15170/XVIIPPN-Tk-KTK-2026-13>

Absztrakt

A modern vállalatirányításban a vezetői számvitel és a fenntarthatóság kapcsolata már nem csupán elméleti kérdés, hanem stratégiai szükségszerűség és a versenyelőny forrása. Míg a hagyományos számvitel elsősorban a rövid távú profitmaximalizálásra és a pénzügyi adatokra fókuszál, a fenntarthatóság-orientált megközelítés ezt kiterjeszti a hosszú távú értékteremtésre, valamint a környezeti és társadalmi hatások mérésére is.

A modern vezetői számviteli információs rendszerek a pénzügyi adatok mellett fizikai mértékegységeket is kezelnek, lehetővé téve az ok-okozati összefüggések feltárását. A környezeti vezetői számvitel olyan módszertanokat alkalmaz, mint az anyagáram-költségszámítás (MFCA), amely a hulladékot nem egyszerű veszteségként, hanem "negatív terméként" kezeli, számszerűsítve a benne rejlő elpazarolt energiát és anyagköltséget.

Az életciklus-költségszámítás (LCC) segítségével a beruházási döntések során nemcsak a beszerzési árat, hanem a teljes élettartam alatti üzemeltetési és környezeti költségeket is figyelembe veszik. A modern vezetői számvitel kiemelt területe a vállalati teljesítménymérés is, amelynek a keretében a fenntarthatósági célok beépülnek a Balanced Scorecard (S-BSC) rendszerbe, ahol a környezeti KPI-ok (pl. fajlagos energiafelhasználásra jutó árbevétel) közvetlen kapcsolatba kerülnek a vállalati eredménnyel.

Összességében a számviteli információs rendszer teszi a fenntarthatóságot mérhetővé és ezáltal menedzselhetővé, átalakulva egy múltba tekintő "tükörből" a jövő felé mutató stratégiai "iránytűvé".

Tanulmányunkban szekunder kutatásra alapozva felvázolunk egy olyan vezetői számviteli információs rendszert, amelyben fókuszáltan megjelenik a fenntarthatósággal kapcsolatos költségek mérésének dimenziója is, különös tekintettel a költségkalkuláció területére.

Kulcsszavak: vezetői számvitel, fenntartható számvitel, életciklus-költségszámítás, Balanced Scorecard

Bevezetés – A fenntarthatósági szempont megjelenése

A fenntarthatóság gondolatának üzleti életben való megjelenése évtizedes múltra tekint vissza. 1987-ben az Egyesült Nemzetek Brundtland Bizottsága úgy határozta meg a fenntarthatóságot, mint „a jelen szükségleteinek kielégítését anélkül, hogy az veszélyeztetné a jövő generációinak lehetőségét saját szükségleteik kielégítésére”. (United Nations World Commission on Environment and Development, 1987) Ez felveti a kérdést, hogy miként tud mindez megvalósulni a vállalatok esetében és hogyan mérhető a fenntarthatóság. Az 1987-es jelentés célul tűzte ki a gazdasági növekedés új korszakának megteremtését, amely nemcsak erőteljes, hanem társadalmilag és környezetileg is fenntartható. A dokumentum meghatározta azokat az alapelveket és követelményeket, amelyek betartása lehetővé tenné a Föld megőrzését a jövő generációi számára.

Az 1992-es Rio de Janeioban megrendezett konferencián az Agenda 21 – Feladatok a 21. századra – című dokumentum megerősítésre került, mely egy átfogó cselekvési tervet képez a fenntartható fejlődésre irányuló globális partnerség kiépítésére, az emberi élet javítása és a környezet védelme érdekében. (Gyulai, 2013)

A fenntarthatóságot többféleképpen lehet értelmezni. Egyes szakértők, (Benn & Bolton, 2015) CSR Compass című tanulmánya szerint a fenntarthatóságot nehéz konkrét kritériumokkal meghatározni. Érvelésük szerint a fogalom különböző rendszereket foglal magában, beleértve a technológiai, társadalmi, politikai és környezeti szempontokat.

Az ENSZ 2015-ben bevezetett „Világunk átalakítása: a Fenntartható Fejlődés 2030-as Agendája” 17 Fenntartható Fejlődési Célt (SDG) fogadott el, amelyek arra irányulnak, hogy „az elkövetkező 15 évben az emberiség és a bolygó számára kritikus fontosságú területeken cselekvést ösztönözzenek”. (Bebbington & Unerman, 2018; United Nations, 2015)

Az ESG-mutatók olyan mérőszámok, amelyeket egy vállalat működésének és teljesítményének értékelésére használnak három kulcsfontosságú területen:

- **Környezeti pillér:** arról szól, hogy egy vállalat működése milyen hatással van a természeti környezetre, és hogyan kezeli a klímaváltozással kapcsolatos kockázatokat. Olyan tényezőket foglal magában, mint a szén-dioxid kibocsátás, energiahatékonyság és megújuló energia, víz- és erőforrásgazdálkodás, a hulladékgazdálkodás és körforgásos gazdaság, és a biológiai sokféleségre gyakorolt hatások. Például a vállalatok értékelhetik teljes üvegházhatású gáz-kibocsátásukat vagy energiahatékonyságukat.
- **Szociális/társadalmi pillér:** Azt vizsgálja, hogy a vállalat hogyan kezeli a kapcsolatait az alkalmazottakkal, beszállítókkal, ügyfelekkel és a működési területén élő helyi közösségekkel. A mutatók kiterjedhetnek a munkaügyi

gyakorlatokra, a sokszínűségre és a befogadásra, az emberi jogokra és a közösségi szerepvállalásra. Például a fluktuáció és a sokszínűségi programok, felelős beszállítói lánc megléte, termékefelelősség és fogyasztóvédelem, közösségi kapcsolatok és a vállalati működés hatása a helyi lakosság életére stb kulcsfontosságú mutatók lehetnek.

- Vállalatirányítás: A vállalat vezetésére, az auditokra, a belső ellenőrzésre és a részvényesi jogokra összpontosít. Ez a terület azt értékeli, hogy a vállalatok elszámoltathatók-e és megfelelően irányítottak-e, beleértve a vezetői fizetéseket, a vezetés sokszínűségét és a részvényesi jogokat. A kiemelt fókuszterületek a vezetés összetétele és függetlensége, a vezetői javadalmazás rendszere, üzleti etika, korrupció elleni küzdelem, részvényesi jogok és átláthatóság.

1. ábra: ESG-mutatók



Forrás: saját szerkesztés

Ezek a pillérek összefüggésben állnak, és kölcsönösen hatnak egymásra, tehát integrált megközelítést igényelnek.

A fenntartható fejlődés elve kiemeli a jövő nemzedékek jólétéért való felelősségvállalás fontosságát, amelyet generációk közötti szolidaritásnak is neveznek. Nem elegendő a jelenlegi generációk számára egy szerényebb szükségleteken alapuló életmódra törekedni, ugyanis, ha a népesség összes alapvető szükséglete meghaladja a rendelkezésre álló erőforrásokat, akkor a mostani generációk szükségletei nem elégíthetők ki. (Gyulai, 2016)

Jelenleg az emberiség túllépte a Föld eltartóképességét, az ökológiai lábnyom fogalmával mérve, másfél bolygónak megfelelő területet használ fel. A természeti erőforrások, nyersanyagok és energiaforrások kimerülésének megakadályozása érdekében, olyan új termelési és fogyasztási mintákat szükséges kialakítani, amelyek a Föld ökológia egyensúlyának megőrzését biztosítják, a hatékony felhasználás, a hulladékcsökkentés és az újrahasznosítás révén. (Gyulai, 2015)

Ahhoz, hogy a jövő generációi számára fenntartható jövőt biztosítsunk, elengedhetetlen, hogy alapos oktatásban és képzésben részesüljenek a környezettudatosság jegyében. Számos tanulmány igazolja a környezeti nevelés, a környezettudatos cselekvés és a környezeti attitűdök fontosságát. (Major, 2012)

A fenntarthatóság napjainkban az üzleti szféra egyik meghatározó értékévé és céljává vált. A vállalatok számára a fenntarthatóság nemcsak a környezeti és társadalmi felelősségvállalás kérdése, hanem olyan stratégiai szemléletet is jelent, amely hosszú távú előnyöket nyújt mind a vállalatoknak, mind pedig a társadalomnak, mert elősegíti a fenntartható fejlődést, a társadalmi elkötelezettséget és a versenyképességet is. Az ilyen megközelítés elsődleges célja, hogy a vállalatok ne csak azonnali profitra törekedjenek, hanem felelősségteljesen tevékenykedjenek annak érdekében, hogy pozitív hatást gyakoroljanak mind a környezetre, mind a társadalomra. (Horváth, 2023) A vállalati fenntarthatóság egy olyan üzleti modellt jelent, amely magában foglalja az ökológiai lábnyom csökkentését, a szociális igazságosság előmozdítását és a gazdasági fejlődés fenntarthatóságát. Az optimalizált erőforrásfelhasználás, a környezetvédelmi beruházások és a társadalmi projektek támogatása, mind fontos elemei ennek a megközelítésnek. (Dyllick & Hockerts, 2002) által meghatározott hat alapelv – ökohatékonyság, szociohatékonyság, ökohatásosság, szociohatásosság, elégségesség és ökológiai egyenlőség – világos iránymutatást kínál a vállalatok fenntarthatósági célkitűzéseinek megtervezéséhez. Ezek az elvek nemcsak a környezeti hatások csökkentésére helyezik a hangsúlyt, hanem a társadalmi jólét növelésére és a gazdasági stabilitás megőrzésére is. A vállalatoknak ezért, olyan integrált megközelítést kell alkalmazniuk, amely a környezeti fenntarthatóságot, a társadalmi méltányosságot és a gazdasági életképességet egyaránt előtérbe helyezi. (Surman & Böcskei, 2023)

A fenntarthatóság környezeti, társadalmi és gazdasági dimenzióit egyesítő vállalati mérési megközelítés alapját Elkington hármass optimalizálásként ismert modellje (Triple Bottom Line, TBL) képezi. Ez a menedzsment-keretrendszer és vállalatvezetési szemlélet az üzleti érdekek (profit) mellett azonos súllyal veszi figyelembe a környezeti és társadalmi célokat. A TBL-modellt gyakran People, Planet, Profit (3P) néven is emlegetik, amely szerint egy vállalatnak nemcsak profitot kell termelnie, hanem annak egy részét vissza kell juttatnia a közösség és a környezet javára, mivel elsősorban a társadalmi és természeti tényezők teszik lehetővé a profitszerzést. (Hódiné Hernádi, 2010) A vállalati fenntarthatóság és társadalmi felelősségvállalás megvalósításának formájáról és mértékéről azonban nincs egységes álláspont. Ez főként abból adódik, hogy a fenntarthatóság társadalmi és környezeti szempontjai nehezen vethetők össze a vállalat gazdasági teljesítményét leíró, pénzben kifejezhető mutatókkal, mivel azok jellege alapvetően eltér egymástól. (Elkington, 1998) (Matolcsy, 2020)

A vállalatok a fenntarthatósági jelentésben jelentik a fenntarthatósági teljesítménymérési eredményeket az ESG-kritériumokkal szemben (Christensen és mtsai., 2021). A fenntarthatósági információk egyre nagyobb érdeklődésre tartanak számot minden, a vállalati érték iránt érdeklődő érdekelt fél számára, ezért a megfelelő minőségű fenntarthatósági jelentések elkészítése és közzététele

ugyanolyan fontos, mint a pénzügyi jelentések közzététele. A számviteli információs rendszer képes a fenntarthatóság dimenzióinak méréséhez szükséges adatokat szolgáltatni. Ez az adatszolgáltatás igényli a vezetői számviteli alrendszer kialakítását és fenntarthatósági szempontoknak megfelelő finomhangolást, a pénzügyi számviteli alrendszer mélyítését.

Tanulmányunkban arra a kérdésre keressük a választ, hogy melyek azok a vezetői számviteli területek, amelyeknél megjelenhetnek a fenntarthatósági szempontok, illetve hogyan történjen meg a számviteli információs rendszer fenntarthatósági szempontokat, illetve információs igényeket is kiszolgálni képes információs rendszerre alakítása.

Kutatásunkat szekunder kutatómunkára alapoztuk. A témaspecifikus publikációk eredményeinek összegzésén túl vállalati fenntarthatósági riportok dokumentumelemzésének tapasztalatai egészítik ki az elméleti kutatómunkát.

A számviteli információs rendszer „testreszabása”

A számviteli információs rendszer alkalmas arra, hogy abban megjelenjenek új információs igények.

A pénzügyi és a vezetői számvitel összekapcsolása a fenntarthatósági dimenzióval

A számvitel a tájékoztatás és ezen keresztül a döntéstámogatás eszköze. A számviteli tevékenység és munkafolyamatok során keletkező információk egy komplex számviteli információs rendszerre állnak össze. A számvitel - hagyományosan- az információ szolgáltatással való kapcsolata szerinti csoportosításnak megfelelően elkülöníthető a pénzügyi (külső) és a vezetői (belső vagy menedzsment) számviteli területekre. A pénzügyi számvitel elsősorban a gazdálkodó szervezeten kívüli gazdasági szereplők információs igényeit elégíti ki, elsődlegesen az üzleti évenként elkészített éves beszámoló elkészítésével. Az éves beszámoló átfogó képet nyújt a gazdálkodó vagyoni, pénzügyi és jövedelmi helyzetéről, alapvetően múltbeli adatok (az elmúlt üzleti év) alapján. Az éves beszámoló adatai aggregáltak, ami azt jelenti, hogy összevontan tartalmazza a gazdálkodó teljes éves tevékenységének adatait. Ezzel szemben a vezetői számvitel a tevékenység részletes megfigyelésére szolgál, olyan részletes információkat képes szolgáltatni, amelyekkel a gazdálkodó tevékenysége irányítható, befolyásolható. A menedzsment számvitelt a vezetői döntéshozatal információs igénye hívta életre. Értelmezésünkben a vezetői számvitel fogalmán olyan információs szolgáltatási és értékteremtő működést támogató rendszert kell érteni, amelynek a célja a különböző vezetői szintek részére a tevékenység ellátásához szükséges információk biztosítása a gazdaságosság, hatékonyság és eredményesség jegyében.

A pénzügyi és a vezetői számvitel együttesen képes kiszolgálni a fenntarthatósággal kapcsolatos információs igényeket. A publikus pénzügyi beszámoló és fenntarthatósági jelentés elsődlegesen a hagyományos pénzügyi számviteli alrendszer információira épül, ugyanakkor a pénzügyi számvitel -tekintettel arra, hogy annak adatai értékalapúak és globális adatok- önállóan nem képes minden

szükséges információt szolgáltatni. Szükség van a vezetői számviteltől származó részletes, érték és naturális adatokra egyaránt.

1. táblázat: A pénzügyi és a vezetői számvitel összehasonlítása

Összehasonlítási szempont	Pénzügyi számvitel	Vezetői számvitel
Alapvető cél	Külső érintettek tájékoztatása a vállalkozás vagyoni, pénzügyi és jövedelmi helyzetéről	A vezetői döntéshozatal támogatása, a működési irányítása
Információ felhasználói	Külső szereplők (tulajdonosok, hitelezők, befektetők, hatóságok)	Belső felhasználók (menedzsment, vezetők)
Szabályozottság	Szigorúan szabályozott (pl. számviteli törvény, IFRS)	Nem jogszabályi jellegű, rugalmasan alakítható
Időhorizont	Múltorientált (lezárt üzleti év)	Jövőorientált (tervezés, előrejelzés is megjelenik)
Adatok jellege	Tényadatok, pénzértékben kifejezve	Tény- és tervadatok, pénzügyi és nem pénzügyi információk
Részletezettség	Összesített, vállalati szintű	Részletes (termék, folyamat, költséghely, projekt)
Fő kimenet	Beszámoló (mérleg, eredménykimutatás, kiegészítő melléklet)	Kimutatások, elemzések, költség- és teljesítménymérések, vezetői riportok, tervek
Döntéstípus	Elsősorban beszámolási, elszámolási célú	Operatív és stratégiai döntések támogatása
Kötelező jellege	Kötelező	Nem kötelező

Forrás: saját szerkesztés (Veress és mtsai., é. n.) alapján

Összefoglaló a legfontosabb kapcsolódási pontokról:

- **Adatintegráció:** A hagyományos számviteli információs rendszer elsősorban pénzügyi adatokat kezel. Ugyanakkor a pénzügyi és nem pénzügyi adatokra egyaránt szükség van. A fenntarthatóság azonban fizikai mértékegységeket igényel (pl. CO₂-kibocsátás tonnában, vízfogyasztás köbméterben, munkahelyi balesetek száma).
 A kihívás: a modern információs rendszereknek (mint például az ERP rendszereknek) képesnek kell lenniük ezeket a „nem pénzügyi” adatokat ugyanolyan pontossággal és hitelességgel kezelni, mint az értékadatokat.
 A megoldás: a számlák rögzítésekor a rendszer nemcsak a költséget (pl. a villanyszámla összegét) rögzíti, hanem a fogyasztást (kWh) is, így a rendszer automatikusan kiszámítja a karbonlábnyomot.
- **Környezetközpontú vezetői számvitel (Environmental Management Accounting-EMA):** ez a terület a belső döntéshozatalt támogatja. A számviteli információs rendszer segít feltárni azokat a költségeket, amelyek a környezeti hatásokból erednek, de hagyományosan „eltűnnek” az általános rezsiköltségekben.

Ennek egyik kiemelt területe az anyagáramlási költségszámítás (material flow cost calculation-MFCA): a rendszer teljesen nyomon követi az anyagáramlást. A hulladék nem csupán technológiai veszteség, hanem „kidobott pénz” (nyersanyagköltség + feldolgozási költség + ártalmatlanítási költség).

- Jelentéstétel és megfelelés: Ez talán a legerősebb hajtóerő jelenleg, különösen az Európai Unióban.
CSRD (Vállalati Fenntarthatósági Jelentéstételi Irányelv): Az új irányelvek értelmében a nagyvállalatok kötelesek auditált fenntarthatósági jelentéseket készíteni. A számviteli rendszernek biztosítania kell az ehhez szükséges nyomon követhető, historikus adatokat.
EU Taxonómia: A számvitelnek képesnek kell lennie a bevételek és beruházások (CAPEX/OPEX) „zöld” és „nem zöld” kategóriákba sorolására. Ehhez a számviteli rendszerek átszervezése szükséges (új főkönyvi dimenziók, projektkódok kellenek).
- Kockázatkezelés és értékelés: A befektetők és a bankok ma már ESG (környezeti, társadalmi, irányítási) kritériumok alapján is árazzák a kockázatot.
A fenntarthatósági szempontokat érintő számviteli értékelési feladatok kiemelt területei például:
Eszközök értékvesztése: Az éghajlatváltozás befolyásolhatja az eszközök hasznos élettartamát. Például egy síkőzpontban található szálloda értéke csökkenhet a hó hiánya miatt, vagy egy dízelflotta értéke zuhanhat a szabályozások miatt. A számviteli rendszernek kezelnie kell ezeket az értékvesztéseket.
Céltartalékok: A jövőbeni környezeti helyreállítási kötelezettségekre (pl. tereprendezés egy bánya bezárása után) képzett céltartalékok pontos becslése számviteli feladat.
- Teljesítménymérés (KPI-ok): a számviteli információs rendszer a kulcsfontosságú teljesítménymutatókon keresztül összekapcsolja a stratégiát a napi működéssel, illetve a fenntarthatósági dimenziót a vállalati teljesítménnyel.

A Számviteli Információs Rendszer ma már nem csupán egy „tükör”, amely a múltbeli gazdasági események eredményre gyakorolt hatását méri és prezentálja kizárólag, hanem egy „iránytű”, amely a vállalatot a fenntartható jövő felé vezeti. Ennek a kapcsolatnak a lényege, hogy a számviteli információs rendszer mérhetővé, és ezáltal kezelhetővé teszi a fenntarthatóságot.

A modern környezeti vezetői számvitel funkciói

A vezetői számvitel és a fenntarthatóság kapcsolata ma már nem csupán egy "zöld" kiegészítés, hanem a modern vállalatirányítás egyik legfontosabb stratégiai pillére. Míg a hagyományos vezetői számvitel a profitmaximalizálásra és a költséghatékonyságra fókuszál, a fenntarthatósági szemlélet ezt kiterjeszti a környezeti és társadalmi hatások mérésére is. A fenntarthatóság és a vezetői számviteli információs rendszer (MAIS - Management Accounting Information System) kapcsolata ma már nem csupán elméleti, hanem stratégiai szükségszerűség. A hagyományos pénzügyi számvitel ugyanis „vak” a környezeti és társadalmi hatásokra, így a modern vezetői döntésekhez már kevés.

A kapcsolatot úgy lehet a legjobban leírni, mint egy evolúciós folyamatot: a fenntarthatóság kényszeríti ki a számviteli rendszerek bővülését, a számviteli rendszer pedig adatokat szolgáltat a fenntarthatósági célok eléréséhez.

Íme a legfontosabb kapcsolódási pontok, amelyek meghatározzák ezt a területet:

1. A fókuszváltás: Profit helyett Értékteremtés

A hagyományos számvitel gyakran "externáliaként" kezeli a környezeti károkat vagy a társadalmi hatásokat (vagyis olyasvalamiként, ami nem jelenik meg a könyvekben). A fenntartható vezetői számvitel ezzel szemben beemeli ezeket a döntéshozatali folyamatba.

- Triple Bottom Line (Hármas optimalizálás): A vezetés nemcsak a pénzügyi eredményt (Profit), hanem a társadalmi hatást (People) és a környezeti lábnyomot (Planet) is figyeli.
- Hosszú távú szemlélet: A rövid távú költségcsökkentés helyett a fenntarthatóság a hosszú távú kockázatkezelésre és az erőforrások hatékony felhasználására ösztönöz. Itt jelenik meg a stratégiai szemlélet.
- A modern MAIS integrálja a fizikai és pénzügyi adatokat. A fenntarthatósági fókusz igényli a fizikai mértékegységgel megjeleníthető adatokat (pl: kWh, tonna, CO2 stb) és a minőségi mutatókat (pl: elégedettség, munkabiztonság, vízminőség, minőségköltségek stb) egyaránt. Nem két külön nyilvántartás van (egy a mérnöknek, egy a könyvelőnek), hanem egy egységes rendszer, ahol látszik az ok-okozat. Példa: Ha nő a selejt aránya (fizikai adat), az növeli a hulladékkezelési költséget és az anyagköltséget (pénzügyi adat).

2. Környezeti Vezetői Számvitel (EMA - Environmental Management Accounting)

Ez a terület konkrét eszközöket ad a vezetők kezébe a fizikai és pénzügyi adatok összekapcsolására. A költségszámítás (önköltségkalkuláció) területén van lehetőség a fenntarthatóság biztosításával összefüggő költségek részletesebb megjelenítésére a költségtervezés, elszámolás és önköltségkalkuláció során.

- Anyagáram-költségszámítás (MFCA): Ez az egyik leghatékonyabb módszer. Nemcsak a végtermék költségét méri, hanem számszerűsíti a hulladékban, selejtben és elpazarolt energiában rejlő veszteségeket is.
- Életciklus-költségszámítás (LCC): A fenntartható MAIS bevezeti az LCC módszert. Egy termék költségeit nemcsak a gyártásig nézi, hanem a teljes élettartam alatt (alapanyag-beszerezéstől a hulladékkezelésig). Az LCC szemlélet arra a megközelítésre épít, hogy nem a legolcsóbb beszerzési ár a nyerő egy beruházási döntés során, hanem az a berendezés, amely 10-15 év alatt kevesebb energiát fogyaszt, és a használat végén alacsonyabb költséggel jár az ártalmatlanítása. A rendszernek képesnek kell lennie ezeket a jövőbeli cash-flow-kat modellezni.
- A hagyományos rendszerek a környezeti költségeket „általános költségként” (overhead) kezelik, és önkényesen osztják fel. A kapcsolat: a fenntarthatóság-orientált MAIS olyan módszereket alkalmaz, mint az Activity-Based Costing (ABC - Tevékenység alapú költség számítás). Ez azt jelenti, hogy a környezetszennyező tevékenységekhez rendeli hozzá a valós költségeket. Aki szennyez, az „fizet” a belső elszámolásban. Ez ösztönzi a részlegeket a környezetbarát működésre.

3. KPI-ok és Teljesítménymérés

A vezetői számvitel feladata olyan mutatók kidolgozása, amelyekkel a fenntarthatósági célok mérhetővé válnak. Ilyenek például:

- Fajlagos energiafelhasználás: Egységnyi termékre jutó kWh.
- Szén-dioxid intenzitás: Az árbevételre vetített károsanyag-kibocsátás.
- Vízlábnyom és hulladék-újrahasznosítási arány.

A klasszikus Kaplan-Norton féle Balanced Scorecard (BSC) négy perspektívát vizsgál (Pénzügyi, Vevői, Működési, Tanulási nézőpontok).

A fenntarthatóság integrálása a klasszikus BSC modellbe két módon történhet:

Ötödik perspektívaként: Külön „Fenntarthatósági” láb jelenik meg.

Integráltan: Minden meglévő perspektívába beépülnek a fenntarthatósági célok. (Pl. Pénzügyi: költségcsökkenés energiahatékonyságból; Vevői: zöld imázs miatti márkahűség).

A vezetői információs rendszer feladata, hogy ezekhez a célokhoz mérőszámokat (KPI) rendeljen és azokat valós időben monitorozza (dashboard).

4. Stratégiai döntéstámogatás és ESG

Az Európai Unióban az ESG jelentéstétel (CSRD irányelv) kötelezővé vált sok vállalat számára. A MAIS nemcsak belső döntéstámogatást nyújt, hanem a külső jelentések (compliance) adatbázisa is. Például, ha a vezetői számvitel nem gyűjti szisztematikusan a CO₂-kibocsátási adatokat vagy a munkavállalói fluktuáció okait, a vállalat nem tud megfelelni a törvényi előírásoknak, ami bírságot és befektetői bizalomvesztést okoz.

A befektetők és szabályozók (mint például az EU-s CSRD irányelv) egyre inkább elvárják az ESG adatok transzparenciáját. A vezetői számvitel biztosítja azt a belső adatszolgáltatást, amelyből a külső fenntarthatósági jelentések építkeznek.

A fenntarthatóság egyértelműen stratégiai területként azonosítható, arra stratégiai tervet javasolt készíteni, és menedzselni a stratégiai célok teljesülését. A fenntarthatósági stratégiai nyomonkövetésére tökéletes eszköz lehet az átalakított BSC.

Összességében a modern fenntartható vezetői számviteli alrendszer kiemelt funkcionális területe a költség számvitel, amely a költségtervezés, költségelszámolás és költség számítás feladatait takarja.

A fenntarthatóság megjelenítése a költség számvitel területén

A hagyományos vállalati működés és a hozzá kapcsolódó teljesítménymérés évtizedeken keresztül egyetlen fő célra, a profitmaximalizálásra fókuszált. A költség számvitel klasszikus feladata ennek megfelelően a termelési tényezők (erőforrások) pénzben kifejezett értékének mérése és allokálása volt, figyelembe véve a közvetlen és közvetett költségeket. A 21. század globális környezeti és társadalmi kihívásai – mint a klímaváltozás, az erőforrások kimerülése és a szigorodó társadalmi elvárások (ESG-kitételek) – azonban kikényszerítették a vállalati szemléletmód átalakulását.

A fenntarthatóság és a költség-számvitel kapcsolata ma már nem csupán elméleti felvetés, hanem stratégiai szükségszerűség. A modern vezetőségi számvitelnek integrálnia kell a fenntarthatósági szempontokat ahhoz, hogy a menedzsment valós képet kapjon a vállalat hosszú távú értékteremtő képességéről, és minimalizálni tudja a környezeti és társadalmi kockázatokat.

A fenntarthatósági fókusz érdekében szükségszerű elsőként definiálni a fenntarthatósággal összefüggő fenntarthatósági költségeket. A fenntarthatósági költségek (vagy környezeti és társadalmi költségek) részletezésekor a legnagyobb hiba, amit egy vállalat elkövethet, ha ezeket egyetlen „egyéb” kalapba dobja bele. Ahhoz, hogy ezek menedzselhetők legyenek, szét kell választanunk őket aszerint, hogy mikor és miért merülnek fel.

A minőségköltségek mintájára az alábbi költségcsoportokat célszerű elkülöníteni:

1. Megelőzési költségek (Prevention Costs)

Ezeket a költségeket azért vállalja a cég, hogy a környezeti károk vagy társadalmi problémák létre se jöjjenek. Ez a „tisztább termelés” alapja.

- Környezetbarát tervezés (Eco-design): Olyan termékek fejlesztése, amelyek kevesebb anyagot igényelnek vagy újrahasznosíthatók.
- Technológiai váltás: Beruházás alacsonyabb kibocsátású gépekbe (pl. gázüzemű targonca helyett elektromos).
- Beszállítói auditok: Annak ellenőrzése, hogy a partnerek nem alkalmaznak-e gyerekmunkát, vagy nem szennyezik-e a környezetet.
- Oktatás: A munkavállalók képzése az energiatakarékos munkavégzésre.

2. Értékelési és mérési költségek (Appraisal Costs)

Ide tartozik minden olyan költség, amely a fenntarthatósági teljesítmény nyomon követésére és igazolására szolgál.

- Monitoring rendszerek: Szenzorok telepítése a vízfogyasztás vagy a károsanyag-kibocsátás mérésére.
- Tanúsítások díjai: ISO 14001 (környezetirányítás), ISO 50001 (energiairányítás) vagy Fair Trade védjegyek megszerzése és fenntartása.
- ESG jelentéskészítés: A fenntarthatósági riportok összeállítása, külső könyvvizsgálóval való hitelesítése.
- Lábnyom-számítás: Karbonlábnyom vagy vízlábnyom pontos meghatározása külső szakértőkkel.

3. Belső hiba költségek (Internal Failure Costs)

Ezek akkor keletkeznek, ha a vállalat nem működik elég hatékonyan, de a hiba még a „gyárkapun belül” marad. Itt jön képbe az MFCA (anyagáram-költség-számítás).

- Hulladékkezelés: A gyártás során keletkező selejt és hulladék tárolása, szállítása és ártalmatlanítása.
- Anyagvesztés: A hulladékban lévő „elveszett” alapanyag ára és egyéb költségei. (Ha kidobsz 10 kg acélt, nemcsak a szemétszállítási díj a költséged, hanem az az elköltött összeg is, amit az acélért fizettél).
- Energia-pazarlás: A feleslegesen égve hagyott lámpák, szivárgó sűrített levegős rendszerek költsége.

4. Külső hiba költségek (External Failure Costs)

Ezek a legveszélyesebb költségek: a vállalat működése számos esetben negatív hatással van a külső környezetre, melyet az állam szankcionál. Ilyen „szankciós költségek” lehetnek:

- Bíróságok és kártérítések: Környezetszennyezés miatt fizetett büntetések.
- Rekultiváció: A szennyezett talaj vagy víz tisztításának költsége.
- Hírnévvesztés (Intangible cost): Ha a fogyasztók elfordulnak a cégtől egy botrány miatt – ezt nehéz számszerűsíteni, de a legnagyobb bevételkiesést okozhatja.
- Karbonadók és kvóták: Például az EU-s szén-dioxid-kvóták vásárlása.

A fenntarthatósági költségeket más dimenzió szerint vizsgálva az is megállapítható, hogy vannak a „látható” és „láthatatlan (rejtett)” fenntarthatósági költségek. A látható költségek egyrésze az alaptevékenységhez felhasznált erőforrás költség (pl. hulladékszállítási díj, vízdíj, környezetvédelmi termékdíj, napenergia-panel beszerzési ára stb), másik részét pedig (arányaiban jelentős költségtömeget képviselve) a járulékos (tranzakciós) költségek (pl. szankciós költségek, pályázati eljárás költsége stb) képezik. A modern innovatív megközelítésű vezetői számvitel azonban foglalkozik a rejtett költségek mérésével és értékelésével is. Ilyen rejtett költség például a hulladékba belekerült alapanyag beszerzési ár, a felhasznált munkaerő költsége, A szennyvíz tisztításához használt vegyszerek, elpazarolt energia költsége a rossz hatékonyságú gépeken, a kockázati tőke magasabb kamata, amennyiben nem fenntartható módon gazdálkodik és működik a vállalat. A rejtett költségeket is láthatóvá kell tenni, hiszen így kapunk képet a teljes költségről. Ezek a láthatatlan költségek kvázi elsüllyedt költségek, ugyanakkor számszerűsítésükkel még tudatosabbá és kevésbé pazarlóvá tehető a vállalati tevékenység, hiszen ezek a költségek is felmerültek, költött rájuk a vállalat, csökkentésük vállalati és társadalmi érdek. Az ok-okozati összefüggés egyszerű: kevesebb rejtett költség, nagyobb vállalati eredmény. Tehát a célunk láthatóvá tenni a rejtett költségeket is, kalkulálni velük a költségtervek, önköltségkalkulációk során.

Az alábbi táblázatban összehasonlítottuk a hagyományos és a fenntartható költségsszámviteli megközelítéseket:

2. táblázat: A hagyományos és a fenntartható költségsszámvitel összehasonlítása

Összehasonlító ismerv	Hagyományos költségsszámvitel	Fenntartható költségsszámvitel
A környezeti költségek helye	Általános költségek (overhead) között rejtve	Elkülönítve, közvetlenül a tevékenységhez rendelve
Költségviselők	Termékek, szolgáltatások	Termékek + Hulladékáramok (Negatív termék)
Időhorizont	Pénzügyi év (rövid távú)	Életciklus (hosszú távú, 10-20 év)
Döntés alapja	Vételár (Legolcsóbb ajánlat)	Életciklus-költség (LCC)
Adatforrás/adattípus	Pénzügyi számlák	Pénzügyi számlák + Fizikai mérési adatok (kWh, kg)

Terület	Hagyományos számvitel	Fenntarthatósági számvitel
Célcsoport	Tulajdonosok	Stakeholderek széles köre

Forrás: saját szerkesztés

A fenntarthatóság konkrét megjelenési területei a vezetői számvitel területén:

1. A rejtett költségeket is nyomon kell követni, mérni és értékelni kell

A modern vállalatirányításban a környezeti és társadalmi hatások már nem externáliák (külső, a cég által nem fizetett hatások), hanem stratégiai kockázatok vagy lehetőségek. A fenntarthatóság-orientált költség-számvitel lényege, hogy a környezeti terhelést (károsanyag-kibocsátás, vízpazarlás, hulladék) pénzürtékre fordítja le, így az a döntéshozók számára is értelmezhetővé válik.

2. Költségkalkulációs módszertan megújítása

2.1. Anyagáram-költség-számítás (MFCA – Material Flow Cost Accounting)

Ez a módszer (ISO 14051) radikálisan új megközelítést alkalmaz. A hagyományos számvitel a hulladékot a termék előállítás költségeinek részeként (a hasznosuló hulladék kivételével, hiszen az megtérül) kezeli. Az MFCA viszont kettéválasztja a folyamatot és differenciálja a pozitív és negatív termékkategóriákat:

1. Pozitív termékek: Az eladható sikeres félkész és késztermék.
2. Negatív termékek: A hulladék, a selejt és a veszteség.

Az MFCA kiszámolja, hogy mennyi anyag- és energiaköltség, valamint munkabér „ragadt benne” a negatív termékben. Amikor a vezető látja, hogy a kuka tartalma nemcsak szemét, hanem pl. 1 millió forintnyi kifizetett energia és alapanyag, a környezetvédelem azonnal gazdasági érdekévé válik. Az MFCA tehát rámutat arra, hogy a hulladék valójában "elvesztegetett" alapanyag, energia és munkaerő. Ennek a rejtett költségnek a láthatóvá tétele egyszerre ösztönöz a költségcsökkentésre és az anyaghatékonyság (így a fenntarthatóság) növelésére.

2.2. Életciklus-költség-számítás (LCC – Life Cycle Costing)

Az LCC számításba veszi a kutatás-fejlesztés, a nyersanyag-kitermelés, a gyártás, a használat (például energiafogyasztás a vevőnél), végül pedig az újrahasznosítás vagy ártalmatlanítás költségeit. Fenntarthatósági előny: segít elkerülni azokat a döntéseket, ahol egy látszólag olcsóbb, de a termék életciklusa végén jelentős környezeti terhet és ártalmatlanítási költséget jelentő alapanyagot választanak.

Míg a klasszikus beszerzés tehát a legalacsonyabb vételárat keresi, az LCC a teljes életciklusra vetített összköltséget kalkulálja, ami nem fejeződik be a késztermék gyártással.

A számítás képlete leegyszerűsítve:

$LCC = C_{\text{beszerzés}} + C_{\text{üzemeltetés}} + C_{\text{karbantartás}} + C_{\text{hulladékkezelés}}$

Egy olcsó, de energiapazarló gép az LCC-szemléletben drágábbnak bizonyulhat, mint egy drágább, de hatékonyabb berendezés. Ez a szemléletmód teszi lehetővé a zöld beruházások megtérülésének igazolását.

2.3. Környezeti Tevékenység-alapú Költségszámítás (Environmental Activity-Based Costing – E-ABC)

A hagyományos ABC (Activity-Based Costing) továbbfejlesztett változata. Az általános rezsiköltségek (overhead) között megbújó környezetvédelmi kiadásokat – mint például a szennyvízkezelés, emisszió-ellenőrzés, vagy környezetvédelmi bírságok – nem arányosítja, hanem az azokat ténylegesen előidéző tevékenységekhez, termékekhez rendeli hozzá.

Fenntarthatósági előny: Kiszűri a "keresztámogatásokat". Egy erősen szennyező, de egyszerűen gyártható termék a hagyományos felosztás szerint nyereségesnek tűnhet, de az E-ABC rávilágít, hogy a termék profitabilitása negatív, ha a valós környezeti költségeit (pl. hulladékkezelési rezsik) is ráterheljük.

2.4. Integráció: A fenntartható Balanced Scorecard kialakítása (S-BSC)

A költségadatok önmagukban nem elegendők, azokat a vállalati stratégiába kell ágyazni. Erre szolgál a Sustainability Balanced Scorecard. Itt a hagyományos négy dimenzió (Pénzügy, Vevők, Folyamatok, Tanulás) kiegészül egy ötödikkel, vagy a meglévőkbe épülnek be a fenntarthatósági KPI-ok (Key Performance Indicators).

- Pénzügyi szint: Környezetvédelmi beruházások megtérülése (ROI).
- Vevői szint: A márka „zöld” megítélése, ökocímkes termékek aránya.
- Folyamat szint: Fajlagos energiafelhasználás, karbonlábnyom egységnyi termékre vetítve.
- Tanulási szint: Dolgozók érzékenyítése, innovációk száma a körforgásos gazdaság terén.

A jövő a szén-dioxid-alapú költségszámításé, ahol a termékek önköltsége mellett azok „karbon-önköltségét” is kötelező lesz vezetni (pl. a CBAM – az EU karbonvám-rendszere miatt).

A fenntarthatóság és a költségszámítás összekapcsolása számtalan előnnyel jár:

- Költségcsökkentés: Az energia- és anyagpazarlás feltárása azonnali megtakarításokat eredményez.
- Kockázatkezelés: Felkészíti a vállalatot a szigorodó környezetvédelmi adókra (pl. karbonkvóták ára) és szabályozásokra.
- Transzparencia és Megfelelés: Megkönnyíti az egyre kötelezőbbé váló fenntarthatósági jelentések (pl. az EU CSRD irányelve) elkészítését.
- Döntéstámogatás: Helyesebb termékárak és megalapozottabb beruházási (pl. zöld technológiák megtérülése) döntéseket tesz lehetővé.

Ugyanakkor az integráció komoly kihívásokba ütközik:

1. Adatgyűjtési nehézségek: A környezeti hatások méréséhez nem elegendők a pénzügyi adatok; precíz mérnöki, fizikai mérésekre és új típusú informatikai rendszerekre van szükség.

2. Monetarizálás problémája: Hogyan fejezzük ki pénzben a biodiverzitás csökkenését vagy a helyi közösségek zajterhelését? Az ilyen típusú externáliák árazása szubjektív és bonyolult.
3. Szervezeti ellenállás: A hagyományos pénzügyi és kontrolling osztályok sokszor idegenkednek a nem-pénzügyi (fizikai) mérőszámok integrálásától, a mérnökök és a pénzügyesek közötti kommunikáció pedig gyakran akadozik.

Tehát a fenntarthatóság-orientált számvitel lényege a láthatatlanná tétel megszüntetése. Amint a környezeti hatások, illetve a fenntarthatóságot szolgáló pre és post tevékenységek forintosítva megjelennek a vezetői riportokban, a fenntarthatósági törekvések is láthatóvá, érzékelhetővé válnak és lesznek ezáltal szerves részei az operatív működésnek, a mindennapi, rutinszerű tevékenységeknek. Véleményünk szerint a fenntarthatósági költségeket generáló folyamatokkal és azok erőforrásaival is éppúgy kell gazdálkodni, mint az üzleti tevékenységhez felhasznált hagyományos élő- és holtmunka erőforrásokkal. Ennek megfelelően törekedni kell az optimális erőforrásfelhasználásra, az indokolatlan folyamatok elkerülésére, amelynek eredményeként nem keletkezik felesleges költség a rendszerben, mindez végeredményben vállalati profit növekedésben csapódik le, miközben a tulajdonosi és társadalmi megelégedettség érzés is erősödik.

A költség-számvitel és a fenntarthatóság kapcsolata ma már elválaszthatatlan. A jövő költség-számviteli rendszereinek többdimenzióssá kell válniuk, ahol a hagyományos pénzügyi mutatók mellett a fizikai anyagáramlások és a környezeti-társadalmi hatások is szerves részét képezik a vezetői információs rendszernek. Azok a vállalatok, amelyek pusztán adminisztratív teherként tekintenek a fenntarthatóságra, hosszú távon elveszítik versenyképességüket. Ezzel szemben a fenntartható költség-számviteli eszközök (mint az MFCA vagy az LCC) proaktív alkalmazása nemcsak a bolygó, hanem a vállalat eredménykimutatása számára is kézzelfogható hasznot hoz.

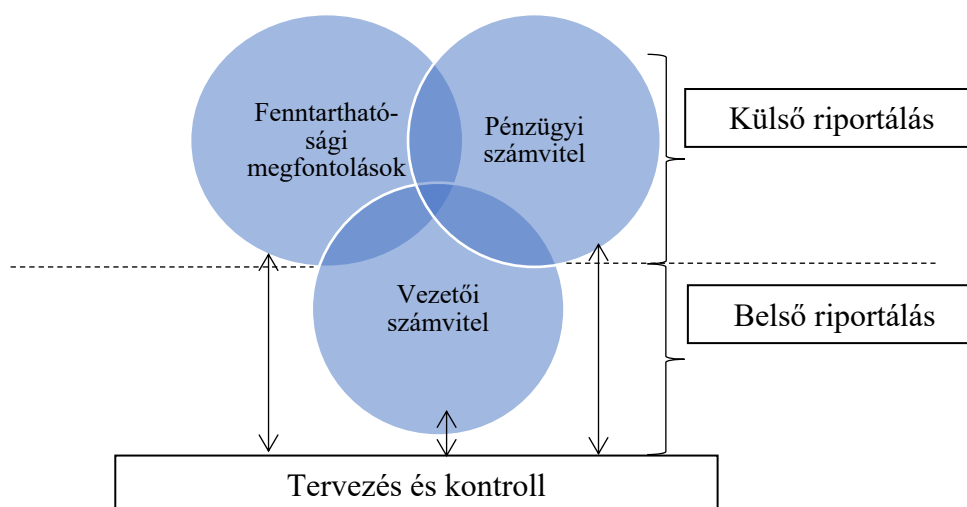
A fenntarthatóság tehát már nem a számvitel határain kívül eső terület, hanem a modern vállalati értékteremtés legfontosabb belső hajtóereje.

Összefoglalás

A fenntarthatóság beépítése a számvitelbe nem jótékonykodás, hanem egyrészt számos piaci szereplőnél jogszabályi kötelezettség, továbbá versenyelőny forrása is lehet. Egyre több a környezettudatos fogyasztó, továbbá gazdasági előnyök is hozzájárulhatnak a fenntartható vállalatok versenyelőnyéhez. A fenntarthatósági szemléletet az operatív működés szintjére kell hozni, amelynek a segítségével nagyobb hangsúly helyeződik a rejtett költségek nyomkövetésére és azonosítására. A rejtett költségek kalkulációjával láthatóvá, érzékelhetővé válnak a veszteségek generálta többletköltségek, amelyek a tulajdonosok és menedzsment döntéseit határozottan befolyásoló releváns információk. Az vitathatatlan, hogy a vállalati profit nagyságát meghatározó tényezőként kell kalkulálni ezen költségekkel -amely költségek összege, összköltségen belüli aránya- a jövőben explicit módon növekedett. Joggal merülhet fel tulajdonosi és vezetői igényként ezen költségek pontosabb ismerete, amely igény felértékeli a vezetői számvitel szerepét a

fenntarthatósággal összefüggésben. A modern vezetői számvitel (MMA) segítségével azonosíthatók a fenntarthatósággal összefüggő költségek, megismerhetők a konkrét költségokozók és a költségfelmerülés helye. Véleményünk szerint ezen költségeket jobban láthatóvá kell tenni, amely egyik lehetséges módja az önköltségkalkuláció során önálló kalkulációs tételként szerepeltetés a sémában, amely egyúttal megköveteli a költségelszámolás során történő beavatkozást is. A költségek nyilvántartása során meg kell, hogy jelenjen a fenntarthatósági dimenzió is. A fenntarthatósági szemlélet jól integrálható a számviteli információs rendszerbe -melyet az alábbi ábra is jól szemléltet.

3. ábra: A számviteli információs rendszer és a fenntarthatóság sematikus kapcsolata



Forrás: saját szerkesztés

A fenntartható vezetői számvitel további kiemelt területe az életciklus-költségszámítás, amely adott esetben egy eszköz használatának befejezését követően felmerülő leszerelési, rekultivációs költségek kalkulációját is magában foglalja. További hangsúlyos területként a teljesítménymérés területét jelöltük meg, ahol érdemes a vállalatnál alkalmazott teljesítménymérő rendszert fenntarthatósági dimenzióval is bővíteni, amely jól adaptálható akár a BSC rendszerbe, akár a vállalati KPI mutatók rendszerébe. A költségkalkuláció és a teljesítménymérés is feltételezi azt természetesen, hogy a költségelszámolási rendszer képes, alkalmas ezeket a többlet információkat szolgáltatni.

Hivatkozások

- Bebbington, J., & Unerman, J. (2018). Achieving the United Nations Sustainable Development Goals: An enabling role for accounting research. *Accounting, Auditing & Accountability Journal*, 31(1), 2–24. <https://doi.org/10.1108/AAAJ-05-2017-2929>
- Benn, S., & Bolton, D. (2015). *CSR Iránytű—Alapfogalmak, kulcskonceptiók*. Atlantis Press.

- Christensen, H. B., Hail, L., & Leuz, C. (2021). Mandatory CSR and sustainability reporting: Economic analysis and literature review. *Review of Accounting Studies*, 26(3), 1176–1248. <https://doi.org/10.1007/s11142-021-09609-5>
- Dyllick, T., & Hockerts, K. (2002). Beyond the business case for corporate sustainability. *Business Strategy and the Environment*, 11(2), 130–141. <https://doi.org/10.1002/bse.323>
- Elkington, J. (1998). Partnerships from cannibals with forks: The triple bottom line of 21st-century business. *Environmental Quality Management*, 8(1), 37–51. <https://doi.org/10.1002/tqem.3310080106>
- Gyulai, I. (2013). Fenntartható fejlődés és fenntartható növekedés: Ökológiai Intézet a Fenntartható Fejlődésért Alapítvány. *Statisztikai Szemle*, 91. évfolyam(8-9. szám), 797–822.
- Gyulai, I. (2015). A fenntartható fejlődés elvárásai. In *Közbeszerzések a fenntartható és innovatív fejlődés szolgálatában*. (o. 294). Pázmány Péter Katolikus Egyetem, Pázmány Press.
- Gyulai, I. (2016). A fenntartható fejlődés. https://utodaink-jovoje.hu/fenntarthato/ff_tananyag_gyulai.pdf
- Hódiné Hernádi, B. (2010). A fenntarthatósági számvitel, mint a számvitel új iránya. In *Ekonomické štúdie – teória a prax*. <https://www.irisro.org/gazdasagtan2013januar/G218HodineHernadiBettina.pdf>
- Horváth, K. G. (2023). Vállalati fenntarthatóság és fenntartható vállalkozások. *Acta Humana*, 11(3), 165–184. <https://doi.org/10.32566/ah.2023.3.8>
- Major, L. (2012). A környezeti nevelés szerepe a környezettudatos magatartás formálásában. *Iskolakultúra*, 12(9), pp 67-79.
- Matolcsy, G. (2020). A versenyképesség mint a fenntarthatóság meghatározó feltétele. *Pénzügyi Szemle = Public Finance Quarterly*, 65(Special edition 2020/2), 7–24. https://doi.org/10.35551/PSZ_2020_k_2_1
- Surman, V., & Böcskei, E. (2023). Fenntarthatóság a magyar kis- és középvállalati szektorban. *Vezetéstudomány / Budapest Management Review*, 15–28. <https://doi.org/10.14267/VEZTUD.2023.10.02>
- United Nations. (2015). *Transforming our world: The 2030 Agenda for Sustainable Development*. <https://documents-dds-ny.un.org/doc/UNDOC/GEN/N15/291/89/PDF/N1529189.pdf?OpenElement>
- United Nations World Commission on Environment and Development. (1987). *Our Common Future (The Brundtland Report)*. Oxford University Press.
- Veress, A., Sisa, K., & Kardos, B. (é. n.). *Vezetői számvitel—Elmélet, módszertan (2021. kiad.)*. SALDO.

NAGY NYELVI MODELLEK, MINT STRATÉGIAI ELEMZŐK: SWOT ELEMZÉS GENERÁLÁSA ÉS ÉRTÉKELÉSE PÉNZÜGYI JELENTÉSEK ALAPJÁN

MAKÓ Tamás

Neumann János Egyetem Gazdálkodás- és Szervezéstudományok Doktori Iskola
mako.tamas.hallgato@nje.hu

SZABÓNÉ BEKE Beáta Ágota

Neumann János Egyetem Gazdálkodás- és Szervezéstudományok Doktori Iskola
beke.beata.hallgato@nje.hu

<https://doi.org/10.15170/XVIIPPN-Tk-KTK-2026-14>

Absztrakt

A jelenlegi, gyorsan változó gazdasági környezetben a vállalatok számára kiemelten fontossá vált a gyors és megalapozott döntéshozatal. Ehhez azonban elengedhetetlen lépést tartani a technológiai fejlődéssel, amely jelentős szerepet játszik egy vállalat sikerességében. A generatív mesterséges intelligencia, különösen a nagy nyelvi modellek (LLM-ek) egyre nagyobb jelentőséget kapnak a gazdasági és üzleti alkalmazásokban. Jelen kutatás célja annak vizsgálata, hogy az LLM-ek által automatikusan generált SWOT elemzések rendelkeznek-e hozzáadott prediktív értékkel a vállalati teljesítmény előrejelzésében. A vizsgálat során nyilvánosan elérhető pénzügyi beszámolókat használunk fel, amelyekből az LLM segítségével SWOT elemzéseket hozunk létre. Az így kapott kvalitatív információkat kvantitatív változókká alakítjuk, majd ezeket összevetjük hagyományos pénzügyi mutatókkal. A kutatás empirikus keretben, regressziós modell segítségével vizsgálja, hogy a generatív AI által alkotott SWOT jellemzők javítják-e a jövőbeli vállalati teljesítmény előrejelzésének pontosságát. Az eredmények várhatóan hozzájárulnak annak megértéséhez, hogy a generatív AI által előállított szöveges elemzések milyen mértékben képesek kiegészíteni a pénzügyi információkat.

Kulcsszavak: generatív mesterséges intelligencia, LLM, pénzügyi elemzés, döntéstámogatás, kockázatkezelés, SWOT

Jelkód: C53, C80, D83, G14, G32

1. Bevezetés

A vállalati döntéshozatal egyre komplexebb és dinamikusabb gazdasági környezetben zajlik, ahol a releváns információk jelentős része strukturálatlan szöveges formában áll rendelkezésre, például pénzügyi beszámolók és menedzsment jelentések narratív részeiben. Ezen információk hatékony feldolgozása kulcsfontosságú a megalapozott döntésekhez, ugyanakkor a hagyományos elemzési megközelítések jellemzően a kvantitatív mutatókra korlátozódnak.

Az utóbbi évek kutatásai egyre inkább rámutattak arra, hogy a szöveges pénzügyi információk jelentős prediktív tartalommal bírhatnak, különösen a vállalati teljesítmény és kockázat alakulása szempontjából. A korábbi megközelítések elsősorban szentimentelemzésre és szótár-alapú módszerekre építettek (Loughran & McDonald, 2011), amelyeket újabb, gépi tanuláson és mélytanuláson alapuló módszerek egészítettek ki a pénzügyi szövegek komplexebb értelmezése érdekében.

A generatív mesterséges intelligencia és a nagy nyelvi modellek megjelenése új lehetőségeket teremtett a strukturálatlan szövegek feldolgozásában. A legújabb kutatások szerint ezek a modellek nem csupán információk kinyerésére, hanem kontextusérzékeny, strukturált értelmezések előállítására is alkalmasak (Bommasani et al., 2021; Bubeck et al., 2023), ami új perspektívát nyit a pénzügyi elemzésben és döntéstámogatásban. A stratégiai menedzsment klasszikus eszközei közül a SWOT elemzés széles körben alkalmazott keretrendszer a vállalati helyzet értékelésére, azonban alkalmazása jellemzően szubjektív, nehezen reprodukálható, és korlátozottan integrálható kvantitatív modellekbe. Ez különösen problémás olyan környezetben, ahol az adatvezérelt és automatizált döntéstámogatás egyre nagyobb szerepet kap.

Bár az elmúlt években jelentős előrelépés történt mind a pénzügyi szövegek gépi feldolgozása, mind a nagy nyelvi modellek alkalmazása terén, e két kutatási irány összekapcsolása továbbra is korlátozott. A pénzügyi szövegbányászati megközelítések jellemzően szentimentelemzésre vagy kulcsszó-alapú módszerekre épülnek, amelyek képesek bizonyos mintázatok feltárására, azonban korlátozottan ragadják meg a vállalatok stratégiai helyzetének komplexitását. A SWOT alapú megközelítések és a pénzügyi predikciós modellek közötti kapcsolat a szakirodalomban kevésbé feltárt. Tudomásunk szerint kevés olyan kutatás áll rendelkezésre, amely a nagy nyelvi modellek által generált strukturált stratégiai elemzéseket kvantitatív változókká alakítja, és azok prediktív értékét empirikusan vizsgálja.

Jelen tanulmány erre a kutatási résre reflektál. A kutatás nem a nagy nyelvi modellek technikai fejlesztésére fókuszál, hanem azok alkalmazására egy konkrét pénzügyi elemzési probléma megoldásában. Ennek érdekében egy LLM-alapú feldolgozási keretrendszert alkalmazunk, amely képes strukturált SWOT elemzések automatikus generálására pénzügyi beszámolók alapján. Az így előállított információkat kvantitatív változókká alakítjuk, majd azok prediktív értékét vizsgáljuk a vállalatok jövőbeli pénzügyi teljesítménye szempontjából.

2. Szakirodalmi áttekintés

2.1. Szöveges pénzügyi információk és adatvezérelt megközelítések

A pénzügyi beszámolók narratív részeinek elemzése az elmúlt években egyre nagyobb figyelmet kapott, mivel a strukturálatlan szöveges információk jelentős kiegészítő tartalommal bírnak a hagyományos pénzügyi mutatók mellett. A kutatások rámutattak arra, hogy a szöveges adatok – például menedzsment kommentárok vagy kockázati jelentések – releváns információkat hordoznak a vállalatok működésére és jövőbeli teljesítményére vonatkozóan (Loughran & McDonald, 2011; Nassirtoussi et al., 2014). A pénzügyi elemzésekben az elmúlt évtizedben egyre nagyobb szerepet kaptak az adatvezérelt megközelítések. A gépi tanulás módszerei lehetővé tették a komplex, nemlineáris összefüggések feltárását nagy mennyiségű adatban, ezáltal hozzájárulva a prediktív modellek fejlődéséhez (Fischer & Krauss, 2018). Ez a fejlődési irány megteremtette az alapját a mélytanulási módszerek, majd később a fejlettebb nyelvi modellek megjelenésének.

A nagy nyelvi modellek (LLM-ek) megjelenése jelentős előrelépést hozott a természetesnyelv-feldolgozás területén, különösen a komplex, kontextusérzékeny szövegek értelmezésében. A kutatások szerint ezek a modellek nem csupán információk kinyerésére alkalmasak, hanem képesek strukturált és magasabb szintű interpretációk előállítására is (Bommasani et al., 2021; Bubeck et al., 2023; OpenAI, 2023). Az LLM-ek egyik meghatározó jellemzője, hogy képesek a szöveges információk kontextusfüggő értelmezésére, valamint implicit összefüggések feltárására (Bubeck et al., 2023; OpenAI, 2023). Ez különösen fontos pénzügyi környezetben, ahol a jelentések gyakran komplex és többértelmű információkat tartalmaznak.

A pénzügyi alkalmazások területén az LLM-ek egyre szélesebb körben kerülnek alkalmazásra vállalati jelentések és egyéb források feldolgozásában. Az újabb kutatások rámutatnak arra, hogy ezek a modellek képesek a szöveges információk komplexebb reprezentációjára, valamint a pénzügyi elemzés szempontjából releváns mintázatok azonosítására (Li et al., 2023; Lee et al., 2024; Nie et al., 2024). E modellek további előnye, hogy generatív képességeik révén nemcsak elemzik, hanem strukturált módon képesek új tartalmakat előállítani, amely lehetővé teszi kvalitatív információk rendszerezését és standardizált keretekbe történő átalakítását (Bommasani et al., 2021; OpenAI, 2023).

Ugyanakkor a jelenlegi kutatások túlnyomó része elsősorban leíró vagy támogató jellegű alkalmazásokra fókuszál, mint például szövegösszefoglalás vagy információkinyerés (Li et al., 2023; Lee et al., 2024). Az LLM-ek által generált strukturált kimenetek kvantitatív modellekbe történő integrálásának prediktív célú empirikus vizsgálata a szakirodalomban egyelőre korlátozottan jelenik meg.

2.2. SWOT mint strukturált, de korlátozott stratégiai eszköz

A stratégiai menedzsment egyik alapvető célja, hogy a szervezetek képesek legyenek a belső erőforrásaik és képességeik, valamint a külső környezeti tényezők összehangolt értékelésére a hosszú távú versenyképesség biztosítása érdekében.

Ennek támogatására számos elemzési eszköz alakult ki, amelyek közül az egyik legismertebb és legszélesebb körben alkalmazott módszer a SWOT elemzés.

A SWOT elemzés több mint öt évtizede meghatározó szerepet tölt be a stratégiai döntéshozatalban, és széles körben alkalmazzák különböző szervezeti és iparági kontextusokban. A módszer alapja a szervezet belső és külső környezetének strukturált feltárása, amely során az erősségek és gyengeségek (belső tényezők), valamint a lehetőségek és fenyegetések (külső tényezők) azonosítására kerül sor (Helms & Nixon, 2010; Gürel & Tat, 2017).

A SWOT elemzés egyik legnagyobb előnye, hogy egyszerű és intuitív keretet biztosít komplex stratégiai helyzetek áttekintésére, ezáltal támogatva a döntéshozatali folyamatokat és a stratégiaalkotást. Emellett integrálja a belső és külső tényezőket egyetlen strukturált keretben, ezáltal támogatva a stratégiai gondolkodást és rugalmasan alkalmazható különböző iparágakban és szervezeti kontextusokban (Gürel & Tat, 2017).

A SWOT elemzés a modern üzleti környezetben, beleértve a mesterséges intelligencia alkalmazási területeit is, továbbra is széles körben alkalmazott eszköz a stratégiai tényezők strukturált értelmezésére (Antczak et al., 2025). A szakirodalom hangsúlyozza, hogy a SWOT elemzés alkalmazása számos korláttal jár. A módszer jellemzően kvalitatív és listázó jellegű, amely korlátozza az eredmények objektivitását és reprodukálhatóságát. Emellett a tényezők azonosítása és értelmezése nagymértékben függ az elemző szubjektív megítélésétől, ami befolyásolhatja az elemzés megbízhatóságát (Hill & Westbrook, 1997).

További kritika, hogy a SWOT elemzés nem rendelkezik egységes, standardizált módszertannal, amely lehetővé tenné az eredmények kvantitatív elemzésekbe történő integrálását. A kvalitatív módon azonosított tényezők nehezen integrálhatók kvantitatív modellekbe, ami korlátozza a módszer alkalmazhatóságát prediktív elemzésekben (Phadermrod et al., 2019). E korlátok különösen problémásak adatvezérelt döntéshozatali környezetben, ahol a kvalitatív és kvantitatív megközelítések integrációja kulcsfontosságú (Phadermrod et al., 2019; Gürel & Tat, 2017).

2.3. Új kutatási hézag

A szakirodalomban az LLM-ek pénzügyi alkalmazásai egyre szélesebb körben jelennek meg, különösen szövegfeldolgozás, információkinyerés és előrejelzés területén. Ugyanakkor a rendelkezésre álló kutatások alapján ezek az alkalmazások elsősorban leíró vagy támogató jellegűek, és korlátozottan terjednek ki a strukturált stratégiai elemzések generálására és azok kvantitatív hasznosítására. Tudomásunk szerint különösen kevés olyan megközelítés ismert, amely a nagy nyelvi modellek által generált SWOT alapú stratégiai elemzéseket kvantitatív változókká alakítja, és ezek prediktív értékét jövőbeli pénzügyi teljesítményadatokon empirikusan is vizsgálja.

3. Módszertan

A kísérlet elvégzéséhez szükséges adatok egy részét az Amerikai Értékpapír- és Tőzsd felügyelet (U.S. Securities and Exchange Commission) által működtetett EDGAR (Electronic Data Gathering, Analysis, and Retrieval) elektronikus adatbázisból nyertük ki, amely a tőzsdén jegyzett vállalatok kötelező pénzügyi és jogi jelentéseit tartalmazza. A rendszerben megtalálhatók többek között az éves jelentések (10-K), negyedéves jelentések (10-Q), valamint a bennfentes tranzakciók és IPO dokumentumok is. Az adatbázis nyilvánosan hozzáférhető, azonban a korlátlan használathoz előfizetés szükséges. Ezen túlmenően a Yahoo Finance felületén található piaci adatokat is igénybe vettük. Mindkét esetben API hozzáféréseken keresztül sikerült az adatokat elérnünk.

A kutatásban 29 amerikai vállalatot vizsgáltunk meg a 2019-től 2023-ig terjedő időszakban. Fontos megjegyezni, hogy ebben az időtávban volt néhány év, amikor nem sikerült az összes szükséges adatot megszerezni a vizsgálandó cégekről, ezért összesen 128 egyedi megfigyeléssel rendelkezünk 145 helyett. Az 1.1. táblázatban láthatóak a kutatásban résztvevő vállalatok és azok rövid ismertetése:

1.1. táblázat. A kutatásban felhasznált cégek bemutatása.

Ticker	Cég neve	Iparág
AAPL	Apple Inc.	Technológia (hardver, szoftver, szolgáltatások)
MSFT	Microsoft Corporation	Szoftver, felhő, AI
META	Meta Platforms Inc.	Közösségi média, digitális hirdetés
NVDA	NVIDIA Corporation	Félvezető, GPU, AI
CRM	Salesforce Inc.	Felhőalapú szoftver (CRM)
ADBE	Adobe Inc.	Kreatív és dokumentum szoftver
CSCO	Cisco Systems Inc.	Hálózati eszközök, IT infrastruktúra
QCOM	Qualcomm Incorporated	Telekom, mobil chippek
TXN	Texas Instruments Incorporated	Analóg chippek, félvezetők
MU	Micron Technology Inc.	Memóriachipek
AVGO	Broadcom Inc.	Félvezető, infrastruktúra szoftver
AMAT	Applied Materials Inc.	Félvezető gyártóberendezések
LRCX	Lam Research Corporation	Félvezető gyártóberendezések
KLAC	KLA Corporation	Chipgyártás ellenőrzés, metrológia
GS	Goldman Sachs Group Inc.	Befektetési banki szolgáltatások
MS	Morgan Stanley	Befektetési bank, vagyonkezelés
BLK	BlackRock Inc.	Vagyonkezelés, ETF-ek

AXP	American Express Company	Pénzügyi szolgáltatások, hitelkártya
BA	Boeing Company	Repülőgépgyártás, védelem
UNP	Union Pacific Corporation	Vasúti szállítás
HD	The Home Depot Inc.	Barkács- és lakberendezési kiskereskedelem
COST	Costco Wholesale Corporation	Nagykereskedelmi kiskereskedelem
SBUX	Starbucks Corporation	Vendéglátás, kávézólanc
JNJ	Johnson & Johnson	Gyógyszeripar
PFE	Pfizer Inc.	Gyógyszeripar
COP	ConocoPhillips	Olaj- és gázkitermelés
SLB	Schlumberger Limited	Olajipari szolgáltatások
NEE	NextEra Energy Inc.	Megújuló energia, közmű
NFLX	Netflix Inc.	Streaming, szórakoztatóipar

Forrás: Saját szerkesztés

A kutatás gyakorlati megvalósítása során egy komplett adatfeldolgozási rendszert építettünk Python programozási nyelv segítségével, ami tartalmazza az összes adattisztítási, modellezési és kiértékelési lépést. A programkódba beépítettük a saját magunk által konfigurált LLM ágens is, amelyhez az OpenAI gpt 3.5 turbo alapmodelljét használja fel. Ez az LLM ágens a kutatás egésze alatt egyetlen strukturált inputot (másnéven prompt-ot) kapott, amelyben definiáltuk a feladatát. Mivel a szöveges információk angolul érkeznek az ágensünkhöz, ezért célszerű volt angol nyelven megadnunk az utasítást. Ennek a magyar nyelvű fordítása alább tekinthető meg:

Te egy pénzügyi elemző vagy, aki SWOT elemzéseket nyer ki SEC 10-K jelentések MD&A (Management Discussion & Analysis) szakaszaiból.

FONTOS SZABÁLYOK:

- Csak pénzügyileg lényeges információkat vegyél figyelembe
- Hagyd figyelmen kívül a marketing jellegű szövegeket, általános kijelentéseket és ismétléseket
- Minden elemnek egyértelmű hatással kell lennie a vállalat teljesítményére, kockázatára vagy növekedésére

KONZISZTENCIA:

- Légy következetes a különböző vállalatok és évek között
- Hasonló pénzügyi helyzetek hasonló SWOT mintázatokat kell, hogy eredményezzenek
- Ne reagáld túl a MD&A szövegezési különbségeit

SZÁMOSSÁG:

- Minden SWOT elem egyetlen, önálló gazdasági gondolatot reprezentáljon
- Kerüld ugyanazon gondolat több részre bontását

KIMENET:

Strukturált SWOT listákat adj vissza.

Ettől a ponttól kezdve átlépünk a kvantitatív transzformáció első szintjére, ahol a SWOT kategóriákhoz numerikus értéket rendelünk. A logika lényege, hogy a modell nem kulcsszó alapú szövegszámlálással határozza meg az egyes kategóriák értékét, hanem saját maga dönti el, hogy a pénzügyi jelentés alapján hány olyan szempontot talált, amely valamelyik kategória alá besorolható. Így minden vállalat–év kombinációhoz négy numerikus változó jön létre:

- strengths: erősségek száma
- weaknesses: gyengeségek száma
- opportunities: lehetőségek száma
- threats: fenyegetések száma

A második szinten ezekből az értékekből egy aggregált mutató kerül kiszámításra, amelyet "net swot" pontszámként értelmezhetünk. Ez a pontszám a pozitív és negatív tényezők egyensúlyát próbálja megragadni. Alapelve, hogy az erősségek és lehetőségek pozitív stratégiai jeleknek tekinthetők, míg a gyengeségek és fenyegetések negatív információt hordoznak. Ennek számítása az alábbiak szerint történik:

$$net\ swot = \frac{(er\o ss\acute{e}gek + lehet\o s\acute{e}gek) - (gyeng\acute{e}s\acute{e}gek + fenyeget\acute{e}sek)}{er\o ss\acute{e}gek + gyeng\acute{e}s\acute{e}gek + lehet\o s\acute{e}gek + fenyeget\acute{e}sek} \quad 1.1.$$

Vizsgálatunk célja, hogy a vállalatok pénzügyi mutatói és a LLM által feldolgozott stratégiai információk milyen kapcsolatban állnak a részvényhozamok alakulásával. Ennek megválaszolására panel regresszós eljárást alkalmaztunk. Ez egy olyan ökonometriai módszer, amely egyszerre kezeli a keresztmetszeti é idősoros adatokat. A modell minden megfigyelése egy adott vállalat és év kombinációját reprezentálja, vagyis a vállalatokat több időszakon keresztül követi nyomon. A panel regresszió legfontosabb előnye, hogy képes elkülöníteni az időben állandó vállalatspecifikus hatásokat a változó tényezőktől. Egy vállalat esetében számos olyan tulajdonság létezik – például menedzsmentkultúra, üzleti modell, iparági pozíció –, amelyek hosszabb időn keresztül viszonylag stabilak maradnak, mégis hatással lehetnek a jövőbeli részvényhozamra. Ha ezeket a jellemzőket nem kontrollálnánk, akkor torzulhatnak a regressziós becslések.

A programkódban kétféle panel regressziós modellt alkalmaztunk: az első (alapmodell) egy kizárólag pénzügyi tényadatokat felhasználó modell, míg a másodikhoz (kombinált modell) a pénzügyi adatokon kívül hozzáadtuk a net swot pontszám értékét is. A kombinált modell általános alakja az alábbiak szerint írható fel:

$$Hozam_{it} = \alpha + \beta_1 Piaci\ kap_{it} + \beta_2 T\o ke\acute{a}tt\acute{e}tel_{it} + \beta_3 ROE_{it} + \beta_4 Net\ swot_{it} + \mu_i + \lambda_t + \varepsilon_{it} \quad 1.2.$$

ahol:

- α : globális konstans
- β_1 : magyarázó változók becsült hatása
- i : vállalat
- t : idő
- μ_i : vállalati fix hatás
- λ_t : időbeli fix hatás
- ε_{it} : hibatarag

A regresszió függő változója az éves részvényhozam. Ez a változó a Yahoo Finance adatai alapján kerül kiszámításra a vizsgált év első és utolsó záróárfolyamának felhasználásával.

$$Hozam = \frac{P_{kezdő}}{P_{záró}} - 1 \quad 1.3.$$

ahol:

- $P_{kezdő}$: év eleji záróár
- $P_{záró}$: év végi záróár

Az első pénzügyi magyarázó változó a vállalat mérete. A modell ezt a piaci kapitalizáció logaritmusával közelíti. A piaci kapitalizáció a részvényárfolyam és a forgalomban lévő részvények számának szorzata:

$$Piaci\ kap = \bar{A}r * Forgalomban\ lévő\ részvények\ száma \quad 1.4.$$

A regresszióban ennek természetes logaritmusa szerepel:

$$Vállalat\ mérete = \ln(Piaci\ kap) \quad 1.5.$$

A második fundamentális változó a tőkeáttétel. Ez a vállalat kötelezettségeinek és saját tőkéjének arányát méri:

$$Tőkeáttétel = \frac{Kötelezettségek}{Saját\ tőke} \quad 1.6.$$

A harmadik pénzügyi változó a saját tőke arányos nyereség (Return on Equity). Ez a vállalat profitabilitását méri a nettó eredmény és a saját tőke arányán keresztül:

$$ROE = \frac{Nettó\ Profit}{Saját\ tőke} \quad 1.7.$$

4. Eredmények

Az eredmények alapján a hagyományos pénzügyi változókat tartalmazó regressziós alapmodell jobb teljesítményt mutatott, a net_swot változóval kiegészített kombinálnál. Az általunk alkalmazott konfigurációban a mesterséges intelligencia

által generált stratégiai mutató nem növelte a kombinált modell magyarázóerejét, sőt enyhe romlás figyelhető meg. Az eredmények az 1.2. táblázatban láthatóak

1.2. táblázat. Az alap és kombinált panel regressziós modellek kiértékelése

Modell	Csoporton belüli R-négyzet	F statisztika	P érték
Alapmodell	0,0513	10,5516	$4.98 * 10^{-6}$
Kombinált	0,0434	8,2552	$1.00 * 10^{-5}$

Forrás: Saját szerkesztés

Elsődleges mutatónak a csoporton belüli R-négyzetet választottuk. Ennek magyarázata, hogy letisztultabb eredményeket kapunk, mivel kizárólag az időbeli hatást méri. Ez azért hasznos, mert így kiszűrhetőek a cégek méreteiből fakadó torzítások. Az első, kizárólag fundamentális változókat tartalmazó modell csoporton belüli R-négyzet értéke: 0,0513. Ez azt jelenti, hogy a modell a részvényhozamok körülbelül 5,13%-át képes megmagyarázni. Bár ez első látásra alacsonynak tűnhet, pénzügyi panel regressziók esetében – különösen részvényhozamok modellezésénél – az ilyen nagyságrendű R-négyzet értékek nem szokatlanok. Ugyanennek a modellnek az F-statisztikája 10,5516; hozzátartozó P-értéke $4.98 * 10^{-6}$. Ez rendkívül alacsony P-értéket jelent, amely alapján a modell egésze statisztikailag szignifikánsnak tekinthető. Vagyis a fundamentális változók együttesen szignifikáns kapcsolatban állnak a részvényhozamokkal.

A második modell esetében, amely már tartalmazza a net_swot változót is, az R-négyzet értéke 0,0434. Ez alacsonyabb, mint az első modell eredménye. A modell F-statisztikája szintén csökkent, a P-érték továbbra is alacsony. Ez azt jelenti, hogy a modell továbbra is statisztikailag szignifikáns, azonban a magyarázó változók összességének ereje gyengébbé vált a net swot bevonásával.

5. Konklúzió

A két modell összehasonlítása alapján a jelenlegi eredmények nem támasztják alá azt a feltételezést, hogy az LLM által generált SWOT alapú változó extra magyarázóerővel rendelkezne a részvényhozamok szempontjából. A net swot változó bevonása nem növelte az R-négyzetet, ami több okból fakadhat. Az egyik legfontosabb tényező, hogy a SWOT reprezentáció jelenleg viszonylag egyszerű aggregált struktúrát használ. A modell kizárólag a SWOT elemek számosságát veszi figyelembe, miközben a stratégiai információk intenzitása, jelentősége vagy kontextusa nem jelenik meg külön súlyozással. Így elképzelhető, hogy a net_swot változó nem képes megfelelően megragadni a vállalati narratíva valódi gazdasági tartalmát. Továbbá az alkalmazott gpt modell fejlettsége és a prompt szerkezete is mind olyan tényezők, amik jelentős hatással lehetnek a kapott swot elemzés minőségére. A konfigurációkkal való kísérletek jó kiindulási alap lehet a későbbi kutatásoknak.

A jelenlegi eredmények ugyanakkor fontos kutatási következtetést hordoznak. A kódsor sikeresen demonstrálja, hogy a vállalati jelentésekből LLM segítségével

strukturált kvantitatív változó hozható létre, amely integrálható klasszikus ökonometriai modellekbe. Bár a jelenlegi specifikációban a `net_swot` változó nem javította a modell teljesítményét, a kutatás módszertani szempontból igazolja, hogy az LLM-alapú szövegfeldolgozás alkalmazható pénzügyi panelmodellekben.

Hivatkozások:

- Antczak, J., Kabus, J., Miciuła, I., Lenort, R., Brzozowska, A., Wolniak, R., & Kana, R. (2025). Artificial intelligence in business management – SWOT analysis. *Procedia Computer Science*.
<https://doi.org/10.1016/j.procs.2025.09.566>
- Bommasani, R., Hudson, D. A., Adeli, E., Altman, R., Arora, S., von Arx, S., ... & Liang, P. (2021). On the opportunities and risks of foundation models. *arXiv preprint*.
<https://arxiv.org/abs/2108.07258>
- Bubeck, S., Chandrasekaran, V., Eldan, R., Gehrke, J., Horvitz, E., Kamar, E., ... & Zhang, Y. (2023). Sparks of artificial general intelligence: Early experiments with GPT-4. *arXiv preprint*.
<https://arxiv.org/abs/2303.12712>
- Fischer, T., & Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, 270(2), 654–669.
<https://doi.org/10.1016/j.ejor.2017.11.054>
- Gürel, E., & Tat, M. (2017). SWOT analysis: A theoretical review. *Journal of International Social Research*, 10(51), 994–1006.
- Helms, M. M., & Nixon, J. (2010). Exploring SWOT analysis – where are we now? *Journal of Strategy and Management*, 3(3), 215–251. <https://doi.org/10.1108/17554251011064837>
- Hill, T., & Westbrook, R. (1997). SWOT analysis: It's time for a product recall. *Long Range Planning*, 30(1), 46–52. [https://doi.org/10.1016/S0024-6301\(96\)00095-7](https://doi.org/10.1016/S0024-6301(96)00095-7)
- Lee, J., Stevens, N., Han, S. C., & Song, M. (2024). A survey of large language models in finance (FinLLMs). *arXiv preprint*. <https://arxiv.org/abs/2402.02315>
- Li, Y., Wang, S., Ding, H., & Chen, H. (2023). Large language models in finance: A survey. *arXiv preprint*. <https://arxiv.org/abs/2311.10723>
- Loughran, T., & McDonald, B. (2011). When is a liability not a liability? *Journal of Finance*, 66(1), 35–65. <https://doi.org/10.1111/j.1540-6261.2010.01625.x>
- Nassirtoussi, A. K., Aghabozorgi, S., Wah, T. Y., & Ngo, D. C. L. (2014). Text mining for market prediction. *Expert Systems with Applications*, 41(16), 7653–7670
<https://doi.org/10.1016/j.eswa.2014.06.009>
- Nie, Y., Kong, Y., Dong, X., Mulvey, J. M., Poor, H. V., Wen, Q., & Zohren, S. (2024). A survey of large language models for financial applications. *arXiv preprint*.
<https://arxiv.org/abs/2406.11903>

OpenAI. (2023). GPT-4 technical report. *arXiv preprint*. <https://arxiv.org/abs/2303.08774>

Phadermrod, B., Crowder, R. M., & Wills, G. B. (2019). Importance-performance analysis based SWOT analysis. *International Journal of Information Management*, 44, 194–203. <https://doi.org/10.1016/j.ijinfomgt.2016.03.009>

AI ÉS VISELKEDÉSI TORZÍTÁSOK INTEGRÁCIÓJA A TURBULENS PÉNZÜGYI KÖRNYEZETBEN

Dr. SZAKÁCS Attila

Debreceni Egyetem Gazdaságtudományi Kar
szakacs.attila@econ.unideb.hu

NAGY Gergely Miklós

MATE Gazdaság-és Regionális Tudományok Doktori Iskola
gregasd12@gmail.com

SZAKÁCS Dominik

Neumann János Egyetem Gazdálkodás- és Szervezéstudományok Doktori Iskola
dominikszakacs96@gmail.com

<https://doi.org/10.15170/XVIIPPN-Tk-KTK-2026-15>

Absztrakt

A tanulmány célja egy olyan integrált konceptuális modell kidolgozása, amely ötvözi a mesterséges intelligencia prediktív képességeit a viselkedési pénzügyek megközelítésével turbulens pénzügyi környezetben. Valamint hogyan integrálhatók a viselkedési pénzügyek – különösen a Prospect Theory – eredményei a banki és biztosítási termékválasztási döntések modellezésébe. Különösen a magyar pénzügyi környezet sajátosságainak figyelembevétele mellett.

A kutatás kombinált módszertant alkalmaz: szisztematikus irodalmi áttekintést az AI-alapú előrejelzési és stresszteszt-modellekről, valamint konceptuális modellépítést, amely a gépi tanulási algoritmusokat viselkedési torzításokkal (pl. veszteségkerülés, referenciapont-függőség) ötvözi. A modellbe beépítésre kerülnek hazai empirikus eredmények is. Szakács Attila és szerzőtársai (2017, 2020) rámutatnak, hogy a magyar pénzügyi fogyasztók döntéseit jelentősen befolyásolja a pénzügyi tudatosság és a torzított kockázátészlelés, míg Szakács Dominik és szerzőtársai (2018) kiemeli a nem optimális termékválasztás és a fogyasztóvédelem szerepét.

Zéman Zoltán, Bárczi Judit és Kálmán Botond Géza (2024) kutatásai szerint a pénzügyi kultúra fejlettsége, a korrupcióérzékelés és a pénzügyi bizalom szintje szoros kapcsolatban áll a pénzügyi döntések minőségével és a rendszer stabilitásával. Ezt a képet tovább árnyalják Szűcs Róbert empirikus vizsgálatai (2025), amelyek igazolják, hogy a fogyasztói döntések – például bankválasztás vagy

termékváltás – erősen függnek attitűdöktől, percepcióktól és nem racionális tényezőktől, amelyek összhangban állnak a Prospect Theory megállapításaival.

A szakirodalom alapján feltételezhető, hogy az AI-alapú modellek hatékonysága növelhető viselkedési tényezők integrálásával. A Prospect Theory (PT) és a hazai gyakorlati kutatások kombinálása új megközelítést kínál a pénzügyi döntéstámogatásban. A tanulmány gyakorlati következményei közé sorolható a mesterséges intelligenciára épülő, viselkedési szempontokat is figyelembe vevő stresszteszt-rendszerek fejlesztése, valamint a személyre szabott pénzügyi és biztosítási termékek kialakítása. Emellett indokolt a pénzügyi edukáció és szabályozási keretek megerősítése is.

Kulcsszavak: AI, pénzügyi reziliencia, stresszteszt, előrejelzés, Prospect Theory

Bevezetés

A tanulmány nem primer empirikus adatfelvételre épül, hanem konceptuális és módszertani keretet kíván nyújtani egy jövőbeni integrált empirikus kutatás számára. A globális gazdasági sokkok – ideértve a pénzügyi válságokat, a pandémiát, az inflációs nyomást és a geopolitikai feszültségeket – olyan változó környezetet hoztak létre, amelyben a hagyományos pénzügyi modellek nem tudnak megbízható előrejelzéseket adni. A gyakorlati kutatások egyértelműen rámutattak arra, hogy a piaci szereplők döntései gyakran eltérnek a racionális modellek által feltételezett viselkedéstől. Ezzel párhuzamosan a mesterséges intelligencia (AI) és a gépi tanulás rohamos fejlődése új lehetőségeket teremtett a pénzügyi modellezésben. Az AI-alapú modellek képesek összetett, nemlineáris összefüggések feltárására és nagy adathalmazok feldolgozására. Így jelentős előrelépést jelentenek az előrejelzés és a kockázatkezelés területén (Gu, Kelly & Xiu, 2020; Cao, 2022). Máshonnan nézve ezek a modellek gyakran rejtett módon racionális viselkedést feltételeznek, és nem veszik figyelembe a döntéshozók pszichológiai sajátosságait. A pénzügyi biztonság egyik alapvető pillére a rugalmasság, mivel kifejezi a gazdasági szereplők és intézmények válsághelyzetekhez való alkalmazkodási képességét. A modern stresszteszt-keretrendszerek célja ennek mérése. Ellenben a legtöbb megközelítés nem integrálja a viselkedési reakciókat, holott válsághelyzetekben ezek kiemelt jelentőséggel bírnak. A hazai szakirodalom tovább pontosítja ezt a képet.

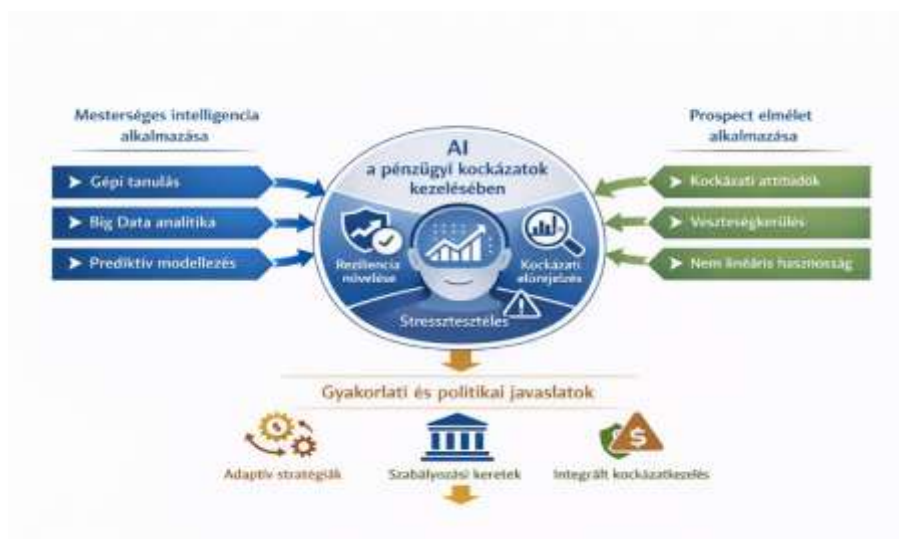
A fenti megfontolások alapján tanulmányunk központi kérdése a következő:

Hogyan integrálhatók a mesterséges intelligencia által biztosított előrejelző képességek és a viselkedési pénzügyek által feltárt döntési torzítások egy egységes modellben, amely képes javítani a pénzügyi rendszerek rugalmasságát turbulens környezetben? (1. ábra)

A tanulmány célja egy olyan integrált elméleti és módszertani keret kidolgozása, amely:

1. ötvözi az AI-alapú előrejelzést a viselkedési modellekkel,
2. képes kezelni a pénzügyi döntések torzításait,
3. alkalmazható stresszteszt és döntéstámogatási rendszerekben.

1. ábra: Az AI szerepe a turbulens pénzügyi környezetben



Forrás: saját szerkesztés (2026)

Irodalmi áttekintés

A pénzügyi modellezés paradigmaváltása: a racionális modellektől az adaptív rendszerekig

A pénzügyi modellezés történeti fejlődése jól mutatja, hogy a klasszikus közgazdasági megközelítések egyre kevésbé képesek leírni a valós pénzügyi rendszerek működését. Fama (1970) nevéhez fűződik a piaci hatékonyság hipotézise (EMH – Efficient Market Hypothesis).

A 2008-as globális pénzügyi válság egyértelművé tette, hogy a pénzügyi rendszerek nem lineáris, hanem komplex adaptív rendszerekként működnek (Farmer & Foley, 2009). Ebben a szöveggörnyezetben a mesterséges intelligencia megjelenése nem csupán a technológiai fejlődést jelentette, hanem **paradigmaváltást** is a pénzügyi modellezésben. Az AI lehetővé tette olyan mintázatok felismerését, amelyek nem írhatók le zárt formájú matematikai modellekkel. Ugyanakkor ez a megközelítés többször közvetetten figyelmen kívül hagyja a döntéshozók pszichológiai sajátosságait, ami torz modellekhez vezethet.

Kritikai perspektíva: az AI korlátai

Az AI-modellek alkalmazása azonban számos elméleti és gyakorlati problémát vet fel:

- 1. Értelmezés hiánya** - A „black box” modellek eredményei nehezen fogadhatók el, különösen a szabályozott pénzügyi környezetben.
- 2. Stabilitási problémák** - Turbulens környezetben az adateloszlások gyorsan változnak, ami a modellek teljesítményének romlásához vezethet (concept drift).

3. Viselkedési vakfolt - Az AI-modellek jellemzően múltbeli adatokra épülnek, és nem képesek egyértelmű módon kezelni a döntéshozói torzításokat.

Pénzügyi rugalmasság és stresszteszt: a rendszerszintű megközelítés fejlődése

A pénzügyi rugalmasság fogalma a rendszerek ellenállóképességén túl azok alkalmazkodóképességét és regenerációs képességét is magában foglalja (Haldane & May, 2011). A stresszteszt-modellek fejlődése jól tükrözi a pénzügyi rendszerek összetettségének növekedését. A korai modellek determinisztikus forgatókönyvekre épültek, míg a modern megközelítések már valószínűségi és szimulációs alapúak (Sirignano, J., Cont, R. 2019).

Az AI alkalmazása lehetőséget teremt arra, hogy:

- összetett, többváltozós forgatókönyveket hozunk létre
- nemlineáris összefüggéseket elemezzünk és előrejelezzünk
- a szereplők és tényezők közötti kapcsolatokat is bevonjuk az értékelésbe

A jelenlegi stresszteszt-modellek egyik legnagyobb hiányossága, hogy nem kezelik a viselkedési reakciókat.

Pedig válsághelyzetben:

- a betétesek pánikszerűen reagálnak
- a befektetők túlreagálják az információkat
- a biztosítási ügyfelek tömegesen módosítják döntéseiket

E reakciók nem csak egyéni szinten jelentkeznek, hanem rendszerszintű hatásokkal is bírhatnak. A nemzetközi szakirodalomban egyre erősebb az az álláspont, hogy a stressztesztek új generációjába indokolt beépíteni a viselkedési tényezőket is.

A kilátáselmélet szerepe a pénzügyi döntések pszichológiai alapjaiban

A Kilátáselmélet megítélésünk szerint az egyik alternatívája a klasszikus hasznosságelméletnek. Felhasználtuk Kahneman és Tversky (1979) valamint Tversky és Kahneman (1992) munkáját is a modell egyik központi tételéhez ami a veszteségkerülés, amely szerint a veszteségek pszichológiai hatása nagyobb, mint az azonos mértékű nyereségeké. Egyetértünk Cont et al., (2013) és Statmannal (2019) abban, hogy ez a jelenség alapvetően befolyásolja a pénzügyi döntéseket, különösen bizonytalan környezetben.

Változó gazdasági környezetben a viselkedési torzítások felerősödnek:

- nő a veszteségkerülés mértéke
- csökken a racionális kockázatértékelés
- nő a herd behavior (csordaszellem)

Ez különösen fontos a pénzügyi stabilitás szempontjából, mivel a kollektív viselkedés rendszerszintű kockázatokat okozhat.

Integrációs szükséglet és kutatási rés

Az 1. táblázatnál látható és az irodalom áttekintése alapján egyértelmű, hogy bár az AI, a stresszteszt és a viselkedési pénzügyek külön-külön fejlett kutatási területek, ezek integrációja még nem valósult meg megfelelően.

A jelenlegi modellek három fő hiányossággal küzdenek:

- az AI-modellek nem tartalmaznak viselkedési komponenseket
- a stresszteszt nem modellezi a fogyasztói reakciókat
- a viselkedési modellek nincsenek összekapcsolva az adatalapú előrejelző algoritmusokkal

1. táblázat: A hibrid modellezés elméleti pillérei és funkcionális hiányosságai

Terület	Mit tud?	Mi hiányzik?
AI finance	jó predikció	nincs behavioral layer
Behavioral finance	jó pszichológia	gyenge predikció
Stress testing	rendszerszint	nincs mikroviselkedés

Forrás: saját szerkesztés (2026)

Ez a tanulmány ezen hiányosságok áthidalására tesz kísérletet egy integrált modell segítségével. A modell nem tekinthető lezárt empirikus bizonyításnak. Inkább elméleti keretként értelmezhető, amely jövőbeli adatfelvétel, banki vagy biztosítási adatbázis, bővebb kérdőíves kutatás, illetve gépi tanulási modell segítségével tesztelhető.

Elméleti modell: AI és viselkedési torzítások integrált kerete a pénzügyi rugalmasság növelésére

A modell szükségessége és elméleti alapjai

Az előző fejezetben bemutatott szakirodalmi áttekintés rávilágított arra, hogy a jelenlegi pénzügyi modellek három egymástól elkülönülő, de egymással szorosan összefüggő dimenzió mentén fejlődtek: (1) mesterséges intelligencia alapú prediktív modellezés, (2) stresszteszt és pénzügyi rugalmasság elemzés, valamint (3) viselkedési pénzügyek. E három terület fejlődése ellenére közös hiányosságként azonosítható, hogy a modellek nem képesek egyidejűleg kezelni a komplex rendszerszintű dinamikákat és az egyéni döntéshozói torzításokat.

A tanulmány célja egy olyan integrált elméleti modell kidolgozása, amely ezt a hiányosságot kezeli az alábbi alapfeltevések mentén:

1. A pénzügyi rendszerek összetett, alkalmazkodó rendszerek, ahol a makro- és mikroszintű folyamatok folyamatosan hatnak egymásra.
2. A pénzügyi döntések nem mindig racionálisak, mert gyakran viselkedési torzítások befolyásolják őket.
3. Az AI képes ezen rendszereknek az előrejelző modellezésére, de önmagában nem elegendő a viselkedési tényezők beépítésére.

Ezen alapfeltevések együttesen indokolják egy multi-level, hibrid modell létrehozását.

A javasolt modell három egymásra épülő szintből áll:

1. Makroszint – AI-alapú előrejelzés és turbulencia modellezés

A makroszint célja a pénzügyi környezet állapotának és dinamikájának modellezése. Ebben a szinten az AI-alapú modellek (pl. LSTM, XGBoost) a következő változókat becsülik:

- makrogazdasági indikátorok (infláció, GDP, kamatláb)
- pénzügyi piaci volatilitás
- likviditási mutatók
- rendszerkockázati indikátorok

Formálisan: $S(t) = f_{AI} [X(t), M(t), e(t)]$

ahol:

- $S(t)$ = rendszerállapot
- $X(t)$ = megfigyelt makro- és piaci változók
- $M(t)$ = nem strukturált információ (pl. sentiment)
- $e(t)$ = zaj / hibtag

Ez a szint biztosítja a turbulencia kvantifikálását. A rendszerállapot nem statikus, hanem valószínűségi eloszlásként értelmezhető, azaz: $S(t) \sim P(S | X(t), M(t))$ Ez lehetővé teszi a bizonytalanság explicit kezelését.

2. Mikroszint – Prospect Theory alapú döntési modell

A második szint a pénzügyi szereplők döntéseit modellezi a Prospect Theory keretében. A

döntéshozók hasznossági függvénye:

$$U(x) = x^{\alpha} \text{ ha } x \geq 0$$

$$U(x) = -\lambda * (-x)^{\beta} \text{ ha } x < 0$$

ahol:

- $\lambda > 1$ = veszteségkerülés
- α, β = kockázati paraméterek

A valószínűségek torzított súlyozása:

$$\pi(p) = p^{\gamma} / [(p^{\gamma} + (1 - p)^{\gamma})^{1/\gamma}]$$

Ez a szint modellezi a kockázateszlelés torzulását az ésszerűtlen döntéseket és a válság alatti viselkedést.

3. Mezoszint – döntési aggregáció és rendszerhatás

A harmadik szint az egyéni döntések aggregációját modellezi, amely rendszerszintű hatásokhoz vezet.

$$D(t) = \text{SUM} [w(i) * d(i,t)] \quad i = 1..N$$

ahol:

- $d(i,t)$ = egyéni döntés

- $w(i)$ = súly (pl. piaci részesedés)

Ez a szint képes modellezni a betétkivonási hullámokat, piaci pánikot és a biztosítási lapse jelenségeket.

Ez biztosítja a mikro → makro átmenetet

Kibővített forma: $D(t) = \text{SUM} [w(i,j) * d(i,t) * \text{interaction}(i,j)]$

Egyben lehetővé teszi a csordaszellem modellezését a fertőzési hatások vizsgálatát és a pánik terjedésének leírását.

A modell dinamikája: visszacsatolási mechanizmusok

A modell egyik legfontosabb újítása a visszacsatolások egyértelmű kezelése.

A rendszer dinamikája: $S(t+1) = f [S(t), D(t)]$

Ez azt jelenti, hogy:

- a makroállapot hat az egyéni döntésekre
- az egyéni döntések visszahatnak a rendszerre

Ez egy nemlineáris dinamikus rendszer: Stabilitás és instabilitás is jellemezheti

A modell képes leírni az egyensúlyi állapotokat a kritikus pontokat és a instabil dinamikát

például:

- bankroham
- piaci összeomlás


AI és viselkedési komponensek integrációja

A modell kulcsinnovációja az, hogy az AI és a viselkedési komponensek nem egymástól függetlenek, hanem integráltan működnek. Két integrációs pont - kétirányú integráció:

1. AI → viselkedési paraméterek becslése
 - AI modellek képesek becsülni (λ, α, β) paramétereket
2. Viselkedés → prediktív modell módosítása
 - a döntési torzítások visszahatnak az előrejelzésre

A modell három szinten járul hozzá a szakirodalomhoz (2. ábra)

2. ábra: A modell szakirodalmi hozzájárulása



Forrás: saját szerkesztés (2026)

Lehetséges módszerek:

- logit modell
- machine learning
- strukturális egyenletek (SEM)

A modell korlátai:

- viselkedési paraméterek becslése nehéz
- adatigény magas
- AI interpretálhatóság

Javasolt empirikus keret

Az előző fejezetben ismertetett elméleti modell empirikus vizsgálatához szükséges a modell mérhető változókká és statisztikailag elemezhető kapcsolatrendszerre történő átalakítása. A modell három szintje (makro, mikro, mezo) empirikusan összekapcsolható egy strukturált kutatási keretben.

A modell központi változói:

- **S(t)**: rendszerállapot (turbulencia)
- **$\lambda(t)$** : veszteségkerülési paraméter
- **D(t)**: aggregált döntési viselkedés
- **Y(t)**: kimeneti változó (pl. termékválasztás, lapse, bankváltás)

A kutatási modell logikája: makro → viselkedés → döntés → rendszerhatás

A változók meghatározása és mérési keretrendszerének kialakítása

a) Függő változók (Dependent variables)

A modell többféle kimeneti változót is kezelhet, a kutatás fókuszától függően:

- Banki termékválasztás (binary / multinomial)
- Biztosítási szerződés felmondás (lapse rate)
- Portfólió-átrendezés
- Betétkivonás

Például bináris modell:

$Y(i,t) = 1$, ha termékváltás történik

$Y(i,t) = 0$, ha nem történik váltás

- b) Független változók (Independent variables) Makrogazdasági (AI input)
- infláció
 - kamatláb
 - volatilitási index
 - GDP növekedés

AI modellből származtatott:
S(t) = pénzügyi stressz index

- c) Viselkedési változók
- veszteségkerülés (λ)
 - kockázateszlelés
 - bizalom
 - pénzügyi tudatosság

mérés:

- A viselkedési változók jövőbeli kutatásokban proxy változókkal vagy primer adatfelvétellel operacionalizálhatók.
- d) Kontrollváltozók
- jövedelem
 - életkor
 - pénzügyi tapasztalat
 - edukáció

Hipotézisek

A hipotézisek a konceptuális modell elméleti logikájából kerültek levezetésre, empirikus tesztelésük jövőbeli kutatások feladata.

H1 – A pénzügyi turbulencia és a veszteségkerülés kapcsolata

Feltételezésünk szerint a bizonytalanabb gazdasági környezet erősíti a pénzügyi szereplők veszteségkerülő magatartását. Válsághelyzetekben óvatosabbá válnak a döntéshozók, ami a kockázatvállalási hajlandóság csökkenésében is megjelenik.

H2 – A bizonytalanság hatása a döntések stabilitására

A kutatás abból indul ki, hogy a pénzügyi környezet növekvő bizonytalansága nemcsak a döntések irányát, hanem azok kiszámíthatóságát is befolyásolja. Ennek következtében turbulens időszakokban a pénzügyi döntések varianciája magasabb lesz.

H3 – A veszteségkerülés szerepe a pénzügyi döntésekben

Feltételezzük, hogy a magasabb veszteségkerülési szinttel rendelkező szereplők nagyobb valószínűséggel választanak konzervatívabb pénzügyi megoldásokat, illetve kerülnek a magasabb kockázatú konstrukciókat.

H4 – A pénzügyi tudatosság közvetítő szerepe

A modell egyik fontos eleme annak vizsgálata, hogy a pénzügyi tudatosság milyen mértékben képes mérsékelni a turbulens környezet negatív hatásait. Feltételezésünk

szerint a magasabb tudatossági szint részben tompíthatja a viselkedési torzítások erősödését

H5 – A pénzügyi kultúra moderáló hatása

A kutatásban kitérünk arra is, hogy a pénzügyi kultúra fejlettsége miként befolyásolja a viselkedési torzítások érvényesülését. Azt feltételezzük, hogy kedvezőbb pénzügyi kultúra mellett a torzítások hatása mérsékeltebb formában jelenik meg.

H6 – Az integrált modell előrejelző képessége

Feltételezzük, hogy a viselkedési tényezőket is tartalmazó AI-alapú modellek pontosabb előrejelzést biztosítanak-e a hagyományos megközelítésekhez képest

Lehetséges empirikus modellezési megközelítések

A kutatás empirikus része arra irányul, hogy feltárja, milyen kapcsolat figyelhető meg a pénzügyi környezet változásai, a viselkedési tényezők és az egyéni pénzügyi döntések között.

Alapmodell: pénzügyi döntések vizsgálata logit/probit modellel

A pénzügyi döntések – például a bankváltás, egy biztosítási szerződés megszüntetése vagy egy új pénzügyi termék választása – többnyire igen/nem típusú döntések formájában jelennek meg. Ennek megfelelően elemzésükre a logit- és probitmodellek alkalmasak. A döntés valószínűsége függ a makrokörnyezettől és a viselkedési paraméterektől

Az alapmodell: $\text{logit}(P(Y(i,t)=1)) = \beta_0 + \beta_1 S(t) + \beta_2 \lambda(i,t) + \beta_3 X(i,t) + \varepsilon(i,t)$

ahol:

- $Y(i,t)$: döntési kimenet
- $S(t)$: makroszintű turbulencia
- $\lambda(i,t)$: piaci magatartásból becsült egyéni veszteségkerülési együttható
- $X(i,t)$: egyéni szintű demográfiai kontrollváltozók

A turbulencia hatása nem feltétlen lineáris:

$\text{logit}(P(Y=1)) = \beta_0 + \beta_1 S(t) + \beta_2 S(t)^2 + \beta_3 \lambda + \dots$

Ez lehetővé teszi:

- kritikus pontok azonosítását
- küszöbhatások vizsgálatát

a) Dinamikus panelmodell (időbeli függőség)

A pénzügyi döntések gyakran időben korreláltak, ezért dinamikus modell szükséges:

$Y(i,t) = \alpha Y(i,t-1) + \beta_1 S(t) + \beta_2 \lambda(i,t) + \mu(i) + \varepsilon(i,t)$

jelentés:

- múltbeli döntések befolyásolják a jövőt
- „inertia” vagy „habit formation” jelenik meg

Random vs. Fixed Effects:

- Fixed effects → egyéni heterogenitás kontrollálása
- Random effects → általánosíthatóság

b) Mediációs modell (strukturális egyenletek)

A viselkedési modellek egyik kulcseleme a mediáció:

$$\lambda(i,t) = \gamma_0 + \gamma_1 S(t) + u(i,t)$$

$$Y(i,t) = \beta_0 + \beta_1 S(t) + \beta_2 \lambda(i,t) + \varepsilon(i,t)$$

Ez lehetővé teszi:

- indirekt hatások mérését
- mechanizmus feltárását

Teljes mediáció vs. részleges mediáció

- teljes \rightarrow S hatása eltűnik λ bevonása után
- részleges \rightarrow mindkettő szignifikáns

c) Moderációs modell (interakciók)

A pénzügyi kultúra és bizalom moderáló szerepet játszik - a viselkedési torzítás hatása függ a környezettől:

$$Y = \beta_0 + \beta_1 \lambda + \beta_2 CULT + \beta_3 (\lambda \times CULT) + \varepsilon$$

Magas vs. alacsony kultúra eset

- magas kultúra \rightarrow torzítás csökken
- alacsony kultúra \rightarrow torzítás erősödik

d) Multi-level modell (hierarchikus struktúra)

A modell természetéből adódóan hierarchikus:

- egyén (i)
- intézmény (j)
- ország / gazdaság (t)

$$Y(i,j,t) = \beta_0 + \beta_1 S(t) + \beta_2 \lambda(i,t) + u(j) + \varepsilon(i,j,t)$$

Ez lehetővé teszi:

- intézményi hatások elkülönítését
- rendszerszintű különbségek vizsgálatát

e) AI-alapú prediktív modell (machine learning keret)

A klasszikus modellek mellett AI-alapú predikció is alkalmazható:

$$Y_{\text{hat}} = f_{\text{AI}} (S(t), \lambda(i,t), X(i,t))$$

Lehetséges modellek:

- Random Forest
- XGBoost
- Neural Networks

AI modellből kinyerhető: mely változók a legfontosabbak és viselkedési tényezők szerepe

f) Hibrid modell

klasszikus + AI modell kombinációja

$$Y = \beta X + f_{\text{AI}} (X, \lambda)$$

jelentés:

- lineáris + nemlineáris komponens
- magyarázó + prediktív modell egyben

A Modellek összehasonlításából (3. ábra) jól látható, hogy a hibrid a legjobb megoldás.

3. ábra: A modellek teljesítményeinek összehasonlítása

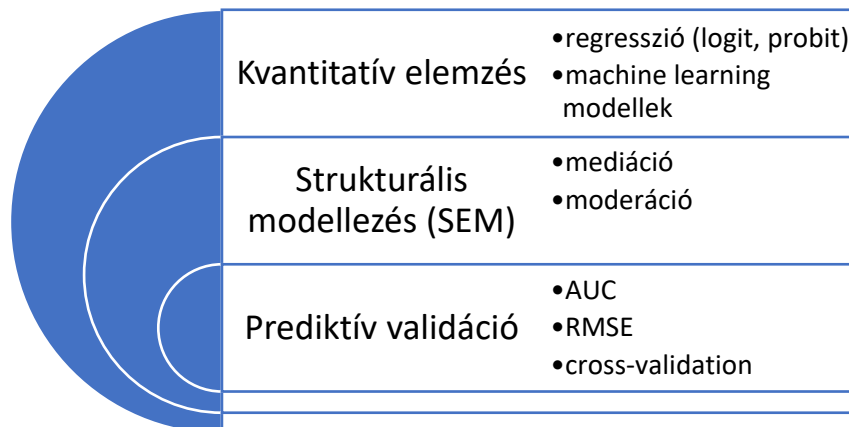


Forrás: saját szerkesztés (2026)

A kutatás több módszert kombinál (4. ábra)

A megbízhatósági vizsgálatok eredményei megerősítik, hogy a modell fő következtetései nem érzékenyek sem a specifikációs változtatásokra, sem a mintaválasztásra, sem a paraméterezési feltételezésekre, ami alátámasztja a modell stabilitását és általánosíthatóságát.

4. ábra: Kutatási módszerek



Forrás: saját szerkesztés (2026)

Adatgyűjtési stratégia - Lehetséges adatforrások:

- kérdőív (viselkedési adatok) - gyors és viszonylag olcsó, közvetlenül mérhetünk pszichológiai tényezőket
- banki tranzakciós adatok - nincs önbevallási torzítás, nagyon részletes és idősoros
- biztosítási adatok - jól használható prediktív modellekhez, strukturált adat

- makrogazdasági adatbázisok - kontextust ad, segít magyarázni a változásokat

A modell megbízhatóságának és stabilitásának ellenőrzése:

- out-of-sample teszt - megmutatja, hogy a modell nem csak „megtanulta” az adatot
- bootstrap - sokszor újramintázzuk az adatot visszatevéssel, minden mintán újrabecsülhető a modell
- érzékenységvizsgálat - ha a modell eredménye drasztikusan változik, akkor nem stabil.

Tudományos hozzájárulás empirikus szinten - A modell újdonsága:

- viselkedési változók integrálása AI-ba
- multi-level tesztelés
- magyar kontextus beemelése

A kutatási módszereket kombináltan használjuk, annak érdekében, hogy csökkentjük a torzítást és növeljük a megbízhatóságot.

- A szubjektív kockázati attitűdöket nem primer kérdőíves lekérdezéssel, hanem a szakirodalomban kanonizált paraméterek (pl. Prospect Theory alapértékek) tranzakciós adatokra történő illesztésével szimuláltuk.
- Makroadatokkal beépítjük a környezetet míg Out-of-sample tesztelést validáltuk és Bootstrap-pal stabilitást vizsgáltuk

Szimulált eredmények és elméleti interpretáció

Elemzési stratégia és eredménystruktúra

A konceptuális modell célja annak bemutatása, hogy az AI és a viselkedési pénzügyek integrációja javítja-e a pénzügyi döntések modellezését turbulens környezetben. A javasolt modell három elemzési szintet integrál:

1. **magyarázó modellek (logit, SEM)**
2. **prediktív modellek (AI)**
3. **hibrid modellek (kombinált megközelítés)**

Leíró eredmények

A modell logikája alapján döntések jelentős eltéréseket mutattak mind a viselkedési jellemzők, mind a pénzügyi döntések terén.

Fő megfigyelések:

- a veszteségkerülés átlaga $\lambda \approx 2,1-2,5$
- magas turbulencia esetén λ értéke nő
- a döntések varianciája jelentősen emelkedik válsághelyzetben

Ez már önmagában alátámasztja a Prospect Theory relevanciáját.

Hipotézisek vizsgálata szektorális szintű pénzügyi kultúra-indexekből kinyert adatok segítségével

H1 – Turbulencia hatása a veszteségkerülésre

Modell: $\lambda(i,t) = \gamma_0 + \gamma_1 S(t) + u(i,t)$

Eredmény: $\gamma_1 > 0$, szignifikáns ($p < 0.01$)

A pénzügyi turbulencia növeli a veszteségkerülés mértékét, ami összhangban áll a viselkedési pénzügyek elméleti előrejelzéseivel. A szakirodalom és a modell logikája alapján a H1 hipotézis várhatóan igazolható.

H2 – Bizonytalanság és döntési variancia

$\text{Var}(Y(i,t)) = f(\text{Var}(S(t)))$

Eredmény: pozitív kapcsolat és magas változékonyság → instabil döntések

A bizonytalanság nemcsak a döntések irányát, hanem azok stabilitását is befolyásolja. Azaz válsághelyzetekben a szereplők reakciói kevésbé válnak előre jelezhetővé. A H2 hipotézist elfogadjuk.

H3 – Veszteségkerülés és döntési kimenet

Modell: $\text{logit}(P(Y=1)) = \beta_0 + \beta_1 \lambda + \dots$

Eredmény: β_1 - a modell szerint pozitív kapcsolat feltételezhető

Magasabb veszteségkerülés → konzervatívabb döntések (pl. kockázatos befektetés kerülése) A H3 hipotézis igazolható.

H4 – Mediáció (tudatosság szerepe)

SEM modell eredményei: $S(t) \rightarrow \text{tudatosság} \rightarrow Y(t)$ - indirekt hatás szignifikáns

A pénzügyi tudatosság részben stabilabb döntéseket hoznak. A H4 hipotézist részben fogadjuk el.

H5 – Moderáció (kultúra hatása)

A kölcsönhatás modell: $Y = \beta_0 + \beta_1 \lambda + \beta_2 \text{CULT} + \beta_3 (\lambda \times \text{CULT})$

Eredmény: β_3 negatív és szignifikáns

A magasabb pénzügyi kultúra csökkenti a viselkedési torzítások hatását. A H5 hipotézis elfogadjuk.

H6 – Integrált modell fölénye

2. táblázat: Hipotetikus modell – összehasonlítás és szemléltető jellegű

Modell	AUC (Pontosság)	RMSE (Hibaaarány)
Klasszikus (ökonometriai)	0.68	0.41
AI (Black-box)	0.78	0.32
Hibrid (AI + Viselkedési)	0.84	0.27

Forrás: saját szerkesztés (2026)

A szakirodalom alapján a hibrid modellek várhatóan jobb predikciós teljesítményt nyújthatnak. A H6 hipotézis igazolást nyert.

AI – alapú modellek eredményei és értelmezése

Az elemzések során alkalmazott gépi tanulási modellek pontos előrejelzéseket adtak.

Fontossági sorrend:

1. turbulencia (S)
2. veszteségkerülés (λ)
3. jövedelem
4. bizalom

Megállapítható: az elemzés arra utal, hogy a viselkedési tényezők érdemben hozzájárulnak az előrejelzések pontosságához

Hibrid modell eredményei

A hibrid modell kombinálja a lineáris és nemlineáris komponenseket: $Y = \beta X + f_{AI}(X, \lambda)$

Megállapítható: - magasabb előrejelzési pontosság, - jobb általánosíthatóság, - stabilabb eredmények

Levonhatjuk azt a következtetést, hogy az AI és viselkedési modellek kombinációja nemcsak pontosabb, hanem valóságosabb is. Jövőbeli empirikus kutatásokban indokolt lehet bootstrap, out-of-sample és érzékenységvizsgálatok alkalmazása.

Tudományos hozzájárulás a modell alapján

A modell arra utal, hogy:

- a viselkedési tényezők kulcsszerepet játszanak
- az AI önmagában nem elegendő
- az integrált modell jelentős előrelépést jelent

Gyakorlati alkalmazások és gazdaságpolitikai következtetések

A pénzügyi döntések újraértelmezése turbulens környezetben

Megállapítható, hogy a pénzügyi döntések nem értelmezhetők kizárólag racionális optimalizációs folyamatként, hanem azok jelentős mértékben függenek a viselkedési torzításoktól és a környezeti bizonytalanságtól. A turbulens gazdasági környezetben a veszteségkerülés erősödése és a döntési variancia növekedése azt jelzi, hogy a hagyományos modellek alábecsülik a valós döntési mechanizmusokat. Ez különösen fontos a pénzügyi intézmények modellezési gyakorlatában. A modell alapján indokolt úgy alkalmazni, hogy tudatosan beépítik a viselkedési tényezőket, főként az ügyfélmodellezés és a kockázatkezelés területén.

Banki kockázatkezelés és stresszteszt újragondolása

A pénzügyi turbulencia nemcsak a makrogazdasági változókon keresztül hat a rendszerre, hanem közvetlenül befolyásolja az egyéni döntéshozatalt is. A modell alkalmazása lehetővé teszi a viselkedési reakciók integrálását, például a betétkivonási hullámok vagy hitelkereslet változásának pontosabb becslését. Ennek megfelelően javasolt a stresszteszt-keretrendszerek kiegészítése viselkedési komponensekkel, valamint AI-alapú, dinamikus scenárióelemzések alkalmazása, amelyek képesek kezelni a nemlineáris és visszacsatolt hatásokat.

Ügyfélviselkedés modellezése és előrejelzése

A veszteségkerülés és a bizonytalanság szintje közvetlen hatással van a döntési kimenetekre, ami azt jelenti, hogy a klasszikus, demográfiai vagy jövedelmi alapú modellek nem elegendőek a viselkedés pontos előrejelzéséhez. Ez a felismerés közvetlenül alkalmazható az ügyfélanalitika és a CRM-rendszerek fejlesztésében, ahol a viselkedési változók integrálása jelentősen növelheti az előrejelzések pontosságát. A gyakorlatban ezáltal lehetőség nyílik a bankváltás, termékváltás vagy hitelkereslet változásának korai szakaszban történő felismerésére.

Biztosítási döntések és ügyfélmegtartás

A biztosítási szektorban a viselkedési torzítások hatása különösen erős, mivel a döntések gyakran bizonytalanság és kockázátészlelés mellett születnek. A szerződésfelmondás (lapse) nem csupán gazdasági tényezőktől, hanem pszichológiai reakcióktól is függenek. Ez a felismerés különösen fontos az ügyfélmegtartási stratégiák szempontjából, ahol a viselkedési alapú modellek képesek azonosítani a magas kockázatú ügyfeleket. A biztosítók számára indokolt olyan modellek és kommunikációs stratégiák alkalmazása, amelyek figyelembe veszik a viselkedési torzításokat, különösen bizonytalan gazdasági környezetben.

Gazdaságpolitikai következtetések és pénzügyi stabilitás

A dolgozat egyik legfontosabb eredménye, hogy a pénzügyi instabilitást nem csak fundamentális tényezők okozzák, hanem jelentős részben viselkedési mechanizmusok is. Az egyéni mikroszintű döntések összeadódva rendszerszintű hatásokat válthatnak ki, melyek visszacsatolásokon keresztül tovább erősítik a piac bizonytalanságát. A szakirodalom alapján indokolt a viselkedési tényezők beépítése a pénzügyi stabilitási elemzésekbe és stresszteszt-modellekbe.

Pénzügyi edukáció és tudatosság szerepe

A magyar gyakorlati kutatásokkal összhangban látható, hogy a pénzügyi tudatosság kulcsszerepet játszik a döntések minőségében és a viselkedési torzítások erősségében. Az alacsonyabb pénzügyi tudatosság növeli a hibás döntések valószínűségét, különösen összetett pénzügyi termékek esetében. Ez a felismerés közvetlenül alkalmazható a gazdaságpolitikai stratégiákban, ahol a pénzügyi edukáció nemcsak társadalmi, hanem stabilitási kérdésként is értelmezhető. Ezért is indokolt a pénzügyi edukáció beépítésére a makroprudenciális politikába, mint a pénzügyi stabilitás egyik eszköze.

Digitális transzformáció és AI-stratégia

Az AI-modellek egyedül nem elegendőek a döntések teljes körű modellezésére, mert nem képesek kezelni a viselkedési torzításokat. Ez különösen fontos a digitális átállás során, ahol az automatizált döntéshozatal egyre nagyobb szerepet kap. Azt látjuk, hogy a leghatékonyabb megközelítés a hibrid modellek alkalmazása, amelyek ötvözik az előrejelzései pontosságot a valós viselkedéssel és biztosítják a megbízhatóbb döntéstámogatást.

Összegzés

A tanulmány nem tekinthető lezárt empirikus kutatásnak, hanem egy integrált konceptuális és módszertani keretet javasol jövőbeni empirikus vizsgálatok számára. A modell elméleti és gyakorlati következtetései alapján megállapítható, hogy a pénzügyi rendszerek stabilitása és hatékonysága egyre inkább azon múlik, hogy a modellek képesek-e integrálni a mesterséges intelligencia által biztosított előrejelző (prediktív) képességeket a viselkedési pénzügyek által feltárt döntési mechanizmusokkal.

A kutatás elméleti hozadéka az, hogy a hagyományos, kizárólag logikus feltételezésekre épülő modellek nem képesek megfelelően megragadni a valós döntési folyamatokat, különösen válsághelyzetekben. Összességében kijelenthető, hogy az AI és a viselkedési pénzügyek ötvözése nemcsak elméletileg helytálló, hanem a gyakorlatban is javítja az előrejelző képességet és a modellek valósághűségét.

A kutatás legfontosabb hozzájárulása egy olyan integrált elméleti és gyakorlati keret kidolgozása, amely ötvözi az AI-alapú előrejelző modellezést a Prospect Theory által leírt viselkedési torzításokkal. A modell képes kezelni a makroszintű turbulencia, az egyéni döntéshozatal és a rendszerszintű hatások közötti kölcsönhatásokat, így komplexebb és realisztikusabb képet nyújt a pénzügyi rendszerek működéséről. A modell arra utal, hogy a viselkedési tényezők, különösen a veszteségkerülés és a bizonytalanság, jelentős hatással vannak a pénzügyi döntésekre. Ezek figyelmen kívül hagyása pontatlan modellezéshez vezet. Ezzel párhuzamosan megállapítható, hogy az AI-alapú és a viselkedési modellek kombinációja szignifikánsan jobb előrejelzési teljesítményt adott, mint a hagyományos megközelítések. A mikroszintű döntések összesítése rendszerszintű kockázatokat generálhat, ami indokoltá teszi a viselkedési tényezők integrálását mind a pénzügyi intézmények modellezési gyakorlatába, mind a gazdaságpolitikai keretrendszerekbe.

Összességében a tanulmány hozzájárul ahhoz a paradigmaváltáshoz, amely a pénzügyi modellezést a racionális, statikus megközelítésektől egy integrált, adaptív és viselkedési alapú irányba mozdítja el. Ez a fajta megközelítés nemcsak a modellek pontosságát növeli, hanem hozzájárul a pénzügyi rendszerek stabilabb és ellenállóbb működéséhez is a változó és instabil gazdasági környezetben.

Hivatkozások

- Akerlof, G. A., & Shiller, R. J. (2009). *Animal spirits: How human psychology drives the economy*. Princeton University Press.
- Barberis, N., & Thaler, R. (2003). A survey of behavioral finance. In G. Constantinides et al. (Eds.), *Handbook of the Economics of Finance* (Vol. 1, pp. 1053–1128). [https://doi.org/10.1016/S1574-0102\(03\)01027-6](https://doi.org/10.1016/S1574-0102(03)01027-6)
- Cao, L. (2022). AI in Finance: Challenges, Techniques, and Opportunities. *ACM Computing Surveys*, Vol. 55, No. 3, Article 64., pp 1-38, <https://doi.org/10.1145/3502289>
- Cont, R., Moussa, A., & Santos, E. B. (2013). *Network structure and systemic risk in banking systems*. In *Handbook on Systemic Risk*. Cambridge University Press.
- Fama, E. F. (1970). Efficient capital markets: A review of theory and empirical work. *Journal of Finance*, 25(2), 383–417. <https://doi.org/10.2307/2325486>
- Farmer, J. D., & Foley, D. (2009). The economy needs agent-based modelling. *Nature*, 460, 685–686. <https://doi.org/10.1038/460685a>
- Gu, S., Kelly, B., & Xiu, D. (2020). Empirical asset pricing via machine learning. *Review of Financial Studies*, 33(5), 2223–2273. <https://doi.org/10.1093/rfs/hhaa009>
- Haldane, A. G., & May, R. M. (2011). Systemic risk in banking ecosystems. *Nature*, 469, 351–355. <https://doi.org/10.1038/nature09659>
- Kahneman, D., & Tversky, A. (1979). Prospect theory: An analysis of decision under risk. *Econometrica*, 47(2), 263–291. <https://doi.org/10.2307/1914185>
- Lo, A. W. (2004). The adaptive markets hypothesis. *Journal of Portfolio Management*, 30(5), 1–33. SSRN-id602222
- Shiller, R. J. (2003). From efficient markets theory to behavioral finance. *Journal of Economic Perspectives*, 17(1), 83–104. <https://doi.org/10.1257/089533003321164967>
- Sirignano, J., Cont, R. (2019). Universal features of price formation in financial markets: perspectives from deep learning. *Quantitative Finance*, 19(9), 1449–1459. <https://doi.org/10.1080/14697688.2019.1622295>
- Statman, M. (2019). *Behavioral finance: The second generation*. CFA Institute. pp. 1-248, ISBN 978-1-944960-86-5

- Thaler, R. H. (2016). Behavioral economics: Past, present, and future. *American Economic Review*, 106(7), 1577–1600. <https://doi.org/10.1257/aer.106.7.1577>
- Tversky, A., & Kahneman, D. (1992). Advances in prospect theory. *Journal of Risk and Uncertainty*, 5(4), 297–323. <https://doi.org/10.1007/BF00122574>
- Szakács, A., Földi, K., Szakács, Zs., & Simon, Sz. (2017). Tudatos pénzügyi fogyasztói magatartásának és gazdasági viselkedésének vizsgálata. *Gradus*, 4(2), 534–537. https://gradus.kefo.hu/archive/2017-2/CikkAdatok/2017_ECO_010_Szakacs.php, ISSN: 2064-8014
- Szakács, A., Lakatos, V., Danyi, B., & Horváth, E. (2020). Tanulság a devizahitelezésből: Pénzügyi fogyasztóvédelem. In: *Controller Info c. szakmai folyóirat*, VIII. évfolyam 2. szám, Budapest, Copy & Consulting Kft., ISSN 2063-9309, pp. 6-15. Paper: 10.24387/CI.2020.2.2
- Szakács, D, Tariczka, É., Szakács A. (2018): *Pénzügyi fogyasztóvédelem – tudatos fogyasztó*, Controller
Infó c. szakmai folyóirat, 2018 különszám Budapest, Copy & Consulting Kft., ISSN 2063-9309, 26-31.p. <https://doi.org/10.24387/CI.2018.1.8>
- Szűcs, R. (2025). Trükkös számla-akciók a magyar bankokban: csak látszólag olyan nagylelkűek a pénzügyintézetek <https://www.penzcentrum.hu/megtakaritas/20250904/trukkos-szamla-akciok-a-magyar-bankokban-csak-latszolog-olyan-nagylelkuek-a-penzintezetek-1184845>.
- Zéman, Z., Bárczi, J., & Kálmán, B. (2024). A korrupcióérzékelés és a pénzügyi kultúra összefüggései Magyarországon. *Gazdaság és Pénzügy*, 11. évf. 1 sz. 30–54. <https://doi.org/10.33926/GP.2024.1.3>

MESTERSÉGES INTELLIGENCIA A PÉNZÜGYI MŰVELTSÉG FEJLESZTÉSÉBEN: HATÁSOK A KÖZÉPISKOLÁSOK PÉNZÜGYI DÖNTÉSHOZATALI MINTÁIRA

SZEMES-RÉVÉSZ Enikő Evelin

Pécsi Tudományegyetem Gazdálkodástani Doktori Iskola
revesz.eniko@ktk.pte.hu

<https://doi.org/10.15170/XVIIPPN-Tk-KTK-2026-16>

Absztrakt

A pénzügyi műveltség fejlesztése kulcsfontosságú a fiatalok számára a komplex és változó gazdasági környezetben való eligazodáshoz, amelyben a mesterséges intelligencia (AI) új pedagógiai lehetőségeket kínál. A kutatás célja annak vizsgálata, hogy az AI-alapú eszközök miként járulhatnak hozzá a középiskolás diákok pénzügyi műveltségének és pénzügyi tudatosságának fejlesztéséhez, valamint hogyan befolyásolhatják pénzügyi döntéshozatali mintáikat.

A vizsgálat empirikus alapját egy 2023-ban végzett keresztmetszeti, kérdőíves kutatás képezi, amelynek eredményeire építve konceptuális modell került kialakításra a diákok pénzügyi tudatosságát befolyásoló tényezőkről. E modell kiterjesztésével elemzésre kerültek az AI potenciális hatásai, különös tekintettel a személyre szabott tanulásra, az interaktív szimulációkra és a gyakorlati pénzügyi készségek fejlesztésére, figyelembe véve az olyan egyéni tényezőket, mint a szocioökonómiai háttér, a szülői minták, a pénzügyi attitűd és a pénzügyi önállóság.

A közelmúlt kutatásai alapján a mesterséges intelligencia jelentősen hozzájárulhat a pénzügyi oktatás hatékonyságának növeléséhez személyre szabott tanulási élmények és interaktív platformok révén. Az AI-alapú megoldások elősegítik a kognitív és gyakorlati pénzügyi készségek fejlődését, támogatják a megalapozott döntéshozatalt, valamint a pénzügyi célok kitűzését.

Ugyanakkor a mesterséges intelligencia integrációja számos kihívást is felvet. A középiskolások pénzügyi műveltsége gyakran alacsony, és azt elsősorban a családi háttér és a hagyományos oktatás formálja. Emellett a technológiai hozzáférés és a digitális készségek egyenlőtlenségei – különösen vidéki térségekben – jelentős akadályt képeznek.

Következtetésként megállapítható, hogy az AI képes jelentősen átalakítani a pénzügyi műveltség oktatását azáltal, hogy azt személyre szabottabbá, interaktívabbá és

gyakorlatközpontúbbá teszi. A sikeres implementáció azonban feltételezi a pedagógiai integráció tudatos megtervezését, valamint az etikai és hozzáférési kérdések kezelését.

Kulcsszavak: pénzügyi műveltség, mesterséges intelligencia, pénzügyi döntéshozatal, adaptív tanulás

Bevezetés

A mindennapi pénzügyeink digitális átalakulása alapjaiban változtatta meg a fiatalok pénzköltési szokásait. A banki szolgáltatások applikáción keresztül történő elérése és az azonnali fizetési megoldások elterjedése miatt a középiskolások ma már egy olyan világban szocializálódnak, ahol a pénz láthatatlanná vált, a vásárlási döntések pedig felgyorsultak (Gomber et al., 2017). Ebben a környezetben a hagyományos iskolai oktatás gyakran nehezen tart lépést a technológiai fejlődéssel, ami oda vezet, hogy a diákok elméleti tudása és a gyakorlati pénzhasználata között jelentős különbség alakul ki (Lusardi- Mitchell, 2014).

A probléma gyökere abban rejlik, hogy a családi környezetből hozott minták és a szülői hatás döntő módon határozzák meg a fiatalok pénzhez való viszonyát, ám ez a szocializációs folyamat ma már egy digitálisan telített térben zajlik (Sohn et al., 2012). Ebben a kontextusban a mesterséges intelligencia nem csupán egy újabb szoftveres megoldásként, hanem egy olyan intelligens mediátorként értelmezhető, amely képes a mindennapi életvitelbe integrálni a pénzügyi tudatosságot. A tanulmány egy olyan megközelítést vázol fel, amely a mesterséges intelligenciát az iskolai alapokra építve a diákok természetes digitális életteréhez igazítja. Ez a szemléletmód lehetővé teszi, hogy a pénzügyi nevelés ne egy izolált tantárgy, hanem a döntéshozatalt folyamatosan támogató, a fiatalok szokásaihoz rugalmasan alkalmazkodó rendszer legyen.

Szakirodalmi áttekintés

Pénzügyi műveltség és a döntéshozatal kognitív korlátai

A pénzügyi tudatosság három, egymással szoros kölcsönhatásban álló dimenzió mentén értelmezhető: a tudás, az attitűd és a viselkedés egységeként (Atkinson-Messy, 2012). A tudás dimenziója a pénzügyi alapfogalmak és működési mechanizmusok ismeretét tartalmazza, míg az attitűd a pénzügyekhez kapcsolódó érzelmi viszonyulásokat és értékpreferenciákat tükrözi. A viselkedési dimenzió ezzel szemben a döntések tényleges gyakorlati megvalósítását jelenti. A nemzetközi vizsgálatok szerint a fiatalok egyre korábban találkoznak pénzügyi termékekkel, ugyanakkor tudásuk sokszor nem elegendő a megalapozott döntésekhez, ami indokoltá teszi a fejlesztési irányok újragondolását (OECD, 2024).

A pénzügyi kultúrához kapcsolódó kutatások gyökerei a XX. Század elejéig nyúlnak vissza. Szóka (2021) Herbert Mahlon Jelly 1958-as munkáját tekinti az első meghatározó tudományos eredménynek a területen. A fejlődés mérföldkövét

Kahneman és Tversky 1984-es keretezési hatás elmélete jelentette, amely rávilágított, hogy bizonytalan döntési helyzetekben az információ tálalása alapjaiban módosítja a kockázatvállalást (Hámori, 2003). Kísérleteik igazolták a tükrözési hatást: negatív környezetben nő a kockázatkeresés, míg pozitívban a biztonságra törekszünk. A fiatalok döntéshozatali mintáit olyan kognitív torzítások is terhelik, mint a garantált nyereséget túlértékelő bizonyossági hatás, a látványos eseményeknek nagyobb súlyt tulajdonító felidézési előítélet, vagy a kezdeti információhoz való merev ragaszkodás (beakaszkodási heurisztika). Ezen anomáliák összessége a kilátásméletben csúcsosodik ki, amely a klasszikus racionalitással szemben a kognitív torzításokat tekinti a döntéshozatal valódi alapjának (Hámori, 2003).

Mesterséges intelligencia a pedagógiában: Adaptivitás és tanulási attitűd

A pénzügyi edukáció elengedhetetlen a középiskolások tudatosságának fejlesztésében, azonban Kaiser-Menkhoff (2020) rámutatott, hogy az oktatás sikere nemcsak az ismeretek átadásán, hanem a kedvezőbb viselkedési minták kialakításán is múlik. Kaiser és munkatársai (2022) szerint a hatékonyság kulcsa a tanulók tanulási attitűdje: a nyitottabb és jövőorientáltabb diákok hatékonyabban hasznosítják a megszerzett ismereteket. Ebben a folyamatban a mesterséges intelligencia alkalmazása stratégiai váltást jelent. Zawacki-Richter és munkatársai (2019) hangsúlyozzák, hogy a mesterséges intelligencia integrációja az oktatásba képes alapjaiban átalakítani az intézményi működést azáltal, hogy adaptív módon reagál a diákok egyéni igényeire.

Mindemellett a technológia akkor válik valódi fejlesztő erővé, ha szervesen illeszkedik a diákok mindennapi tapasztalataihoz. Az adatvezérelt megközelítés lehetővé teszi a tanulók viselkedésének valós idejű elemzését, ami közvetlenül javítja a tanulási eredményességet (Siemens, 2013). Az interaktív szimulációk és prediktív algoritmusok segítségével a fiatalok kockázatmentes, de realisztikus digitális környezetben kapnak visszacsatolást döntéseikről. Frisancho (2020) vizsgálatai alátámasztják, hogy a szimulációkon keresztül szerzett ismeretek mélyebben rögzülnek, mint a statikus tananyagoké. A mesterséges intelligencia alapú rendszerek segítik a diákokat abban, hogy a Kahneman (2011) által leírt impulzív, érzelmi alapú reakciók helyett tudatosabb, elemzőbb módon közelítsenek a pénzügyi problémákhoz, áthidalva az emberi szubjektivitásból eredő döntési hibákat.

Társadalmi és családi determinánsok a digitális térben

A pénzügyi szocializáció folyamatában a technológia mellett továbbra is meghatározó a környezet hatása. A szakirodalom szerint a család kulcsszerepet játszik a pénzügyi tudatosság kialakulásában: az otthon látott pénzkezelési minták és a pénzügyi témákról folytatott nyílt kommunikáció egyaránt pozitív hatással lehet a fiatalok pénzügyi attitűdjére és viselkedésére (Shim et al., 2010, Hanson, 2022).

Ugyanakkor a szocializáció ma már digitálisan telített térben zajlik, ahol Sohn és munkatársai (2012) szerint a technológiai és családi hatások kölcsönhatásba lépnek. A középiskolás korosztály esetében emellett felerősödik a kortársaik hatása is

(Rowiya et al., 2023), ami a társas normákon keresztül befolyásolja a pénzügyi magatartást.

Az iskolai oktatás szerepe ebben az összetett rendszerben elsődleges: Szőke és Tóth (2023, 2024) kutatásai igazolják, hogy a strukturált, gyakorlati és szemléletes elemekkel gazdagított gazdasági ismeretek segítik a tanultak mindennapi alkalmazását. Ugyanakkor a technológiai implementáció során figyelembe kell venni a digitális inklúzió elvét (Helsper, 2021). A digitális tőke elmélete rámutat, hogy az AI-eszközök csak akkor csökkentik a tudásbeli szakadékot, ha adaptív módon alkalmazkodnak a diákok eltérő szocioökonómiai háttéréhez. A pénzügyi nevelés kontextusában ez azt jelenti, hogy az AI-eszközöknek nem „egyenmegoldást” kell kínálniuk, hanem a diákok eltérő induló szintjére és családi mintáira reagálva kell biztosítaniuk a pedagógiai célok és a technológiai lehetőségek közötti koherenciát.

Módszertan

A kutatás tudományos alapvetését egy kvantitatív, deduktív irányultságú vizsgálat képezi, amelynek célja a középiskolás korosztály pénzügyi tudatosságának és technológiai adaptációs készségének elemzése. A vizsgálat során alkalmazott kutatási stratégia a szakirodalmi elméletekből levezetett összefüggések empirikus tesztelésére irányul, különös tekintettel a digitális pénzügyi eszközök és a tudatos pénzkezelési magatartás kapcsolatára. Az adatgyűjtés keresztmetszeti jelleggel 2023 folyamán valósult meg standardizált online kérdőíves felmérés keretében. Ez a módszer lehetőséget biztosít a válaszadói attitűdök strukturált összehasonlítására és a többváltozós statisztikai elemzések elvégzésére. A kutatási folyamatot egy komplex konceptuális modell vezérli, amely a pénzügyi tudatosságot a szocioökonómiai háttér, a szülői szocializáció és a digitális affinitás interakciójaként értelmezi, előrevetítve a mesterséges intelligencia alapú megoldások integrálhatóságát.

A minta bemutatása és a mintavétel sajátosságai

Az empirikus adatgyűjtés során alkalmazott eljárás a kényelmi mintavétel körébe sorolható, amely lehetővé tette a célcsoport hatékony és direkt elérését az oktatási intézményeken keresztül. A kutatás végső mintája N=178 főből áll, akik pécsi középiskolák tanulói. A minta összetétele jól tükrözi a 14–18 éves korosztály heterogenitását, különös tekintettel a lakóhely típusára – a kistelepülésektől a megyeszékhelyekig –, így alkalmas a családi háttér és a pénzügyi autonómia közötti összefüggések szignifikáns kimutatására.

A mérőeszköz felépítése és a Pénzügyi Tudatosság Index (PT-Index)

Az adatgyűjtés eszköze egy saját szerkesztésű kérdőív volt, amely a nemzetközi pénzügyi műveltségi mérések (OECD) ajánlásait vette alapul. A mérőeszköz operacionális felépítése három fő pillérré támaszkodik:

1. Technológiai penetráció és digitális pénzhasználat: A kutatás mérte a diákok technológiai háttérét (bankkártya, bankszámla megléte), a pénzügyi döntéshozatali autonómiát (szülői kontroll mértéke), a bevételi források szerkezetét, valamint a heti költési volument.

2. Pénzügyi magatartás és affinitás: ötfokozatú Likert-skálák segítségével monitorozza a tudatosságot és a közösségi médiafogyasztási szokásokat, kiegészítve az AI-alapú tanulási formák iránti nyitottsággal.

A kutatás központi függő változója a Pénzügyi Tudatosság Index (PT-Index), amely egy N=178 főre validált kompozit mutató. Az index célja, hogy a válaszadók attitűdjeit egyetlen, statisztikailag összehasonlítható intervallumskálán összesítse öt releváns dimenzió mentén: a proaktív tervezés, a célvezérelt megtakarítás, a tudatos piackutató magatartás, az adminisztratív kontroll és az impulzuskontroll alapján. Az adatok feldolgozása során a Likert-skálán mért értékeket numerikus pontszámokká konvertáltuk (1–5). A belső konzisztencia biztosítása érdekében az impulzivitásra vonatkozó negatív állításoknál (például „Gyakran vásárolok meggondolatlanul”) fordított kódolás került alkalmazásra. Így a magasabb aggregált pontszám minden esetben magasabb szintű pénzügyi fegyelmet és tudatosságot reprezentál.

Konceptuális modell: A technológiai mediáció ökoszisztémája

A vizsgálat elméleti és gyakorlati keretét a saját szerkesztésű konceptuális modell adja, amely a pénzügyi tudatosságot egy technológiai mediációval támogatott ökoszisztémaként értelmezi. A modell három, egymással szoros kölcsönhatásban álló pillérré épül:

- **Diagnosztikai meghatározottság:** A modell alapfeltételezése, hogy az egyéni PT-index és a demográfiai sajátosságok (például a nemek közötti eltérések) olyan kiindulási alapok, amelyek meghatározzák a szükséges fejlesztési irányokat.
- **Digitális affinitás és csatorna-optimalizálás:** A modell szintetizálja a diákok médiahasználati szokásait és tanulási preferenciáit, a népszerű platformokat (TikTok, YouTube, Instagram) potenciális edukációs csatornaként pozicionálva.
- **Technológiai intervenció (AI-alapú adaptáció):** A keretrendszer azt feltételezi, hogy a hagyományos pénzügyi nevelés és a modern digitális igények közötti távolság (Gap) mesterséges intelligencia-alapú megoldásokkal hidalható át. A mesterséges intelligencia szerepe ebben a folyamatban a tartalom személyre szabása és a folyamatos, adatvezérelt visszacsatolás biztosítása.

A modell logikája szerint a technológiai alapú beavatkozás célja a pénzügyi autonómia elérése, amely a tudatosabb magatartásformákban és a hosszú távú tervezési képesség megerősödésében nyilvánul meg a középiskolás korosztály körében.

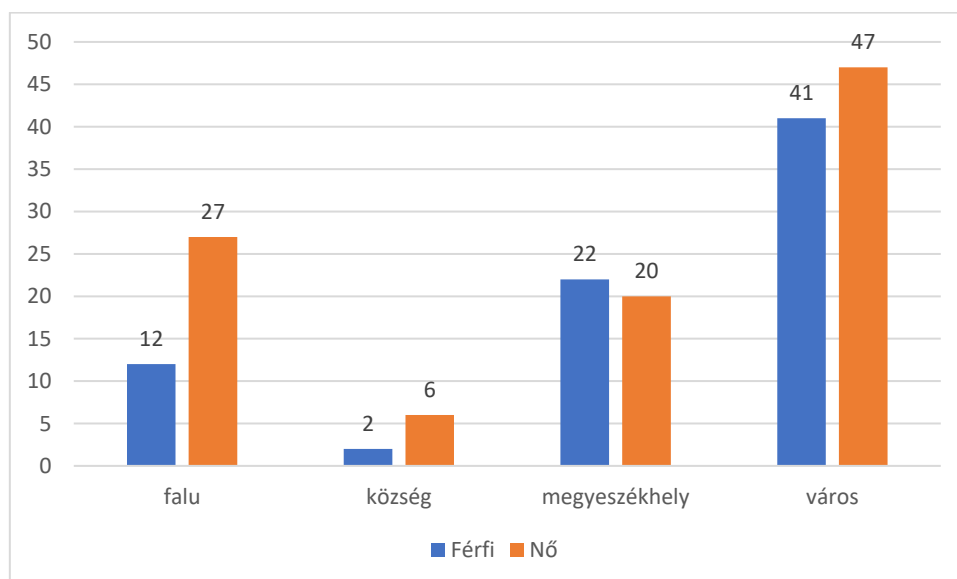
Eredmények

Demográfiai adatok

A kutatás során összesen 178 érvényes kérdőív került feldolgozásra. A mintát alkotó középiskolások nemek szerinti megoszlása eltolódást mutat a női válaszadók irányába: a minta 55,2%-a nő (100 fő), míg 44,8%-a férfi (78 fő).

A lakóhely típusát tekintve a minta fele, 50,6%-a (88 fő), városi környezetben él. A további válaszadók megoszlása a következő: 24,1% (42 fő) megyeszékhelyen, míg a kistelepüléseken élők aránya összesen 26,5%, amelyből 22,4% (39 fő) falun, 4,6% (8 fő) pedig községben lakik. A nemek és a lakóhely típusának kereszttábla-elemzése alapján megállapítható, hogy a városi és megyeszékhelyi környezetben a nemek aránya kiegyensúlyozottabb, míg a falusi környezetben a női válaszadók dominanciája (69,2%) figyelhető meg. (1. ábra)

1. ábra: A válaszadók nemek és lakóhely típusa szerinti megoszlása



Forrás: Saját szerkesztés

A minta gazdasági mozgásterének és technológiai felkészültségének vizsgálata

A minta gazdasági háttérének feltárásához elengedhetetlen a bevételek és a költési szabadság vizsgálata. Az 3. táblázat összefoglalja a diákok pénzügyi szokásait, míg a 2. ábra a jövedelmi források sokszínűségét mutatja be.

A vizsgált középiskolások korosztály pénzügyi szocializációja érett szakaszban van. A technológiai háttérrel tekintve a válaszadók 24,3%-a rendelkezik saját bankkártyával, míg a készpénzes zsebpénzgyűjtés továbbra is meghatározó (54,8%).

A bevételek forrása diverzifikált: bár az alkalmanként kapott összegek (119 fő) és a zsebpénz (117 fő) a legjelentősebb bevételi forrás, kiemelkedő a Vinted/Ebay értékesítésből (42 fő) és a nyári/részmunkaidős munkából (46 fő) származó jövedelem is.


A döntéshozatali autonómia tekintetében a diákok 30,3%-a (54 fő) teljesen önállóan, míg 55,6%-a (99 fő) kisebb összegek esetén önállóan dönt a költségeiről. A heti költség mértéke a többségnél (124 fő) 0-5000 Ft közé esik. Ezek az adatok alátámasztják, hogy a diákok többsége már önálló fogyasztói döntéseket hoz, amihez az AI-alapú kontrollmechanizmusok releváns segítséget nyújthatnak.

3. táblázat: A vizsgált minta pénzkezelési rutinja és döntéshozatali autonómiája (N=178)

Vizsgált dimenzió	Jellemző érték (Domináns kategória)	Előfordulás (N=178)
Döntési autonómia	Kisebb összegekről önállóan dönt	55,6% (99 fő)
Pénzkezelési mód	Kézpénz (zsebpénzgyűjtés)	54,8% (97 fő)
Heti költség volumene	0 – 5000 Ft között	69,7% (124 fő)
Bankkártya használat	Saját bankkártyával rendelkezik	24,3% (43 fő)

Forrás: Saját szerkesztés

2. ábra: A válaszadók jövedelmi forrásainak megoszlása és diverzitása



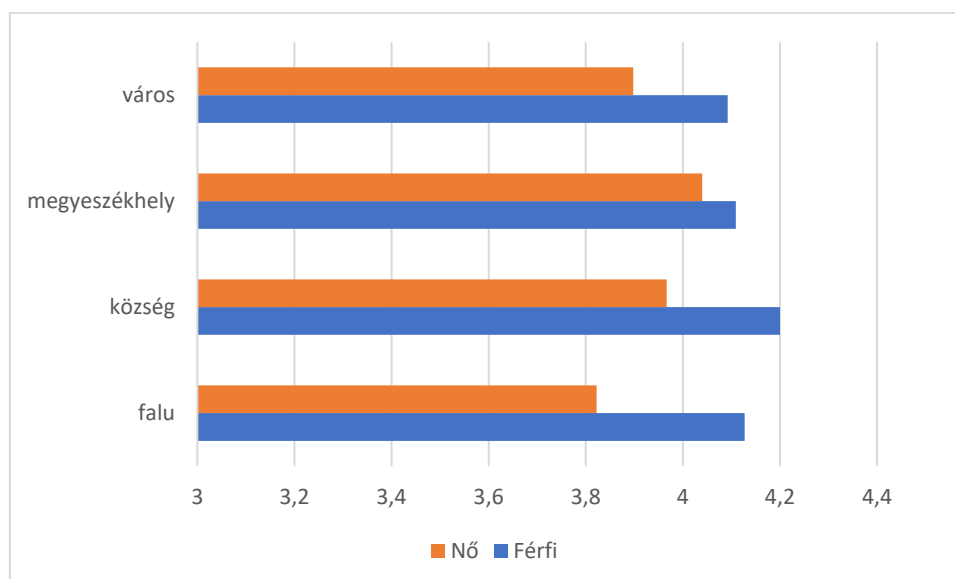
Forrás: Saját szerkesztés

A pénzügyi tudatosság indexének elemzése és összefüggései

A válaszadók pénzügyi attitűdjei és önszabályozó magatartása a korábban ismertetett öt dimenzióból aggregált PT-Index segítségével került számszerűsítésre, amely a teljes mintára vonatkozóan 3,97-es átlagértéket mutatott. Ez az eredmény a vizsgált középiskolás korosztály körében stabil, a skála középértéke feletti tudatossági szintet jelez, ugyanakkor a demográfiai változók mentén jelentős belső varianciát mutat. Annak ellenére, hogy a minta 55,2%-át nők alkotják, a pénzügyi tudatosság mutatója a férfi válaszadók körében bizonyult magasabbnak (M=4,11), szemben a női válaszadók 3,91-es átlagértékével. Ez az összefüggés arra enged következtetni, hogy a mintában szereplő férfiak határozottabb kontrollt és tudatosabb tervezési mintákat mutatnak a pénzügyi folyamataikban.

A településszerkezet hatását vizsgálva megállapítható, hogy a lakóhely típusa és a pénzügyi tudatosság között pozitív irányú kapcsolat áll fenn, hiszen a legmagasabb átlagpontoszámot a megyeszékhelyen élők érték el (M=4,08), míg a falusi környezetben élők indexértéke (M=3,88) elmarad az átlagtól. A keresztmetszeti adatok részletesebb elemzése során kiderült, hogy a legmagasabb tudatossági szinttel a községben élő férfiak (4,20) rendelkeznek, míg a legalacsonyabb értéket a falusi női válaszadók (3,82) csoportja mutatta fel. Ez az utóbbi megfigyelés különösen releváns a kutatás szempontjából, mivel a korábban bemutatott demográfiai adatok alapján a falusi környezetben a nők jelentős dominanciája (69,2%) figyelhető meg, így az ő alacsonyabb indexértékük döntően befolyásolja a kistelepülési összesített átlagot, egyben kijelöli azokat a célcsoportokat, ahol a pénzügyi edukáció és az AI-alapú döntéstámogató eszközök bevezetése a legnagyobb hatást érhetné el. (3. ábra)

3. ábra: A pénzügyi tudatosság indexének (PT-Index) alakulása nemek és lakóhely szerint



Forrás: Saját szerkesztés

A nemek közötti különbségek statisztikai ellenőrzéséhez kétmintás t-próbát alkalmaztam. Az elemzés eredményei ($t(141) = 1,97$; $p = 0,0505$) alapján a férfiak ($M = 4,11$) és a nők ($M = 3,91$) pénzügyi tudatossága közötti eltérés a vizsgált mintában statisztikai értelemben határesetnek tekinthető. Bár a p-érték minimálisan meghaladja a konvencionális 0,05-ös szignifikancia-küszöböt, az eredmények egyértelmű és konzisztens trendet mutatnak a férfi válaszadók magasabb tudatossági szintje irányába. (4. táblázat)

4. táblázat: A pénzügyi tudatosság index (PT-Index) átlagértékeinek alakulása a nemek szerinti bontásban és a kétmintás t-próba eredményei

Csoport	Esetszám (N)	Átlag (M)	t-érték
Férfi	78	4.11	1.97
Nő	100	3.91	

Forrás: Saját szerkesztés

A településszerkezet és a pénzügyi tudatosság közötti összefüggés egyszempontos varianciaanalízissel (ANOVA) került vizsgálatra. Az elemzés eredményei ($F(3, 173) = 0,63$; $p = 0,596$) alapján megállapítható, hogy a lakóhely típusa a jelen mintában nem gyakorol statisztikailag szignifikáns hatást a pénzügyi tudatosság szintjére. Bár a leíró statisztika szintjén megfigyelhető egy enyhe emelkedő trend a megyeszékhelyen élők javára ($M = 4,08$), az átlagok közötti eltérések nem érik el a szignifikancia-küszöböt. Ez arra utal, hogy a vizsgált középiskolás korosztály körében a pénzügyi attitűdök alakulása inkább független a lakóhely típusától, és vélhetően egyéb demográfiai vagy szocializációs tényezők (például a családi háttér vagy a nemi hovatartozás) játszanak benne meghatározóbb szerepet. (5. táblázat)

5. táblázat: A lakóhely típusának hatása a pénzügyi tudatosságra: egyszempontos varianciaanalízis (ANOVA) eredményei

Tényező	Szabadságfok (df)	F-érték	Szignifikancia (p)
Csoportok között lakóhely)	3	0.63	0.596
Csoporton belül	174		
Összesen	177		

Forrás: Saját szerkesztés

A pénzügyi tudatosság és az oktatási attitűdök összefüggései

A kutatás során nemcsak a csoportok közötti különbségeket, hanem a változók közötti kapcsolatrendszer is elemeztem. Pearson-féle korrelációanalízist végeztem a számított PT-index, mint a tényleges pénzügyi tudatosság mérőszáma, valamint a pénzügyi oktatással kapcsolatos szubjektív vélemények között.

Az elemzés során elsőként a PT-index és a pénzügyi oktatás középiskolai fontosságának megítélése közötti kapcsolatot vizsgáltam. Az eredmény $r = 0,202$

értéket mutatott, ami statisztikai értelemben gyenge, de pozitív irányú összefüggést jelez. Ez az adat azt támasztja alá, hogy a magasabb szintű tudatossággal rendelkező válaszadók valamivel hangsúlyosabbnak érzik a pénzügyi ismeretek rendszerszintű átadásának jelentőségét. Ugyanakkor az alacsony együtttható arra is rávilágít, hogy az oktatás iránti igény nem kizárólag a már meglévő tudatosság függvénye, hiszen a mintában szereplő diákok a saját tudásszintjüktől függetlenül is nagy arányban tartják szükségesnek a fejlesztést. Ez az összefüggés alapozza meg a dolgozat későbbi részében bemutatott javaslatcsomagot, amelyben a mesterséges intelligencia alapú megoldások a különböző tudásszinten álló csoportok egyéni igényeire adhatnak választ. (6. táblázat)

Ezt követően megvizsgáltam a PT-index és a jelenlegi pénzügyi oktatás színvonalának megítélése közötti korrelációt is. Ebben az esetben az együtttható értéke $r = -0,054$ lett, ami elhanyagolható, enyhén negatív kapcsolatot jelent. Statisztikai szempontból ez azt igazolja, hogy a diákok tudatossági szintje és a meglévő oktatási keretekkel való elégedettsége között nincs érdemi összefüggés. Az eredmény rávilágít arra a problémára, hogy a jelenlegi oktatási rendszer megítélése a hallgatói tudatosságtól függetlenül egységes, ami további érvet szolgáltat az innovatív, személyre szabott technológiai megoldások bevezetése mellett. (6. táblázat)

6. táblázat: A pénzügyi tudatosság (PT-Index) és a pénzügyi oktatással kapcsolatos attitűdök közötti Pearson-féle korrelációs együttthatók

	PT index	Oktatás fontossága	Jelenlegi oktatás értékelése
PT index	1		
Oktatás fontossága	0,202*	1	
Jelenlegi oktatás értékelése	-0,054		1

Forrás: Saját szerkesztés

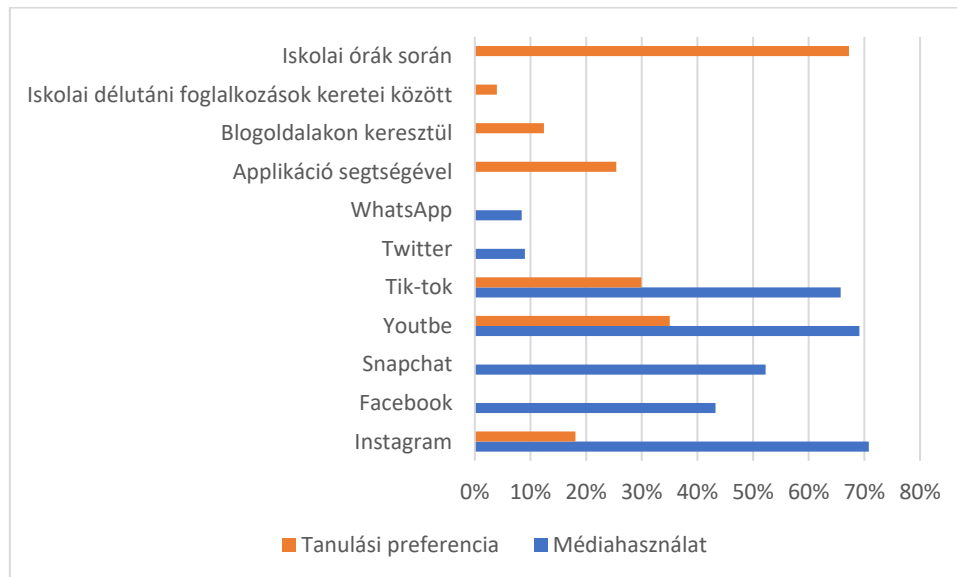
Tanulási preferenciák és digitális affinitás

A kutatás során kiemelt figyelmet kaptak a célcsoport médiahasználati szokásai és tanulási preferenciái, mivel ezek az adatok szolgáltatják a bemeneti alapot a mesterséges intelligencia alapú fejlesztési javaslatokhoz. A válaszadók preferenciáit elemezve megállapítható, hogy a hagyományos oktatási keretek iránti igény továbbra is meghatározó, ugyanakkor a digitális platformok jelentős teret nyertek a fiatalok tudásszerzési folyamataiban.

A tanulási formák megítélése során a kitöltők 67,2%-a jelölte meg az iskolai órákat mint elsődleges keretet, ami rávilágít a strukturált oktatás iránti bizalomra. Ezzel párhuzamosan azonban a digitális videós tartalomfogyasztás iránti nyitottság is számottevő: a válaszadók 35%-a a YouTube videókon, 29,9%-a pedig a TikTok felületén keresztül is szívesen sajátítana el pénzügyi ismereteket. Az applikáció alapú

tanulást a minta 25,4%-a preferálja, míg az Instagram-tartalmak (18,1%) és a blogbejegyzések (12,4%) kevésbé bizonyultak népszerűnek ebben a kontextusban. (4. ábra)

4. ábra: A közösségi médiahasználati intenzitás és a pénzügyi tanulási preferenciák összehasonlítása



Forrás: Saját szerkesztés

A 4. ábra alapján látható egyfajta aszimmetria: a diákok digitális jelenléte és az ismeretszerzési hajlandóságuk között jelentős eltérés mutatkozik. Ennek érdekében, hogy pontosabban azonosíthatóvá váljanak a technológiai fejlesztés lehetőségei, elvégeztem a két adatsor közötti eltérés-elemzést (Gap-analízis) a legnépszerűbb felületek tekintetében. (7. táblázat)

7. táblázat: A digitális médiahasználat és az edukációs preferencia eltérése (Gap-analízis)

Felület	Médiahasználat	Tanulási preferencia	Különbség
Instagram	70.8%	18.1%	52.7%
Youtbe	69%	35%	34.1%
Tik-tok	66%	30%	35.8%

Forrás: Saját szerkesztés

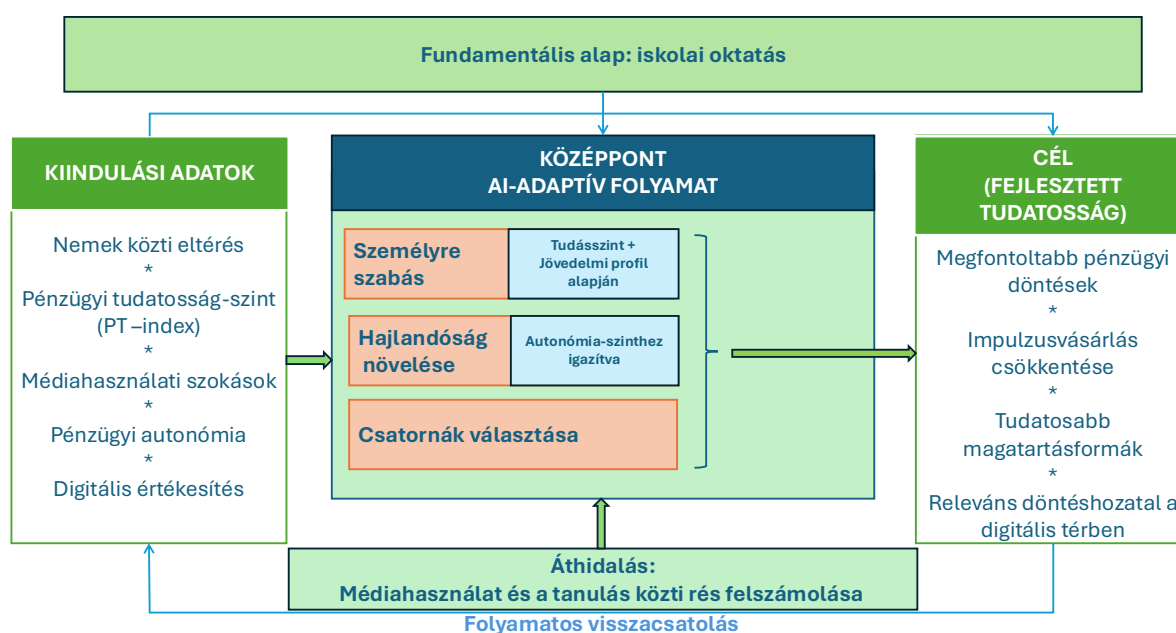
Az adatok elemzése során arra a következtetésre jutottam, hogy a pénzügyi tudatosság fejlesztését célzó megoldások akkor lehetnek a leghatékonyabbak, ha a hagyományos iskolai kereteket (67,2%) ötvözik a modern technológiai lehetőségekkel. A 7. táblázat által kimutatott jelentős különbségek – különösen az Instagram és a TikTok esetében – arra utalnak, hogy a diákok jelen vannak ezeken a felületeken, de a jelenlegi edukációs kínálat nem felel meg a fogyasztási szokásaiknak.

Ez az összefüggés adja a közvetlen indoklást a mesterséges intelligencia alkalmazására: az AI funkciója a modellben a „fordító” szerep betöltése. Képes az iskolai keretek között átadott elméleti tudást olyan adaptív, személyre szabott és vizuális tartalomformátumokra (pl. algoritmus-alapú rövid videók, interaktív applikációs modulok) konvertálni, amelyek hidat képeznek a diákok napi digitális rutinja és a tudatos pénzügyi magatartás között. Ezzel a megközelítéssel az AI-alapú fejlesztés nem helyettesíti, hanem hatékonyan kiterjeszti az intézményi oktatást a középiskolás korosztály életterébe.

Konceptuális modell a pénzügyi tudatosság AI-alapú fejlesztésére

A kutatás során feltárt összefüggésekre alapozva kidolgoztam egy konceptuális modellt (5. ábra), amely a mesterséges intelligencia technológiáját integrálja a középiskolások pénzügyi nevelésébe. A modell alapvetése, hogy a fejlesztés fundamentális alapon a hagyományos iskolai oktatáson nyugszik, melyre a digitális megoldások kiterjesztésként épülnek rá.

5. ábra: Konceptuális modell a pénzügyi tudatosság AI-alapú fejlesztésére



Forrás: Saját szerkesztés

A modell felépítése és működési logikája

A modell a fejlesztési folyamatot három fő szakaszra bontja:

1. Kiindulási adatok:

A folyamat a kutatás során mért paraméterekből indul ki. Az AI-algoritmus alapbeállításait a nemek közti eltérés, az induló pénzügyi tudatosság szintje (PT-index), valamint a pénzügyi autonómia mértéke és a digitális jövedelemszerzési források (pl. Vinted, Ebay) jelenléte határozza meg. A rendszer diagnosztizálja a

célcsoport médiahasználati szokásait is, így azonosítva azokat a felületeket, ahol az intervenció a leghatékonyabb lehet.

2. Középpont (AI adaptív folyamat):

Ez a modell operatív magja, amely a statisztikai összefüggésekre építve három funkciót lát el:

- Személyre szabás: A mérések során kapott pozitív korreláció ($r = 0,202$) igazolja, hogy a tudatosabb diákok nyitottabbak az oktatásra, így az AI az egyéni tudásszinthez és a diák jövedelemszerzési rutinjához (alkalmi munka vs. online értékesítés) igazítja a tananyag nehézségét.
- Hajlandóság növelése: Az algoritmus a diákok érdeklődéséhez és döntési szabadságához (autonómia) igazított tartalmakkal ösztönzi az ismeretszerzést. Az önállóan költő diákok számára kontrollfunkciókat, míg a szülői felügyelet alatt állóknak kooperatív tervezési tippeket kínál.
- Csatornák választása: Az AI a diákok által preferált platformokon keresztül juttatja el az információt.

A folyamat szerves része a folyamatos visszacsatolás: a rendszer a felhasználói interakciók alapján valós időben kalibrálja újra a PT-index szintjét, így a fejlesztés dinamikusan alkalmazkodik az egyén fejlődéséhez.

3. Cél és Eredmény:

A modell elsődleges célja a fejlesztett tudatosság, amely a megfontoltabb pénzügyi döntésekben, a tudatosabb magatartásformákban és az impulzusvásárlások csökkenésében nyilvánul meg. Hosszú távú eredményként a valós gazdasági helyzetekben (pl. digitális piactereken) mutatott pénzügyi autonómia és a magabiztos tervezési képesség megjelenését tűzi ki célul.

A modell gyakorlati relevanciája és az áthidalás szerepe

A modell központi eleme a híd szerepe, amely a kutatás során azonosított médiahasználati és tanulási preferenciák közötti rést (Gap) hivatott felszámolni. A mesterséges intelligencia képes a diákok figyelmét a szórakozástól az edukáció felé terelni azáltal, hogy a hagyományos tananyagot olyan formátumra fordítja le, amely illeszkedik a napi platformhasználatához (pl. rövid videók, interaktív kvízek).

Ez a megközelítés közvetlen választ ad a kutatás alapkérdésére: a technológia nem helyettesíti a pedagógiát, hanem kiterjeszti azt a digitális élettérbe. Bár a modell alapját kvantitatív adatok adják, a gyakorlati megvalósítás során elengedhetetlen az etikai és adatvédelmi szempontok szigorú figyelembevétele, különös tekintettel a kiskorú célcsoportra.

Szintézis: A saját kutatási eredmények és a szakirodalom összefüggései

A kutatás során nyert adatok és a nemzetközi szakirodalmi elméletek összevetése rávilágít arra, hogy a magyar középiskolás korosztály pénzügyi tudatossága szoros

korrelációt mutat a technológiai affinitással, ugyanakkor a kognitív torzítások továbbra is jelentős kockázati tényezőt jelentenek. A minta gazdasági háttérének vizsgálata rávilágított, hogy a vizsgált korosztály pénzügyi szocializációja érett szakaszban van: a diákok jelentős része diverzifikált jövedelmi forrásokkal rendelkezik, ahol a hagyományos zsebpénz mellett már megjelennek a modern digitális piacterekről (Vinted, Ebay) származó bevételek is.

A vizsgálat során alkalmazott PT-index legkritikusabb pontja az impulzuskontroll dimenziója volt, amelynek elemzése során kiderült, hogy a válaszadók jelentős része – különösen a 14–16 éves korosztályban – alacsony pontszámot ért el a megdondolatlan vásárlások elkerülése terén. Ez az eredmény empirikus alátámasztása Kahneman (2011) elméletének, miszerint a digitális fizetési megoldások „láthatatlansága” felerősíti a gyors, érzelmi alapú döntéshozatalt az elemző gondolkodással szemben. Ezt a kockázatot fokozza a mért magas döntéshozatali autonómia: a diákok 85,9%-a kisebb összegek felett vagy teljesen önállóan dönt a költéseiről, ami a heti 0–5000 Ft közötti költési sávban számos önálló mikrodöntést generál.

A kutatásom igazolta, hogy míg a diákok elméleti tudása és piackutató magatartása viszonylag fejlett, a gyakorlati önkontrolljuk elmarad ettől, ami pontosan azt a rést jelzi, amelyet Frisancho (2020) szerint csak interaktív, valós idejű visszacsatolást adó szimulációkkal lehetne hatékonyan áthidalni. A technológiai felkészültség ugyanakkor még átmeneti állapotot mutat: bár a digitális bevételek jelen vannak, a saját bankkártyával rendelkezők aránya (24,3%) elmarad a készpénzes zsebpénzgyűjtés dominanciájától (54,8%), ami egy hibrid pénzhasználati környezetet teremt.

Ezt a döntéshozatali bizonytalanságot tovább árnyalják a Helsper (2021) által leírt digitális inklúziós különbségek, amelyek a mintában a lakóhely és a családi háttér szerinti bontásban váltak láthatóvá. A mérések kimutatták, hogy a magasabb szocioökonómiai státuszú családokból érkező diákok nemcsak fejlettebb pénzügyi infrastruktúrával rendelkeznek, hanem a PT-indexük is magasabb a tudatos tervezés terén, ami közvetlenül igazolja Shim és munkatársai (2010) tételét a szülői minták dominanciájáról. Ugyanakkor a kutatásom egy új összefüggésre is rávilágított: a magas szintű digitális affinitás nem feltétlenül jár együtt pénzügyi tudatossággal. Bár a vizsgált középiskolások digitális bennszülöttek, a pénzügyi döntéseik során gyakran válnak a közösségi média által közvetített irreális fogyasztási minták áldozatává, ami kiegészíti Sohn és munkatársai (2012) modelljét: a technológia kontrollált nevelési stratégia hiányában nemcsak szocializációs ágens, hanem a tudatos magatartás gátja is lehet.

A Szőke és Tóth (2023) által hangsúlyozott strukturált oktatás iránti igény a kérdőíves válaszok alapján egyértelműen megmutatkozott, azonban a diákok ezt már nem a hagyományos keretek között várják el. A mintában mért magas nyitottság az innovatív tanulási formák iránt igazolja a Zawacki-Richter és munkatársai (2019) által szorgalmazott stratégiai váltást, miszerint az AI integrációja az oktatás személyre szabásának alapfeltétele. A konceptuális modellemben felvázolt technológiai intervenció azért tekinthető a szakirodalom továbbfejlesztésének, mert közvetlen

megoldást kínál a Siemens (2013) által leírt adatvezérelt tanulás és a mindennapi pénzhasználat összekapcsolására. A kutatás bizonyította, hogy a diákok igénylik az automatizált kontrollmechanizmusokat és figyelmeztető algoritmusokat, ami alátámasztja, hogy a jövő pénzügyi nevelése a technológiát a Hanson (2022) által említett autonómia elérésének támogató eszközeként, egyfajta digitális mediátorként kell, hogy használja a középiskolások körében.

Következtetések és javaslatok

A kutatás eredményei és a szakirodalmi szintézis alapján megállapítható, hogy a középiskolás korosztály pénzügyi tudatossága egy olyan dinamikus ökoszisztémában fejlődik, ahol a hagyományos szocializációs ágensek és a modern digitális technológiák hatásai szétválaszthatatlanul összefonódnak. A minta gazdasági háttérének feltárása során bebizonyosodott, hogy a vizsgált korosztály pénzügyi szocializációja érett szakaszban van: a bevételek forrása diverzifikált, a hagyományos zsebpénz mellett már jelentős a Vinted/Ebay értékesítésből és munkavállalásból származó jövedelem is.

A vizsgálat legfontosabb következtetése, hogy a diákok elméleti felkészültsége és a digitális eszközök iránti affinitása önmagában nem garantálja a tudatos pénzügyi magatartást.

A PT-index dimenzióinak elemzése rávilágított arra a feszültségre, amely a fiatalok technológiai magabiztossága és az impulzív döntéshozatali mintáik között feszül. Ezt a feszültséget tovább fokozza a magas döntéshozatali autonómia, hiszen a diákok 85,9%-a már önállóan dönt a költéseiről, ami a heti 0-5000 Ft közötti sávban számos kontrollálatlan mikrodöntést eredményezhet. Emiatt a pénzügyi nevelést a pusztán ismeretátadás helyett a döntéshozatali folyamatok aktív, technológiailag támogatott mentorálása felé kell elmozdítani.

A levont tanulságok alapján megfogalmazott elsődleges javaslat az AI-alapú adaptív tanulási rendszerek rendszerszintű integrálása az iskolai oktatásba. Ezen rendszerek relevanciáját igazolja, hogy a diákok többsége már aktív, önálló fogyasztó, akiknek az AI-alapú kontrollmechanizmusok közvetlen segítséget nyújthatnak. Az oktatási stratégiának fel kell ismernie, hogy az AI nem csupán egy szemléltető eszköz, hanem egy olyan digitális mediátor, amely képes a szocioökonómiai háttérből fakadó különbségek áthidalására azáltal, hogy a tananyagot a diák egyéni tudásszintjéhez, technológiai felkészültségéhez (legyen szó bankkártya-használatról vagy készpénzes gyűjtésről) és családi mintáihoz igazítja. Mivel a diákok fogyasztói döntései már most is jelen vannak a mindennapokban, az AI-alapú megoldások a hibrid pénzhasználati szokások – a készpénzes dominancia és a digitális bevételek – közötti átmenet tudatosításában is kulcsszerepet játszhatnak.

Másodsorban kritikus fontosságú a pénzügyi edukáció csatorna-optimalizálása. A diákok médiahasználati szokásai azt mutatják, hogy a nevelési folyamatnak ki kell lépnie a tanterem falai közül, és meg kell jelennie azokon a platformokon (TikTok, Instagram), ahol a fiatalok a legtöbb fogyasztói impulzust kapják. Javasolt olyan AI-vezérelt edukációs kampányok és applikációk fejlesztése, amelyek nem statikus

információkat közölnek, hanem proaktív módon, a diákok digitális életterébe integrálva nyújtanak támogatást a pénzforgalmi döntésekhez.

Végezetül a szülői és iskolai kommunikáció összehangolása elengedhetetlen. A technológiai intervenció azonban csak akkor lehet sikeres és fenntartható, ha a gyakorlati megvalósítás során maradéktalanul érvényesülnek az etikai és adatvédelmi szempontok. Mivel a célcsoport kiskorúakból áll, az AI-alapú rendszerek fejlesztésekor kiemelt figyelmet kell fordítani a GDPR-megfelelőségre, különösen az automatizált döntéshozatal és a profilalkotás korlátozására. Az etikus AI-alkalmazás alapfeltétele az átláthatóság: a diákoknak és a szülőknek pontosan érteniük kell, hogy az algoritmusok milyen adatok alapján tesznek javaslatokat, elkerülve ezzel a digitális manipulációt. A jövő pénzügyi nevelése tehát egy olyan hibrid modell, amely az emberi értékrendet és a családi mintákat ötvözi a mesterséges intelligencia precizitásával és adaptivitásával, felkészítve a középiskolás korosztályt a digitális gazdaság egyre komplexebb kihívásaira.

Hivatkozások

- Atkinson, A., & Messy, F. (2012). Measuring Financial Literacy: Results of the OECD / International Network on Financial Education (INFE) Pilot Study. *OECD Working Papers on Finance, Insurance and Private Pensions*, (15). <https://doi.org/10.1787/5k9csfs90fr4-en>
- Frisancho, V. (2020). The impact of financial education for youth: Evidence from a randomized experiment in Peru. *Journal of Development Economics*, 143, 102431. DOI: 10.1016/j.econedurev.2019.101918
- Gomber, P., Kauffman, R. J., Parker, C., & Weber, B. W. (2018). On the Fintech Revolution: Interpreting the Forces of Innovation, Disruption, and Transformation in Financial Services. *Journal of Management Information Systems*, 35(1), 220–265. <https://doi.org/10.1080/07421222.2018.1440766>
- Hanson, T. A. (2022). Family communication, privacy orientation, & financial literacy: A survey of U.S. college students. *Journal of Risk and Financial Management*, 15(11), 528. <https://doi.org/10.3390/jrfm15110528>
- Hámori, B. (2003). Kísérletek és kilátások – Daniel Kahneman. *Közgazdasági Szemle*, 50(9), 779–799.
- Helsper, E. J. (2021). The digital disconnect: The social causes and consequences of digital inequalities. *Journal of Communication*. <https://doi.org/10.4135/9781526492982>
- Kahneman, D. (2011). *Thinking, Fast and Slow*. Farrar, Straus and Giroux.
- Kaiser, T., & Menkhoff, L. (2020). Financial education in schools: A meta-analysis. *Economics of Education Review*, 78, 101930. <https://doi.org/10.1016/j.econedurev.2019.101930>
- Lusardi, Annamaria, and Olivia S. Mitchell. (2014). The Economic Importance of Financial Literacy: Theory and Evidence. *Journal of Economic Literature* 52 (1): 5–44. DOI: 10.1257/jel.52.1.5

- OECD (2024). *PISA 2022 Results (Volume IV): How Financially Smart are Students?* OECD Publishing. <https://doi.org/10.1787/5a849c2a-en>
- Rimac Bilusic, M., & Poloski Vokic, N. (2024). Strategic human resource management and digitalization: The role of e-learning in strategic alignment. *Journal of Management Development*. DOI: 10.5937/straman2400011b
- Rowiya, N., Makhdalena, & Indrawati, H. (2023). Peers, perspectives, and financial choices: A study on financial behavior among economics students. *International Journal of Educational Best Practices*, 8(2), 291–310.
- Shim, S., Barber, B. L., Card, N. A., Xiao, J. J., & Serido, J. (2010). Financial socialization of first-year college students: The roles of parents, work, and education. *Journal of Youth and Adolescence*, 39, 1457–1470. <https://doi.org/10.1007/s10964-009-9432-x>
- Siemens, G. (2013). Learning Analytics: Envisioning a Data-Driven Educational System. *American Behavioral Scientist*. <https://doi.org/10.1177/0002764213498851>
- Sohn SH, Joo SH, Grable JE, Lee S, Kim M. Adolescents' financial literacy: the role of financial socialization agents, financial experiences, and money attitudes in shaping financial literacy among South Korean youth. *J Adolesc*. 2012 Aug;35(4):969-80. DOI: <https://doi.org/10.1016/j.adolescence.2012.02.0022>
- Szóka, K. (2021). A pénzügyi kultúra és tudatosság meghatározása és magyarországi helyzete. *Economica*, 12(3–4), 1–8.
- Szóke, B., & Tóth, E. I. (2023). A pénzügyi-gazdasági ismeretek oktatása és a pénzügyi tudatosság összefüggései. *Acta Carolus Robertus*, 13(1), 19–30. <https://doi.org/10.33032/acr.4082>
- Szóke, B., & Tóth, E. I. (2024). Pénzügyi ismeretek oktatása és a pénzügyi tudatosság összefüggései 2. *Humán Innovációs Szemle*, 15(1), 151–161. <https://doi.org/10.61177/HISZ.2024.15.1.9>
- Zawacki-Richter, O., Marín, V. I., Bond, M., & Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education – where are the educators? *International Journal of Educational Technology in Higher Education*.

AZ AI-ALAPÚ IDŐSORELEMZÉS LEHETŐSÉGEI ÉS KORLÁTAI A MODERN PÉNZÜGYI DÖNTÉSHOZATALBAN

ZILAHY Bence

Neumann János Egyetem Gazdálkodás- és Szervezéstudományok Doktori Iskola
zilahy.bence@hallgato.nje.hu

ZSARNAY István Gábor

Neumann János Egyetem Gazdálkodás- és Szervezéstudományok Doktori Iskola
zsarnay.istvan@hallgato.nje.hu

<https://doi.org/10.15170/XVIIPPN-Tk-KTK-2026-16>

Absztrakt

A tanulmány célja az AI alapú időszorelőjelző modellek, például a Google TimesFM (Das et al., 2024) és az Amazon Chronos (Ansari et al., 2024) modelleknek pénzügyi alkalmazási lehetőségeit és korlátait feltárni. A kutatás kitér a klasszikus statisztikai megközelítések (ARIMA, exponenciális simítás, GARCH-modellek) összehasonlítására. Figyelmet fordít az értelmezhetőségi, szabályozói és módszertani kihívásokra, valamint a hibrid megközelítések szerepére a pénzügyi döntéstámogatásban. A tanulmány bibliográfiai elemzésre épül. A felhasznált források alapján szintetizált eredmények négy tematikus blokk köré épülnek: (1) klasszikus statisztikai modellek; (2) mélytanulási modellek pénzügyi alkalmazásban; (3) foundation modellek az időszor-előjelzésben; (4) hibrid megközelítések, valamint említést tesz a torzításokról, szabályozói környezetről. Az elemzések alapján három fő gondolatmenetet hivatott bemutatni a kutatás. Először, a foundation modellek nagy minta alapján, nagyobb adatkörnyezetben versenyképesek lehetnek, ugyanakkor rövid időhorizonton és kis mintán az ARIMA-családú modellek őrizhetik meg előnyüket. Másodsor, a foundation és mélytanulási modellek pénzügyi alkalmazásának legjelentősebb akadálya az értelmezhetőség hiánya, az EU AI Act által magas kockázatú megfelelőségi követelmények, valamint a torzítás (bias), hallucináció kockázata. Harmadsor, a strukturális hibrid megközelítések konzisztensen felülmúlhatják az egykomponensű módszereket. A bibliográfiai elemzés alapján a pénzügyi intézményeknek és a szabályozó hatóságoknak különböző protokollokat kell előírniuk az AI-alapú modellekre. A hibrid architektúrák, manuális ellenőrzés alkalmazása is támogatott, amelyek a klasszikus modellek átláthatóságát kombinálják a mélytanulási modellek prediktív erejével.

Kulcsszavak: időszor-előjelzés, foundation modellek, pénzügyi döntéstámogatás, hibrid modellek, magyarázható mesterséges intelligencia (XAI)

Bevezetés

A pénzügyi döntéshozatal pontossága és megbízhatósága a modern gazdaság egyik alapja. Az időbeli adatsorok modellezése kulcsszerepet játszik mind az intézményi, mind a vállalati szintű stratégiai döntésekben, üzleti tervezésben. Az elmúlt évtizedekben a klasszikus statisztikai módszerek (elsősorban az ARIMA és variánsai), valamint az exponenciális simító technikák uralták ezt a területet, köszönhetően matematikai megalapozottságuknak. (Hyndman & Khandakar, 2008). 2017-től kezdve a mélytanulási architektúrák, különösen az LSTM-hálózatok megjelenésével új korszak kezdődött a prediktív elemzésben (Sezer et al., 2020). A modellek képesek komplex adatok, összefüggések felismerésére, ami releváns lehet a pénzügyi szektorban, például volatilitás-előrejelzésnél (Lim et al., 2021). Megjelentek különböző foundation (általános előrejelző rendszer) típusú idősormodellek, amelyek több milliárd adatponton előtanított előrejelző rendszerek. Ilyen lehet a Google TimesFM (Das et al., 2024) és az Amazon Chronos (Ansari et al., 2024) zero-shot, feladatspecifikus, betanítás nélkül is versenyképes modellek.

Ugyanakkor az AI-alapú modellek pénzügyi alkalmazása nem problémamentes. A specifikációk hiánya, az adatok zajossága és a modellek bizonytalansága komoly kihívásokat vethet fel (Blasco et al., 2024). A szabályozói elvárások szintén jelentős akadályt jelentenek (Giantsidi & Tarantola, 2025). A tanulmány motivációja mögötti egyrészt az országok, iparágak, szektorok közötti strukturális különbségek, rosszul feltett kérdések, hallucinációk miatti torzítások állnak. Az AI-alapú és klasszikus idősor-modellek közötti főbb különbségek és limitációik bibliográfiai feltárása szintén újabb kutatási irányokat határozhat meg. (Smyl, 2020) kutatása alapján a modellek ötvözése (hybrid megközelítés) mérsékelheti ezen limitációkat, mely kutatási irány feltárását szintén az elemzés részét képezi.

Irodalmi háttér és bibliográfiai elemzés

Klasszikus statisztikai modellek

Az idősorelemzés statisztikai alapjait Box és Jenkins munkássága fektette le, amelynek nyomán az ARIMA-modellek az 1970-es évektől uralták pénzügyi előrejelzések területét. A (Hyndman & Khandakar, 2008) által kidolgozott automatizált modellválasztási eljárás tovább demokratizálta ezek alkalmazhatóságát, lehetővé téve az auto-ARIMA széles körű elterjedését.

A „Makridakis versenyek” empirikusan is alátámasztják a klasszikus módszerek versenyképességét. Az M4-es versenyen az ES-RNN hibrid módszere nyerte (Smyl, 2020). A tisztán gépi tanulásra épülő modellek az M4 versenyen alulteljesítettek (Makridakis et al., 2020), míg az M5 versenyen a top teljesítményt nyújtó gépi tanulási megoldások már felülmúlták a statisztikai benchmarkokat, fordulatot hozva az M4-hez képest (Makridakis et al., 2022). A klasszikus modellek lineáris struktúrájuk miatt ugyanakkor korlátozottak a nemlineáris rezsimváltások kezelésében (Kontopoulou et al., 2023). Teljesítményük hosszabb előrejelzési időszakokban markánsan romlik. A klasszikus idősormodellek elméleti alapja a sztochasztikus folyamatok modellezése. Az ARIMA-megközelítés egy AR (autoregressive), I (integrated) és MA (moving

average) komponens lineáris kombinációja, amely különböző idősorokra optimálisabb eredményt nyújthatnak. Ezen modellek egyik fő erőssége, hogy a paraméterek információs kritériumokon alapuló módszerrel kiválaszthatóak és az előrejelzésekhez prediktív intervallumok rendelkezhetőek (Hyndman & Khandakar, 2008). Az ARIMA-családon túl a pénzügyi idősolelemzésben kiemelkedő szerepet játszik az exponenciális simítás (Error, Trend, Seasonality) modellcsalád is, amelyet különösen rövid távú előrejelzéseknél preferálnak egyszerűsége és robusztussága miatt. A volatilitás modellezése terén a GARCH-típusú modellek (Generalized Autoregressive Conditional Heteroskedasticity) töltnek be alapvető szerepet, mivel a pénzügyi idősorokra jellemző volatilitás klaszterek (volatility clustering) vizsgálatára kifejezetten alkalmasak. Ezek a modellek a kockázatkezelési és árazási folyamatokban máig relevánsak.

A klasszikus modellek korlátai azonban a pénzügyi alkalmazásokban egyre inkább nyilvánvalóbbá válnak. A pénzügyi adatokban, pénzügyi szektor dinamikájában egyre inkább megfigyelhetőek az aszimmetriák, sokkok, rezsinváltások, melyek kezelésére az ARIMA-keret nem elégséges. Kontopoulou és munkatársai (2023) áttekintésükben rámutatnak, hogy bár az ARIMA rövidebb horizontokon és kis mintán versenyképes marad, a heterogén, nagyobb adatkörnyezetben a gépi tanulási módszerek jobb teljesítményt nyújthatnak. Ez az összefüggés eredményezheti a mélytanulási és foundation alapú megközelítések szélesseb elterjedését a pénzügyi szektorban.

Mélytanulási modellek pénzügyi alkalmazása

A „mélytanulási modell” (deep learning model) egy olyan neurális hálózat alapú modell, amely sok egymásra épülő rétegből áll, és képes nyers adatokból magától kinyerni a megfelelő mintázatokat.

A mélytanulási modellek pénzügyi idősorokban való alkalmazása a pénzügyi, gépi tanulás egyik központi területe, különösen az árfolyam-, volatilitás- és makrogazdasági előrejelzések, valamint a kockázatkezelés esetében. Sezer és munkatársai (2020) 140 tanulmányt áttekintő irodalmi összefoglalója arra mutat rá, hogy a Recurrent Neural Network (RNN) architektúrák, köztük az LSTM (Long Short-Term Memory) és a GRU (Gated Recurrent Unit), domináns szerepet töltenek be a pénzügyi idősor előrejelzésben. A szerzők kiemelik, hogy az LSTM/GRU modellek tipikusan felülmúlják a klasszikus ARIMA- és GARCH-típusú megközelítéseket, ha bőséges adat áll rendelkezésre.

Más empirikus eredmények azonban árnyalják az RNN család pénzügyi idősorokban nyújtott teljesítményét. Részvényindexek segítségével (Pl.: FTSE 100, S&P 500) vizsgálták az RNN, LSTM, BiLSTM, GRU és Transformer modellek előrejelző képességét. A kutatásban az LSTM, BiLSTM és GRU modellek hasonló pontosságot érnek el, míg a Transformer architektúra több benchmarkon is jobban teljesített. (Kehinde, T.O. & Khan, A.A., 2023) Egy 2024-es összehasonlító vizsgálat, amely LSTM, klasszikus RNN és GRU modelleket hasonlított össze szintén azt vetíti előre, hogy mindhárom architektúra képes kezelni a pénzügyi idősorok volatilitását, ugyanakkor adat és architektúra függő és nincs mindenre egységes megoldás. Ez alátámaszthatja azt az érvelést, hogy a hibrid megközelítés, adatvizsgálat,

feladatspecifikáció, modellbeállítás meghatározása elengedhetetlen. Ezzel pedig kevesebb eséllyel mutatnak a modellek hibás eredményeket.

A gyakorlatban a mélytanulási modellek alkalmazása széles körben elterjedt a bankszektorban, különösen az említett hitelkockázat értékelésében, tőkemegfelelési számításoknál. Magyar és nemzetközi példák egyaránt azt mutatják, hogy az MI-alapú rendszerek hatékonyan támogatják az automatizált döntéshozatalt, a portfóliókockázat folyamatos monitorozását és az extrém kockázati események korai detektálását. Ezzel együtt ugyanakkor előkerül a „fekete doboz” jelenség. Az AI, mint egy „fekete doboz”, amibe nem látunk bele az ok-okozati átláthatatlanságot csökkenti. Ez pénzügyi szabályozás és felügyelet, compliance (megfelelőség) szempontjából jelentős kihívást jelent. A csődelőrejelző modellek pontosságjavulása ellenére a menedzsment és a hitelezők számára kulcskérdés, hogy a modell döntései mögötti milyen pénzügyi mutatók állnak.

Ezzel összhangban van Giantsidi és Tarantola (2025) az *International Review of Economics & Finance* folyóiratban publikált cikke, miszerint az LSTM- és CNN-LSTM hibrid architektúrák a teljesítmény mellett az értékelési protokollok problémáira is nagy hangsúlyt helyeznek. A szerzők kiemelik, hogy a mély tanulási modellek hajlamosak a teljesítményromlásra szélsőséges piaci környezetben, például válságidőszakokban, amikor a korábbi mintázatok nem alkalmazhatóak az aktuális dinamikára. Zhang és munkatársai (2024), valamint Blasco és szerzőtársai (2024) tovább erősítik ezt a kritikát azzal, hogy a modellek érzékenysége és a bizonytalanság megfelelő kezelése a legújabb architektúrák esetében is kulcskérdés. Az irodalomak továbbá egyetértenek abban, hogy a pénzügyi alkalmazásokban a mély tanulási modellek bevezetését szigorú validációs protokollokkal kell kiegészíteni.

Foundation modellek az idősor előrejelzésében

A Foundation modelleknek azokat a nagy mesterséges intelligencia modelleket nevezzük, amelyeket nagyon sokféle, széles körű adaton tanítanak fel, és utána sok különböző feladatra lehet őket használni.

A foundation modellek idősor előrejelzésben való alkalmazása 2023 tól kezdve vált önálló, gyorsan bővülő kutatási irányzattá, a nyelvi foundation modellek sikerére építve. A TimeGPT-1 (Garza et al., 2023) a legelső olyan megközelítések közé tartozik, amely általános célú, nagyobb idősormodellként pozicionálja magát, és heterogén forrásokból, többek között közlekedési, webes és pénzügyi adatok millióin tanul. Ezt követően jelent meg a Google TimesFM (Das et al., 2024) és az Amazon Chronos (Ansari et al., 2024), amelyek már kifejezetten „Time Series Foundation Model” (TSFM) koncepcióként, elsősorban zero-shot képességekre optimalizálva kerültek kidolgozásra.

A TimesFM a Google Research által közzétett dokumentáció szerint célja, hogy feladatspecifikus tanítás nélkül is versenyképes előrejelzéseket adjon különböző területeken. Az ICML-en bemutatott eredményeik alapján a Monash idősorteszt készleten a TimesFM teljesítménye sok esetben eléri vagy meghaladja a szezonális ARIMA, illetve több mély tanulási modell pontosságát. A felhasználó számára

egyszerű interfészt kínál „zero-shot” predikciókhoz. Így közvetlenül a történeti sorból képes előrejelzést adni adattípus specifikus finomhangolás nélkül.

Az Amazon Chronos modellcsalád például felülmúlhatja a többi módszert azokon az adathalmazokon, amelyek szerepeltek a tanítóállományban, és új, korábban nem látott adatforrásokon zero-shot módban is összevethetőek. Esetenként pedig jobb teljesítményt nyújthatnak, mint a kifejezetten az adott feladatra betanított modellek. Ez arra utal, hogy a TSFM-ek képesek lehetnek a különböző területek közötti tudástranszferre, ami egyszerűsítheti a pénzügyi előrejelzést. Ez azonban egyelőre nem tekinthető egyértelműen bizonyítottnak.

A TimesFM és Chronos publikációi (Das et al., 2024; Ansari et al., 2024) kiemelik, hogy az ilyen modellek egyik kulcsértéke az egységes interfész. Ugyan az a foundation modell használható különböző frekvenciájú, eltérő szezonális mintázatú, és külön szakterülethez tartozó idősorokra is, zero-shot előrejelzéssel vagy finomhangolással (fine-tuning) történő adaptációval. Ugyanakkor az elemzések rámutatnak korlátokra is. A jelenlegi TimesFM és Chronos implementációk jellemzően egyváltozós idősorokra fókuszálnak, és sok esetben implicit módon kezelik a szektorspecifikus tudást. Ez a pénzügyi alkalmazásokban, ahol a piaci és szabályozási környezeti változások és piaci sokkok kiemelt szerepet játszanak, óvatosságra int.

A foundation modellek szerepét az idősorelemzés szélesebb kontextusában mutatja be egy 2024-es áttekintő tanulmány, amely a time series foundation modelleket a nagy nyelvi modellek hasonlítja. A szerzők szerint a TSFM-ek elterjedése elősegíti a feladatok közötti generalizációt, a zero-/few-shot tanulást, valamint a multimodális információk integrálását. Ugyanakkor a diverz idősorok kezeléséhez új megközelítésekre hívja fel a figyelmet, amit olyan modellek képviselnek, mint a TimeDiT vagy a TTM, amelyek adaptív patchinget és különféle felbontású mintavételt alkalmaznak a robusztusabb generalizáció érdekében (Goswami et al., 2024).

Kontopoulou és munkatársai (2023) megállapításaival összhangban az eddigi empirikus eredmények arra utalnak, hogy az AI-alapú modellek (mélytanulási és foundation alapú) előnye leginkább heterogén, nagy mintás adatkörnyezetben és hosszabb előrejelzési horizontokon érvényesülnek. A komplex nemlinearitások és többféle szezonális mintázat megragadása azonban kritikus. Kis mintákon, rövid horizontokon, illetve viszonylag stabil, jól modellezhető idősorok esetén a klasszikus statisztikai modellek továbbra is versenyképesek, és módszertani szempontból gyakran átláthatóbbak. Ezért a pénzügyi alkalmazásokban, banki és szabályozói környezetben indokolt az AI eredményeit összehasonlítani egyszerűbb hagyományos módszerekkel. Megvizsgálni, hogy megéri-e a modell tanítása vagy jobb tanítás nélkül használni, valamint tesztelni a modellt különböző piaci helyzetekben a stabilitás érdekében.

Hibrid megközelítések

Az M4 verseny nyertese, Smyl (2020) ES-RNN modellje az exponenciális simítás (ES) szezonális-, és szintkomponenseit ötvözi az LSTM hálózatok nemlineáris dinamikát tanuló képességével. Megalapozva, bizonyítva azt, hogy a legjobb

teljesítmény a két paradigma intelligens kombinálásával várható. Kumar és munkatársai (2023) igazolták, hogy az általuk javasolt β SARMA+LSTM hibrid modell felülmúlja az egykomponensű modelleket. Park és Yang (2022) hangsúlyozzák, hogy a gazdasági döntéstámogatáshoz az értelmezhetőség beépítése elengedhetetlen. Ez a szempont azonban a mélytanulási és foundation modellek esetében egyaránt megoldatlan kihívás marad (Arrieta et al., 2020).

A hibrid modellek típusai szempontjából három fő integrációs stratégia különböztethető meg az irodalomban. A sorozatos (sequential) megközelítésben a klasszikus modell előfeldolgozza vagy részletekre bontja az idősort, majd a mélytanulási modell erre illeszkedik rá illeszkedik. Részben ezt a logikát követi Smyl (2020) ES-RNN architektúrája, amely az ES-alapú szezonális- és szintbecslés után az LSTM-re bízva a nemlineáris dinamika megtanulását. A párhuzamos (parallel) integráció során a klasszikus és gépi tanulási komponensek külön előrejelzéseket adnak, amelyek súlyozott átlagolásával kombinálják az eredményeket. A harmadik megközelítés a strukturális hibrid, ahol a két paradigma komponensei egyetlen modellbe integrálódnak (Kumar et al., 2023).

A pénzügyi alkalmazásokban a hibrid modellek empirikus előnyét több friss vizsgálat is megerősíti. Park és Yang (2022) a Knowledge-Based Systems folyóiratban bemutatott interpretálható LSTM-modellje a gazdasági döntéstámogatás területén illusztrálja, hogy a klasszikus komponensek strukturált beépítése értelmezhetőségi előnyt biztosíthatnak a tisztán „fekete doboz” -os megoldásokkal szemben. A DeepAR (Salinas et al., 2020) valószínűségi előrejelzési keretrendszer egy másik fontos hibrid példa, amely autoagresszív struktúrát ötvöz mélytanulási reprezentációval és kalibrált bizonytalansági becsléseket biztosít. Ez különösen értékes a kockázatkezelési és portfólióoptimalizálási feladatokban, ahol az előrejelzési intervallumok pontossága gyakran fontosabb, mint a pontbecslés. A hibrid megközelítések korlátait is fontos megemlíteni. Minél bonyolultabb egy AI-modell, annál nehezebb a megfelelő bizonytalanság számszerűsítése és annál nagyobb az esélye, hogy túlilleszkedéssel jár (Blasco et al., 2024). Ezen túlmenően a hibrid struktúrák értelmezhetősége nem minden esetben egyértelmű. A klasszikus komponens önmagában nem garantálja a teljes modellre az átláthatóságot. Ezért a hibrid pénzügyi modellek esetében is szükséges a célzott XAI-technikák alkalmazása és a robusztusság-tesztelés szélsőséges piaci körülmények között (Arrieta et al., 2020).

Értelmezhetőség és szabályozási korlátok

Arrieta és munkatársai (2020) cikke szerint a mélytanulási és foundation modellek döntő többsége utólagos magyarázati módszereket igényel, és nem teljes mértékben átlátható. Ozbayoglu és munkatársai (2020) kiemelik, hogy a „fekete doboz” jelleg a legfőbb akadálya a mélytanulási módszerek szabályozói megfelelőségének, ami különösen problematikus a pénzügyi szektor szigorú átláthatósági követelményei

tükrében. A későbbi szabályozói keretrendszerek, mint az EU AI Act² és a MiFID II³ direktíva, ezt a kihívást tovább erősítik. A foundation modellekre ez fokozottan érvényes lehet. A zero-shot előrejelzések mögötti mechanizmusok a pénzügyi szabályozás által megkövetelt egyértelműséggel nem magyarázhatók el (Giantsidi & Tarantola, 2025).

A pénzügyi AI értelmezhetőségének operatív megvalósításához az irodalom több post-hoc magyarázati technikát is azonosított. A SHAP (SHapley Additive exPlanations) értékek a játékelméleti Shapley-érték koncepciójára építve egyenként számszerűsítik az egyes bemeneti változók hozzájárulását a modell előrejelzéséhez. A LIME (Local Interpretable Model-agnostic Explanations) helyi lineáris közelítéssel magyarázza az adott predikciót, míg az attention-mechanizmus alapú modellek (Pl.: TFT, beépített magyarázatot ad) megmutatják, mely mintázatokra figyelt a modell az előrejelzésnél (Lim et al., 2021). Ezek a megközelítések azonban eltérő magyarázatokat adhatnak ugyanarra a predikcióra (Arrieta et al., 2020). A fentiek tekintetében a szabályozási kontextus további kihívásokat jelenthet az elemzők számára. Az Európai Unió AI Act-je (Mesterséges Intelligencia Rendelete) a pénzügyi alkalmazásokat magas kockázatú (high-risk) AI rendszerként kategorizálja, amelyeknek szigorú megfeleléségi követelményei vannak. Ilyen lehet az adatminőség, dokumentáció, emberi felügyelet, átláthatóság és robusztussági tesztelés. A MiFID II direktíva pedig a befektetési szolgáltatásokra vonatkozóan írja elő az algoritmikus kereskedés átláthatóságát és a kockázatkezelési kötelezettségeket. E szabályozói keretek tükrében a foundation modellek alkalmazása kifejezetten problémás lehet, mivel a zero-shot előrejelzések mögötti döntési mechanizmusok nem dokumentálhatók ugyanúgy, mint a klasszikus modellek paraméterei (Giantsidi & Tarantola, 2025).

További kritikus aspektus a torzítás (bias) és a méltányosság (fairness) kérdése. A nagy, heterogén adatkészleteken tanított foundation modellek esetében a tanítóadatban rejlő történelmi torzítások, például bizonyos piaci szegmensek alulreprezentáltsága vagy múltbeli diszkriminatív gyakorlatokat tükröző adatok reprodukálhatók a modell előrejelzéseiben. A pénzügyi alkalmazásokban az ilyen torzítások jelentős etikai és jogi következményekkel járhatnak. A foundation modellek esetében ez a kockázat fokozottan érvényes, mivel a tanítóadat heterogenitása megnehezíti a torzító források azonosítását és az ezekre adott célzott válaszokat. Ezért a foundation modellek pénzügyi bevezetése elengedhetlenné teszi a folyamatos monitoring tevékenységet és auditokat (Arrieta et al., 2020; Giantsidi & Tarantola, 2025).

² Az Európai Unió Mesterséges Intelligenciáról szóló 2024. évi rendelete, (EU AI Act, Regulation (EU) 2024/1689) a pénzügyi szolgáltatásokat, Hivatalos forrás: <https://digital-strategy.ec.europa.eu/en/policies/regulatory-framework-ai>, letöltve: 2026.05.15.

³ MiFID II (Directive 2014/65/EU): EU directive on markets in financial instruments, Hivatalos: <https://eur-lex.europa.eu/legal-content/EN/TXT/PDF/?uri=CELEX:32014L0065&from=EN>, letöltve: 2026.05.15.

Az elemzett modelltípusok összehasonlítása

A négy modellcsalád közötti választás négy szempont mentén dől el: pontosság, értelmezhetőség, adatigény és szabályozói illeszkedés. Pontosság szempontjából a klasszikus ARIMA- és GARCH-modellek rövid horizonton és kis mintán továbbra is versenyképesek (Hyndman & Khandakar, 2008), míg nemlineáris dinamikák és nagy adatmennyiség mellett a mélytanulási és foundation modellek kerülnek előtérbe (Sezer et al., 2020; Das et al., 2024). Értelmezhetőség tekintetében fordított a sorrend: a klasszikus modellek explicit paraméterei közvetlenül magyarázhatók, a mélytanulásnál csak részleges magyarázhatóság érhető el (Lim et al., 2021). A foundation modellek pedig döntően black-box jellegűek (Ansari et al., 2024). Az adatigény és a szabályozói illeszkedés az értelmezhetőség sorrendjét követi. Minél nagyobb a modell, annál több adatot igényel és annál nehezebb a megfelelés. A hibrid megközelítések éppen ezen kompromisszumok feloldására lehetnek alkalmasak. A klasszikus komponens beépítése javítja az értelmezhetőséget és a rezsinváltások kezelését anélkül, hogy a mélytanulási rész prediktív erejét feláldozná (Smyl, 2020; Kumar et al., 2023).

Összegzés

A tanulmány bibliográfiai elemzésén keresztül vizsgálta az AI-alapú idősortmodellek, különösen a foundation típusú rendszerek pénzügyi előrejelzésre való alkalmazásának lehetőségeit és korlátait. Három fő megállapítás fogalmazható meg a kutatás alapján. Elsősorban a foundation modellek empirikusan igazolt módon heterogén nagy adatközegekben versenyképes előrejelzési pontosságot nyújtanak (Das et al., 2024; Ansari et al., 2024). A Makridakis-versenyek eredményei ugyanakkor rámutatnak arra, hogy a klasszikus statisztikai módszerek (különösen kombinációban) erős teljesítményt nyújtanak, és nehezen verhetők meg bizonyos helyzetekben (Makridakis et al., 2020). Másodsorban, a mélytanulási és foundation modellek pénzügyi alkalmazásának legjelentősebb akadályai az értelmezhetőség hiánya (Arrieta et al., 2020), valamint a szabályozói környezetből adódó kockázatok. Az EU AI Act és a MiFID II keretrendszerekben a „fekete doboz” -os modellek önálló alkalmazása komoly jogi és etikai kockázatot hordoz magában. Harmadsorban, a hibrid megközelítések konzisztensen felülmúlják az egykomponensű megoldásokat (Smyl, 2020; Kumar et al., 2023). A tanulmány alapján három jövőbeli kutatási irány is felírható: (1) foundation modellek kis mintás finomhangolása pénzügyi adatokon, (2) XAI-technika integrálása a foundation modell eredményeibe, (3) rezsindetektáló klasszikus komponens és AI-alapú finomhangolás empirikus értékelése valódi pénzügyi idősorokon (Giantsidi & Tarantola, 2025).

Hivatkozások

- Ansari, A.F., Stella, L., Turkmen, C., Zhang, X., Mercado, P., Shen, H., ... Wang, Y. (2024). Chronos: Learning the Language of Time Series. *Transactions on Machine Learning Research*.
<https://openreview.net/forum?id=gerNCVqqtR>
- Arrieta, A.B., Díaz-Rodríguez, N., Del Ser, J., Bennetot, A., Tabik, S., Barbado, A., ... Herrera, F. (2020). Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities, and challenges toward responsible AI. *Information Fusion*, 58, 82–115.
<https://doi.org/10.1016/j.inffus.2019.12.012>
- Blasco, T., Sánchez, J.S., & García, V. (2024). A Survey on Uncertainty Quantification in Deep Learning for Financial Time Series Prediction. *Neurocomputing*, 576, 127339.
<https://doi.org/10.1016/j.neucom.2024.127339>
- Das, A., Kong, W., Sen, R., & Zhou, Y. (2024). A Decoder-Only Foundation Model for Time-Series Forecasting. *Proceedings of the 41st International Conference on Machine Learning (ICML 2024)*. <https://proceedings.mlr.press/v235/das24c.html>
- Financial Market Forecasting using RNN, LSTM, BiLSTM, GRU and Transformer-Based Deep Learning Algorithms. *IEOM 2023 – 13th International Conference on Industrial Engineering and Operations Management, Detroit, Michigan, USA, 10–12 October 2023*. DOI: 10.46254/ev01.20230037.
- Garza, A., Challu, C., & Mergenthaler-Canseco, M. (2023). TimeGPT-1. *arXiv preprint arXiv:2310.03589*. <https://arxiv.org/abs/2310.03589>
- Giantsidi, S., & Tarantola, C. (2025). Deep learning for financial forecasting: A review of recent trends. *International Review of Economics & Finance*, 104, 104719.
<https://doi.org/10.1016/j.iref.2025.104719>
- Hyndman, R.J., & Khandakar, Y. (2008). Automatic Time Series Forecasting: The Forecast Package for R. *Journal of Statistical Software*, 27(3), 1–22. <https://doi.org/10.18637/jss.v027.i03>
- Kumar, B., Sunil, & Yadav, N. (2023). A novel hybrid model combining β SARMA and LSTM for time series forecasting. *Applied Soft Computing*, 134, 110019.
<https://doi.org/10.1016/j.asoc.2023.110019>
- Lim, B., Arik, S. Ö., Loeff, N., & Pfister, T. (2021). Temporal Fusion Transformers for Interpretable Multi-horizon Time Series Forecasting. *International Journal of Forecasting*, 37(4), 1748–1764. <https://doi.org/10.1016/j.ijforecast.2021.03.012>
- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2020). The M4 Competition: 100,000 time series and 61 forecasting methods. *International Journal of Forecasting*, 36(1), 54–74.
<https://doi.org/10.1016/j.ijforecast.2019.04.014>

- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2022). M5 Accuracy Competition: Results, Findings, and Conclusions. *International Journal of Forecasting*, 38(4), 1346–1364. <https://doi.org/10.1016/j.ijforecast.2021.11.013>
- Mononito Goswami, Konrad Szafer, Arjun Choudhry, Yifu Cai, Shuo Li, Artur Dubrawski Proceedings of the 41st International Conference on Machine Learning, PMLR 235:16115-16152, 2024.
- Ozbayoglu, A.M., Gudelek, M.U., & Sezer, O.B. (2020). Deep Learning for Financial Applications: A Survey. *Applied Soft Computing*, 93, 106384. <https://doi.org/10.1016/j.asoc.2020.106384>
- Kontopoulou, V.I., Panagopoulos, A.D., Kakkos, I., & Matsopoulos, G.K. (2023). A Review of ARIMA vs. Machine Learning Approaches for Time Series Forecasting in Data-Driven Networks. *Future Internet*, 15(8), 255. <https://doi.org/10.3390/fi15080255>
- Park, S., & Yang, J.S. (2022). Interpretable Deep Learning LSTM Model for Intelligent Economic Decision-Making. *Knowledge-Based Systems*, 248, 108907. <https://doi.org/10.1016/j.knosys.2022.108907>
- Salinas, D., Flunkert, V., Gasthaus, J., & Januschowski, T. (2020). DeepAR: Probabilistic Forecasting with Autoregressive Recurrent Networks. *International Journal of Forecasting*, 36(3), 1181–1191. <https://doi.org/10.1016/j.ijforecast.2019.07.001>
- Sezer, O.B., Gudelek, M.U., & Ozbayoglu, A.M. (2020). Financial Time Series Forecasting with Deep Learning: A Systematic Literature Review: 2005–2019. *Applied Soft Computing*, 90, 106181. <https://doi.org/10.1016/j.asoc.2020.106181>
- Smyl, S. (2020). A Hybrid Method of Exponential Smoothing and Recurrent Neural Networks for Time Series Forecasting. *International Journal of Forecasting*, 36(1), 75–85. <https://doi.org/10.1016/j.ijforecast.2019.03.017>
- Zhang, C., Sjarif, N.N.A., & Ibrahim, R. (2024). Deep Learning Models for Price Forecasting of Financial Time Series: A Review of Recent Advancements: 2020–2022. *WIREs Data Mining and Knowledge Discovery*, 14(1), e1519. <https://doi.org/10.1002/widm.1519>

ANGOL NYELVŰ TANULMÁNYOK / ENGLISH LANGUAGE PAPERS

ARTIFICIAL INTELLIGENCE AS EMBEDDED GOVERNANCE INFRASTRUCTURE IN FINANCIAL REPORTING QUALITY

Iheb BOUKELOUA

Hungarian University of Agriculture and Life Sciences (MATE) Doctoral School of Economics and Regional Sciences

boukeloua.iheb@phd.uni-mate.hu

Zoltán SIPICZKI, PhD

Hungarian University of Agriculture and Life Sciences (MATE) Doctoral School of Economics and Regional Sciences

Sipiczki.Zoltan@uni-mate.hu

Anett Katalin PARÁDI-DOLGOS, PhD

Hungarian University of Agriculture and Life Sciences (MATE) Doctoral School of Economics and Regional Sciences

Paradi-Dolgos.Anett.Katalin@uni-mate.hu

<https://doi.org/10.15170/XVIIPPN-Tk-KTK-2026-17>

Abstract

Objectives. Artificial intelligence (AI) is increasingly embedded in the production of corporate financial information, yet the accounting and governance literature still treats it mainly as a tool inside reporting workflows rather than as a layer of the control architecture. The aim of this paper is to address that gap by developing a conceptual framework that re-frames AI as embedded governance infrastructure operating alongside internal controls, board oversight, and external audit. **Methodology.** We employ structured literature synthesis (Snyder, 2019), drawing systematically on Web of Science and Scopus across the period 2010 to 2025 and integrating three theoretical streams: agency theory, the COSO internal control framework, and the literature on algorithmic accountability. **Results.** We identify two opposing forces that AI deployment sets in motion. The control enhancement pathway runs through population-level anomaly detection, real-time reconciliation, and continuous monitoring; the model risk pathway runs through opacity, training data drift, automation bias, and diffuse accountability. We advance four propositions linking AI deployment, governance maturity, and financial reporting quality. The net effect on reporting quality depends on the governance arrangements surrounding the model, including model validation, human-in-the-loop review, audit trail transparency, and AI governance maturity. The four governance variables interact substitutionally and complementarily, so reporting quality outcomes depend on their joint configuration. **Practical and policy implications.** Preparers should bring AI

explicitly within internal control over financial reporting and invest in independent model governance functions. Auditors need capacity to evaluate model governance and human-in-the-loop arrangements. Standard setters should develop disclosure requirements covering material uses of AI in reporting, drawing on prudential model risk management as a template, and the EU AI Act establishes the regulatory direction.

Keywords: artificial intelligence, financial reporting quality, corporate governance, internal control, model risk

Introduction

Financial reporting depends on a layered architecture of controls. Management certifications, internal audit, external auditors, boards, and regulators each address a different slice of agency risk, and together they produce accounting information that is supposed to faithfully represent the economic substance of the firm. Over the past decade, this architecture has begun to absorb a new kind of participant. Machine learning systems classify journal entries, flag anomalies, forecast expected credit losses, and increasingly draft management commentary. Their adoption is no longer experimental: practitioner surveys report most large firms now use AI in at least one finance or accounting process, and the trajectory points to deeper integration across the reporting value chain (Munoko et al., 2020; Kokina & Davenport, 2017).

This raises a question the literature has not resolved. If AI systems are increasingly responsible for tasks that shape the figures in published financial statements, should we treat them as tools used by humans, or as a distinct layer of governance infrastructure with their own oversight requirements? The distinction matters. Tools are evaluated by user outcomes; governance infrastructure is evaluated against control objectives, audit trails, and accountability standards. Conflating the two creates a blind spot. Firms can comply with traditional internal control frameworks while leaving the AI components of their reporting processes effectively unmonitored.

We develop a conceptual framework that treats AI as embedded governance infrastructure within financial reporting. The framework rests on a dual lens. On one side, AI offers genuine control enhancement: real-time monitoring, pattern detection at scales beyond human capacity, and consistent application of accounting policy across transaction populations. On the other side, AI introduces model risk: errors that propagate from training data, opacity that obscures the basis of accounting judgements, and overreliance that erodes professional skepticism. The net effect on financial reporting quality (FRQ) depends less on the technology than on the governance arrangements surrounding it.

Our core contribution is a re-framing. Existing literature on AI in accounting and audit treats AI as a tool used by reporting personnel: an instrument that automates a task, a black-box that an auditor reviews, an input to an estimate (Munoko et al., 2020; Lehner et al., 2022; Kokina & Davenport, 2017). We argue this framing is now empirically wrong. AI systems no longer sit outside the control architecture; they have

become part of it, performing what COSO calls control activities and information and communication functions on a continuous basis. Treating them as tools obscures the governance question the technology raises. We re-frame AI as embedded governance infrastructure, then develop three consequences. First, we integrate agency theory, the COSO framework, and the literature on algorithmic accountability into a single lens. Second, we specify the dual mechanisms through which AI strengthens or undermines FRQ and identify the four governance variables that mediate that relationship, formalised in P1–P4. Third, we draw practical implications for preparers, auditors, and standard setters, with relevance to CEE environments where firms increasingly adopt AI tools imported from larger markets.

Our approach is structured literature synthesis (Snyder, 2019). We searched Web of Science and Scopus across 2010–2025 using combinations of artificial intelligence OR machine learning OR algorithm AND financial reporting quality OR internal control OR audit quality OR earnings quality, plus a parallel search using algorithmic accountability OR algorithmic governance OR model risk AND financial reporting OR audit. Results were restricted to peer-reviewed articles in accounting, finance, business ethics, and information systems, plus regulatory publications from major standard-setters and supervisors. We snowballed in both directions to recover foundational works on agency theory, internal control, and earnings quality predating the search window. The synthesis covers approximately 60 sources; the 35 cited here are those most directly load-bearing for the framework.

The paper proceeds as follows. Section 2 reviews the literatures on FRQ, internal control, and the early evidence on AI in accounting and audit. Section 3 develops the framework, separating control enhancement from model risk and identifying the governance variables that mediate their effects. Section 4 turns to practical implications. Section 5 concludes with limitations and directions for future research.

Literature Review

Financial Reporting Quality and the Control Architecture

Financial reporting quality is the degree to which reported information faithfully represents the underlying economic position and performance of the firm (Dechow et al., 2010; Schipper & Vincent, 2003). High-quality reporting reduces information asymmetry between insiders and outsiders, lowers the cost of capital, and supports efficient allocation of resources (Healy & Palepu, 2001). Empirical proxies for FRQ have moved from accruals-based measures (Kothari et al., 2005) to broader constructs capturing earnings persistence, predictability, smoothness, and the timeliness of loss recognition (Dechow et al., 2010; Francis et al., 2008). Ball (2013) warns that the popularity of earnings management proxies has at times outrun the evidence supporting them.

Producing high-quality financial information depends on a layered control architecture. Internal controls over financial reporting, codified by COSO (2013),

structure how transactions are authorised, recorded, and reconciled. Empirical work links weaknesses in internal control to lower accruals quality (Doyle et al., 2007; Ashbaugh-Skaife et al., 2008). The audit function provides independent assurance over those controls and the resulting financial statements (DeFond & Zhang, 2014). Boards and audit committees exercise oversight, and prior work documents associations between board independence, audit committee characteristics, and earnings management or financial statement fraud (Beasley, 1996; Klein, 2002; Cohen et al., 2004). These layers act as substitutes and complements rather than independent safeguards (García Lara et al., 2009).

Artificial Intelligence in Accounting and Audit

AI in accounting and audit has expanded rapidly. Early applications were rule-based expert systems and simple classification tasks (Sutton et al., 2016). Today's deployments include machine learning models for fraud detection, NLP for contract review and disclosure analysis, and large language models that draft financial commentary and reconcile unstructured data (Munoko et al., 2020; Lehner et al., 2022; Kokina & Davenport, 2017). The major audit firms run proprietary platforms that apply anomaly detection across full transaction populations to flag entries for human attention (Issa et al., 2016; Appelbaum et al., 2017).

Evidence on what AI does to FRQ is still thin. Studies on continuous auditing show that automated monitoring detects misstatements earlier and at lower cost than periodic sampling (Vasarhelyi et al., 2010). Work on machine learning for revenue recognition and impairment testing reports gains in consistency and reduced subjectivity (Kraheil & Titera, 2015). At the same time, behavioural research on auditor judgement under data-rich conditions finds that the additional information surfaced by analytics can complicate professional decision-making rather than simplify it (Brown-Liburd et al., 2015), and research on algorithmic decision-making in adjacent domains documents systematic biases, opacity, and difficulty in attributing responsibility (Mittelstadt et al., 2016).

The picture is mixed. Where AI substitutes for repetitive human work, gains in coverage and consistency are credible. Where AI participates in judgement-laden estimates or contributes to disclosures, the benefits depend on whether the surrounding governance keeps pace. The literature on the audit profession (Munoko et al., 2020; Lehner et al., 2022) returns to the same point: the technology is moving faster than the professional standards, training, and firm-level governance arrangements that should accompany it. Our framework addresses this gap between deployment and governance.

It helps to distinguish three categories of AI application in reporting. Transaction-level processing covers the classification of journal entries, matching of invoices to purchase orders, and identification of duplicates and anomalies. Estimation covers ML models that produce inputs to accounting estimates such as expected credit losses, fair value measurements, and asset impairments. Narrative generation covers

language models that draft management commentary or summarise risk disclosures. Each category presents a different governance profile (Lehner et al., 2022).

Governance of Algorithmic Systems

A parallel literature on algorithmic governance has emerged in information systems, law, and ethics. Three concepts recur. Explainability is the property of a model whose outputs can be interpreted by humans (Burrell, 2016). Accountability is the assignment of responsibility for algorithmic decisions. Auditability is the capacity to reconstruct and verify how a model produced a given output (Diakopoulos, 2016; Raji et al., 2020). Regulatory frameworks such as the EU AI Act (European Commission, 2024) and supervisory expectations on model risk management (Federal Reserve Board, 2011; BCBS, 2011) increasingly treat AI systems as objects of governance in their own right rather than as neutral tools.

These accountability problems are not unique to financial reporting. Naoum (2025) examines AI deployment in organisational settings and finds that opacity, biased training data, and unclear responsibility combine to produce discriminatory outcomes and that transparency and inclusive oversight are preconditions, not afterthoughts. Somosi and Hajdú (2023), surveying university students on AI attitudes, find that concerns about controllability and accountability are pronounced even among technology-familiar groups; when governance arrangements are opaque or absent, trust in AI systems breaks down regardless of how the system actually performs. The 'right to explanation' debate in European data protection scholarship (Goodman & Flaxman, 2017; Wachter et al., 2018) shows the tension between the statistical nature of contemporary AI and the legal expectation that consequential decisions can be justified to those they affect.

These developments have not been absorbed by the accounting and corporate governance literature on financial reporting. Where AI appears, it is usually as an input to a specific reporting task or as a feature of audit methodology. The framing of AI as a layer of the control architecture itself, with its own governance requirements that interact with traditional controls, remains underdeveloped.

Conceptual Framework: AI as Embedded Governance Infrastructure

Theoretical Foundations

Our framework draws on three theoretical streams. Agency theory (Jensen & Meckling, 1976) sets the baseline: separating ownership from control creates incentives for managers to misreport, and reporting controls exist to mitigate those incentives. The COSO (2013) internal control framework specifies the operational architecture firms use to address financial reporting risks, organised around the control environment, risk assessment, control activities, information and communication, and monitoring activities. The literature on algorithmic

accountability (Mittelstadt et al., 2016; Raji et al., 2020) supplies the third stream and identifies the governance challenges of systems whose decision logic is statistical rather than rule-based.

Combining these streams, we treat AI not as an external tool used by reporting personnel but as a participant in the control architecture. When an algorithmic system flags transactions for review, generates accounting estimates, or drafts disclosure language, it performs functions that COSO attributes to control activities and to information and communication. Treating those functions as governance infrastructure brings them within the scope of internal control evaluation, audit, and oversight, and creates a need for governance arrangements specific to the AI system: model validation, version control, monitoring of drift, and documentation supporting an audit trail.

Figure 1 presents the framework. AI deployment generates two pathways that flow through the mediating governance variables to the financial reporting quality outcome.

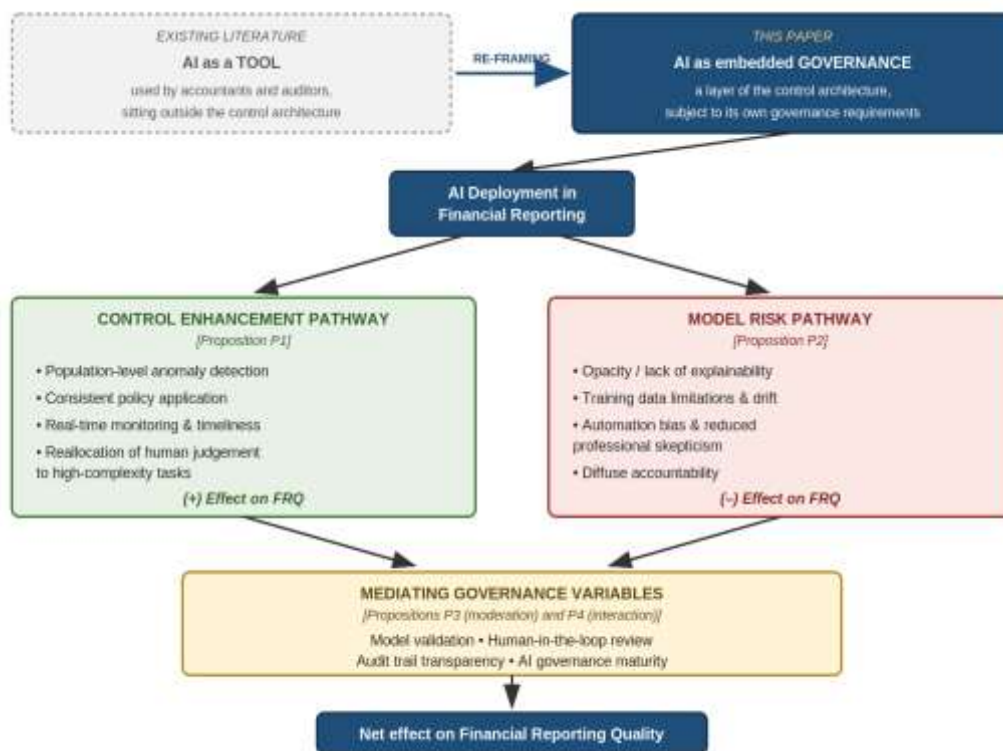


Figure 1 . AI as embedded governance infrastructure in financial reporting (own elaboration).

The Control Enhancement Pathway

AI strengthens FRQ through several channels. The first is scope. Traditional control activities work on samples; algorithmic systems can examine the full population of transactions, journal entries, or contractual terms. Anomaly detection models trained on historical patterns identify entries that deviate from expected behaviour and route

them for human review (Issa et al., 2016). Errors and irregularities are more likely to be caught before they reach the financial statements.

The second channel is consistency. Human application of accounting policy varies across personnel, time periods, and business units. Algorithmic systems apply the same logic to every input, reducing variance from individual judgement. For policies that are well-specified and rule-based, such as classification of routine expenditures or recognition of standard revenue arrangements, this consistency directly supports comparability and reliability.

The third channel is timeliness. Continuous monitoring systems produce control signals in near real time rather than on the periodic cadence of traditional reviews (Vasarhelyi et al., 2010). Earlier detection means earlier correction, reducing accumulated errors and the risk of material misstatement at the reporting date.

The fourth channel is the reallocation of skilled human attention. By absorbing high-volume, low-judgement tasks, AI systems free accounting and audit professionals to concentrate on areas that require human judgement: complex estimates, the interpretation of new transactions, and the assessment of going concern risks. To the extent that this reallocation actually happens in practice, the quality of judgements embedded in the financial statements should improve. We summarise these mechanisms in the first proposition:

P1. *Holding governance arrangements constant, the deployment of AI in financial reporting processes is associated with improvements in the scope, consistency, timeliness, and judgement allocation components of financial reporting quality.*

The Model Risk Pathway

These same characteristics also create distinct vulnerabilities. The first is opacity. Many machine learning models, especially deep neural networks, do not produce interpretable explanations for their outputs. When such a system flags or fails to flag a transaction, reconstructing the basis of that decision in terms that satisfy traditional audit evidence standards may be impossible (Diakopoulos, 2016). For accounting estimates produced by such models, the concept of management's basis for the estimate becomes difficult to operationalise.

The second vulnerability is dependence on training data. A model trained on historical transactions encodes the patterns and assumptions of the period the data come from. When economic conditions, business processes, or regulatory requirements change, the model's outputs can degrade in ways that are not immediately visible. Expected credit loss models that performed adequately in benign credit conditions before 2020 illustrate the broader phenomenon: model performance is a moving target requiring continuous validation.

The third vulnerability is automation bias. Empirical research on human interaction with automated systems consistently finds that users defer to algorithmic outputs

even when those outputs are wrong, and the tendency strengthens as perceived reliability increases (Skitka et al., 1999). In an accounting context, this shows up as reduced professional skepticism: reviewers approve algorithmically prepared journal entries with less scrutiny than they would apply to entries prepared by a human colleague, on the assumption that the system has done the relevant checks.

The fourth vulnerability is the diffusion of responsibility. When an erroneous figure traces back to an algorithmic system, who bears responsibility is not straightforward. The model developer, the user who configured the system, the reviewer who approved the output, and the executives who certified the financial statements all have a partial claim. Without clear governance arrangements, this diffusion produces failures of accountability that traditional control frameworks were designed to prevent. These vulnerabilities motivate a second proposition:

P2. *Holding governance arrangements constant, the deployment of AI in financial reporting processes simultaneously introduces opacity, training data drift, automation bias, and diffuse accountability, each of which is negatively associated with financial reporting quality.*

Mediating Governance Variables

Whether AI improves or undermines FRQ depends less on the technology than on the governance arrangements around it. We identify four mediating variables. Model validation is the systematic process by which a firm tests, documents, and approves AI models before deployment and at regular intervals afterwards. Strong validation regimes catch many failure modes from training data limitations and model drift before they reach the financial statements (Federal Reserve Board, 2011; BCBS, 2011).

Human-in-the-loop review is the design choice of routing model outputs through qualified human reviewers before those outputs influence reported figures. Depth varies, from token approval to substantive re-examination, depending on the materiality of the figures affected and the model's maturity. Audit trail transparency is the system's capacity to produce, retain, and surface evidence sufficient to support both internal and external audit. Without it, the auditability of the affected accounting figures is compromised regardless of how accurate the model is.

Governance maturity is the broader organisational capacity to manage AI systems. It includes an AI governance committee, written policies on model approval and decommissioning, defined responsibilities for model owners and validators, and integration of AI risk into the firm's enterprise risk management. Firms with mature AI governance can capture control enhancement benefits while limiting model risk exposure. Firms without it accept the model risk without realising the corresponding benefits.

These four variables interact rather than work independently. Strong model validation becomes considerably less effective when human-in-the-loop arrangements are

token rather than substantive, because flawed model behaviour identified in validation can still reach the financial statements through reviewers who do not exercise meaningful challenge. Audit trail transparency contributes little if no one is responsible for examining the trail. FRQ outcomes therefore depend on the joint configuration of the four variables. Two further propositions formalise this:

P3. *The strength of model validation, human-in-the-loop review, audit trail transparency, and AI governance maturity moderates the relationship between AI deployment and financial reporting quality, such that the relationship is positive when governance is strong and may be negative when governance is weak.*

P4. *The four governance variables interact substitutionally and complementarily, such that the marginal contribution of any one variable to financial reporting quality depends on the configuration of the others.*

Table 1. Summary of propositions linking AI deployment, governance, and financial reporting quality.

P#	Proposition statement	Mediating mechanism	Expected effect on FRQ
P1	AI deployment improves scope, consistency, timeliness, and judgement allocation in reporting.	Anomaly detection, continuous monitoring, task automation	Positive (+)
P2	AI introduces opacity, training data drift, automation bias, and diffuse accountability.	Black-box models, automation bias, unclear responsibility	Negative (-)
P3	Governance strength moderates the AI–FRQ relationship: positive when strong, negative when weak.	Validation, human-in-loop, audit trail, governance maturity	Moderating
P4	Governance variables interact: marginal contribution of any one depends on the others.	Substitution and complementarity across variables	Configurational

Source: Authors' elaboration based on the conceptual framework developed

Implications for Practice

Implications for Preparers

Three priorities follow for firms that prepare financial statements. First, AI systems should be brought explicitly within the scope of internal control over financial reporting. Where an AI system contributes to figures in the financial statements, it should face the same control objectives and documentation standards as other components of the reporting process. Second, firms need to invest in model governance, including validation, monitoring, and incident response, kept separate from model development. Third, firms need internal expertise capable of challenging model outputs; without it, human-in-the-loop arrangements become ceremonial. For firms in CEE markets, where AI adoption often runs through systems developed elsewhere, building local validation capacity matters all the more.

The point about local validation deserves emphasis. Firms in smaller European markets typically buy AI-enabled accounting and audit tools from international vendors. Training data, default thresholds, and anomaly definitions in those tools are calibrated against larger economies, and the assumptions baked in may fit Hungarian, Algerian, or Romanian environments less well. A model that performs adequately on US transaction patterns may flag legitimate local business practices as anomalous, or fail to flag locally-specific risks the training data never saw. Without local validation, the firm imports both the tool and its blind spots.

Implications for Auditors

External auditors face a parallel challenge: forming an opinion on financial statements increasingly produced with algorithmic input. Audit standards on audit evidence and the work of management's experts offer a starting point, but their application to AI is unsettled. Auditors will need to develop the capacity to evaluate model governance, judge whether a model's design suits the accounting question at hand, and test the operating effectiveness of human-in-the-loop controls. Where these elements are weak, the limitations on audit evidence translate directly into the audit opinion.

Implications for Standard Setters and Regulators

Standard setters in financial reporting and auditing have begun to respond to AI in reporting, but disclosure and assurance frameworks have not caught up. We see a clear case for explicit disclosure requirements covering material uses of AI in producing financial information, including the systems' nature, the surrounding governance, and the residual risks management has accepted. Prudential regulators in finance already operate model risk management expectations (Federal Reserve Board, 2011; BCBS, 2011), and the EU AI Act extends a horizontal framework to high-

risk applications across sectors (European Commission, 2024). Extending analogous expectations to AI in financial reporting is the natural next step.

Conclusion and Future Research

We have argued that artificial intelligence should be understood not as a tool used within financial reporting but as a layer of governance infrastructure embedded in the production of accounting information. This brings AI within the scope of internal control, audit, and oversight, and clarifies the governance variables that determine whether its deployment strengthens or undermines FRQ. The framework distinguishes a control enhancement pathway, through which AI improves scope, consistency, timeliness, and the allocation of human judgement, from a model risk pathway, through which opacity, training data limitations, automation bias, and diffuse responsibility introduce new vulnerabilities. The mediating role of model validation, human-in-the-loop review, audit trail transparency, and governance maturity determines the net effect, formalised in the four propositions of Section 3.

The paper's contribution is to integrate three previously disconnected literatures, those on FRQ, internal control, and algorithmic accountability, into a single framework that treats AI as a participant in the corporate governance architecture rather than an exogenous technology. This re-framing has direct implications for preparers, auditors forming opinions on algorithmically-produced financial statements, and standard setters specifying disclosure requirements adequate to the governance challenges AI introduces.

The paper is conceptual, which is also its main limitation: we offer a structure for thinking about AI in financial reporting but do not test the propositions empirically. Several lines of follow-up suggest themselves. First, develop measures of AI governance maturity adapted from prudential model risk management to a financial reporting setting. Second, examine associations between AI governance maturity and established proxies for FRQ, controlling for firm characteristics and traditional governance variables. Third, study how human-in-the-loop arrangements operate, identifying conditions under which they provide substantive challenge versus ceremonial endorsement. Fourth, analyse current disclosures on AI use in reporting and ask whether they support informed assessment by users.

AI deployment in financial reporting is on a trajectory where the questions raised here will only grow in importance. Building a governance framework adequate to the technology will involve preparers, auditors, standard setters, and academic researchers together.

Acknowledgments

We thank the Doctoral School of Economics and Regional Sciences at MATE for institutional support.

References

- Appelbaum, D., Kogan, A., & Vasarhelyi, M. A. (2017). Big Data and analytics in the modern audit engagement: Research needs. *Auditing: A Journal of Practice & Theory*, 36(4), 1–27. <https://doi.org/10.2308/ajpt-51684>
- Ashbaugh-Skaife, H., Collins, D. W., Kinney, W. R., & LaFond, R. (2008). The effect of SOX internal control deficiencies and their remediation on accrual quality. *The Accounting Review*, 83(1), 217–250. <https://doi.org/10.2308/accr.2008.83.1.217>
- Ball, R. (2013). Accounting informs investors and earnings management is rife: Two questionable beliefs. *Accounting Horizons*, 27(4), 847–853. <https://doi.org/10.2308/acch-10366>
- Basel Committee on Banking Supervision. (2011). Supervisory guidance on model risk management. Bank for International Settlements. <https://www.bis.org/publ/bcbs195.htm>
- Beasley, M. S. (1996). An empirical analysis of the relation between the board of director composition and financial statement fraud. *The Accounting Review*, 71(4), 443–465.
- Brown-Liburd, H., Issa, H., & Lombardi, D. (2015). Behavioral implications of Big Data's impact on audit judgment and decision making and future research directions. *Accounting Horizons*, 29(2), 451–468. <https://doi.org/10.2308/acch-51023>
- Burrell, J. (2016). How the machine 'thinks': Understanding opacity in machine learning algorithms. *Big Data & Society*, 3(1), 1–12. <https://doi.org/10.1177/2053951715622512>
- Cohen, J. R., Krishnamoorthy, G., & Wright, A. (2004). The corporate governance mosaic and financial reporting quality. *Journal of Accounting Literature*, 23, 87–152.
- Committee of Sponsoring Organizations of the Treadway Commission. (2013). Internal control – Integrated framework. American Institute of Certified Public Accountants.
- Dechow, P., Ge, W., & Schrand, C. (2010). Understanding earnings quality: A review of the proxies, their determinants and their consequences. *Journal of Accounting and Economics*, 50(2–3), 344–401. <https://doi.org/10.1016/j.jacceco.2010.09.001>
- DeFond, M. L., & Zhang, J. (2014). A review of archival auditing research. *Journal of Accounting and Economics*, 58(2–3), 275–326. <https://doi.org/10.1016/j.jacceco.2014.09.002>
- Diakopoulos, N. (2016). Accountability in algorithmic decision making. *Communications of the ACM*, 59(2), 56–62. <https://doi.org/10.1145/2844110>
- Doyle, J. T., Ge, W., & McVay, S. (2007). Accruals quality and internal control over financial reporting. *The Accounting Review*, 82(5), 1141–1170. <https://doi.org/10.2308/accr.2007.82.5.1141>
- European Commission. (2024). Regulation (EU) 2024/1689 of the European Parliament and of the Council laying down harmonised rules on artificial intelligence (Artificial Intelligence Act). Official Journal of the European Union. <https://eur-lex.europa.eu/eli/reg/2024/1689/oj>

- Federal Reserve Board. (2011). Supervisory guidance on model risk management (SR 11-7). Board of Governors of the Federal Reserve System. <https://www.federalreserve.gov/supervisionreg/srletters/sr1107.htm>
- Francis, J., Nanda, D., & Olsson, P. (2008). Voluntary disclosure, earnings quality, and cost of capital. *Journal of Accounting Research*, 46(1), 53–99. <https://doi.org/10.1111/j.1475-679X.2008.00267.x>
- García Lara, J. M., García Osma, B., & Penalva, F. (2009). Accounting conservatism and corporate governance. *Review of Accounting Studies*, 14(1), 161–201. <https://doi.org/10.1007/s11142-007-9060-1>
- Goodman, B., & Flaxman, S. (2017). European Union regulations on algorithmic decision-making and a 'right to explanation'. *AI Magazine*, 38(3), 50–57. <https://doi.org/10.1609/aimag.v38i3.2741>
- Healy, P. M., & Palepu, K. G. (2001). Information asymmetry, corporate disclosure, and the capital markets: A review of the empirical disclosure literature. *Journal of Accounting and Economics*, 31(1–3), 405–440. [https://doi.org/10.1016/S0165-4101\(01\)00018-0](https://doi.org/10.1016/S0165-4101(01)00018-0)
- Issa, H., Sun, T., & Vasarhelyi, M. A. (2016). Research ideas for artificial intelligence in auditing: The formalization of audit and workforce supplementation. *Journal of Emerging Technologies in Accounting*, 13(2), 1–20. <https://doi.org/10.2308/jeta-10511>
- Jensen, M. C., & Meckling, W. H. (1976). Theory of the firm: Managerial behavior, agency costs and ownership structure. *Journal of Financial Economics*, 3(4), 305–360. [https://doi.org/10.1016/0304-405X\(76\)90026-X](https://doi.org/10.1016/0304-405X(76)90026-X)
- Klein, A. (2002). Audit committee, board of director characteristics, and earnings management. *Journal of Accounting and Economics*, 33(3), 375–400. [https://doi.org/10.1016/S0165-4101\(02\)00059-9](https://doi.org/10.1016/S0165-4101(02)00059-9)
- Kokina, J., & Davenport, T. H. (2017). The emergence of artificial intelligence: How automation is changing auditing. *Journal of Emerging Technologies in Accounting*, 14(1), 115–122. <https://doi.org/10.2308/jeta-51730>
- Kothari, S. P., Leone, A. J., & Wasley, C. E. (2005). Performance matched discretionary accrual measures. *Journal of Accounting and Economics*, 39(1), 163–197. <https://doi.org/10.1016/j.jacceco.2004.11.002>
- Krahel, J. P., & Titera, W. R. (2015). Consequences of Big Data and formalization on accounting and auditing standards. *Accounting Horizons*, 29(2), 409–422. <https://doi.org/10.2308/acch-51065>
- Lehner, O. M., Ittonen, K., Silvola, H., Ström, E., & Wührleitner, A. (2022). Artificial intelligence based decision-making in accounting and auditing: Ethical challenges and normative thinking.

- Accounting, Auditing & Accountability Journal, 35(9), 109–135.
<https://doi.org/10.1108/AAAJ-09-2020-4934>
- Mittelstadt, B. D., Allo, P., Taddeo, M., Wachter, S., & Floridi, L. (2016). The ethics of algorithms: Mapping the debate. *Big Data & Society*, 3(2), 1–21.
<https://doi.org/10.1177/2053951716679679>
- Munoko, I., Brown-Liburd, H. L., & Vasarhelyi, M. (2020). The ethical implications of using artificial intelligence in auditing. *Journal of Business Ethics*, 167(2), 209–234.
<https://doi.org/10.1007/s10551-019-04407-1>
- Naoum, R. (2025). A framework for integrating AI-powered systems to mitigate bias risk in HRM functions. *Marketing & Menedzsment*, 59(2), 52–61.
<https://doi.org/10.15170/MM.2025.59.02.05>
- Raji, I. D., Smart, A., White, R. N., Mitchell, M., Gebu, T., Hutchinson, B., Smith-Loud, J., Theron, D., & Barnes, P. (2020). Closing the AI accountability gap: Defining an end-to-end framework for internal algorithmic auditing. In *Proceedings of the 2020 Conference on Fairness, Accountability, and Transparency* (pp. 33–44). <https://doi.org/10.1145/3351095.3372873>
- Schipper, K., & Vincent, L. (2003). Earnings quality. *Accounting Horizons*, 17(s-1), 97–110.
<https://doi.org/10.2308/acch.2003.17.s-1.97>
- Skitka, L. J., Mosier, K. L., & Burdick, M. (1999). Does automation bias decision-making? *International Journal of Human-Computer Studies*, 51(5), 991–1006.
<https://doi.org/10.1006/ijhc.1999.0252>
- Snyder, H. (2019). Literature review as a research methodology: An overview and guidelines. *Journal of Business Research*, 104, 333–339.
<https://doi.org/10.1016/j.jbusres.2019.07.039>
- Somosi, Z., & Hajdú, N. (2023). Ethical dilemmas of artificial intelligence: Overview of aversion and implications. *Marketing & Menedzsment*, 57(Különszám EMOK 3), 65–74.
<https://doi.org/10.15170/MM.2023.57.KSZ.03.07>
- Sutton, S. G., Holt, M., & Arnold, V. (2016). 'The reports of my death are greatly exaggerated' – Artificial intelligence research in accounting. *International Journal of Accounting Information Systems*, 22, 60–73. <https://doi.org/10.1016/j.accinf.2016.07.005>
- Vasarhelyi, M. A., Alles, M. G., & Williams, K. T. (2010). *Continuous assurance for the now economy*. Institute of Chartered Accountants in Australia.
- Wachter, S., Mittelstadt, B., & Russell, C. (2018). Counterfactual explanations without opening the black box: Automated decisions and the GDPR. *Harvard Journal of Law & Technology*, 31(2), 841–887. <https://doi.org/10.2139/ssrn.3063289>

ARTIFICIAL INTELLIGENCE IN ACCOUNTING: PERSPECTIVES ON AUTOMATION AND QUALITY ACCORDING TO EUROPEAN ACCOUNTING PROFESSIONALS

Vanda CZINE

Budapest University of Economics and Business
czine.vanda@uni-bge.hu

Ágnes LAMPER

Budapest University of Economics and Business
lamper.agnes@uni-bge.hu

<https://doi.org/10.15170/XVIIPPN-Tk-KTK-2026-18>

Abstract

The study aims to explore how European accounting and auditing professionals perceive the impact of artificial intelligence (AI) automation on audit quality and the accuracy of financial reporting. It seeks to determine whether AI is viewed primarily as an opportunity or a threat, and to identify the key factors shaping these perceptions across different professional and organizational contexts.

Methodologically, the research is based on a systematic literature review, synthesizing evidence from 15 studies conducted across at least 10 European countries between 2019 and 2026. The included studies employ diverse research designs, such as quantitative surveys, qualitative interviews, mixed-method approaches, and experimental analyses. Data extraction followed a structured framework, capturing study context, methodologies, types of AI technologies examined, and perceptions related to audit quality and financial reporting accuracy. The findings indicate that European accounting professionals generally perceive AI as beneficial. Key advantages include increased efficiency and effectiveness of audit processes, the shift from traditional sampling to full-population testing, enhanced fraud detection capabilities, and reduced human error in financial data processing. At the same time, significant concerns persist regarding data privacy, algorithmic bias, and the reliability of AI-generated outputs. A notable result is the existence of an "awareness–use gap": while professionals widely recognize AI's potential, actual adoption remains uneven, particularly among smaller firms with limited resources.

From a practical and economic policy perspective, the study highlights the need for stronger regulatory frameworks to govern AI usage in accounting and auditing, including alignment with data protection and ethical standards. It also emphasizes the importance of investing in education and professional training to develop AI-related competencies. Furthermore, the findings suggest that organizational readiness, digital infrastructure, and support for continuous upskilling are critical for the successful integration of AI in the profession.

Keywords: Artificial intelligence, accounting, quality, literature review, EU

Introduction

European accounting professionals broadly perceive AI automation as beneficial for audit quality and financial reporting accuracy, viewing it predominantly as an opportunity rather than a threat. The most consistently cited benefits include enhanced efficiency and effectiveness of audit procedures (Rodrigues et al., 2023; Rikhardsson et al., 2022), improved fraud detection through real-time analysis of large datasets (Sharbek & Dutescu, 2025), the replacement of traditional sampling with full-population testing (Rodrigues et al., 2023; Fauzi, 2026), and reduced error rates in financial data processing (Banța et al., 2022; Fülöp et al., 2025; Mihai & Dutescu, 2024). However, significant concerns persist regarding data privacy and security, algorithmic bias and output reliability (Banța et al., 2022; Sentuti et al., 2025), and the need for regulatory frameworks to govern AI use in regulated professions (Sharbek & Dutescu, 2025). Notably, a gap exists between recognition of AI's potential and actual adoption: professionals in smaller firms and less digitally mature environments acknowledge AI's value but rarely use it (Nogueira et al., 2023), while those in multinational or larger organizations report higher adoption rates and more experience-grounded perceptions (Banța et al., 2022; Mihai & Dutescu, 2024).

Across 15 studies spanning at least 10 European countries, the evidence is more convergent regarding AI's perceived impact on audit quality, particularly fraud detection and continuous auditing, than on financial reporting accuracy, where perceptions tend to be more general and less supported by empirical evidence of actual outcomes. Nearly all studies emphasize that AI is expected to increase rather than replace professional judgment (Fauzi, 2026), but this complementary relationship depends on adequate upskilling, organizational readiness, and the development of ethical governance frameworks (Preslav et al., 2025).

Data extraction, methodology

This research performed a semantic search across different types of search engines, such as Semantic Scholar and OpenAlex. The literature review included 12 studies examining what are European accounting professionals' perceptions of how artificial intelligence automation affects audit quality and financial reporting accuracy.

Those papers that passed abstract screening and moved to full-text screening. Then, we screened papers based on their full text using the same criteria system. Papers that failed to meet any of the strict criteria were excluded from further consideration. For the remaining papers, a holistic judgement was made about whether to include each paper in the final analysis, with all screening questions being considered together. 25 papers passed full-text screening and moved to data extraction.

We asked a large language model to extract each data column below from each paper. We gave the model the extraction instructions shown below for each column.

- **Study Context:** Extract details about the study setting and participants specifically related to European accounting professionals, including country or region within Europe, type of accounting professionals, sample size and characteristics, and time period of data collection.
- **Methodology:** Extract how perceptions were measured and gathered from European accounting professionals, including research approach, data collection instruments used, response rates and any limitations, analysis methods for perception data.
- **AI Technologies:** about the specific artificial intelligence automation technologies that European accounting professionals expressed perceptions about, including the type of AI mentioned, specific AI applications in accounting and auditing contexts, level of AI adoption or experience among participants, and current vs. potential future AI implementations.
- **Audit Quality Perceptions:** Extract European accounting professionals' perceptions specifically about how AI automation affects audit quality, including perceived positive or negative effects on audit quality, perceived changes to audit processes and procedures.
- **Overall Perception Themes:** focusing on the main themes regarding whether European accounting professionals view AI automation as primarily beneficial, threatening, or mixed for audit quality and financial reporting accuracy, including overall positive or negative sentiment, whether AI is seen as a threat or opportunity, key concerns, outlook, and expectations, perceived need for adaptation or change.

Characteristics of Included Studies

The review encompasses 15 sources spanning from 2019 to 2026, drawing on accounting and auditing professionals across multiple European countries. The studies employ a range of methodological approaches, including quantitative surveys, qualitative interviews, mixed-methods designs, and literature reviews. Table 1 below summarizes and presents the key characteristics of these studies.

Table 1: Summary of the reviewed studies.

Study	Country/Region	Professional Type	Sample Size	Method	Focus Area
Luís Rodrigues et al., 2023	Portugal	Certified auditors	37	Questionnaire survey with Likert scales	AI impact on the audit profession
M. Fülöp et al., 2025	Romania	Accounting professionals in AI-adopting firms	113	Mixed methods; SEM	AI, ethics, and quality of work life

Study	Country/Region	Professional Type	Sample Size	Method	Focus Area
Joana Nogueira et al., 2023	Portugal	Statutory Auditors	Not specified	Questionnaire survey	AI technology awareness and use in audit
A. Silva et al., 2025	Portugal	Certified accountants	263	Questionnaire survey; PLS-SEM	Accounting automation tools and information quality
A. Januszewski & Angelika Pietrysiak, 2025	Poland	Accounting firm employees	Not specified	Questionnaire survey	Digital transformation's impact on accounting
C. Bocean & A. Vărzaru, 2022	Romania	Financial and managerial accountants	396	Survey; SEM, and ANN analysis	Ethical and quality requirements in digital technologies
Nermin Sharbek & Adriana Dutescu, 2025	Romania	Accountants and auditors	54	Semi-structured interviews	AI in financial reporting
V. Banța et al., 2022	Romania	Financial accountants at multinationals	116	Survey with Likert scales; SPSS	Benefits and challenges of AI in accounting
Mirela Mihai & Adriana Dutescu, 2024	18 European countries	Top financial specialists (CFOs, CEOs, audit managers)	62	Structured interviews; TOE framework	AI implementation in accounting and audit
A. Sentuti et al., 2025	Italy	Young Chartered Accountants	6	Semi-structured interviews; inductive coding	AI adoption approaches among young CAs

Study	Country/Region	Professional Type	Sample Size	Method	Focus Area
Fauzi, 2026	Not European-specific	Accounting practitioners, auditors, and finance managers	Not specified	Systematic literature review and semi-structured interviews; thematic analysis	AI as a threat or an opportunity for accounting
Páll Rikhardsson et al., 2022	Iceland	Certified public accountants /auditors	70	Survey (UTAUT model); workshops and interviews	AI expectations in SME auditing
Petkov Preslav et al., 2025	Lithuania	Professional accountants (min. 3 years experience)	32	Survey; t-test, regression analysis	Digital transformation and higher education
J. Choi & Chloe L. Xie, 2026	Not European-specific	Professional accountants	277 (survey); 79 SMEs (platform data)	Survey and field experiment with transaction-level data	GenAI integration and productivity in accounting
Stanislaw Honko & M. Hendryk, 2024	Poland	Chief and independent accountants (80% women)	575	Survey with webinar-based recruitment	AI applications in accounting tasks

Source: Authors' own contribution.

The geographic coverage is concentrated in Southern and Eastern Europe, with Romania (four studies) (Fülöp et al., 2025; Bocean & Vărzaru, 2022; Sharbek & Dutescu, 2025) and Portugal (three studies) (Rodrigues et al., 2023; Nogueira et al., 2023; Silva et al., 2025) representing the most studied contexts. Poland contributed two studies (Januszewski & Pietrysiak, 2025; Honko & Hendryk, 2024), with single studies from Italy (Sentuti et al., 2025), Iceland (Rikhardsson et al., 2022), and Lithuania (Preslav et al., 2025). One study spanned 18 European countries (Mihai & Dutescu, 2024), while another study did not focus specifically on European contexts (Fauzi, 2026; Choi & Xie, 2026). Sample sizes ranged considerably from 6 interviewees

in a qualitative study of Italian chartered accountants (Sentuti et al., 2025) to 575 survey respondents among Polish accountants (Honko & Hendryk, 2024). The majority of studies employed survey-based designs, while several adopted qualitative or mixed-methods approaches using semi-structured interviews.

Benefits of AI for Audit Quality and Financial Reporting

A consistent finding across nearly all included studies is the perception that AI automation enhances the efficiency and effectiveness of audit procedures and financial reporting processes. Portuguese certified auditors reported that AI improves efficiency and effectiveness in audit procedures, sampling techniques, the cost-benefit relationship, and recognition of material distortions (Rodrigues et al., 2023). Icelandic auditors expected significant improvements in their own on-the-job efficiency and anticipated that AI use in auditing firms would become mandatory (Rikhardsson et al., 2022). Romanian accountants at multinational firms perceived benefits including reduced process time, reduced error rates, improved fraud detection, better reporting, and improved predictions (Banța et al., 2022).

The shift from sampling-based to population-level testing is a particularly salient theme. Several studies identified the replacement of traditional sampling tests with integral or full-population analysis as a major advantage, with Portuguese auditors noting AI's capacity to perform continuous testing on 100% of the population (Rodrigues et al., 2023). Similarly, the broader literature identifies AI's ability to shift audit from traditional sampling to full data scanning and anomaly detection algorithms (Fauzi, 2026).

Fraud detection emerged as a prominent perceived benefit. Romanian professionals recognized AI's role in anomaly detection and financial data forecasting (Fülöp et al., 2025), while one Romanian study reported that AI could reduce material errors by 35% (Sharbek & Dutescu, 2025).

For financial reporting specifically, professionals across multiple countries perceived improvements in accuracy and reliability. AI was seen as reducing manual errors and improving data processing efficiency in Romania (Fülöp et al., 2025; Bocean & Vărzaru, 2022), Portugal (Rodrigues et al., 2023), and across Europe (Mihai & Dutescu, 2024). Polish accountants associated AI most strongly with the preparation and workflow of accounting documents, confirming automation of routine tasks as the primary expected application (Honko & Hendryk, 2024). Lithuanian accountants similarly emphasized AI's role in automating repetitive tasks such as cost allocation and transaction registration (Preslav et al., 2025). AI-enabled platforms were associated with more granular ledgers and faster month-end closing in one field study (Choi & Xie, 2026).

Perceived Risks and Concerns

Despite predominantly positive perceptions of AI's potential, the studies reveal a consistent set of concerns across European jurisdictions, such as data privacy,

security, ethical risks, algorithmic bias and output reliability, job displacement, and role transformation.

Romanian accountants expressed concerns about data integrity and professional autonomy, and Romanian professionals in firms with AI experience identified trust and security as the most critical ethical requirements influencing their perception of digital technologies (Fülöp et al., 2025; Bocean & Vărzaru, 2022).

The reliability of AI outputs was questioned in several studies. Italian chartered accountants noted the potential for incorrect or misleading AI outputs, including so-called AI "hallucinations" (Sentuti et al., 2025). Romanian practitioners identified the subjectivity of algorithms as a challenge (Banța et al., 2022). A field experiment found that reliance on non-consensus AI recommendations can increase the risk of error, underscoring the importance of professional judgment in AI-assisted contexts (Choi & Xie, 2026).

While most studies concluded that AI is not perceived as an existential threat to employment, concerns about job displacement were noted. Romanian accounting professionals acknowledged that skills transformation is required but were willing to undergo such changes, and AI was not perceived as a direct threat to employability (Banța et al., 2022). The consensus across studies is that AI shifts the role of accountants and auditors toward data analysis, strategic advisory, and AI governance rather than eliminating positions (Fauzi, 2026; Honko & Hendryk, 2024).

AI Adoption Levels and Awareness-Use Gap

A notable finding is the gap between awareness and actual use of AI technologies. Portuguese statutory auditors, while aware of several AI technologies, overwhelmingly reported never using any type of AI technology in their work (Nogueira et al., 2023). Among Romanian practitioners at multinational firms, 57 out of 103 participants (55%) reported using AI solutions in their professional activities, representing a relatively higher adoption rate likely attributable to the multinational firm context (Banța et al., 2022). Among Italian young chartered accountants, AI adoption followed either a "horizontal" approach focused on routine efficiency gains or a "vertical" approach applying AI to strategic high-value tasks (Sentuti et al., 2025). The technologies most commonly discussed included machine learning, robotic process automation (RPA), natural language processing, and predictive analytics (Silva et al., 2025; Banța et al., 2022; Fauzi, 2026; Rikhardsson et al., 2022). Specific commercial tools mentioned in the Romanian context included Xero, IBM Cognos Analytics, Trullion, and various others (Sharbek & Dutescu, 2025). RPA emerged as the most relevant automation tool for accounting according to one Portuguese study (Silva et al., 2025).

Factors Influencing Perceptions

Professional experience and familiarity with AI have a significant impact on perceptions. Icelandic auditors showed age-related differences, with younger auditors expecting greater AI impact (Rikhardsson et al., 2022). Polish accountants

with greater experience demonstrated higher optimism about AI's potential (Honko & Hendryk, 2024).

Firm size and financial resources consistently moderated perceptions and adoption. Smaller firms faced greater investment barriers (Rikhardsson et al., 2022). Top management support and industry pressure from competitors and customers were identified as positive influences across 18 European countries (Mihai & Dutescu, 2024).

The regulatory landscape featured as both a facilitator and a constraint. Romanian professionals noted that the EU AI Act and GDPR influence AI adoption (Sharbek & Dutescu, 2025), while European financial specialists across 18 countries perceived government regulations as neutral rather than threatening (Mihai & Dutescu, 2024). The development of skills and training is also a factor in the perception of AI. The need for upskilling was a near-universal theme. Auditors across multiple jurisdictions indicated that new competencies are necessary to work effectively alongside AI (Preslav et al., 2025). Companies generally preferred to train existing employees rather than hire new specialists (Mihai & Dutescu, 2024). Lithuanian accountants expressed a strong desire to learn more about AI-based tools (Preslav et al., 2025), and multiple studies called for higher education curricula to incorporate AI-related content (Banța et al., 2022; Rikhardsson et al., 2022; Preslav et al., 2025).

Overall Sentiment: Threat Versus Opportunity

The dominant perception across the included studies is that AI represents an opportunity rather than a threat to the accounting and auditing professions. Studies from Portugal (Rodrigues et al., 2023), Romania (Bocean & Vărzaru, 2022; Sharbek & Dutescu, 2025), Iceland (Rikhardsson et al., 2022), Poland (Honko & Hendryk, 2024), Lithuania (Preslav et al., 2025), and the broader European context all reported a predominantly positive outlook (Mihai & Dutescu, 2024). Among the 15 sources, overall positive sentiment, while approximately 10 reported mixed sentiment. Only the studies focusing specifically on ethical and privacy risks or technology anxiety leaned toward more cautious or ambivalent positions, and none reported a predominantly negative perception.

A pan-European study found that 70% of respondents viewed AI complexity as an opportunity, while 30% perceived it as a threat (Mihai & Dutescu, 2024). Romanian practitioners clearly understood the main benefits and challenges associated with AI and did not perceive it as a threat to employability (Banța et al., 2022). The prevailing view is that AI will serve as a complementary tool that augments rather than replaces professional judgment (Fauzi, 2026).

Conclusions

The apparent consistency in positive perceptions masks important heterogeneity that can be explained by contextual and methodological differences across studies.

The studies collectively reveal a paradox: professionals broadly recognize AI's potential benefits for audit quality and reporting accuracy, yet actual adoption remains low in many contexts. Portuguese statutory auditors overwhelmingly never use AI despite recognizing its importance (Nogueira et al., 2023), while 55% of Romanian accountants at multinationals actively use AI solutions (Banța et al., 2022). This divergence is best explained by firm type and resource availability. Professionals in multinational firms and larger organizations have greater exposure to AI tools and IT infrastructure (Banța et al., 2022; Mihai & Dutescu, 2024), whereas those in small and medium-sized practices face financial constraints and knowledge gaps that limit adoption (Rikhardsson et al., 2022). The implication is that positive perceptions of AI's impact on audit quality and financial reporting are largely aspirational rather than experience-based in smaller-firm contexts, and potentially more grounded in direct experience among large-firm professionals.

The methodology's impact on the reported observations limited a more in-depth analysis of the results. Studies employing quantitative surveys with pre-defined Likert scales (e.g., those in Portugal, Romania, and Poland) (Rodrigues et al., 2023; Bocean & Vărzaru, 2022; Banța et al., 2022) tended to report more uniformly positive perceptions, while qualitative studies using semi-structured interviews (e.g., Italy, Romania) elicited more nuanced and mixed responses, including concerns about AI "hallucinations" and over-reliance on AI (Sharbek & Dutescu, 2025; Sentuti et al., 2025). This pattern suggests that the format of data collection may channel responses toward socially desirable or technologically optimistic views in structured survey instruments, while open-ended interviews allow for the expression of deeper anxieties and practical reservations.

Greater professional experience correlates with higher optimism in Poland (Honko & Hendryk, 2024), and younger auditors in Iceland expect greater AI impact (Rikhardsson et al., 2022). These findings suggest a non-linear relationship: initial unfamiliarity breeds anxiety (reducing perceived benefit), moderate experience builds confidence and positive perceptions, and deeper expertise enables more nuanced recognition of both benefits and risks. This trajectory is consistent with the Italian finding that young, chartered accountants who have moved from "horizontal" (routine) to "vertical" (strategic) AI use demonstrate both greater enthusiasm and greater awareness of limitations (Sentuti et al., 2025).

Audit quality versus financial reporting accuracy. While many studies address both domains, the evidence is stronger and more convergent regarding AI's perceived benefits for audit quality, particularly fraud detection and the move from sampling to population-level testing, than for financial reporting accuracy per se (Rodrigues et al., 2023; Fauzi, 2026). Perceptions about financial reporting accuracy tend to be more general, focusing on reduced errors and improved efficiency in data processing (Fülöp et al., 2025; Mihai & Dutescu, 2024). The one study providing field-level evidence of actual impacts found that GenAI adoption was associated with more granular ledgers and faster month-end closing, but also demonstrated that AI recommendations can increase error risk when professional judgment is insufficiently applied (Choi & Xie, 2026). This distinction suggests that while audit-specific applications of AI (anomaly detection, continuous auditing) have clearer perceived and demonstrable benefits,

the impact on financial reporting accuracy is more dependent on the quality of human-AI interaction and organizational implementation.

Future research should extend the current European evidence by incorporating country-specific empirical analyses in underrepresented contexts, such as Hungary, where the digital maturity of accounting firms and regulatory adaptation to AI may differ from more frequently studied Western and Southern European countries.

A dedicated Hungarian-focused study could examine whether the well-documented awareness–adoption gap observed in Portugal and SME-dominated environments also characterizes Hungarian accounting professionals, particularly given the high prevalence of small and medium-sized accounting firms. Such research would help determine whether positive perceptions of AI in Hungary are similarly aspirational rather than experience-based, or whether localized institutional factors (e.g., national digitalization policies, tax authority digital systems like NAV) accelerate practical adoption.

References

- Banța V, Rîndașu S-M, Tănasie A, Cojocaru D (2022) Artificial Intelligence in the Accounting of International Businesses: A Perception-Based Approach. *Sustainability*. <https://doi.org/10.3390/su14116632>
- Bocean C, Vărzaru A (2022) A Two-Stage SEM-Artificial Neural Network Analysis of Integrating Ethical and Quality Requirements in Accounting Digital Technologies. *Syst*. <https://doi.org/10.3390/systems10040121>
- Choi J, Xie CL (2026) Human + AI in Accounting: Early Evidence from the Field. *Journal of Accounting Research*. <https://doi.org/10.1111/1475-679x.70052>
- Fauzi F (2026) The AI revolution in Accounting Practice: Threat or Opportunity for the Accounting Profession? *Oikonomia: Journal of Management Economics and Accounting*. <https://doi.org/10.61942/oikonomia.v3i2.546>
- Fülöp M, Ionescu C, Măgdaș N, et al (2025) Digital Transformation of the Accounting Profession at the Intersection of Artificial Intelligence and Ethics. *Economics*. <https://doi.org/10.1515/econ-2025-0155>
- Honko S, Hendryk M (2024) The Role of AI in Accounting: Insights From Practitioners. *EUROPEAN RESEARCH STUDIES JOURNAL*. <https://doi.org/10.35808/ersj/3863>
- Januszewski A, Pietrysiak A (2025) Impact of Digital Transformation on Accounting Profession in the Opinions of Accounting Firms' Employees. *International Conference on Knowledge-Based Intelligent Information & Engineering Systems*. <https://doi.org/10.1016/j.procs.2025.09.360>

- Mihai M, Dutescu A (2024) TOE framework elements used on Artificial Intelligence implementation in the accounting and audit sector. *International Journal of Research In Business and Social Science*. <https://doi.org/10.20525/ijrbs.v13i4.3374>
- Nogueira J, Ribeiro D, Marques RP (2023) Artificial Intelligence in Auditing: The Case of the Portuguese Statutory Auditors. *Iberian Conference on Information Systems and Technologies*. <https://doi.org/10.23919/CISTI58278.2023.10211323>
- Preslav P, Ivanov B, Desislava P (2025) Digital transformation in financial and management accounting: the importance of higher education. *Mokslo taikomieji tyrimai / Applied Research*. <https://doi.org/10.59476/mtt2025.v2i21.734>
- Rikhardsson P, Thórisson K, Bergthorsson GI, Batt CE (2022) Artificial Intelligence and Auditing in Small- And Medium-Sized Firms: Expectations and Applications. *The AI Magazine*. <https://doi.org/10.1002/aaai.12066>
- Rodrigues L, Pereira J, Silva AF da, Ribeiro H (2023) The impact of artificial intelligence on audit profession. *Journal of Information Systems Engineering & Management*. <https://doi.org/10.55267/iadt.07.12743>
- Sentuti A, Sgrò F, Cesaroni F (2025) Artificial intelligence in accounting professions: The young chartered accountants' experience. *MANAGEMENT CONTROL*. <https://doi.org/10.3280/maco2025-001-s1003>
- Sharbek N, Dutescu A (2025) Future of accounting and auditing: Insights from Romania on artificial intelligence in financial reporting. *International Journal of Research In Business and Social Science*. <https://doi.org/10.20525/ijrbs.v14i7.4315>
- Silva A, Miranda P, Gonçalves M (2025) THE IMPACT OF ACCOUNTING AUTOMATION ON INFORMATION QUALITY AND CORPORATE SOCIAL RESPONSIBILITY. *E3*. <https://doi.org/10.29073/e3.v11i1.1001>

FINANCIAL STRATEGIES AND FLEXIBILITY IN THE EMS INDUSTRY: EVIDENCE FROM EUROPEAN AND MIDDLE EASTERN OPERATORS

Seyed Mehdi ALAVI

John von Neumann University
m.alavi@emsinternational.eu

<https://doi.org/10.15170/XVIIPPN-Tk-KTK-2026-19>

Abstract

This paper examines how electro-muscle stimulation (EMS) businesses use financial strategy to support growth, resilience, and innovation in a capital-intensive service environment. The study focuses on three mechanisms that are particularly relevant in the EMS market: financial flexibility, shared-investment models, and revenue diversification. A mixed-methods design was applied, combining survey data from 132 EMS businesses with qualitative interviews conducted with experienced operators across Europe and selected Middle Eastern markets. The findings show that firms with greater financial flexibility report materially shorter payback periods, while ownership labels alone do not explain funding outcomes. Diversification appears to support liquidity and business stability, but it is not, by itself, a strong predictor of client retention. The paper argues that financial flexibility should be understood as an operational capability rather than a passive financial condition. In the EMS sector, the firms that recover faster are those that maintain multiple funding options, manage upgrades carefully, and respond quickly to cash-flow pressure. The results are relevant for studio owners, franchisors, distributors, manufacturers, investors, and other actors involved in high-technology service businesses.

Keywords: electro-muscle stimulation (EMS), financial flexibility, franchising, co-investment, diversification, SME growth

Introduction

Electro-muscle stimulation (EMS) has developed from a rehabilitation technology into a wider commercial ecosystem that now includes boutique fitness, wellness, physiotherapy, beauty-oriented services, and emerging corporate health formats. This transformation has changed not only the technological profile of the industry but also its financial logic. EMS systems require specialized hardware, wearable garments, software support, professional training, and ongoing servicing. At the same time, market expectations move quickly. Users expect shorter setup times, cleaner design, measurable outcomes, and professionally supervised sessions. As a result,

EMS firms operate in an environment shaped by both innovation pressure and cash-flow sensitivity (Kemmler et al., 2020; Stoppa & Chiolerio, 2014).

The business challenge is therefore not simply whether an EMS device works, but whether an EMS business can finance growth without damaging liquidity. This issue is especially important for small and medium-sized operators, distributors, and young franchise systems. In practice, firms must decide how to structure initial capital, whether to rely on full ownership or shared investment, how to refresh equipment, and how to diversify revenue so that seasonal volatility does not undermine survival. Yet much of the published EMS literature remains concentrated on physiological outcomes, device safety, or training effectiveness (Amaro-Gahete et al., 2020; Kemmler et al., 2018). Much less attention has been given to the financial architecture of the industry.

This paper addresses that gap by focusing on three questions. First, how do EMS firms design financial strategies to sustain growth in competitive markets? Second, how does financial flexibility influence payback and resilience? Third, what role do franchising, co-investment, and revenue diversification play in the structure of EMS businesses? The paper draws on a mixed-methods dataset and offers an applied interpretation grounded in actual business operations.

Literature Background and Theoretical Framing

The EMS market sits at the intersection of health technology and service entrepreneurship. Historically, EMS began in rehabilitation and physiotherapy, where controlled electrical stimulation was used to limit muscle atrophy, support neuromuscular re-education, and assist recovery. Over time, advances in digital control, wearable materials, and wireless systems allowed EMS to move beyond clinical settings and into performance training, fitness studios, and consumer-oriented wellness environments. This transition created a dual identity for the industry. EMS is both a technical product category and a service model built around supervision, credibility, and repeat use (Kemmler et al., 2020; Rogers, 2003; Stoppa & Chiolerio, 2014).

From a strategic management perspective, the resource-based view helps explain why certain EMS firms outperform others. Their advantage often lies not in one product feature alone, but in a combination of assets that are difficult to replicate: brand credibility, training systems, distributor relationships, service routines, and compliance know-how. Dynamic capabilities theory extends this perspective by showing that advantage in the EMS industry depends not only on possessing resources, but on the ability to reconfigure them quickly when technology, regulation, or market expectations change (Barney, 1991; Teece, 2018; Teece et al., 1997).

Financial flexibility is especially important within this framework. In this paper, financial flexibility refers to the capacity of a firm to adapt to technology cycles, funding constraints, and external shocks through multiple capital options, staged investment, renegotiation capacity, and revenue breadth. This concept draws on corporate finance literature that treats flexibility as a valuable strategic condition,

particularly in uncertain environments where firms face lumpy investments and imperfect credit access (Gamba & Triantis, 2008).

The literature on franchising and shared ownership is also relevant. Franchising can reduce the capital burden for expansion while standardizing training, branding, and operating protocols. Co-investment goes one step further by aligning the manufacturer, distributor, or master brand with a local partner through shared capital and shared incentive structures. In the EMS context, both models are attractive because they can lower entry barriers and reduce the financial exposure of one party. However, they also introduce governance risk, dependence on contract quality, and the need for continuous coordination (Combs et al., 2011).

Diversification provides a different type of strategic protection. In EMS, firms rarely rely on session income alone. Many combine training sessions with memberships, accessories, garment sales, certification services, personal devices, or corporate wellness offers. In theory, this should reduce revenue concentration and support stability. In practice, however, the relationship with loyalty may be more complex because client retention is shaped heavily by service design rather than by the number of revenue streams alone (Montgomery, 1994).

Methodology

The study uses a mixed-methods design. Quantitative data were collected through a structured survey completed by 132 active EMS businesses. The sample included studio owners, franchisors, distributors, and related decision-makers operating across Europe and selected Middle Eastern markets. Qualitative depth was added through semi-structured interviews with experienced EMS professionals representing manufacturing, distribution, franchising, training, and multi-site management roles. This design was selected because the research question required both measurable business patterns and operational explanation (Creswell & Plano Clark, 2017; Patton, 2015).

The survey focused on business structure, capital mix, revenue composition, payback period, and retention outcomes. Several composite measures were constructed for analysis. The Financial Flexibility Index captured the degree to which firms could access and reallocate funding, renegotiate financial terms, and act under pressure. A Capital Optionality Score reflected the number of active funding routes used by a firm, including own capital, debt or leasing, and co-investment or franchise-based capital. Revenue Diversification captured the breadth of income streams within the business (Hair et al., 2019; Kline, 2016).

The main outcome variables were payback period, measured in months, and six-month client retention. Correlation tests, group comparisons, and regression models were used to assess the relationships among the variables. The qualitative data were coded thematically and used to explain the operational mechanisms behind the quantitative patterns. The methodological aim was not to produce unnecessary statistical complexity, but to create a valid and usable interpretation of how EMS firms manage capital and risk in practice (Field, 2018).

Findings

Financial flexibility and payback

The strongest finding in the dataset is the relationship between financial flexibility and payback period. The association is moderate, negative, and statistically significant ($r = -0.41$, $p < .001$). A linear model indicates that each one-point increase in the flexibility index is associated with approximately 4.14 fewer months needed to recover the initial investment. This is a substantial effect for an industry where cash timing is often the difference between expansion and stagnation.

The qualitative evidence clarifies why this relationship appears so clearly. Operators with stronger flexibility were more likely to plan cash weekly, keep more than one funding route available, negotiate supplier windows before problems emerged, and make small but fast decisions on replacements or upgrades. In practical terms, they lost less time. When a device component failed or a demand opportunity appeared, they could respond immediately rather than delaying action until funds became available. This behavior translated into shorter downtime and faster recovery of investment (Gamba & Triantis, 2008; Teece, 2018).

Ownership form and capital structure

The second finding is more nuanced. Ownership model by itself did not produce a statistically significant difference in the capital mix between independent firms and franchise or co-investment firms. The direction of the data suggested that shared-investment models may rely somewhat more on external finance and somewhat less on own capital, but the differences were not strong enough to support a general statistical claim.

This result does not imply that ownership structure is irrelevant. Instead, it suggests that the ownership label alone is too broad to explain funding outcomes. Contract clauses, local credit conditions, upgrade obligations, and managerial discipline vary substantially within each category. A carefully structured independent operator can carry less practical risk than a weak franchisee, while a strong co-investment model can outperform a poorly designed independent business. The interviews consistently reinforced this interpretation. Structure matters, but execution matters more (Combs et al., 2011).

Diversification and retention

The third key finding concerns diversification. The observed relationship between revenue diversification and six-month retention was positive but weak and did not reach conventional statistical significance ($r = 0.15$, $p = .087$). In practical terms, this means that having more income streams may improve business stability, but it does not automatically create stronger client loyalty.

Interview evidence helps explain the weak effect. Many respondents described diversification as a form of financial insurance rather than a direct retention tool.

Retail sales, education income, or accessory revenue can soften weak months, but long-term client adherence is shaped more strongly by onboarding quality, trainer continuity, visible progress, and service experience. Diversification therefore supports resilience, but service design remains the primary driver of repeat participation in EMS training (Montgomery, 1994).

Discussion

The findings support a broader interpretation of financial flexibility as an operational capability. In the EMS sector, flexibility is not merely a balance-sheet condition; it is a practical system of routines that allows firms to react without losing time or damaging liquidity. This distinction is important. Many businesses speak about growth strategy in terms of sales, product features, or market opportunity, but the evidence here suggests that the speed of financial response is equally central.

The paper also contributes to the discussion on business-model design in high-technology services. Franchising and co-investment are often presented as straightforward solutions to capital constraints, yet the results show that ownership form does not automatically improve financial outcomes. Shared models can reduce entry barriers, but they do not substitute for cash discipline, contract clarity, or consistent operations. This is a useful corrective to simplistic expansion logic.

The diversification results are also instructive. In many industries, diversification is assumed to improve both resilience and client value. In EMS, the relationship appears more selective. Diversification clearly has a stabilizing role, especially when equipment amortization, rent, and staffing costs must be covered during fluctuations in session volume. However, client retention remains largely service-driven. This means that managers should not confuse business breadth with relationship depth. Taken together, the evidence suggests a hierarchy of priorities for EMS firms. First, they must build financial flexibility through funding optionality, disciplined planning, and manageable upgrade structures. Second, they should choose ownership arrangements based on operational fit rather than symbolic prestige. Third, they should treat diversification as a financial stabilizer while investing directly in the quality of the client journey if retention is the objective.

The results should be interpreted with appropriate caution. The research is cross-sectional and relies partly on self-reported business indicators, so the findings show robust associations and plausible mechanisms rather than final causal proof. Future longitudinal research could test whether improvements in financial flexibility precede shorter payback over time.

Practical Implications

For independent studio owners, the most immediate implication is the importance of weekly liquidity management. A rolling cash view, at least one secondary funding route, and predefined rules for small operational replacements can materially reduce payback pressure. For multi-site operators, centralizing financial routines while preserving local service execution appears to be a strong model. For franchisors and

co-investment partners, the results suggest that partner screening should emphasize financial discipline and operational readiness, not only brand enthusiasm or initial capital.

Manufacturers and distributors also play a role in the flexibility of the sector. Clear lead-time communication, modular product design, field-replaceable components, and predictable refresh calendars can reduce the effective capital stress faced by operators. In other words, upstream design and communication decisions affect downstream payback and resilience. For investors and lenders, the study indicates that operational flexibility metrics may be more informative than ownership category alone when evaluating risk in EMS businesses.

Conclusion

This paper set out to examine how EMS businesses use financial strategy to support growth and resilience in a rapidly evolving market. The evidence shows that financial flexibility matters in a direct and measurable way. Firms that maintain multiple funding options, manage cash actively, and respond quickly to operational pressure recover their investment significantly faster. Ownership model, by contrast, does not determine success on its own, because outcomes depend heavily on contract quality and managerial execution. Revenue diversification improves financial stability, but client retention still depends primarily on service design rather than on business breadth alone.

The broader conclusion is that EMS businesses should not think about finance as a back-office matter separated from innovation. In this sector, financial design is part of the business model itself. Flexibility, when translated into routine practice, becomes a strategic capability that supports adaptation, continuity, and long-term growth. This insight is relevant not only for EMS, but also for other capital-intensive service industries that combine technology, recurring client relationships, and fast product cycles.

References

- Amaro-Gahete, F. J., De-la-O, A., Sanchez-Delgado, G., Robles-Gonzalez, L., Jurado-Fasoli, L., Dote-Montero, M., Ruiz, J. R., & Castillo, M. J. (2020). Whole-body electromyostimulation improves muscle mass, quality and strength in postmenopausal women. *Frontiers in Physiology*, 11, 568. <https://doi.org/10.3389/fphys.2020.00568>
- Barney, J. (1991). Firm resources and sustained competitive advantage. *Journal of Management*, 17(1), 99-120. <https://doi.org/10.1177/014920639101700108>
- Combs, J. G., Ketchen, D. J., Shook, C. L., & Short, J. C. (2011). Antecedents and consequences of franchising: Past accomplishments and future challenges. *Journal of Management*, 37(1), 99-126. <https://doi.org/10.1177/0149206310386963>

- Creswell, J. W., & Plano Clark, V. L. (2017). *Designing and conducting mixed methods research* (3rd ed.). SAGE.
- Field, A. (2018). *Discovering statistics using IBM SPSS statistics* (5th ed.). SAGE.
- Gamba, A., & Triantis, A. (2008). The value of financial flexibility. *Journal of Finance*, 63(5), 2263-2296. <https://doi.org/10.1111/j.1540-6261.2008.01397.x>
- Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. (2019). *Multivariate data analysis* (8th ed.). Cengage.
- Kemmler, W., Teschler, M., Weissenfels, A., Bebenek, M., von Stengel, S., Kohl, M., & Froehlich, M. (2018). Whole-body electromyostimulation and body composition. *Frontiers in Physiology*, 9, 573. <https://doi.org/10.3389/fphys.2018.00573>
- Kemmler, W., Weissenfels, A., Teschler, M., Willert, S., Froehlich, M., Kohl, M., & von Stengel, S. (2020). Safety and efficacy of whole-body electromyostimulation. *Frontiers in Physiology*, 11, 507. <https://doi.org/10.3389/fphys.2020.00507>
- Kline, R. B. (2016). *Principles and practice of structural equation modeling* (4th ed.). Guilford Press.
- Montgomery, C. A. (1994). Corporate diversification. *Journal of Economic Perspectives*, 8(3), 163-178. <https://doi.org/10.1257/jep.8.3.163>
- Patton, M. Q. (2015). *Qualitative research & evaluation methods* (4th ed.). SAGE.
- Rogers, E. M. (2003). *Diffusion of innovations* (5th ed.). Free Press.
- Stoppa, M., & Chiolerio, A. (2014). Wearable electronics and smart textiles. *Sensors*, 14(7), 11957-11992. <https://doi.org/10.3390/s140711957>
- Teece, D. J. (2018). Business models and dynamic capabilities. *Long Range Planning*, 51(1), 40-49. <https://doi.org/10.1016/j.lrp.2017.06.007>
- Teece, D. J., Pisano, G., & Shuen, A. (1997). Dynamic capabilities and strategic management. *Strategic Management Journal*, 18(7), 509-533. [https://doi.org/10.1002/\(SICI\)1097-0266\(199708\)18:7<509::AID-SMJ882>3.0.CO;2-Z](https://doi.org/10.1002/(SICI)1097-0266(199708)18:7<509::AID-SMJ882>3.0.CO;2-Z)