

A SOLOW–SWAN–MODELLTŐL AZ IPAR 5.0-IG

Az AI-vezérelt tudásmenedzsment és a fenntartható gazdasági növekedés kapcsolatrendszer

Zéman Zoltán – Orbán Zsuzsanna¹

ABSZTRAKT

A gazdasági növekedési modellek fejlődése eltérő módon értelmezte a technológiai fejlődés szerepét. A Solow–Swan-féle exogén megközelítés a technológiai haladást külső adottságként kezelte, míg az endogén növekedésméletek a tudást és az innovációt a növekedés belső hajtóerejeként azonosították. A schumpeteri kreatív rombolás tovább árnyalta ezt a képet az innováció ciklikus természetének és a verseny dinamikus szerepének hangsúlyozásával.

A tanulmány e növekedésméleti ívre építve vizsgálja a mesterséges intelligencia gazdasági szerepét, különös tekintettel az AI-jal támogatott tudásmenedzsmentre. Az elemzés amellett érvel, hogy a mesterséges intelligencia nem pusztán automatizációs technológia, hanem a tudás létrehozását, szervezését és hasznosítását átalakító platform, amely a növekedés belső tényezőire hat. A cikk bemutatja, miként befolyásolja az AI-alapú tudásmenedzsment a termelékenységet és a munkaerőpiac szerkezetét, valamint milyen korlátok és kockázatok kapcsolódnak az alkalmazásához.

A tanulmány következtetése szerint az AI és a tudásmenedzsment integrációja új értelmezési keretet kínál a gazdasági növekedés vizsgálatához, különösen az Ipar 5.0 emberközpontú megközelítésében, ahol a technológiai fejlődés nem a munkaerő kiváltására, hanem annak kiegészítésére épül.

JEL-kódok: D80, D83, J24, O33, O47

Kulcsszavak: mesterséges intelligencia, tudásmenedzsment, gazdasági növekedés, ipar 5.0

¹ Zéman Zoltán egyetemi tanár, Neumann János Egyetem, Gazdaságtudományi Kar, Gazdálkodás- és Szervezéstudományok Doktori Iskola. E-mail: zeman.zoltan@nje.hu.

Orbán Zsuzsanna PhD hallgató, kapcsolattartó szerző. Neumann János Egyetem, Gazdaságtudományi Kar, Gazdálkodás- és Szervezéstudományok Doktori Iskola. E-mail: del88j@hallgato.nje.hu; orbanzsuzsanna.ovb@gmail.com.

1. BEVEZETÉS ÉS HÁTTÉR

A mesterséges intelligencia robbanásszerű fejlődése és az Ipar 5.0 megjelenése napjainkban alapjaiban írja felül a gazdasági növekedésről alkotott elképzeléseinket. A technológiai fejlődés szerepének közgazdasági értelmezése a neoklasszikus megközelítéstől a schumpeteri kreatív rombolásig fokozatosan mélyült. A technológiai lehetőségek látványos bővülése ellenére azonban a statisztikai adatokban még mindig visszaköszön a Solow-paradoxon néven ismert jelenség. Ez az ellentmondás arra mutat rá, hogy a számítógépek és a digitális eszközök jelenléte önmagában nem eredményez azonnali termelékenységnövekedést a makrogazdasági mutatókban.

A jelenlegi tudományos diskurzusban hiányosság mutatkozik a technológiai potenciál és a tényleges gazdasági teljesítmény közötti átmenet részletes elemzésében. Különösen kevés figyelem irányul arra a kérdésre, hogy a szervezeti tudásmenedzsment átalakítása miként hidalhatja át ezt a szakadékot a mesterséges intelligencia korában. Jelen tanulmány éppen ennek az elméleti résnek a kitöltésére törekszik a neoklasszikus alapok és a generatív mesterséges intelligencia korszakának szintézisével.

Tanulmányunk Joel Mokyr tudásgazdasági keretrendszerére támaszkodva vizsgálja, hogy az információ bősége mellett miként válik kulcsfontosságúvá az adatok hasznos tudássá alakítása. Emellett áttekinti az AI fejlődésével együtt járó kihívásokat, különös tekintettel a digitális egyenlőtlenségekre és az etikai kockázatokra. Kitér az ember és gép közötti együttműködés társadalmilag fenntartható alkalmazásának szabályozási és oktatási feltételeire is.

A tanulmány fő hozzájárulása, hogy integrálja a szakirodalomban eddig *jellemzően különállóként kezelt* növekedésméleteket, Mokyr tudásgazdasági keretrendszerét (megközelítését) és az AI-alapú tudásmenedzsment területét. A szintézis alapján a tanulmány egy saját koncepcionális értelmezési keretet javasol. A keret a generatív AI gazdasági hatását a tudáshoz való hozzáférés és felhasználás költségstruktúrájának átalakulásán keresztül értelmezi, figyelembe véve a szervezeti alkalmazkodás, a humán tőke és a kiegészítő immateriális beruházások szerepét.

1.1. Célkitűzés és kutatási kérdések

A jelen kutatás központi célkitűzése a gazdasági növekedésméletek evolúciójának kritikai elemzése és szintézise, különös tekintettel a mesterséges intelligencia által előidézett technológiai paradigmaváltásra.

A tanulmány az alábbi négy, egymással összefüggő kutatási kérdésre keresi a választ:

- Q1: Hogyan értelmezhető újra a technológiai fejlődés szerepe a gazdasági növekedésben a Solow-modelltől az Ipar 5.0-ig?
- Q2: Milyen folyamatokon keresztül képes a generatív AI csökkenteni a tudáshoz való hozzáférés költségeit?
- Q3: Miért nem jelenik meg azonnal a mesterséges intelligencia hatása a makrogazdasági termelékenységi mutatókban, és milyen szerepet játszanak ebben a kiegészítő immateriális beruházások?
- Q4: Milyen keretrendszerek szükségesek ahhoz, hogy az ember-gép szinergia (Ipar 5.0) fenntartható és társadalmilag igazságos növekedést eredményezzen?

2. MÓDSZERTAN

A tanulmány a Torracó (2005, 2016) által definiált integratív szakirodalmi áttekintés (ILR) módszertanát alkalmazza. Ez a megközelítés olyan értelmezési keretet biztosít, amely alkalmas arra, hogy a kiforrott növekedésméleti modellek (Solow, Romer, Schumpeter) és a jelenleg formálódó technológiai paradigmaváltás közötti összefüggéseket feltárjuk. A módszertan lehetőséget ad arra, hogy a klasszikus elméleti alapvetéseket és a legfrissebb, gyakran még a tudományos publikációs folyamat korai szakaszában járó szakmai elemzéseket (műhelytanulmányok, iparági jelentések) egyetlen, konzisztens logikai rendszerben szintetizáljuk.

A kutatás fókusz a generatív mesterséges intelligencia makrogazdasági hatásainak sajátosságaihoz igazodik. Mivel a technológiai adaptáció és a termelékenységi mutatókban való megjelenés között jelentős időbeli eltolódás tapasztalható, a jelenleg rendelkezésre álló rövid idősoros adatok önmagukban félrevezetőek lehetnek. Ezért primer adatgyűjtés helyett a releváns elméleti és empirikus szakirodalom, valamint az intézményi becslések összehasonlító szintézisére építünk. Ez a szintézis lehetővé teszi, hogy az egyedi mérések esetleges torzításai helyett a globális tendenciák és a mögöttes gazdasági folyamatok váljanak láthatóvá.

A forrásfeltárás során iteratív keresési stratégiát és a hivatkozási hálózatokat követő hólabda-módszert alkalmaztunk. Az adatbázis építésekor a tudományos platformok (Scopus, Google Scholar) mellett kiemelt szerepet kapott a minősített szakirodalom is. A forrásgyűjtés két, egymást kiegészítő időszakra épül, ahol az elméleti alapművek az 1950 és 2000 közötti periódust, a modern hatásvizsgálatok pedig a 2018 és 2026 közötti időszakot fedik le. A források kiválasztását a kutatási kérdésekhez való kapcsolódás, a tudományos megbízhatóság és az elemzéshez nyújtott elméleti vagy empirikus hozzájárulás vezérelte.

A kutatás forrásbázisának felépítését és a szelekciós folyamatot az 1. táblázat foglalja össze:

1. táblázat

A kutatás forrásbázisa

Specifikáció és részletek	
Elsődleges Adatbázisok	Tudományos: Scopus, Google Scholar, JSTOR, ScienceDirect. Intézményi: NBER Working Papers, MIT Szakmai: World Economic Forum (WEF), McKinsey Global Institute, Goldman Sachs Research, IMF Publications.
Időbeli lefedettség	Elméleti alapok: 1950–2000 (Solow, Romer, Lucas, Mokyr, Schumpeter alapművei). Modern AI és empirikus adatok: 2018–2026 (Kiemelt fókusz a 2022 utáni generatív AI irodalomra).
Kulcsszavak	Economic growth theory, Solow paradox, Total Factor Productivity (TFP), Artificial Intelligence, Generative AI, LLM, Knowledge economy, Propositional vs Prescriptive knowledge, Industry 5.0, Human-centric AI.
Forráskiválasztás szempontjai	Kapcsolódás a kutatási kérdésekhez; tudományos megbízhatóság; releváns elméleti vagy empirikus hozzájárulás; gazdasági vagy szervezeti relevancia
Szintézis módja	A források tematikus rendezése a négy kutatási kérdés mentén; az eredmények, eltérések és bizonytalanságok narratív összevetése

Forrás: A szerzők saját szerkesztése

A forrásokat három típusba soroljuk: lektorált tudományos publikációk, intézményi műhelytanulmányok, valamint iparági és piaci jelentések. A hivatkozott makrogazdasági becslések és termelékenységi hatások eltérő feltételezéseken alapuló forgatókönyv-elemzésekéből és szakirodalmakban publikált empirikus eredmények szintéziséből származnak. Ezek nem egzakt előrejelzésként, hanem a lehetséges hatásirányok és nagyságrendi különbségek szemléltetésére szolgáló értelmezési keretként jelennek meg.

3. GAZDASÁGI NÖVEKEDÉSI MODELLEK

3.1. A Solow–Swan-modell

3.1.1. A modell fő tényezői

A Solow–Swan-modell szerint a tőke, munkaerő és exogén technológiai fejlődés együttesen határozzák meg a gazdaság teljes kibocsátását és növekedését. A modell hosszú távú egyensúlyi állapotokra koncentrál, feltételezve, hogy a gazdaság teljes foglalkoztatás mellett működik, és a tőke teljes kapacitással kerül kihasználásra (Solow, 1956; Barro–Sala-i-Martin, 2004).

A gazdasági kibocsátást egy Cobb–Douglas termelési függvény segítségével ábrázolja a modell:

$$Y = A \cdot K^{\alpha} \cdot L^{1-\alpha} \quad (1)$$

ami a gazdasági növekedés alapvető szerkezetét írja le, ahol:

- **Y:** a gazdaság teljes kibocsátása.
- **K:** a tőkeállomány, amely a termelési folyamatban részt vevő fizikai eszközöket jelenti, például gépeket, épületeket és infrastruktúrát. Ezek hozzájárulnak a termelékenység növekedéséhez, bár a csökkenő hozadék törvénye miatt a tőkeállomány növelésének hatása idővel mérséklődik. A modell feltételezi, hogy a tőke teljes mértékben kihasznált, nem számol kihasználatlan kapacitással vagy elavult tööeszközökkel, pedig ezek a gazdaságban gyakran előfordulnak.
- **L:** a munkaerő, amely az aktívan foglalkoztatott munkaerőt jelöli. A modell szerint a gazdaság teljes foglalkoztatottsággal működik, ami azt jelenti, hogy minden rendelkezésre álló munkaerőt bevonnak a termelési folyamatba, és nincs tartós munkanélküliség. Bár a munkaerő bővítése rövid távon növeli a kibocsátást, ez sem eredményez hosszú távon fenntartható növekedést, ha nem társul tőkefelhalmozással vagy technológiai fejlődéssel.
- **A:** az exogén technológiai szint, amely az a tényező, amely hosszú távon fenntarthatóvá teszi a gazdasági növekedést. A modell exogén tényezőként kezeli a technológiai fejlődést, vagyis feltételezi, hogy az innovációk és fejlesztések külső tényezők eredményei, amelyeket a gazdasági szereplők közvetlenül nem befolyásolhatnak. A technológia fejlődése egy multiplikátor $A(t)$ formájában jelenik meg a termelési függvényben, amely növeli a tőke és a munka termelékenységét, anélkül, hogy megváltoztatná azok egymáshoz viszonyított arányait. Ez a technológiai szint folyamatos fejlődése biztosítja, hogy a gazdaság képes legyen túllépni a csökkenő hozadék korlátain, és hosszú távon is növekedést érjen el.

• α : a tőke részesedését jelöli a termelésben, amely azt mutatja meg, milyen arányban járul hozzá a tőke a kibocsátáshoz. Az értéke általában 0 és 1 közötti, ahol az $1-\alpha$ a munka részesedését jelenti (Barro–Sala-i-Martin, 2004).

A termelési függvény feltételezi, hogy a tőke és munka összesített növekedése arányos a kibocsátás növekedésével, azonban a tőke vagy a munka egyoldalú növekedése esetén a csökkenő hozadék törvénye érvényesül. Az egyoldalú növekedés hatása idővel mérséklődik, mivel a termelési tényezők korlátai akadályozzák a további növekedést (Solow, 1956). A technológiai fejlődés (A) azonban képes ellensúlyozni ezeket a korlátokat, ami a modell legfontosabb elméleti újítása.

3.1.2. A technológiai fejlődés szerepe a hosszú távú növekedés fenntartásában

A modell alapvető állítása, hogy a tőke és a munkaerő növelése rövid távon hozzájárulhat a termelékenység emelkedéséhez, azonban a csökkenő hozadék törvénye miatt ezek a hatások idővel mérséklődnek. A hosszú távú gazdasági növekedés fenntartásának kulcsa így az exogén technológiai fejlődés, amely a termelési tényezők hatékonyságának folyamatos javulását eredményezi. Solow szerint a gazdasági növekedés egyensúlyi pályája csak akkor tartható fenn, ha a technológiai szint folyamatosan emelkedik (Barro–Sala-i-Martin, 2004).

A technológiai fejlődés hatását a modell számszerűsítette a „Solow-maradék” koncepciójával, amely a termelékenység növekedésének azon részét jelenti, amelyet nem lehet közvetlenül a tőke és a munka növekedéséhez kötni. Ez a növekedési elem megvilágítja, milyen mértékben járul hozzá az innováció és a technológiai haladás a gazdasági fejlődéshez, anélkül, hogy megváltoztatná a tőke és a munka egymáshoz viszonyított arányát. Például a semleges technológiai változás esetében a termelési függvény egyszerűen megszorozható egy növekvő tényezővel ($A(t)$), amely a kibocsátás szintjét emeli anélkül, hogy torzítaná a termelési tényezők közötti helyettesítési viszonyokat (Solow, 1957).

Ezen túlmenően a technológiai fejlődés jelentős gyakorlati hatással bír. A reálberek növekedésének és a gazdasági stabilitás fenntartásának egyik fő mozgatórugója, mivel a termelési tényezők mennyiségi korlátain túl is lehetővé teszi a gazdasági növekedést.

3.1.3. A modell korlátai

Bár a Solow–Swan-modell a modern makroökonómia elengedhetetlen kiindulópontja, számos egyszerűsítése korlátozza az empirikus alkalmazhatóságát.

A modell legfőbb hiányossága a hosszú távú növekedés forrásának kezelésében rejlik. A neoklasszikus keretrendszerben a technológiai fejlődés exogén válto-

zóként jelenik meg, nem pedig a gazdasági szereplők döntéseiből fakadó eredményként. Mivel a tőke csökkenő hozadéka miatt a tőkefelhalmozás önmagában nem eredményezhet fenntartható növekedést, a modell paradox módon úgy magyarázza a növekedést, hogy annak legfőbb motorját, a technológiai haladást a modellen kívül hagyja. Ez a megközelítés a technológiát szabadon elérhető közjóságnak tekinti, figyelmen kívül hagyva a kutatás-fejlesztés (K+F) ösztönzőit és a tudás részleges kizárhatóságát.

Empirikus szempontból a modell legvitatottabb pontja a konvergenciasebesség és a nemzetközi jövedelemkülönbségek magyarázata, mivel a sztenderd keretrendszer irreálisan gyors felzárkózást jósol a szegény és gazdag országok között. A modell emellett a nemzetközi tőkeáramlások tekintetében is pontatlannak bizonyult, hiszen a tőke a várakozásokkal ellentétben nem áramlik a magasabb határtermékkel rendelkező szegényebb régiók felé, amely jelenség a szakirodalomban Lucas-paradoxonként ismert. A pusztán fizikai tőke felhalmozásával nem magyarázható ellentmondásokat csak a tőke fogalmának kiterjesztése és az intézményi tényezők figyelembevétele oldhatja fel, ahogyan azt a Lucas-féle humán tőke modell javasolja (Barro–Sala-i-Martin, 2004).

3.2. Endogén növekedési modellek

Válaszul a neoklasszikus modellek alapvető hiányosságára, a kutatások fókuszra az 1980-as évektől az exogén tényezőkről fokozatosan a gazdasági szereplők belső döntéseire és az innovációra irányult (Romer, 1990). Az elméleti keret hiányossága már korán megmutatkozott a növekedési számvitelek eredményeiben. Solow (1957) az Egyesült Államok 1909 és 1949 közötti adatait elemezve rámutatott arra az összefüggésre, hogy az egy főre jutó növekedésnek mindössze 12,5 százaléka magyarázható a tőke felhalmozásával. A fennmaradó részt a modell által nem részletezett reziduum adta, amit a szakirodalom elsődlegesen a technológiai fejlődéssel azonosított. Moses Abramovitz ezt a maradványt találóan „tudatlanságunk mértékének” nevezte, hiszen a növekedés legfőbb motorja így magyarázat nélkül maradt (Abramovitz, 1956). A cél ezért az lett, hogy a technológiai fejlődést a gazdasági szereplők profitmaximalizáló döntéseiből, belső tényezőként vezessék le (Barro–Sala-i-Martin, 2004).

3.2.1. Az elméleti előzmények

Mielőtt a tudatos kutatás-fejlesztésre épülő modellek megjelentek volna, a tudás gazdasági szerepének endogenizálása felé az első lépést Kenneth Arrow tette meg. Arrow koncepciója szakított azzal a feltételezéssel, hogy a technológiai fejlődést a gazdasági folyamatoktól független, külső adottságnak tekintse. Elméletének köz-

ponti eleme a gyakorlat általi tanulás (learning-by-doing) folyamata volt. Ebben a megközelítésben a tudás a beruházások és a termelési tevékenység nem szándékolt mellékterméke (Arrow, 1962).

Arrow szerint a termelékenység növekedése szorosan összefügg a kumulált bruttó beruházással, amely a termelési tapasztalat mérőszámaként szolgál. Bár az egyedi vállalatok saját profitérdekükben, kapacitásbővítés céljából ruháznak be fizikai tőkébe, ez a tevékenység új tudást is generál. Ez a tudás azonban nem marad a vállalat falai között, hanem pozitív externáliák, úgynevezett spillover hatások révén szétterjed a gazdaságban, növelve az összes többi szereplő hatékonyságát (Arrow, 1962). Ezt az összefüggést később Lucas (1988) is beépítette a humán tőke felhalmozásának modelljébe, különbséget téve az oktatás egyéni bérnövelő és társadalmi szintű hatékonyságnövelő hatása között (Lucas, 1988).

Robert Solow az új növekedésméletek ősenek, sőt prototípusának nevezte Arrow modelljét. Értékelése szerint ebben a keretben a technológiai fejlődés már a gazdasági folyamatok belső következményeként jelenik meg, jóllehet hiányzik belőle a tudatos, optimalizáló innovációs döntés (Solow, 1997). Ez a passzív, átmeneti jelleg különbözteti meg Arrow megközelítését a későbbi, első generációs endogén modellektől, ahol a szereplők már erőforrásokatallokálnak a tudás létrehozására (Romer, 1990).

3.2.2. Az első generációs modellek – A tudás és az innováció mint a növekedés belső tényezői

Paul Romer (1990) és Robert Lucas (1988) megközelítése szakított azzal a hagyománnyal, amely a technológiát külső adottságként kezelte. Munkásságuk az endogén növekedésméletek igazi áttörését hozta el. Modelljeikben a technológiai fejlődés a gazdasági szereplők szándékos és profitorientált döntéseinek eredménye. Lucas (1988) a humán tőke felhalmozására helyezte a hangsúlyt, megkülönböztetve az oktatás egyéni termelékenységnövelő hatását a társadalmi szintű pozitív külső hatásoktól. Romer (1990) pedig a tudást egy teljesen új típusú gazdasági jószágként definiálta.

Romer modelljének alapja a tudás nem versengő jellegének felismerése (Romer, 1990). A hagyományos javak használata korlátozott, hiszen egy gép vagy egy mérnök munkaideje egyszerre csak egy helyen hasznosítható. Ezzel szemben egy szoftver kódja vagy egy kémiai képlet egyidejűleg végtelen számú helyen felhasználható anélkül, hogy az értéke csökkenne vagy újratermelése többletköltséggel járna (Barro–Sala-i-Martin, 2004).

Ez a tulajdonság alapvető változást igényel a piaci szerkezet megértésében. A tudás létrehozása magas fix költséggel járó kutatás-fejlesztési tevékenység, a másolása viszont olcsó. Csakhogy egy tőkéletes verseny esetén az ár a határköltség

szintjére süllyedne, így a feltaláló számára soha nem térülhetne meg a befektetése (Dixit–Stiglitz, 1977). A vállalatok ezért csak akkor fektetnek innovációba, ha az új ötletek vagy tervrajzok részlegesen kizárhatók. Ezt a védelmet a szabadalmi rendszerek és az üzleti titkok biztosítják számukra (Romer, 1990). A technológiai szektorban tehát szükségszerűen monopolisztikus verseny érvényesül, így a kizárhatóság biztosítja azt a monopoljáradékot, amely fedezi a kutatás fix költségeit és profitot termel (Aghion–Howitt, 1992).

Romer (1990) modelljében az új ötletek előállítása a kutatási szektorban történik a következő összefüggés szerint:

$$\dot{A} = \delta H_A A \quad (2)$$

A képletben $\dot{A}$ jelöli az új technológiák áramlását, a kutatásban dolgozó emberi tőkét, A a meglévő tudásállományt, δ pedig a kutatási hatékonyságot. A modellben az innováció dominánsan horizontális jellegű. Ez a termékválaszték bővülését jelenti, ahol az új javak nem szorítják ki a régieket, hanem kiegészítik azokat (Grossman–Helpman, 1991). A termelési láncban való specializáció révén az újítások növelik a végső termék előállításának hatékonyságát (Young, 1998).

A (2) egyenlet egyik legfontosabb üzenete a tudás kumulatív természete. A meglévő tudásállomány pozitív externáliaként segíti az új kutatásokat. A kutatók Newton híres hasonlatával élve óriások vállán állnak (Jones, 1995). Ez a törvényszerűség teszi lehetővé a növekvő skálahozadékot a gazdaság egészére nézve. Elméletük szerint azok az országok és vállalatok, amelyek nagyobb mértékben fektetnek be kutatás-fejlesztésbe, tartósan gyorsabb növekedést érhetnek el. A növekedési ráta tehát endogén, mivel végső soron a társadalom türelmétől, vagyis az időpreferenciától és a kutatási szektorba áramló erőforrásoktól függ (Romer, 1990; Lucas, 1988; Barro–Sala-i-Martin, 2004).

3.2.3. Az empirikus kritika – A skálahatás problémája

Az első generációs modellek egyik leggyakrabban kritizált előrejelzése az úgynevezett skálahatás. A Romer-féle egyenletből matematikailag az következik, hogy a növekedési ütem egyenesen arányos a kutatásban foglalkoztatottak számával. Ez az összefüggés azt sugallja, hogy egy nagyobb népességű, vagy a kutatási szektorba több erőforrást allokáló gazdaságnak exponenciálisan gyorsabban kellene növekednie (Jones, 1995). Charles Jones elemzésében rámutatott ennek a feltételezésnek az empirikus korlátaira. Az adatok azt mutatták, hogy amíg az Egyesült Államokban a K+F szektorban dolgozó tudósok és mérnökök száma 1950 és 1990 között több mint ötszörösére emelkedett, addig a gazdasági növekedés nem követte ezt a robbanásszerű változást. A teljes tényezőtermékenység (TFP) növekedési üteme ebben az időszakban nem gyorsult fel, hanem egy viszonylag állandó,

évi 2 százalékos körüli szinten maradt (Jones, 1995; Barro–Sala-i-Martin, 2004). Ezt Jakob Madsen is megerősítette az OECD országok 1870 és 2006 közötti adatait elemezve. Arra jutott, hogy bár a kutatói létszám és a K+F ráfordítások globálisan is hatalmasat nőttek, az egy főre jutó GDP növekedési rátája hosszú távon meglepően stabil maradt. Madsen adatai szerint a növekedés rátája több mint egy évszázadon keresztül az évi 1,5 és 2,5 százalékos közötti sávban mozgott az érintett országokban. Rámutatott még arra is, hogy a növekedési számvetések sokszor túlértékelik a tőke szerepét, miközben a növekedés valódi forrása a technológiai fejlődés és a humán tőke (Madsen, 2010).

Ezeknek az ellentmondásoknak a feloldására jelentek meg a szemi-endogén modellek (Jones, 1995; Segerstrom, 1998). Ezekben a modellekben már érvényesül az úgynevezett kimerülési effektus, azaz a technológia fejlődésével a könnyen elérhető ötletek fogynak, így az újításokhoz egyre nagyobb kutatói munka szükséges (Segerstrom, 1998). Alwyn Young (1998) szintén arra világított rá, hogy a gazdaság méretének növekedése sokszor inkább a termékváltozatok számát növeli, és nem a növekedés ütemét gyorsítja. Így a hosszú távú növekedés nem a kutatók abszolút számától, hanem azok növekedési ütemétől függ (Young, 1998).

3.2.4. Schumpeteri modellek – A kreatív rombolás és a vertikális innováció

A növekedésméletek következő generációja túllépett a termékválaszték pusztá bővítésén. Philippe Aghion és Peter Howitt (1992) a minőségi javulást és a vertikális innovációt helyezték középpontba. Ez a megközelítés visszanyúl Joseph Schumpeter eredeti gondolatához. Az elmélet szerint az innováció nem békés felhalmozás, hanem állandó küzdelem. Ennek során az új és hatékonyabb technológia szükségszerűen kiszorítja és elértékteleníti a régit (Aghion–Howitt, 1992).

A schumpeteri modellben minden sikeres innováció egy adott mértékkel növeli a technológiai színvonalat az előző időszakhoz képest. Ez a folyamat hozza létre a kreatív rombolás ciklusait. A technológiai szint változását az alábbi egyszerűsített összefüggés írja le:

$$A_{t+1} = \gamma A_t \quad (3)$$

A képletben a γ paraméter a minőségi ugrás mértékét jelöli, amely mindig egynél nagyobb szám. Ebben a dinamikus keretrendszerben a gazdasági növekedés ütemét két tényező határozza meg. Az egyik az innovációk érkezésének valószínűsége, a másik pedig a minőségi ugrás nagysága (Aghion et al., 2015).

A modell egyik legfontosabb újdonsága a verseny szerepének újra értelmezése. A korai modellekben az erős verseny csökkentette a profitot és ezzel az innovációs kedvet. Ezzel szemben a modern schumpeteri modellekben a verseny ösztönzőleg is hathat. A technológiai élvonalban lévő vállalatok az innováció révén tesznek

szert előnyre, hogy ezáltal kivonják magukat az intenzív árverseny alól és magasabb profitot biztosítsanak maguknak (Aghion et al., 2021). Ez a piaci dinamika különösen releváns a mai digitális gazdaság elemzésekor. A termékéletciklusok drasztikusan lerövidültek az elmúlt évtizedekben. Empirikus adatok is igazolják a kreatív rombolás felgyorsulását. Míg a XX. század közepén egy nagyvállalat átlagos élettartama 60 év körül mozgott, mára ez 20 év alá csökkent (Aghion et al., 2021). A mesterséges intelligencia korában ez a folyamat még inkább meghatározóvá válik. Az új technológiák túlmutatnak a meglévő folyamatok finomhangolásán, és akár teljes üzleti modellek gyors újraszervezését is lehetővé teszik. Az AI által vezérelt automatizáció felgyorsíthatja a kreatív rombolást, ami fokozott alkalmazkodási nyomást helyez a munkaerőpiacra és a szabályozói környezetre.

4. AZ IPAR 4.0 GAZDASÁGI MODELLJEI – AZ AI HATÁSA A TERMELÉKENYSÉGRE ÉS A MUNKAERŐ HELYETTESÍTÉSÉRE

A gazdasági növekedésméletek evolúciója az Ipar 4.0 megjelenésével új szakaszba lépett. Amíg a harmadik ipari forradalom a termelési folyamatok automatizációjáról szólt, az Ipar 4.0 lényege a kiberfizikai rendszerek autonómiája, a dolgok internetje (IoT), a mesterséges intelligencia és az adat mint új termelési tényező megjelenése. Ebben a modellben a fizikai tőke már nem passzív eszköz, hanem képes lehet a környezetével való kommunikációra és intelligens döntéshozatalra (Kovari, 2024). Ez a technológiai váltás alapjaiban írja át a hagyományos termelési függvényeket. A modern AI-vezérelt gazdasági modellekben az adat már konkrétan nevesített, a tőkével és a munkával egyenrangú, potenciális bemeneti tényezőként jelenhet meg (Brynjolfsson et al., 2025).

Az adat tehát a digitális gazdaság új nyersanyagává válik, amely már most nélkülözhetetlen az autonóm rendszerek tanítása, finomítása és tesztelése során. Az Ipar 4.0 kontextusában az adatmennyiség és az adatminőség közvetlen hatással van a gazdasági rendszerek teljesítményére és a növekedési potenciálra. A valós idejű adatokra támaszkodó döntéshozatal és a Big Data analitika integrációja Sun et al. (2024) empirikus vizsgálata szerint szignifikánsan növelheti a vállalatok teljes tényezőtermelékenységet, miközben csökkentheti a határköltségeket és az információs aszimmetriát a piacon (Buri-Kiss, 2025).

A legkritikusabb kérdés azonban ezeknek a technológiáknak a munkaerőpiaci hatása. Daron Acemoglu és Pascual Restrepo modelljei rámutatnak, hogy amíg a korábbi technológiák (pl. a gőzgép vagy a számítógép) dominánsan növelték a munka határtermékét, addig például a fejlett robotika képes lehet teljes mértékben kiváltani az emberi munkát a rutinszerű és szabályalapú feladatokban. Ez

a folyamat a gazdasági polarizáció kockázatát hordozza; miközben visszaszoríthatja az alacsony képzettséget igénylő pozíciókat, felértékelheti a magas hozzáadott értékű, kreatív és problémamegoldó munkaköröket. A technológiai fejlődés tehát nem semleges. A tőke részaránya a nemzeti jövedelemben növekedhet a munka rovására, ami újraelosztási kihívások elé állíthatja a gazdaságpolitikát (Acemoglu–Restrepo, 2020). Az Ipar 4.0 adatvezérelt infrastruktúrája és a rutin-feladatok automatizálása azonban csak az első lépés volt. Ez a technológiai fejlődés alapozta meg a következő forradalmi ugrást, amelyben a mesterséges intelligencia már nemcsak elemzi az adatokat, hanem újakat is létrehoz.

4.1. A generatív AI korszakának forradalma

Az automatizációs technológiák évtizedek óta a termelékenység növekedésének kulcs tényezői, de a 2022-es év fordulópontot hozott a mesterséges intelligencia fejlődésében. Az OpenAI generatív nagy nyelvi modelljei alapjaiban változtatták meg az innováció természetét. Az AI mostanra olyan területeken is meghatározó szereplővé vált, amelyeket korábban kizárólag az emberi kreativitás terepének tartottunk. Ez a fejlődés nemcsak a technológiai, hanem a gazdasági lehetőségek dimenzióit is bővítette. Az AI technológiák korábban főként nagyvállalatok privilégiumai voltak, hiszen ezek rendelkeztek a szükséges erőforrásokkal és szakértelemmel. A kisebb vállalkozások számára a mesterséges intelligencia alkalmazása túlságosan költséges és bonyolult, míg magánszemélyek számára gyakorlatilag elképzelhetetlen lehetőség volt. Az olyan fejlesztések, mint például az OpenAI ChatGPT-je azonban új korszakot nyitottak. Az AI eszközök egyszerűen használhatók, széles körben hozzáférhetők és megfizethetők lettek, ami forradalmasította a technológia szerepét a gazdaságban.

A technológiai ugrás gazdasági hatása az AI-ágensek megjelenésével válik teljessé. Ezek a rendszerek aktív digitális munkatársként funkcionálhatnak. Az autonóm ágens-alapú architektúrák képesek lehetnek önállóan navigálni a vállalati folyamatokban és emberi felügyelet mellett komplex döntéseket is meghozhatnak. Ez a váltás csökkentheti a tranzakciós költségeket és a koordinációs terheket (Samuels, 2025). A kognitív automatizáció így már a magas szintű szakértői feladatokat is érinti, ami a tudásmenedzsment alapvető átszervezését igényli a fenntartható növekedés érdekében (Acemoglu, 2025; World Economic Forum, 2025). A hosszú távú növekedési pálya befolyásolása azonban csak akkor valósulhat meg, ha az AI a tudásmenedzsment központi elemévé válik.

5. AZ AI-JAL KIEGÉSZÍTETT TUDÁSMENEDZSMENT SZEREPE

A tudásmenedzsment modern szemléletmódja azonban megköveteli, hogy túl-
lépjünk a tudás mennyiségi szemléletén. A generatív mesterséges intelligencia
megjelenése nemcsak az ismeretek akkumulációját gyorsítja fel, hanem megvál-
toztatja a tudáshoz való hozzáférés rendszerét. Ennek elemzéséhez Joel Mokyr
gazdaságtörténeti keretrendszere nyújt megfelelő elméleti alapot, amely a „hasz-
nos tudás” szerkezetét vizsgálja.

5.1. A tudás mint gazdasági növekedési tényező

Az endogén modellek helyesen mutatnak rá, hogy a tudás nem rivalizáló jó-
szág, vagyis használata során nem merül ki, sőt a megosztás révén társadalmi
határhaszna növekszik (Romer, 1990). A történelmi tapasztalatok azonban azt
mutatják, hogy a tudás felhalmozása önmagában nem elégséges feltétele a tartós
növekedésnek. Mokyr (2002) érvelése szerint a technológiai fejlődés sebességét
nem a tudás abszolút mennyisége, hanem a tudáselemek közötti kapcsolatok mi-
nősége és a tudáshoz való hozzáférés költsége határozza meg. A tanulmányban
a tudáshoz való hozzáférés költségei a releváns információ felkutatásának, ér-
telmezésének, validálásának és alkalmazásának idő- és erőforrásigényét jelentik
(Mokyr, 2002, 2017).

Mokyr (2002) modellje két, egymással szoros kölcsönhatásban álló tudástípust
különböztet meg. A propozicionális tudás (Ω -tudás) a természeti jelenségek el-
méleti leírását és a „mi” típusú ismereteket foglalja magában. Ezzel szemben a
preskriptív tudás (λ -tudás) a gyakorlati megvalósításhoz szükséges technikák,
utasítások és eljárások halmaza, vagyis a „hogyan” tudása. A gazdasági növeke-
dés akkor válik fenntarthatóvá, ha a propozicionális tudás bővülése folyamatosan
és alacsony költséggel képes új preskriptív tudást generálni.

Mokyr (2017) szerint az ipari forradalom sikerét nem a találmányok száma okozta,
hanem az „ipari felvilágosodás”, amely csökkentette a tudáshoz való hozzáférés
költségeit, és lehetővé tette a tudományos felismerések gazdasági hasznosítását.

A modern információs társadalomban azonban a tudásmenedzsment egy sajátos
paradoxonnal szembesül. A digitalizáció révén a propozicionális tudásbázis (Ω)
exponenciálisan növekszik. A becslések szerint a globális adatmennyiség 2027-re
eléri a 291 zettabájtot (Jalal et al., 2026), ami gyakorlatilag feldolgozhatatlan meny-
nyiségű információt jelent. John Naisbitt már évtizedekkel ezelőtt figyelmeztetett
a jelenség veszélyeire: „Belefulladunk az információkba, miközben tudásra szom-
jazunk” (Naisbitt, 1982:24). Ez a hatalmas adatmennyiség jelentős kihívás elé ál-
lítja az egyéneket és a szervezeteket egyaránt, amely információs túlterheltséghez

vezethet. Ez nemcsak a termelékenységet csökkenti, hanem a döntéshozatalt is nehezíti, komoly stresszt és életminőségbeli romlást okozva (Arnold et al., 2023). Gazdasági szempontból ez azt jelenti, hogy bár a tudáskínálat bőséges, a releváns információ megtalálásának és alkalmazásának hozzáférési költségei drasztikusan megemelkedtek. Az emberi kognitív kapacitások korlátai miatt a hatalmas Ω -halmazból egyre nehezebb kinyerni a gazdaságilag hasznosítható λ -tudást.

Ebben a kontextusban értelmezhető a mesterséges intelligencia jelentősége, mivel a hagyományos informatikai megoldásokon túl a tudáshoz való hozzáférés költségeinek csökkentésében az egyik leghatékonyabb eszközzé válhat. A nagy nyelvi modellek (LLM) és a generatív algoritmusok képesek a strukturálatlan és hatalmas mennyiségű propozicionális tudást szintetizálni, majd azt alkalmazható preskriptív tudássá alakítani. Ezzel a technológia áthidalja az implicit tudás átadásának nehézségeit is, mivel képes a rejtett mintázatok és összefüggések explicitté tételére. Az AI által vezérelt tudásmenedzsment tehát Mokryi digitális felvilágosodás eszköze, amely biztosíthatja, hogy a tudásbázis bővülése közvetlen termelékenységnövekedésben és innovációban hasznosuljon.

5.2. A tudástranszfer költségstruktúrájának átalakulása az AI korában

A generatív mesterséges intelligencia gazdasági hatása a Joel Mokyr által leírt tudástranszfer folyamatában érhető tetten. Az elméleti tudás (Ω) és a gyakorlati alkalmazás (λ) közötti átmenetet hagyományosan magas tranzakciós költségek és információs akadályok nehezítették. Az AI technológia elsődleges szerepe ezen a téren a tudáshoz való kognitív hozzáférési korlátok és az információfeldolgozási költségek mérséklése.

A 2. táblázat azt rendszerezi, hogy a releváns vizsgálatok szerint az AI milyen konkrét eszközökkel képes csökkenteni az innovációs ciklusokat fékező megvalósítási akadályokat.

2. táblázat
Az AI szerepe a tudáshoz való hozzáférés költségeinek csökkentésében:
Joel Mokyr tudástípusainak gyakorlati transzformációja

Költség-típus	Hagyományos folyamat (Mokyr $\Omega \rightarrow \lambda$ gátjai)	AI-vezérelt megoldás	Hatás a tudásáramlásra	Empirikus bizonyítékok és forrás
Keresési és hozzáférési költség	A releváns tudás (Ω) megtalálása időigényes. Az innovációk gyakran elszigetelt tudásterületek (silók) összekapcsolásából születnek, de ezek felismerése emberi kognitív korlátokba ütközik.	Szemantikus keresés és RAG: Az AI nem kulcsszavak, hanem jelentés alapján tárja fel a releváns propozicionális tudást percek alatt, illetve képes a heterogén adatbázisok között rejtett összefüggéseket feltárni tudásgráfok segítségével.	A releváns elméleti tudás gyorsabban rendelkezésre állhat.	Egy vállalati RAG-rendszerben a problémafeloldási idő 34 percről 12 percre csökkent, a top-5 relevancia pedig 58%-ról 87%-ra nőtt a kulcsszóalapú kereséshez képest (Baqar, 2026).
Értelmezési költség	A tudás „hallgatólagos” (tacit) jellegű vagy magas szintű szakzsargonba kódolt, ami speciális emberi tőkét igényel a megértéshez.	Az LLM-ek képesek a komplex információt (Ω -t) a felhasználó tudásszintjére „lefordítani” és végrehajtható utasítássá (λ) alakítani.	A „tudás-demokratizálás” révén alacsonyabb képzettségű munkaerő is képes komplex utasításokat végrehajtani.	40%-kal gyorsabb feladatmegoldás, 18%-os minőségjavulás (Noy-Zhang, 2023) volt megfigyelhető az AI használatával.
Verifikációs és alkalmazási költség	Egy új technikai megoldás (λ) tesztelése fizikai prototípusokat és drága „próba-szerencse” folyamatokat igényel.	Digitális Ikrek és Szimuláció: A javasolt megoldások validálása virtuális térben történik. A prediktív modellek csökkentik a tudásbeli szakadékokat.	A hibás preskriptív tudás kiszűrési költsége csökken; az innovációs ciklusidő rövidül.	Az AI-asszisztens használó ügyfélszolgálati munkatársak termelékenysége 14%-kal, a legkevesbé tapasztaltaké 30%-kal nőtt (Brynjolfsson et al., 2025).

Forrás: Saját szerkesztés az alábbi cikkek adatai alapján: Brynjolfsson et al. (2025), Noy-Zhang (2023), Baqar (2026). A táblázatban szereplő Ω a Mokyr-féle elméleti/propozicionális tudást jelöli, míg a λ a gyakorlati/preskriptív tudást (utasításokat), amelyek a technológiai alkalmazáshoz szükségesek.

A generatív mesterséges intelligencia nem automatikusan eredményez termelékenységi ugrást, hanem azon keresztül járulhat hozzá a gazdasági növekedéshez, hogy fokozatosan csökkenti a tudáshoz való hozzáférés költségeit. Ez a csökkenés tehát elsősorban az információfeldolgozás hatékonyságában, a tanulási idő rövideülésében és a döntéshozatal támogatásában érhető tetten, és makrogazdasági szinten csak hosszabb távon válhat mérhetővé.

5.3. Az AI rendszerek alkalmazkodóképessége és a személyre szabott tudásmenedzsment szerepe

A mesterséges intelligencia ebben a térben multiplikatív hatást fejt ki, különösen a személyre szabott tudásmenedzsment terén. Az AI rendszerek képesek valós idejű adatokat elemezni, amelyek segítségével a felhasználók igényeihez igazodó megoldásokat nyújtanak. A személyre szabott tudásmenedzsment különösen fontos a modern szervezetek számára, mivel az egyének és csapatok specifikus igényeit célozza meg. A KEAS (Knowledge Enhancement and Advisory System) esettanulmánya például kimutatta, hogy az ilyen rendszerek 42%-kal csökkentették a döntési időt és 35%-kal növelték a döntéshozók önbizalmát (Bankole–Falaye, 2024).

Az AI-alapú rendszerek képesek kiküszöbölni a tudásmenedzsment fő akadályait, például az adatsilók és az információk hiányosságok problémáját. Ezek az eszközök nemcsak a hatékonyságot növelik, hanem a tudás gyorsabb és pontosabb megosztását is lehetővé teszik (Jarrahi et al., 2023).

Az AI-alapú tudásmenedzsment nemcsak rendszerezi az információt, hanem dinamikusan alkalmazkodik a felhasználói igényekhez. Ez az adaptív képesség lehetővé teszi, hogy az AI támogassa az egyéni és csoportszintű kreativitást, valamint gyorsítsa a stratégiai döntéshozatalt. Például a természetes nyelvi feldolgozáson (NLP) alapuló generatív AI modellek képesek automatizálni a tudás rendszerezését és olyan rejtett mintákat azonosítani, amelyek elősegítik az innovációs döntéseket.

Az AI-al támogatott tudásmenedzsment tehát nemcsak az információ hasznosítását forradalmasítja, hanem a kreativitás és produktivitás növelésében is meghatározó szerepet játszik. Az ember és AI szinergia révén az emberi intuíció és stratégiai gondolkodás találkozik az AI gyors elemző kapacitásaival, lehetővé téve a hatékonyabb szervezeti működést.

6. IPAR 5.0 – EMBER-GÉP SZINERGIA ÉS FENNTARTHATÓ MUNKAERŐPIAC

Az Ipar 5.0 koncepciója az Ipar 4.0 technológiai vívmányaira épít, de alapvetően felülvizsgálja annak kizárólagos hatékonyság-központúságát (Ghobakhloo et al., 2023). A hangsúly az automatizálásról a társadalmi értékkeremtésre és a fenntarthatóságra helyeződik át, így a digitális transzformáció már nem öncélú folyamat (Buri–Kiss, 2025). Ez a megközelítés a gazdasági növekedés forrását már nem az emberi munkaerő kiváltásában és a költségek csökkentésében látja, hanem az ember és a gép közötti szinergikus együttműködésben (Woo, 2020).

Az ember és a mesterséges intelligencia kapcsolata ebben a rendszerben egyfajta hibrid intelligenciaként vagy ko-kreációként értelmezhető, ahol a két fél kiegészíti egymás hiányosságait. Daugherty és Wilson (2024) kutatásai rávilágítanak arra, hogy a legjelentősebb termelékenységi előnyök az úgynevezett hiányzó közép területén keletkeznek. Ezen a területen az emberek megtanítják a gépeket a komplex folyamatok elvégzésére, miközben a gépek kiterjesztik az emberi képességeket az adatok gyors feldolgozásával (Daugherty–Wilson, 2024). Ez a szinergia nem helyettesítést, hanem augmentációt jelent, ahol az emberi kreativitás és etikai ítélőképesség ötvöződik a gépi precizitással és sebességgel (Jarrahi et al., 2023).

Az együttműködés hatékonyságát konkrét mérési eredmények is igazolják a kritikus ágazatokban. Egy konkrét példa a Harvard Medical School által publikált kutatás, amely megállapította, hogy az orvosi diagnosztikában az emberi szakértelem és az AI együttműködése akár 99%-os pontosságot is elérhet, szemben az emberi vagy gépi elemzés önálló 96% és 92%-os pontosságával (Woo, 2020). Az eredmény egy specifikus, magas téttől függő döntési környezetre vonatkozik, így önmagában nem általánosítható a gazdaság egészére, ugyanakkor szemlélteti az emberi-gépi együttműködésben rejlő potenciált. A szakirodalom feltételezése szerint az ilyen típusú partnerség a döntéshozatali hibák mérséklése révén hatást gyakorolhat a vállalati és nemzetgazdasági szintű eredményességre is (Jarrahi et al., 2023).

Az emberközpontú megközelítés lényege, hogy a technológiát a munkavállalók jólétének fokozására és kognitív képességeik támogatására használják (Kaigom, 2025). Ebben a struktúrában a mesterséges intelligencia kollaboratív partnerként jelenik meg, aktívan támogatva a komplex problémák megoldását. A fejlett rendszerek átvállalják a rutinszerű feladatokat, így a kreatív és stratégiai funkciók az emberi munkaerőnél maradnak (Kovari, 2024). A humán tőke ebben a felfogásban a növekedés és az innováció dinamikus forrása (Ghobakhloo et al., 2023).

A technológiai háttér stabilitását és a hosszú távú versenyképességet a reziliencia pillére biztosítja (Samuels, 2025). A jelenlegi gazdasági környezetben a tisztán hatékonyságra optimalizált modellek gyakran sebezhetőnek bizonyulnak a váratlan külső hatásokkal és bizonytalanságokkal szemben, ezért szükség van a rugalmas alkalmazkodásra (Ghobakhloo et al., 2023). Az Ipar 5.0 keretein belül alkalmazott digitális ikrek és prediktív algoritmusok lehetővé tehetik a folyamatok valós idejű módosítását és az eltérések előrejelzését (Kaigom, 2025). A szakirodalom szerint egy ilyen reziliens struktúra hozzájárulhat ahhoz, hogy a technológia és az emberi tudás együttműködése ne csak hatékony, hanem fenntartható és válságálló is legyen (Buri–Kiss, 2025).

7. AZ AI ALKALMAZÁSÁNAK KIHÍVÁSAI

A mesterséges intelligencia terjedése nemcsak lehetőségeket nyit meg, hanem új típusú kockázatokat is felszínre hoz. Ilyen a digitális egyenlőtlenségek mélyülése, az adatok biztonságának garantálása, valamint az alkalmazásával kapcsolatos etikai kérdések. Ezek a tényezők közvetlenül befolyásolják az AI hosszú távú fenntarthatóságát és társadalmi elfogadottságát. Ez a fejezet egy további, gyakran alulértékelt kihívást is kiemel, azt, hogy a technológiai áttörések makrosztintű termelékenységi hozama késleltetve és sokszor egyenlőtlenül jelenik meg.

7.1. A Solow-paradoxon

Robert Solow 1987-ben Nobel-díjat kapott a technológiai fejlődés elméleti modellezéséért és empirikus vizsgálatáért a gazdasági növekedés elméletében. Ugyanebben az évben a *New York Times*-ban látott napvilágot azóta szállóigévé vált megállapítása, mely szerint „a számítógépek korszakát mindenhol láthatjuk, kivéve a termelékenységi statisztikákat” (Solow, 1987:36). Ez az első látásra ellentmondásnak tűnő állítás nem a saját elméletének érvényességét kérdőjelezi meg, hanem arra mutat rá, hogy a gyors technológiai fejlődés nem jelenik meg egyértelmű, azonnali termelékenységnövekedésként a makrogazdasági statisztikákban. Ezek gazdasági hatásai időben, szerkezeti jellemzőikben és mérési szintjeikben általában eltérnek (Oliner–Sichel, 2000).

A szakirodalom a Solow-paradoxont több, egymással szorosan összefüggő tényező együttes hatásával magyarázza. Brynjolfsson, Rock és Syverson (2017) négy fő magyarázó tényezőt vázol fel: a túlzott várakozásokat, a mérési problémákat, az újraelosztási és piacszerkezeti hatásokat, valamint az alkalmazási és szervezeti késéseket. E tényezők együttesen eredményezik, hogy a technológiai képességek gyors fejlődése ellenére a makrogazdasági termelékenységi mutatók csak mérsékelten reagálnak. Az egyik alapvető ok a technológiai lehetőségek és azok gazdasági alkalmazása közötti időbeli eltérés. Az új technológiák bevezetése fokozatos folyamat, amely jelentős tanulási költségekkel és szervezeti átalakításokkal jár. A vállalatoknak nemcsak új eszközöket kell beszerezniük, hanem át kell alakítaniuk folyamataikat, döntési struktúráikat és humán erőforrás-gyakorlatukat is. Ezek az átmeneti költségek rövid távon akár a mért termelékenység romlásához is vezethetnek (Brynjolfsson et al., 2017).

A termelékenység mérésének korlátai tovább erősítik a paradoxont. A digitális technológiák és az információs rendszerek által létrehozott érték egyre nagyobb része immateriális formában jelenik meg, például minőségjavulás, időmegtakarítás vagy jobb döntéstámogatás révén. Ezek a hatások csak korlátozottan tükrö-

zódnek a GDP-ben és a hagyományos termelékenységi mutatókban, különösen a technológiai átmenet korai szakaszában (Oliner–Sichel, 2000).

A technológiai nyereségek eloszlása szintén fontos szerepet játszik. Számos esetben az új technológiák előnyei nem az aggregált termelékenység növekedéseként jelennek meg, hanem a piacszerkezet átalakulásában és a jövedelmek koncentrációjában. A vezető technológiai vállalatok térnyerése mellett a gazdaság nagy része csak korlátozott mértékben részesül a technológiai hozamokból, ami gyengíti a makroszintű statisztikai hatást (Brynjolfsson et al., 2017). A kutatások középpontjában az alkalmazás időigénye és a komplementer tényezők szerepe áll. Az új technológiák csak akkor képesek tartós termelékenységnövekedést generálni, ha megfelelő kiegészítő beruházások valósulnak meg. Ide tartozik a szervezeti innováció, a humán tőke fejlesztése és az adat-infrastruktúra kiépítése. Ezek hiányában a technológiai potenciál nem válik gazdasági teljesítménnyé (Brynjolfsson et al., 2021).

Ezt a folyamatot a szakirodalom gyakran J-alakú termelékenységi pályával írja le. A kezdeti szakaszban az átállási költségek dominálnak, ezért a mért termelékenység stagnálhat vagy akár romolhat is. Később azonban, amikor a komplementer tényezők összeállnak, a technológiai hozamok megjelennek, és a termelékenységi mutatók is egyértelműbben követni kezdik a technológiai fejlődést (Brynjolfsson et al., 2021). Empirikus vizsgálatok kimutatták, hogy az Egyesült Államokban az 1990-es évek második felében a termelékenység gyorsulása már szoros összefüggésben állt az információs és kommunikációs technológiai beruházásokkal és a kapcsolódó szervezeti átalakulásokkal (Oliner–Sichel, 2000). Hasonló mintázat volt megfigyelhető a fejlődő gazdaságokban is, ahol az IKT-beruházások hatása csak intézményi és strukturális alkalmazkodást követően jelent meg a termelékenységi mutatókban (Zhang et al., 2021). A történeti IKT-tapasztalatok alapján elmondható, hogy a Solow-paradoxon nem tartós állapot, hanem a technológiai átmenet korai szakaszának sajátossága.

A Solow-paradoxon eredetileg az információs és kommunikációs technológiák elterjedésének időszakához kapcsolódott, azonban a mesterséges intelligencia széles körű elterjedésével napjainkban is megjelenik. Bár az AI számos területen már eléri vagy meghaladja az emberi teljesítményt, makrogazdasági szinten ennek hatása egyelőre csak korlátozottan érzékelhető.

Az AI középtávú makrogazdasági hatására vonatkozó becslések jelentősen eltérnek egymástól. Acemoglu elemzése szerint az AI a következő évtizedben az Egyesült Államok GDP-jét körülbelül 1 százalékkal növelheti, miközben a teljes tényezőtermelékenység-növekedés (TFP) ennél is visszafogottabb, 0,53 és 0,66 százalék közötti marad (Acemoglu, 2025). Ez a megközelítés éles kontrasztban áll a piaci elemzők által megfogalmazott forgatókönyvekkel. A Goldman Sachs előrejelzése szerint a mesterséges intelligencia a következő tíz évben globálisan mintegy 7 százalékkal, azaz körülbelül 7 billió dollárral emelheti a globális GDP-t

(Goldman Sachs, 2023). A McKinsey a generatív AI közvetlen éves gazdasági értékteremtési potenciálját 2,6 és 4,4 billió dollárra, a hagyományos analitikai és AI-alkalmazásokat is magában foglaló teljes potenciált pedig 17,1 és 25,6 billió dollárra becsülte (Chui et al., 2023). A becslések közötti különbség jól érzékelteti, hogy az AI technológiai lehetőségei és azok makrogazdasági megjelenése között továbbra is jelentős eltérés lehet.

Összességében elmondható, hogy a Solow-paradoxon nem a technológiai fejlődés gazdasági jelentőségének tagadása, hanem annak hangsúlyozása, hogy a technológiai áttörések hatásai késleltetve, strukturális átalakulásokon keresztül és korlátozott mérhetőség mellett jelennek meg. Ez az értelmezési keret az információs technológiák korszakában alakult ki, de továbbra is releváns alapot nyújt a mesterséges intelligencia gazdasági hatásainak vizsgálatához.

7.2. Digitális egyenlőtlenségek

A mesterséges intelligencia technológiákhoz való hozzáférés és azok hasznosítása terén mutatkozó regionális különbségek jelentős mértékben járulnak hozzá a globális digitális egyenlőtlenségek elmélyüléséhez. Yuran Wu (2022) tanulmánya az AI-szakadék három dimenzióját különíti el, amelyek közvetlen, egymásra épülő gazdasági hatásokkal bírnak. Bár az alapvető internet-hozzáférési különbségek globálisan csökkentek, a hozzáférési szakadék az AI-specifikus eszközök (hardver és szoftver) terén továbbra is erősen jövedelemfüggő maradt, ami az infrastruktúra egyenlőtlen eloszlása miatt növeli a szektorok közötti termelékenységi különbségeket (Acemoglu, 2025). A kapacitási szakadékot tovább mélyíti a technológia komplexitása és a szükséges készségek hiánya, ami különösen a hátrányos helyzetű csoportokat és az alacsonyabb jövedelmű régiókat érinti kedvezőtlenül (Wu, 2022). A WEF (2025) ezt a technológiai írástudás és a készségkínálat eltolódásaként határozta meg. Ez a folyamat gátolja a technológia kiaknázásához szükséges humántőke-beruházások megtérülését, ezáltal lassítva a produktív J-görbe felfelé ívelő szakaszát (Brynjolfsson et al., 2021). Végül az eredményekben mutatkozó szakadék a piaci koncentráció fokozódásához és a „szupersztár cégek” dominanciájához vezet, mivel a technológiai előnyöket profitra váltani képes szereplők magukhoz vonzzák a növekedési forrásokat a lemaradóktól (Aghion et al., 2021), állandósítva a digitális egyenlőtlenségeket.

Ezt az elméleti keretet Azhar et al. (2025) makrogazdasági empirikus adatokkal támasztja alá, rámutatva a strukturális felkészültség döntő szerepére. Az OECD országokon végzett vizsgálatuk rávilágít a Solow-paradoxon jelenségére az AI kontextusában. Eredményeik szerint, míg a magas jövedelmű gazdaságokban az AI-beruházások a bevezetési időszakot követően szignifikáns GDP-növekedést

generálnak, addig az alacsonyabb jövedelmű országokban ez a pozitív hatás statisztikailag nem mutatható ki egyértelműen. Ennek oka, hogy a fejlődő régiókban gyakran hiányzik a megfelelő abszorpciós kapacitás. A gyengébb digitális infrastruktúra, az alacsonyabb humántőke-tartalékok és a K+F ráfordítások elégtelensége miatt ezek az országok nehezebben tudják az új technológiát termelékenységi nyereségre váltani (Azhar et al., 2025).

A technológiai előnyökből származó társadalmi javak és a tényleges gazdasági növekedés így elsősorban a fejlettebb területekre koncentrálódik. Ez a folyamat tovább nyitja az ollót a gazdaságilag fejlett és a fejlődő térségek között (Azhar et al., 2025; Wu, 2022). A World Economic Forum (2025) jelentése is megerősíti ezt a tendenciát. A munkáltatók 60 százaléka a digitális hozzáférés szélesítését tekinti a legkritikusabb üzleti átalakító tényezőnek, miközben a munkaerőpiaci készséghiányt azonosítják a transzformáció legfőbb akadályaként. Wu (2022) hangsúlyozza, hogy az egyenlőtlenségek csökkentése érdekében elengedhetetlen a digitális infrastruktúra fejlesztése és a digitális kompetenciák széles körű oktatása, különösen a marginalizált régiókban.

7.3. Adatvédelem és információbiztonság

A mesterséges intelligencia fejlődése hatalmas mennyiségű adat feldolgozását igényli, amely komoly adatvédelmi és információbiztonsági kihívásokat jelent. Az exponenciálisan növekvő adatmennyiség miatt a titkosítás, azonosítási protokollok, valamint az adatok anonimizálása és átlátható szabályozása kritikus jelentőségűvé vált. Az AI által feldolgozott adatok személyes vagy érzékeny információkat is tartalmazhatnak, amelyek jogosulatlan hozzáférése vagy nem szándékos nyilvánosságra kerülése egyéni és szervezeti szinten egyaránt kockázatot jelenthet.

Emellett a szakirodalom olyan új sérülékenységeket is azonosított, mint az adat- és modellmérgezés, a jogosulatlan információkinyerés, vagy a felhasználói adatok kiszivárgása (Yao et al., 2024; Das et al., 2025). Az AI gazdasági és szervezeti előnyeinek fenntartható kiaknázása ezért megfelelő adatirányítást, hozzáférés-szabályozást és folyamatos információbiztonsági kontrollokat igényel.

7.4 Az AI etikai dimenziói

Miközben a generatív AI soha nem látott lehetőségeket nyitott meg, komoly etikai és társadalmi kérdéseket is felszínre hozott. A „deepfake” technológia manipulált videók és hangfelvételek révén nemcsak a személyiségi jogokat sértheti, hanem politikai destabilizációt és társadalmi bizalmatlanságot is okozhat.

Caldwell (2023) szerint az algoritmikus elfogultság komoly társadalmi kockázatot jelent, mivel az AI modellek gyakran a tréning adatokban rejlő torzításokat reprodukálják, vagy akár felerősítik, ezzel tovább mélyítve a meglévő társadalmi egyenlőtlenségeket. Az adatfelhasználás és az AI rendszerek átláthatóságának hiánya szintén jelentős problémákat vet fel. Az úgynevezett „fekete doboz” rendszerek döntéshozatali folyamatai gyakran érthetetlenek a felhasználók számára, ami jelentős akadályt jelent a technológia iránti bizalom kialakulásában. A felelősségre vonhatóság kérdése különösen sürgető, mivel az AI döntéshozatali architektúrájának komplexitása és autonómiája miatt nehezen határozható meg az, hogy ki vonható felelősségre az esetleges nem kívánt következményekért (Jarrahi et al., 2023; Daugherty–Wilson, 2024).

7.5. Szabályozási és oktatási intézkedések szükségessége

A digitális transzformáció fenntartható és társadalmilag elfogadható irányítása az előzőekben bemutatott technológiai, adatbiztonsági, etikai és társadalmi kockázatok kezelését szolgáló összehangolt szabályozási és oktatási intézkedéseket igényel. E keretrendszer központi eleme az Európai Unió mesterséges intelligenciáról szóló rendelete, az AI Act, amely összehangolt szabályokat állapít meg a mesterséges intelligencia-rendszerek uniós piacon történő forgalomba hozatalára, üzembe helyezésére és alkalmazására. A kockázatalapú megközelítés révén a szabályozás célja az alapvető jogok, a biztonság és az egészség magas szintű védelme, miközben lehetőséget teremt a megbízható és emberközpontú AI-rendszerek gazdasági hasznosítására. A kizárólag hatékonyságra optimalizált technológiai megoldásokkal szemben a szabályozási logika a reziliencia, az átláthatóság és az emberi felügyelet intézményesítését helyezi előtérbe, különösen a magas kockázatú alkalmazások esetében (Regulation {EU} 2024/1689, 2024). Azonban, ha a szabályozási korlátozás kizárólag az Európai Unió keretein belül érvényesül, fennáll annak kockázata, hogy a technológiai innováció és az AI-alapú megoldások gazdasági hasznosítása lassúbbá válik. Ez relatív versenyhátrányt eredményezhet azokkal a régiókkal szemben, ahol rugalmasabb szabályozási környezet működik, például az Egyesült Államok vagy Kína esetében.

A szabályozási környezet azonban önmagában nem elegendő a mesterséges intelligencia sikeres és felelős integrációjához. Az oktatás és az átképzés kulcsszerepet játszik abban, hogy a munkaerő képes legyen alkalmazkodni az AI által generált új kompetenciaigényekhez, valamint megfelelni a szabályozás által támasztott működési és etikai elvárásoknak. Az AI-alapú rendszerek megértéséhez szükséges alapvető digitális készségek korai, iskolai szintű fejlesztése hosszú távon hozzájárul a technológiai egyenlőtlenségek mérsékléséhez. A felsőoktatásban és a szakmai képzésekben pedig a specializált ismeretek elsajátítása teszi lehetővé a

gazdasági szereplők számára a szabályozásnak megfelelő, ugyanakkor versenyképes technológiai alkalmazást. E három terület összehangolt működése teremti meg annak feltételeit, hogy a mesterséges intelligencia egyszerre járuljon hozzá a termelékenység növeléséhez és a hosszú távon fenntartható gazdasági fejlődéshez.

8. AZ AI MAGYARORSZÁGI NÖVEKEDÉSI ÉS PÉNZÜGYI RELEVANCIAJA

Az AI-alapú tudásmenedzsment magyarországi relevanciáját a vállalati AI-adaptáció és a digitális felkészültség közötti különbség is jelzi. Az Európai Bizottság adatai szerint 2025-ben a magyar vállalkozások 10,4 százaléka alkalmazott AI-technológiát, míg az uniós átlag 20,0 százalék volt. A legalább alapvető digitális intenzitással rendelkező magyar kkv-k aránya 59,8 százalékot ért el, szemben az EU 71,4 százalékos értékével (European Commission, 2026). A két mutató arra utal, hogy a technológiai infrastruktúra mellett a digitális készségek, a szervezeti alkalmazkodás és a tudás hasznosításának képessége is befolyásolhatja az AI gazdasági hasznosulását.

A pénzügyi szektorban az AI-integráció előrehaladottabb képet mutat. Az MNB 2025. évi FinTech és Digitalizációs jelentése szerint a hazai bankszektor digitális fejlettségi indexe 2024-ben 66-ról 69 pontra emelkedett. Az AI-hoz és folyamatautomatizációhoz kapcsolódó munkavállalói képzések elérhetősége egy év alatt megduplázódott, miközben az AI alkalmazása szinte minden hazai hitelintézetnél megjelent, jóllehet egyelőre jellemzően kísérleti fázisban, elsősorban a termékértékesítési folyamatok támogatásában (MNB, 2025).

9. A SZAKIRODALMI SZINTÉZIS EREDMÉNYEI

A szakirodalmi szintézis alapján a négy kutatási kérdésre eltérő bizonyosságú válaszok adhatók. Az első kutatási kérdés esetében a növekedésméletek fejlődése a technológia exogén kezelésétől a tudás, a humán tőke és az innováció endogén szerepének felismeréséig vezetett. Az endogén modellek egyes előrejelzései, különösen a skálahatások azonban nem kaptak egyértelmű empirikus megerősítést (Jones, 1995).

A második kutatási kérdéshez kapcsolódó eredmények arra utalnak, hogy a generatív AI egyes tudásintenzív feladatokban mérsékelheti a keresés, a feldolgozás és az alkalmazás időigényét (Noy-Zhang, 2023; Brynjolfsson et al., 2025). A hatások ugyanakkor feladat- és felhasználófüggők, ezért ezekből nem következik a tudáshoz való hozzáférés teljes költségének általános csökkenése.

A harmadik kutatási kérdés esetében a szakirodalom a szervezeti alkalmazkodás és a kiegészítő immateriális beruházások szerepét hangsúlyozza a termelékenységi hatás kialakulásában (Brynjolfsson et al., 2021). Az AI makrogazdasági hatásának nagyságára és időbeli lefutására vonatkozó becslések azonban jelentősen eltérnek.

A negyedik kutatási kérdésnél az Ipar 5.0 szakirodalma az emberközponúságot, a fenntarthatóságot és a rezilienciát helyezi előtérbe. Az ember és AI közötti komplementaritás azonban nem tekinthető automatikusnak, mivel a technológia egyes feladatokban kiegészítő, más esetekben helyettesítő hatást gyakorolhat. Az együttműködés hosszú távú gazdasági és társadalmi következményei ezért további empirikus vizsgálatot igényelnek.

10. A TANULMÁNY KORLÁTAI ÉS TOVÁBBI KUTATÁSI IRÁNYOK

A tanulmánynak három korlátja van. Az első az adatok jellege; mivel az elemzés másodlagos forrásokra épül és primer adatgyűjtést nem végez, a megfogalmazott összefüggések értelmezési javaslatok és nem empirikusan tesztelt állítások. A második korlát a forrásbázis összetétele; a generatív mesterséges intelligencia gazdasági hatásaira vonatkozó irodalom jelentős része még nem esett át teljes lektorálási folyamaton, a piaci elemzőházak becslései pedig módszertani szempontból nem egyenértékűek az akadémiai eredményekkel. A harmadik korlátozó tényező a megfigyelési időtáv rövideksége; a generatív modellek csupán 2022 óta érhetők el széles körben, ami – különösen a J-görbe-irodalom által jelzett alkalmazkodási késések fényében – még túl rövid idő a termelékenységi hatások megbízható méréséhez.

Ezekből a korlátokból három kutatási irány következik. Az egyik a hozzáférési költség négy összetevőjének vállalati szintű operacionalizálása és mérése. A másik a hazai kis- és középvállalati körben végzett vizsgálat, amely az abszorpció kapacitás és a tudáskezelési gyakorlat kapcsolatát tesztelné. A harmadik pedig a pénzügyi szektorra vonatkozó esettanulmány, amely a szabályozói megfelelés által kikényszerített tudáskezelési formalizálás termelékenységi hozamát vizsgálná.

11. ÖSSZEGZÉS

A gazdasági növekedés és az AI-vezérelt tudásmenedzsment összekapcsolása új értelmezési keretet ad a hosszú távú termelékenységi folyamatok elemzéséhez. A vizsgálat rámutat, hogy a digitális korszakban elengedhetetlen a makrogazdasági folyamatok és a szervezeti szintű tudáskezelés szorosabb integrációja. A mesterséges intelligencia korában a gazdasági növekedés dinamikáját a fizikai tőke felhalmozása mellett egyre inkább az határozza meg, milyen hatékonysággal képesek a szervezetek a rendelkezésre álló információkat hasznosítható tudássá alakítani.

Ez a megközelítés új keretbe helyezi a neoklasszikus és az endogén modellek fejlődését. Míg a gazdasági gondolkodás íve a technikai haladást előbb külső adottságként, majd az innováció motorjaként azonosította, addig a mai gazdasági környezetben a technológiai fejlődés egyre inkább a tudásmenedzsment belső, szervezeti folyamatokon keresztül alakítható elemévé válik. A dolgozat rámutat, hogy a generatív mesterséges intelligencia a Joel Mokyr által definiált tudáshozzáférési költségek érdemi csökkentésén keresztül válik makrogazdasági tényezővé. A technológia ugyanis képes a felhalmozott, strukturálatlan elméleti tudást (Ω) alacsonyabb ráfordítással gyakorlati alkalmazássá (λ) konvertálni, ezáltal hozzájárulva az innováció és a termelékenység közötti kapcsolat értelmezéséhez.

A makrogazdasági adatokban tapasztalható Solow-paradoxon egyik lehetséges magyarázata a technológiai bevezetés és a vállalati szintű alkalmazkodás közötti időbeli eltérésben kereshető. A termelékenységi J-görbe elmélete arra utal, hogy a technológiai beruházás szükséges, de önmagában nem elegendő feltétel. A növekedési többlet realizálása a technológiai bevezetés mellett a kiegészítő immateriális beruházásoktól, elsősorban a szervezeti folyamatok átalakításától és a humán tőke fejlesztésétől függ.

Végezetül az Ipar 5.0 megközelítés alapján feltételezhető, hogy a hosszú távú gazdasági stabilitás az emberi és gépi kompetenciák együttműködésére épül. Ez a kiegészítő jellegű együttműködés hozzájárulhat ahhoz, hogy a tudásalapú gazdaság növekedése társadalmilag is befogadható maradjon, feltéve, hogy a szabályozási és oktatási rendszerek képesek kezelni a digitális átállásból fakadó kihívásokat.

HIVATKOZÁSOK

- Abramovitz, M. (1956): Resource and Output Trends in the United States Since 1870. *The American Economic Review*, 46(2), 5–23. [HTTP://WWW.JSTOR.ORG/STABLE/1910656](http://www.jstor.org/stable/1910656).
- Acemoglu, D. – Restrepo, P. (2020): Robots and Jobs: Evidence from US Labor Markets. *Journal of Political Economy*, 128(6) <https://doi.org/10.1086/705716>.
- Acemoglu, D. (2025): The simple macroeconomics of AI. *Economic Policy*, 40(121), 13–58 <https://doi.org/10.1093/epolic/eiae042>.
- Aghion, P. – Howitt, P. (1992): A Model of Growth Through Creative Destruction. *Econometrica*, 60(2), 323–351. <https://doi.org/10.2307/2951599>.
- Aghion, P. – Akcigit, U. – Howitt, P. (2015): Lessons from Schumpeterian Growth Theory. *American Economic Review*, 105(5), 94–99. <https://doi.org/10.1257/aer.p20151067>.
- Aghion, P. – Antonin, C. – Bunel, S. (2021): The Power of Creative Destruction: Economic Upheaval and the Wealth of Nations. *Harvard University Press*. <https://doi.org/10.2307/j.ctv33mgbqt>.
- Arnold, M. – Goldschmitt, M. – Rigotti, T. (2023): Dealing with Information Overload: A Comprehensive Review. *Frontiers in Psychology*, 14, 1–28. <https://doi.org/10.3389/fpsyg.2023.1122200>.
- Arrow, K. J. (1962): The Economic Implications of Learning by Doing. *The Review of Economic Studies*, 29(3), 155–173. <https://doi.org/10.2307/2295952>.
- Azhar, S., – Zhang, Z., – Lu, S. (2025): Empirical analysis of the Solow paradox in artificial intelligence. *Open Journal of Business and Management*, 13(5), 3716–3729. <https://doi.org/10.4236/ojbm.2025.135200>.
- Bankole – Falaye, A. (2024): AI-Powered Knowledge Systems for SME Financial Management: A Conceptual Approach. *International Journal of Science and Research (IJSR)*. <https://doi.org/10.21275/SR241117060640>.
- Baqar, M. (2026): Retrieval-augmented generation in enterprise knowledge systems: architecture, benefits, and applications. *International Journal of Electrical and Computer Engineering (IJECE)*, 16(3), 1407–1416, <http://doi.org/10.11591/ijece.v16i3.pp1407-1416>.
- Barro, R.J. – Sala-i-Martin, X. (2004): Economic Growth. *MIT Press, London and Cambridge*.
- Brynjolfsson, E. – Korinek, A. – Agrawal, A. K. (2025): A Research Agenda for the Economics of Transformative AI (NBER Working Paper No. 34256). *National Bureau of Economic Research*. <https://doi.org/10.3386/w34256>.
- Brynjolfsson, E. – Rock, D. – Syverson, C. (2017): Artificial intelligence and the modern productivity paradox: A clash of expectations and statistics. *National Bureau of Economic Research Working Paper No. 24001*. <https://doi.org/10.3386/W24001>.
- Brynjolfsson, E. – Rock, D. – Syverson, C. (2021): The productivity J-curve: How intangibles complement general purpose technologies. *American Economic Journal: Macroeconomics*, 13(1), 333–372. <https://doi.org/10.1257/mac.20180386>.
- Brynjolfsson, E. – Li, D. – Raymond, L. (2025): Generative AI at Work. *The Quarterly Journal of Economics*, 140, 889–942, <https://doi.org/10.1093/qje/qjae044>.
- Buri, Zs. – Kiss T. J. (2025): Digitalisation in the Context of Industry 4.0 and Industry 5.0: A Bibliometric Literature Review and Visualisation. *Applied System Innovation*, 8(5), 137. <https://doi.org/10.3390/asi8050137>.
- Caldwell, A. (2023): Novel Cybersecurity Challenges Within Artificial Intelligence. *Journal of Internet Technology and Secured Transactions (JITST)*, 11(1), 796–801, <https://doi.org/10.20533/jitst.20463723.2023.0098>.

- Chui, M. – Hazan, E. – Roger R. – Singla, A. – Smaje, K. – Sukharevsky, A. – Yee, L. – Zimmel, R. (2023): The Economic Potential of Generative AI: The Next Productivity Frontier. *McKinsey & Company*. <https://www.mckinsey.com/capabilities/tech-and-ai/our-insights/the-economic-potential-of-generative-ai-the-next-productivity-frontier>.
- Daugherty, P. R. – Wilson, H. J. (2024): Human + Machine, Updated and Expanded: Reimagining Work in the Age of AI. *Harvard Business Press*.
- Das, B. C. – Amini, M. H. – Wu, Y. (2025): Security and Privacy Challenges of Large Language Models: A Survey. *ACM Computing Surveys*, 57(6), 1–39. <https://doi.org/10.1145/3712001>.
- Dixit, A. K. – Stiglitz, J. E. (1977): Monopolistic Competition and Optimum Product Diversity. *The American Economic Review*, 67(3), 297–308. <https://www.jstor.org/stable/2117514>.
- European Commission (2026) Hungary's 2026 Digital Decade Country Report. *European Commission, Brussels*.
- Ghobakhloo, M. – Iranmanesh, M. – Tseng, M. L. – Grybauskas, A. – Stefanini, A. – Amran, A. (2023): Behind the definition of Industry 5.0: a systematic review of technologies, principles, components, and values. *Journal of Industrial and Production Engineering*, 40(6), 432–447. <https://doi.org/10.1080/21681015.2023.2216701>.
- Goldman Sachs (2023): Generative AI could raise global GDP by 7 percent. <https://www.goldmansachs.com/insights/articles/generative-ai-could-raise-global-gdp-by-7-percent>. Letöltve: 2025.02.12.
- Grossman, G. M. – Helpman, E. (1991): Quality Ladders in the Theory of Growth. *The Review of Economic Studies*, 58(1), 43–61. <https://doi.org/10.2307/2298044>.
- Jalal, A. – Farooq, U. – Rabbi, I. – Badshah, A. – Khan, A. – Alam, M.M. (2026): Empowering edge computing: public edge as a service for performance and cost optimization. *Computers, Materials and Continua*, 86(2), 1–19. <https://doi.org/10.32604/cmc.2025.068289>.
- Jarrahi, M. H. – Askay, D. – Eshraghi, A. – Smith, P. (2023): Artificial intelligence and knowledge management: A partnership between human and AI. *Business Horizons*, 66, 87–99. <https://doi.org/10.1016/j.bushor.2022.03.002>.
- Jones, C. I. (1995): Time series tests of endogenous growth models. *The Quarterly Journal of Economics*, 110(2), 495–525. <https://doi.org/10.2307/2118448>.
- Jones, C. I. (1995): R & D-Based Models of Economic Growth. *Journal of Political Economy*, 103(4), 759–784. <https://doi.org/10.1086/262002>.
- Kaigom, E. G. (2025): Deep Generative and Discriminative Digital Twin endowed with Variational Autoencoder for Unsupervised Predictive Thermal Condition Monitoring of Physical Robots in Industry 6.0 and Society 6.0. *IFAC-PapersOnLine*, 59(18), 7–12. <https://doi.org/10.1016/j.ifacol.2025.10.188>.
- Kovari, A. (2024): Industry 5.0: Generalized Definition, Key Applications, Opportunities and Threats. *Acta Polytechnica Hungarica*, 21(3), 267–284. <https://doi.org/10.12700/APH.21.3.2024.3.17>.
- Lucas, R. E. (1988): On the Mechanics of Economic Development. *Journal of Monetary Economics* 22(1), 3–42. [https://doi.org/10.1016/0304-3932\(88\)90168-7](https://doi.org/10.1016/0304-3932(88)90168-7).
- Madsen, J.B. (2010): The Anatomy of Growth in the OECD since 1870: the Transformation from the Post-Malthusian Growth Regime to the Modern Growth Epoch. *Journal of Monetary Economics*, 57(6), 753–767. <https://doi.org/10.1016/J.JMONECO.2010.05.014>.
- Magyar Nemzeti Bank (2025): FinTech és Digitalizációs jelentés 2025. *Magyar Nemzeti Bank, Budapest*.
- Mokyr, J. (2002): The Gifts of Athena: Historical Origins of the Knowledge Economy. *Princeton University Press*.
- Mokyr, J. (2017): A Culture of Growth: The Origins of the Modern Economy. *Princeton University Press*. <https://doi.org/10.1515/9781400882915>.

- Naisbitt, J. (1982): *Megatrends: Ten New Directions Transforming Our Lives*. Warner Books, 24.
- Noy, S. – Zhang, W. (2023): Experimental evidence on the productivity effects of generative artificial intelligence. *Science*, 381, 187–192 <https://doi.org/10.1126/science.adh2586>.
- Oliner, S. D. – Sichel, D. E. (2000): The resurgence of growth in the late 1990s: Is information technology the story? *Journal of Economic Perspectives*, 14(4), 3–22. <https://doi.org/10.1257/jep.14.4.3>.
- Regulation (EU) 2024/1689 (2024): Regulation (EU) 2024/1689 of the European Parliament and of the Council of 13 June 2024 laying down harmonised rules on artificial intelligence (Artificial Intelligence Act). *Official Journal of the European Union*, L 2024/1689. <http://data.europa.eu/eli/reg/2024/1689/oj>.
- Romer, P. M. (1990): Endogenous Technological Change. *Journal of Political Economy*, 98(5), 71–102, <https://doi.org/10.1086/261725>.
- Samuels, A. (2025): Examining the integration of artificial intelligence in supply chain management from Industry 4.0 to 6.0: a systematic literature review. *Frontiers in Artificial Intelligence*, 7, 1477044. <https://doi.org/10.3389/frai.2024.1477044>.
- Segerstrom, P. S. (1998): Endogenous Growth Without Scale Effects. *The American Economic Review*, 88(5), 1290–1310, <https://www.jstor.org/stable/116872>.
- Solow, R. M. (1956): A Contribution to the Theory of Economic Growth. *The Quarterly Journal of Economics*, 70(1), 65–94, <https://doi.org/10.2307/1884513>.
- Solow, R. M. (1957): Technical Change and the Aggregate Production Function. *The Review of Economics and Statistics*, 39(3), 312–320. <https://doi.org/10.2307/1926047>.
- Solow, R. M. (1987): We'd better watch out. *New York Times Book Review*, 36.
- Solow, R. M. (1997): *Learning from 'Learning by Doing': Lessons for Economic Growth*. Redwood City: Stanford University Press. <https://doi.org/10.1515/9781503622579>.
- Sun, Z. – Che, S. – Wang, J. (2024): Deconstruct artificial intelligence's productivity impact: A new technological insight. *Technology in Society*, 79. <https://doi.org/10.1016/j.techsoc.2024.102752>.
- Torraco, R. J. (2005): Writing Integrative Literature Reviews: Guidelines and Examples. *Human Resource Development Review*, 4(3), 356–367. <https://doi.org/10.1177/1534484305278283>.
- Torraco, R. J. (2016): Writing Integrative Literature Reviews: Using the Past and Present to Explore the Future. *Human Resource Development Review*, 15(4), 404–428. <https://doi.org/10.1177/1534484316671606>.
- Woo, W. L. (2020): Future Trends in I&M: Human-Machine Co-Creation in the Rise of AI. *IEEE Instrumentation & Measurement Magazine*, 23(2), 71–73. <https://doi.org/10.1109/MIM.2020.9062691>.
- World Economic Forum (2025): The Future of Jobs Report 2025. <https://www.weforum.org/publications/the-future-of-jobs-report-2025/>.
- Wu, Y. (2022): An Overview Analysis of AI Divide: Applications and Prospects of AI Divide in China's Society. <https://doi.org/10.2991/assehr.k.220704.002>.
- Yao, Y. – Duan, J. – Xu, K. – Cai, Y. – Sun, Z. – Zhang, Y. (2024): A Survey on Large Language Model (LLM) Security and Privacy: The Good, the Bad, and the Ugly. *High-Confidence Computing*, 4(2), 100211. <https://doi.org/10.1016/j.hcc.2024.100211>.
- Young, A. (1998): Growth without Scale Effects. *Journal of Political Economy*, 106(1), 41–63. <https://doi.org/10.1086/250002>.
- Zhang, H. – Wei, Y. – Ma, S. (2021): Overcoming the Solow paradox: Tariff reduction and productivity growth of Chinese ICT firms. *Journal of Asian Economics*, 74, Article 101316. <https://doi.org/10.1016/j.asieco.2021.101316>.