

KORSÓS ZOLTÁN–BARANYAI ESZTER–
FEKETE DALMA ESZTER

A nagy nyelvi modellek potenciális termelékenységi hatásai a magyar gazdaságban

A tanulmány a nagy nyelvi modellek (*Large Language Model, LLMs*) termelékenységre és gazdasági növekedésre gyakorolt potenciális hatását vizsgálja Magyarországon. Az elemzés Acemoglu (2025), valamint Aghion és Bunel (2024) keretrendszerére épül, és a hazai munkaerőpiac munkakörszintű LLM-érintettségének becslését használja fel, álláshirdetési adatok alapján. A számítások szerint az LLM-ek által érintett gazdasági tevékenységek aránya mérsékelt, ami a teljes tényezőtermelékenység (TFP) 0,25–0,81 százalékpontos növekedését eredményezheti a következő évtizedben. Ez éves szinten 0,05–0,15 százalékpontos GDP-növekedésnek felel meg. A becsült hatások elmaradnak az amerikai eredményektől, ami elsősorban a hazai munkaerő alacsonyabb LLM-érintettségével és a munkajövedelmek GDP-ből való kisebb részesedésével magyarázható. Az eredmények rámutatnak az iparági és munkaerőpiaci szerkezet, valamint a jövedelemeloszlás szerepére az MI által elérhető növekedési potenciál alakulásában.*
Journal of Economic Literature (JEL) kódok: O33, E23, J24, O47, O14.

Kulcsszavak: mesterséges intelligencia, nagy nyelvi modellek (LLM-ek), termelékenység, gazdasági növekedés, munkaerőpiaci érintettség.

The potential productivity impact of Large Language Models in Hungary

ZOLTÁN KORSÓS, ESZTER BARANYAI AND DALMA ESZTER FEKETE

This paper examines the potential impact of large language models (LLMs) on productivity and economic growth in Hungary. The analysis builds on the frameworks of Acemoglu (2025) and Aghion and Bunel (2024), using occupation-level estimates

* Köszönettel tartozunk a Metropolitan Egyetemen megrendezett Tudományos Diákköri Konferencia (TDK) bírálóbizottságának a munka korábbi változatához fűzött hasznos észrevételeiért. Korsós Zoltán TDK-kutatását Baranyai Eszter témavezetőként irányította. Továbbá köszönjük az MNB belső fórumain hozzászóló kollégák és az anonim lektorok javaslatait is.

Korsós Zoltán a Budapesti Metropolitan Egyetem mesterszakos hallgatójaként vett részt a kutatásban (e-mail: zoltan@korsos.hu).

Baranyai Eszter a Magyar Nemzeti Bank vezető oktatási és kutatási szakértője (e-mail: baranyaie@mnb.hu).

Fekete Dalma Eszter a Magyar Nemzeti Bank közgazdasági elemzője (e-mail: feketed2@mnb.hu).

A tanulmányra a Creative Commons CC-BY irányelvei érvényesek.

A kézirat első változata 2026. február 12-én érkezett szerkesztőségünkbe.

DOI: <https://doi.org/10.18414/KSZ.2026.5.522>

of LLM exposure derived from job posting data. The results indicate that the share of economic activities affected by LLMs is moderate, implying a 0.25–0.81 percentage point increase in total factor productivity (TFP) over the next decade. This corresponds to an annual GDP growth effect of 0.05–0.15 percentage points. The estimated effects are lower than those for the United States, primarily due to lower labour market exposure and a smaller labor income share. The findings highlight the importance of sectoral structure, labour market composition, and income distribution in shaping the growth potential of AI.

Journal of Economic Literature (JEL) codes: O33, E23, J24, O47, O14.

Keywords: artificial intelligence, large language models (LLMs), productivity, economic growth, labor market exposure.

Bevezetés

A mesterséges intelligencia (MI) tág fogalom, amely olyan technológiákat foglal magában, mint például a gépi tanulás vagy a számítógépes látás. A generatív mesterséges intelligencia evolúciójában központi szerepet játszanak a nagy nyelvi modellek (LLM), különösen a 2022 végétől tapasztalható robbanásszerű növekedésük óta (Peñalvo & Ingelmo, 2023). Az LLM-ek az MI gyorsan fejlődő területét képviselik, amelyek egyre jobban képesek utánozni és megérteni az emberi nyelvi intelligenciát (Zhao et al., 2023). Számos feladatban bizonyították már hasznosságukat, többek között ötletbörzéken, szövegek összegzésében és elemzésében, prezentációs anyagok elkészítésében, szövegformázásban, fordításban és a kódíráshoz való segítségnyújtásban (Korinek, 2024).

Felmerül a kérdés, hogy milyen hatással lesznek ezek a fejlesztések a termelékenységre (Czarnitzki et al., 2023), a gazdasági növekedésre (Brynjolfsson et al., 2019) és az innovációra (Felten et al., 2021), valamint a munkaerőpiacra és a társadalom egészére (Acemoglu et al., 2023).

Jelen tanulmány kifejezetten Magyarországra koncentrál, és részletes magyar álláshirdetéseket elemezve, munkakörszintű LLM-érintettségekből kiindulva vizsgálja azokat a potenciális hatásokat, amelyeket az LLM-ek az ország termelékenységére, GDP-növekedésére, illetve munkaerőpiaci viszonyaira gyakorolhatnak. A tanulmány Acemoglu (2025), valamint Aghion és Bunel (2024) keretrendszerét használja, amelyek elsősorban az Egyesült Államok adataira támaszkodnak. Acemoglu (2025) elemzése az Acemoglu és Restrepo (2018, 2019, 2022) által kidolgozott modelleken alapul, amelyek – számos kutatás eredményeit integrálva – a munkaerőpiac és az MI kapcsolatát tárják fel, különös tekintettel az automatizálás és a termelékenység közötti összefüggésekre.

A gazdasági hatások mértékét és természetét illetően megoszlanak a tudósok és elemzőházak véleményei. A Goldman Sachs (2023) becslése szerint az MI 7 százalékos globális GDP-növekedést eredményezhet tíz év alatt, míg a McKinsey Global Institute (Chui et al., 2023) szerint a generatív MI 17,1 és 25,6 billió dollár közötti mértékben járulhat hozzá a világgazdaság növekedéséhez. Bár ezek az előrejelzések optimista képet festenek, az MI gazdaságba történő integrációját és annak hosszú távú hatásait még mindig jelentős bizonytalanság övezi. Acemoglu (2025) becslései szerint a teljes

tényezőtermelékenység (TFP) LLM-ek használata által elérhető növekedése az Egyesült Államokban a következő tíz évben mindössze 0,55 és 0,66 százalék között alakulhat, míg a GDP-növekedésre gyakorolt hatás felső határa 1,8 százalék körül mozoghat. Az LLM-ek hatása nem minden iparágban és gazdasági szektorban érvényesül egyformán, ami tovább növeli az előrejelzések bizonytalanságát.

Baranyai és szerzőtársai (2024) álláshirdetéseket elemezve becsülték meg az egyes munkakörök LLM-ek által való érintettségét. Az ő eredményeikre építve számítjuk ki a magyar GDP LLM-érintettségét, vagyis a GDP azon részét, amelyet az LLM-ek várhatóan befolyásolhatnak a következő tíz évben. Ehhez Acemoglu (2025) nyomán a foglalkozásszintű LLM-érintettséget az adott foglalkozás bérköltségének arányával súlyozzuk, majd korrigáljuk azzal, hogy a potenciálisan érintett feladatok közül mennyit lehet ténylegesen és profitábilisan LLM-ekkel kiváltani. A következő lépésben a korábbi empirikus vizsgálatokból (például Brynjolfsson et al., 2023; Noy és Zhang, 2023) származó adatok alapján becsüljük meg az LLM-ek által elérhető költségcsökkentéseket. Ezt követően a Hulten-tétel alkalmazásával kiszámítjuk a TFP változását. Végül Acemoglu (2025), valamint Aghion és Bunel (2024) feltételezéseit alkalmazzuk annak meghatározására, hogy a TFP növekedése milyen mértékben ösztönöz új beruházások megvalósítására, és ezek alapján számszerűsítjük a GDP-ben a következő tíz évben várható hatásokat.

A tanulmány fő megállapítása, hogy Magyarországon az LLM-ek gazdasági hatása a közeljövőben várhatóan mérsékelt, különösen az egyes elemzőházak – más országokra vagy a világgazdaságra vonatkozó – becsléseihez viszonyítva. Az Egyesült Államokra készült *tudományos* becslésekhez képest szintén kisebb a hatás, mivel a magyar munkaerő kisebb hányada foglalkozik az LLM-ek által érintett feladatokkal, és a munkajövedelmek GDP-n belüli aránya is alacsonyabb. Ez a két tényező együttesen mérsékli a GDP LLM-ek által generált bővülési potenciálját.

Fontos hangsúlyozni, hogy a keretrendszer a meglévő munkaerőpiaci feladatstruktúrából indul ki, amelyet azonban hosszabb távon új technológiák érdemben átalakíthatnak. A becslések ezért egyrészt inkább rövidebb távon alkalmasak az MI-potenciál felmérésére, másrészt rámutatnak arra, hogy egyes iparágak és a munkaerőpiacok országok közötti szerkezeti különbségei, valamint a tőke és a munka közötti jövedelemeloszlásban mutatkozó eltérések számottevően befolyásolják a termelékenységnövekedési potenciált és ezáltal a versenyképességet is. A tanulmány eredményei összességében azt mutatják, hogy a nemzetközi összehasonlításban mérsékelt eredmények ellenére Magyarország számára is kiemelkedő jelentőségű az MI- és LLM-technológiák elterjedését figyelembe vevő, megfelelő szakpolitikák alkalmazása.

Szakirodalmi áttekintés

A mesterséges intelligencia az adatokban rejlő mintázatok felismerésén és értelmezésén alapuló technológia, amely az elmúlt években gyors fejlődésen ment keresztül. Különösen nagy intenzitással robbant be a generatív MI fogalma a mindennapokba. A generatív (azaz új tartalmakat nem emberi entitások által előállító) MI

egyik legjelentősebb alkalmazási területe a nagy nyelvi modellek (LLM-ek) fejlesztése, amelyek nagyméretű szöveges adatbázisokon végzett mintázatfelismerés révén képesek összetett feladatokat automatizálni és az emberi döntéshozatalt ezáltal támogatni (Eloundou et al., 2023). A legismertebb példák közé tartozik az OpenAI GPT-4o-ja, a Google Geminije és a Meta LLaMA3-as modellje (Korinek, 2024). Sokan egyre inkább általános célú technológiaként (*General Purpose Technology, GPT*) tekintenek az MI-re, amely széles körben alkalmazható, folyamatosan fejlődik, és kiegészítő innovációkat is inspirál, ezáltal további gazdasági lehetőségeket teremtve. Bresnahan és Trajtenberg (1995) a könyvnyomtatás és a mikrochipek megjelenéséhez hasonló forradalmi hatást várnak az MI-től: szerintük ez az új technológia képes lehet gyökeresen átalakítani a termelési folyamatokat és az információfeldolgozást, miáltal új munkakörök és akár új iparágak is létrejöhetnek. Ráadásul e technológia folyamatosan fejlődik, így új megoldások, például fejlett orvosi diagnosztikai rendszerek kialakításának vagy autonóm robotok megépítésének alapját is képezheti (Brynjolfsson et al., 2019).

A mesterséges intelligencia gazdasági hatásmechanizmusai

Az MI mikroökonómiai hatásai a feladatok szintjén bekövetkező költségcsökkenésben (másképpen fogalmazva: termelékenységnövekedésben) érhetők tetten, legyen szó akár automatizálásról, akár feladatok kiegészítéséről. Ezeket a gazdasági következményeket Hulten (1978) tételének egyik verziója írja le: a GDP és a teljes termelékenység növekedése attól függ, hogy a feladatok mekkora részét érinti az MI, és mekkora a feladatonkénti költségcsökkenés mértéke (Acemoglu, 2025). Jóllehet ez az összefüggés egyszerűnek tűnik, alkalmazása korántsem triviális, mivel jelentős bizonytalanság övezi azt, hogy pontosan melyik feladatokat fogja érinteni az MI, valamint milyen költségcsökkenési hatásai lesznek.

A makrogazdasági növekedés értelmezésében fontos szerepet játszik a Baumol-féle „növekedési betegség”, amely szerint a lassú termelékenységnövekedésű szektorok (például az egészségügy vagy az oktatás) hosszú távon növekvő súlya visszafoghatja az aggregált teljesítmény javulását még akkor is, ha más ágazatokban jelentős termelékenységi ugrás következik be (Baumol, 1967). Filippucci és szerzőtársai (2024) rámutatnak, hogy a termelékenység MI által előidézett növekedése elsősorban néhány magas információintenzitású ágazatban koncentrálódik, különösen az információfeldolgozásban, a pénzügyi szolgáltatásokban és az adminisztratív tevékenységekben. Így a GDP növekedésének üteme nemcsak a technológiai potenciáltól, hanem a gazdaság szerkezeti átalakulásától is függ: ha azok az ágazatok, amelyekben a termelékenység javulása hagyományosan lassú (és ahol általában sok munkavállaló koncentrálódik), továbbra is változatlan vagy növekvő arányt képviselnek a gazdaságban, az érdemben mérsékelheti az MI-ben élen járó szektorok termelékenységi potenciáljának makroszintű hatását.

Acemoglu és Restrepo (2018, 2019, 2022) keretrendszere szerint az MI-nek köszönhető termelékenységi nyereségek több csatornán keresztül valósulhatnak meg (1. táblázat). Közvetlen hatás érhető el az *automatizálás* révén, hiszen a mesterséges intelligencia átveheti bizonyos feladatok végrehajtását, és ezáltal csökkentheti a költségeket.

A generatív MI különösen hasznos lehet adminisztratív, szövegösszegző, adatfeldolgozási, mintázatfelismerési és számítógépes feladatok automatizálásában. A *feladatok komplementaritása* révén az MI a kiegészítő részfeladatok elvégzésével növeli a munkavállalók tevékenységének hozzáadott értékét. Ebben a dimenzióban értelmezhető az *innováció felgyorsítása* is: az MI itt közvetlenül a kutatás-fejlesztési munkameneteket támogatja, növelve a kutatói munka hatékonyságát. Ezekon túlmenően az MI *új feladatok* létrejöttét is ösztönözheti, amelyek hatással lehetnek az egész termelési folyamat hatékonyságára. Az új technológiai lehetőségek révén a vállalatok *új munkaköröket* alakíthatnak ki, amelyek az MI alkalmazásával még tovább növelhetik a termelékenységet.

1. táblázat

Az MI közvetett és közvetlen gazdasági hatásai

Közvetlen hatás	Közvetett hatás
– automatizálás (kiváltás)	– tudáshoz való hozzáférés költségeinek csökkentése
– feladatok komplementaritása	
– innováció felgyorsítása (K + F)	– gazdasági növekedés (GDP-hatás)
– új feladatok létrehozása	– új üzleti modellek megjelenése

Forrás: saját szerkesztés.

A mesterséges intelligencia közvetett, nem egy-egy feladat kiváltásához kapcsolódó gazdasági hatásait a szakirodalom egyre hangsúlyosabban tárgyalja (Filippucci et al., 2024). Az egyik legfontosabb közvetett hatás a *tudáshoz való hozzáférés költségének csökkentése*. Az LLM-ek és más generatív MI-eszközök lehetővé teszik a vállalatok és egyének számára, hogy olcsóbban és gyorsabban jussanak hozzá komplex információkhoz, elemzésekhez, jogi vagy technikai dokumentációkhoz, ami korábban jelentős erőforrásokat igényelt. Ez a „tudáshoz való demokratizált hozzáférés” különösen a kis- és középvállalkozások számára nyithat új lehetőségeket, amelyek korábban korlátozottan tudtak élni a magas szintű szakértelmet igénylő megoldásokkal. Filippucci és szerzőtársai hangsúlyozzák, hogy az MI által támogatott gyorsabb termékfejlesztési ciklusok hozzájárulhatnak a *gazdasági növekedéshez*, új termékek, szolgáltatások és *üzleti modellek létrejöttéhez*, amelyek hosszabb távon a TFP-t is növelhetik. Továbbá az MI az *on-demand* szolgáltatások (generatív tartalomgyártás, automatikus ügyfél-szolgálat) elterjedését, valamint az adatalapú platformok gyorsabb kiépülését is lehetővé teszi. Ezek nemcsak a hagyományos iparágakat alakíthatják át, hanem új piaci réseket is létrehozhatnak, amelyek hozzájárulhatnak a GDP növekedéséhez, a vállalati termelékenységnövekedéséhez és az exportkapacitások bővüléséhez is.

A termelékenységnövekedés korlátai

Acemoglu és Restrepo (2022) szerint a termelékenység LLM-ek által generált növekedése elsődlegesen a könnyen automatizálható feladatok átvételéből származik, ahol az LLM-ek gyorsan képesek elsajátítani és alkalmazni a szükséges döntéshozatali

mechanizmusokat. A jelenlegi becslések többsége azonban nem veszi kellően figyelembe a nehezen automatizálható feladatokat, ahol a döntések erősen kontextusfüggők, és nagy szerepet játszanak az emberi tapasztalatok, valamint a szociális interakciók. Ezekben az esetekben az LLM-ek termelékenységi hatása várhatóan mérsékeltebb lesz, bár ennek a pontos mértéke nehezen meghatározható. Acemoglu (2025) az elemzésében Eloundou és szerzőtársai (2023) alapvetésére támaszkodik, akik szerint az amerikai munkaerőpiac 19,9 százalékát érinti a mesterséges intelligencia. Acemoglu rámutat, hogy rövid távon az ebben a szegmensben elvégzendő feladatok 74 százaléka tartozik a könnyen automatizálható kategóriába. Ha a nehezen automatizálható feladatok esetében a termelékenység növekedése csupán negyede a könnyen automatizálható feladatok kiváltásával elérhetőnek, akkor a TFP növekedése 0,66 százalék helyett legfeljebb 0,55 százalékra, a GDP-növekedés felső határa pedig 1,17 százalék helyett 0,91 százalékra mérséklődik a következő évtizedben (lásd a 2. táblázat 1. sorát).

Bár az LLM-technológia hozzájárulhat a termelékenység növekedéséhez, az automatizálási lehetőségek önmagukban nem garantálják a vállalati beruházások jelentős bővülését. Acemoglu (2025) szerint az LLM-ek termelékenységi hatásainak egyik kulcskérdése az, hogy a vállalatok hajlandóak-e tőkét investálni az LLM-alapú rendszerek kiépítésébe és fenntartásába. Egyes iparágakban, például a pénzügyi szektorban vagy az online szolgáltatások területén, az LLM-ek alkalmazása alacsony beruházási költséggel járhat, mivel a generatív modellek és automatizált rendszerek gyorsan integrálhatók az üzleti folyamatokba. Ezzel szemben a hagyományos iparágakban, mint amilyen a gyártás vagy a logisztika, az MI alkalmazása jelentős infrastruktúrális beruházásokat és új tőkebefektetéseket igényelhet, ami lassíthatja az elterjedés ütemét. Emellett a vállalatok MI-alapú befektetései nem feltétlenül járnak automatikusan jelentős GDP-növekedéssel. Acemoglu és Restrepo (2022) modellje szerint a gazdasági növekedés mértéke attól is függ, hogy az MI hogyan változtatja meg a tőke és a munka arányát a termelésben. Ha az MI terjedése főként a meglévő tőke hatékonyságának növelésére korlátozódik, és nem ösztönöz jelentős új beruházásokra, akkor a gazdasági növekedés üteme mérsékeltebb lehet a várakozásoknál.

Az OECD egyik friss tanulmánya kiemeli, hogy a diffúzió sebessége alapvetően meghatározza a makrogazdasági termelékenység növekedésének elérhető mértékét. A technológiai adaptáció gyorsabb a nagyobb, tőkeerős multinacionális vállalatok körében, míg a kkv-k sokszor lassabban tudják bevezetni az MI-alapú megoldásokat, részben a beruházási költségek, részben a gyengébb technológiaabszorpciók képességeik miatt. Magyarország esetében ez a különbség hatványozottan jelentkezik: a hazai kkv-szektor hatékonysága és technológiai érettsége jelentősen elmarad a fejlett gazdaságok kisvállalataitól. A lassú diffúzió jelentősen korlátozza az MI által kínált növekedési potenciál kihasználását. Ezért a szakpolitikának nemcsak az MI-vel kapcsolatos innovációkat, hanem a technológia széles körű elterjedését is ösztönöznie kell, például a digitális infrastruktúra fejlesztésével, a kkv-k támogatásával és munkaerő-átképzési programokkal (Filippucci et al., 2024). Egy másik fontos tényező a szabályozási környezet alakulása, amely jelentősen befolyásolhatja az MI terjedését. Az adatvédelmi előírások, például a GDPR és más – nemzeti szintű – jogszabályok korlátozhatják az MI-alapú rendszerek működését, különösen azokban az esetekben, ahol nagy

mennyiségű személyes adat feldolgozása szükséges. Az MI társadalmi elfogadottsága szintén kulcsszerepet játszhat a technológia széles körű elterjedésében (Gerlich, 2023). A munkahelyek automatizálásával és az etikai kérdésekkel kapcsolatos aggodalmak globálisan is egyre intenzívebb szabályozási és politikai vitákat váltanak ki, amelyek befolyásolhatják az MI alkalmazásának ütemét és kiterjedtségét.

A magyar gazdaság szempontjából ezek a tényezők különösen nagy jelentőséggel bírnak. Egyrészt a magyar munkaerőpiacon a gyengébb digitális készségekkel rendelkező munkavállalók aránya még mindig magasabb, mint az EU átlagában (European Commission, 2022), ami korlátozhatja az MI-technológiák gyors elterjedését. Másrészt az adatvédelmi és etikai szabályozások kialakítása során Magyarországon is ügyelni kell arra, hogy azok ne akadályozzák indokolatlan mértékben az innovációt, ugyanakkor megfelelő védelmet nyújtsanak a fogyasztóknak és a munkavállalóknak.

Szakirodalmi becslések a mesterséges intelligencia gazdasági növekedésre gyakorolt hatásáról

Az MI gazdasági hatásainak vizsgálata egyre nagyobb hangsúlyt kap a közgazdaságtanban, ugyanakkor az eddigi eredmények erősen eltérnek aszerint, hogy milyen módszertannal és időtávra készültek a becslések. Filippucci és szerzőtársai (2024) átfogó tanulmányukban kiemelik, hogy az MI-nek köszönhető potenciális gazdasági növekedésre vonatkozó előrejelzések eredményei nagyban függenek az alkalmazott megközelítéstől, illetve az alapfeltevések típusától. A legfontosabb eddigi eredményeket a 2. táblázat foglalja össze.

2. táblázat

Az eddigi szakirodalmi eredmények összefoglalása

Szerző	A vizsgálat tárgya	Eredmény
Acemoglu (2024), felhasználva Acemoglu és Restrepo (2022) modelljét	az MI hatása az Egyesült Államok GDP-jére (10 év)	1,6–1,8%
Acemoglu (2025)	az LLM hatása az Egyesült Államok GDP-jére (10 év)	0,91–1,17%
Aghion és Bunel (2024)	az LLM hatása az Egyesült Államok Amerika GDP-jére (10 év)	12%
Goldman Sachs (2023)	az MI hatása a globális GDP-re (10 év)	7%
McKinsey (Chui et al., 2023)	a generatív MI hatása a globális GDP-re	17,1–25,6 billió dollár

Forrás: saját szerkesztés.

Az egyik megközelítést – amelyet többek között Acemoglu (2025) képvisel – a feladatszintű mikroalapú tudományos modellek jellemzik. Ezek a modellek az LLM-ek gazdasági hatásait elsősorban a már meglévő feladatok automatizálására fókuszálva becsülik meg. A feladatszintű megközelítések részletesen elemzik, hogy az LLM-ek

mely konkrét tevékenységeket képesek átvenni, és milyen mértékű költségcsökkenést lehet ennek révén elérni. Az ilyen típusú becslések alapvetően konzervatívabbak, mivel: 1. nem feltételeznek azonnali, nagy léptékű munkaerőpiaci alkalmazkodást, 2. kizárják a műszaki fejlődés által életre hívott új feladatok, iparágak és üzleti modellek hatását, 3. figyelembe veszik a technológia jelenlegi korlátait, valamint 4. óvatosan becsülik meg a tőkeállomány bővülésének ütemét. Acemoglu például szigorúan a meglévő feladatstruktúrák elemzéséből indul ki, és számításai során korlátozott tőkebővüléssel és lassú technológiai diffúzióval számol. Modelljében nem szerepelnek azok a tovagyrúzó hatások, amelyek hosszabb távon új piacok, innovációk és termelékenységi ugrások formájában jelentkezhetnek.

Ezzel szemben a nemzetközi tanácsadó cégek – gyakran egyszerűsített automatizálhatósági feltételezésekre vagy kevésbé részletes adatokra támaszkodva – jelentősen optimistább előrejelzéseket fogalmaznak meg. A Goldman Sachs (2023) becslése szerint a mesterséges intelligencia elterjedése akár 7 százalékkal is növelheti a globális GDP-t, míg a McKinsey Global Institute 17,1 és 25,6 billió dollár közötti globális gazdasági hozzájárulást valószínűsít a generatív MI széles körű alkalmazásának köszönhetően (Chui et al., 2023).

A következőkben részletesebben bemutatjuk azt a két kutatást, amelyre az elemzésünk alapvetően támaszkodik.

Acemoglu (2025) modellje szerint a munkaerőköltségek átlagosan 27 százalékkal csökkenhetnek, amit a Noy és Zhang (2023), valamint Brynjolfsson és szerzőtársai (2023) tanulmányaiban közölt eredmények átlagolásával állapított meg. Az iparági munkaerőarányokat figyelembe véve ez 14,4 százalékos átlagos összköltség-megtakarítást eredményezhet. Ezen számítások alapján Acemoglu arra jut, hogy a következő évtizedben a TFP várható hatása legfeljebb 0,66 százalékos lehet, ami körülbelül évi 0,064 százalékos növekedést jelent.

A növekedési hatások becsléséhez Acemoglu (2025) azt is figyelembe veszi, hogy az LLM-ek mekkora tőkebővülést eredményezhetnek. Ha a tőkeállomány a TFP növekedésével arányosan emelkedik, akkor a GDP növekedése 0,91 és 1,17 százalék közé tehető a következő évtizedben. Ha viszont a modellbe beépítjük a munkaerő szektorok közötti reallokációját, valamint a tőkeállomány növekedését és a tőke GDP-n belüli részarányának növekedését – amint az Acemoglu és Restrepo (2022) modelljében szerepel –, akkor a felső becslési határ (a nehéz és könnyű feladatok megkülönböztetésével) akár 1,6 százalékra vagy (a feladatok megkülönböztetése nélkül) 1,8 százalékra is emelkedhet (Acemoglu, 2025). A technológia hatása nem egyformán terjed ki minden ágazatra és országra; a foglalkozási struktúra, a bérköltségek súlya, a tőkeintenzitás és az automatizálás megtérülése is befolyásolja a hatás mértékét (Acemoglu & Restrepo, 2018, 2019, 2022; Svanberg et al., 2024).

Aghion és Bunel (2024) elemzése a feladatok helyett a képességekre¹ lebontva becsüli az egyes munkakörök LLM-érintettségét. A munkakörökhöz szükséges képességeket az amerikai Occupational Information Network (O*NET) adatbázisából nyerik. Az egyes képességek LLM-érintettsége pedig felmérésekből származik. A képességalapú

¹ A képességek közé tartozik például a szelektív figyelem, az ötletgazdagság vagy az írott szöveg megértése.

módszertan is a feladatalapúhoz hasonló logikára épül, vagyis meghatározza a GDP LLM-ek által érintett részét, és a munkaerőköltség csökkenésével számol. A képesség-alapú becslések jellemzően magasabb szintű LLM-érintettséget mutatnak, mint a feladatalapúak. Ezen túlmenően Aghion és Bunel (2024) Acemogluhoz képest optimistább feltételezésekkel élnek a költségcsökkenés és a technológia nyereséges alkalmazhatósága vonatkozásában. E megközelítés alapján tíz év alatt akár 12 százalékos GDP-növekedést is lehetségesnek tartanak. A szerzők ugyanakkor kiemelik, hogy a növekedési előnyök elérése nagymértékben függ a piaci struktúrától és a szabályozási környezettől.

Összességében megállapítható, hogy az eltérések egyik fő oka a módszertanban rejlik: a mikroszintű, feladatalapú modellek (mint Acemoglu, 2025) visszafogottabb produktivásnövekedést jeleznek előre, míg a kevésbé részletes vagy képesség-alapú modellek szélesebb körű és jelentősebb gazdasági hatással számolnak. A konzervatív és az optimista megközelítések különbségeit tovább árnyalják azok az újabb szakirodalmi foratókönyvek, amelyek az MI és a robottechnológiák szorosabb integrációjára építenek, és ezzel további növekedési lehetőségeket feltételeznek (például Svanberg, 2024).

Az MI munkaerőpiaci hatásai

A munkaerőpiaci hatásokról szintén megoszlanak a vélemények: míg Frey és Osborne (2017) vagy Duckworth és szerzőtársai (2019) a technológia által fenyegetett munkahelyek leépülését hangsúlyozzák, addig Brynjolfsson és szerzőtársai (2019, 2023), Noy és Zhang (2023) vagy Peng és szerzőtársai (2023) az MI munkavállalókat segítő, termelékenység-növelő hatásait emelik ki. Az LLM-ek térnyerése önálló kutatási területté vált, mivel ezek a modellek nem csupán automatizálják, hanem ki is egészítik az emberi munkát, különösen a szövegfeldolgozást igénylő feladatokban (Ghose, 2023). A korábbi automatizálási hullámok tapasztalatai alapján egyes tanulmányok arra figyelmeztetnek, hogy az MI előnyeit elsősorban a vállalati döntéshozók és a technológiai szektor szereplői élvezhetik, míg a munkavállalók jelentős részének romolhat a jövedelmi helyzete (Acemoglu & Restrepo, 2020). Más kutatások ezzel szemben arra mutatnak rá, hogy az MI növelheti a kevésbé képzett munkavállalók termelékenységét, és elősegítheti a kiegyenlített bérdinamikát (Brynjolfsson et al., 2023; Noy & Zhang, 2023; Peng et al., 2023). Emellett az MI új foglalkozások megjelenését is támogatja: az MI-alapú szolgáltatások, az adatalapú gazdaság és az új technológiai alkalmazások olyan új munkaköröket és iparágakat hozhatnak létre, amelyek számszakilag részben ellensúlyozhatják más állások megszűnését. A szakirodalom szerint a jövő munkahelyei egyre inkább olyan kompetenciákra épülhetnek, mint a digitális írástudás, az adatelemzés, az MI-rendszerek kezelése vagy az etikai szabályozás (Brynjolfsson et al., 2023; Filippucci et al., 2024).

Jelen tanulmány szorosan kapcsolódik Baranyai és szerzőtársai (2024) kutatásához, amely az LLM-ek magyar munkaerőpiaci hatásait vizsgálta álláshirdetési adatok alapján, és amelynek empirikus eredményei kiindulópontként szolgálnak számunkra. Az eredmények alapján Magyarországon az LLM-ek által érintett munkafeladatok aránya mintegy 10 százalék, ami elmarad az Egyesült Államokban mért 15 százaléktól (Eloundou et al., 2023).

Különösen fontos Magyarország esetében figyelembe venni a lokális munkaerőpiaci struktúrák, jövedelemarányok és technológiai adaptációs képességek sajátosságait. Tanulmányunk hozzájárulása a gazdasági hatásokról szóló szakirodalomhoz elsősorban abban rejlik, hogy a vizsgált folyamatokat egy sajátos gazdasági szerkezettel rendelkező országban elemzi, ahol az MI elterjedésének feltételei és következményei érdemben eltérhetnek a technológiai éllovas országok esetében megfigyelt mintázatoktól.

Adatok

Az LLM-érintettség számításához a Baranyai és szerzőtársai (2024) tanulmányában meghatározott LLM-érintettségi arányokat használjuk, amelyeket magyar álláshirdetések alapján számítottak ki: a *profession.hu* álláshirdetéseiből kinyert munkafeladatokat az O*NET Detailed Work Activities (DWA) kategóriáival illesztették össze, majd Eloundou és szerzőtársai (2023) LLM-érintettségi eredményeit reprodukálták LLM-ek segítségével az O*NET-ben szereplő több mint 20 000 feladat szintjén. Baranyai és szerzőtársai ezt követően az LLM-érintettségeket először DWA-szinten, majd munkakörök szintjén aggregálták. Eloundou és szerzőtársai (2024) definíciójával összhangban az egyes feladatokat akkor tekintették az LLM által érintettnek, ha a nagy nyelvi modellek várhatóan legalább 50 százalékkal csökkenteni tudják az adott feladat elvégzéséhez szükséges időt anélkül, hogy a munka minősége romlana.

A foglalkozások kategorizálásában és elnevezésében szintén Baranyai és szerzőtársai (2024) tanulmányát követtük. A foglalkozások FEOR-kódok szerinti besorolása a magyar munkaerőpiaci osztályozásnak megfelelően történt. Mivel Baranyai és szerzőtársai az O*NET adataiból indultak ki, az amerikai foglalkozáskategóriák magyar FEOR-kódokhoz való hozzárendelése két számjegyű FEOR-kód pontosságot tesz lehetővé. Jelen tanulmány elemzése is ezen a szinten történik. A 3. táblázat – a tanulmány részeredményein túl – többek között az egyes foglalkozáskategóriák LLM-érintettségét is feltünteti.

A GDP-n belüli munkaerőarányos érintettség becslésére, valamint a foglalkozási súlyok számításához a bérköltségadatokat – vagyis a foglalkozási csoportonkénti létszám és átlagbér szorzatát – használjuk, amelyek a KSH munkaerőpiaci statisztikáiból származnak. A részletes létszámadatokat a KSH-tól adatigénylés alapján kaptuk meg,² az átlagbérek adatai pedig nyilvánosak (Központi Statisztikai Hivatal, 2024b).

A termelékenységre és GDP-re vonatkozó becsléseink emellett három fő tényezőt vesznek figyelembe: 1. a profitábilisan automatizálható feladatok arányát, 2. a munkaerőköltség-megtakarítás arányát, valamint 3. a tőke GDP-ből való részesedését.

A profitábilisan automatizálható feladatok arányának számszerűsítéséhez az első módszertannál Svanberg és szerzőtársai (2024) becsléseire támaszkodunk, amelyek szerint az MI képességeinek fejlődésével ez az érték 23 százalék. Fontos azonban hangsúlyozni, hogy ez az arány kizárólag a gépi látás által érintett feladatokra

² Kevésbé részletes szinten, foglalkozási főcsoportok szerint elérhető a KSH honlapján is: Központi Statisztikai Hivatal (2024a).

vonatkozik, nem pedig az LLM-ek teljes spektrumára. A második – kevert – módszertan esetében, ami Acemoglu (2025), illetve Aghion és Bunel (2024) számításait ötvözi, 50 százalékos aránnyal számolunk. Ez az MI által elérhető automatizálás gazdasági realitását tükröző mutató, amely azt jelzi, hogy a LLM-ek által érintett feladatok mekkora része automatizálható költséghatékonyan.

Acemoglu (2025) a modelljében használt 27 százalékos munkaerőköltség-megtakarítást két empirikus tanulmány alapján határozta meg. Noy és Zhang (2023) szerint a ChatGPT-3.5-öt használó dolgozók 40 százalékkal gyorsabban és 18 százalékkal jobb minőségben végezték el a feladataikat. Brynjolfsson és szerzőtársai (2023) kutatásaiban pedig egy ügyfélszolgálati MI-alkalmazás 14 százalékos időmegtakarítást eredményezett. A munkaerőköltség-megtakarítást Acemoglu (2025) alapján az első módszertanban 27 százaléknak tekintjük, míg a második, kevert módszertan esetén az optimistább, 40 százalékos aránnyal számolunk (Aghion & Bunel, 2024).

Mind a költségmegtakarítási arány, mind a GDP-növekedés becslésénél figyelembe vesszük a GDP munka- és tőkejövedelemre való megoszlásának arányát. A magyar gazdaságban a munkajövedelem részesedése 48,2 százalék (Our World in Data, 2020), a tőke részesedése pedig értelemszerűen³ 51,8 százalék.

Módszertan

Az MI által érintett munkaerőpiaci és gazdasági változásokat három fő lépésben számszerűsítjük. Az első lépésben az LLM-érintettség és a foglalkozási kategóriák bérköltségének súlyozott összesítésével meghatározzuk a GDP LLM-érintettségét. A második lépésben kiszámítjuk a TFP várható növekedését, amely az LLM által érintett GDP-részesedés és az MI használata által lehetővé tett költségmegtakarítások összekapcsolásával történik. A harmadik lépésben az LLM gazdasági hatásait elemezzük, ennek során a termelékenységnövekedésből származó lehetséges GDP-növekedést vizsgáljuk a következő tíz évre kivetítve. Ez a módszertan szorosan követi Acemoglu (2025), valamint Aghion és Bunel (2024) keretrendszerét.

Fontos ugyanakkor megemlíteni, hogy az amerikai gazdaságra alapozott becslések adaptációja során felmerülhetnek olyan strukturális eltérések, amelyek befolyásolhatják a technológiai hatásmechanizmusok érvényesülését. Cerutti és szerzőtársai (2025) rávilágítanak arra, hogy míg Amerikában a szolgáltató szektor digitális intenzitása nagyfokú, addig Magyarországon a gazdasági szerkezet sajátosságai és a hazai kkv-szektor hatékonysági jellemzői fékezhetik a várható produktivitási hatást. Az IMF elemzése szerint a mesterséges intelligencia előnyeinek kiaknázása szorosan összefügg az országspecifikus digitális ökoszisztémával (Cazzaniga et al., 2024). Hazai vonatkozásban a digitális gazdaság és társadalom mutatói alapján az látható, hogy bár a konnektivitás terén Magyarország jól teljesít, a vállalati digitalizáció és a lakossági digitális készségek elmaradása gátat szabhat az LLM-alapú megoldások

³ Magyarországon a magánszektor tőkejövedelemből való részesedésére vonatkozó közvetlen adat nem érhető el.

elterjedésének (European Commission, 2022). Ennek megfelelően a magyarországi hatások becslésekor érdemes figyelembe venni, hogy a digitalizációs különbségek miatt az elméleti hatékonyságjavulás milyen ütemben és mértékben tud majd ténylegesen megvalósulni a gyakorlatban.

A nagy nyelvi modellek által való érintettség becslése és súlyozása

A Baranyai és szerzőtársai (2024) által kidolgozott LLM-érintettségi index az automatizálás és a feladatkiegészítés együttes figyelembevételével méri az LLM-ek munkaerőpiaci hatását Magyarországon.

Az LLM-érintettség mértékének becslése során az egyes foglalkozási csoportokhoz tartozó, bérköltséggel súlyozott LLM-érintettséget számítjuk ki az alábbi képlet alapján:

$$\text{Bérköltséggel súlyozott LLM-érintettség} = \frac{\sum_{i=1}^n \text{Bérkötség}_i \times \text{LLM-érintettség}}{\sum_{i=1}^n \text{Bérkötség}_i}, \quad (1)$$

ahol:

- LLM-érintettség: az adott foglalkozási csoport mesterséges intelligenciával szembeni kitettsége,
- Bérkötség: átlagos bér_i × foglalkoztatottak száma; az adott foglalkozási csoport bérköltsége,
- *n*: a foglalkozási kategóriák száma.

Az LLM-érintettség GDP-arányának meghatározása

A GDP-n belüli LLM-érintettség meghatározása az alábbi képlet szerint történik:

$$\text{GDP-arányos LLM-érintettség} = \text{Bérköltséggel súlyozott LLM-érintettség} \times \text{Profitábilisan automatizálható feladatok aránya}, \quad (2)$$

ahol:

- Bérköltséggel súlyozott LLM-érintettség: az (1) képlet eredménye, amely az adott foglalkozási csoport LLM-kel szembeni kitettségének bérköltséggel súlyozott átlaga.
- Profitábilisan automatizálható feladatok aránya: azon mesterséges intelligenciával érintett feladatok aránya, amelyek nyereségesen automatizálhatók a következő években. Az első módszertanban ez 23 százalék Svanberg és szerzőtársai (2024) alapján, ami kifejezetten a gépi látás által kiváltott feladatokra vonatkozik, a kevert módszertanban pedig 50 százalék Acemoglu (2025), valamint Aghion és Bunel (2024) alapján.

Az LLM-érintettség GDP-arányos értéke azt mutatja meg, hogy az LLM-ek által érintett és potenciálisan automatizálható munkafolyamatok milyen arányban járulnak hozzá a teljes GDP-hez, figyelembe véve az egyes foglalkozások bérköltségét,

MI-érintettségét és az automatizálás megvalósíthatóságát. Ezt a mutatót a TFP-növekedés kiszámításához használjuk, amely meghatározza az LLM hatását a magyar gazdaságra a következő évtizedben.

A teljes tényezőtermelékenység kiszámítása

A TFP növekedését a következő képlettel határozzuk meg:

$$\text{TFP-növekedés} = \text{GDP-arányos LLM-érintettség} \times \text{Költségmegtakarítási ráta}, \quad (3)$$

ahol:

- GDP-arányos LLM-érintettség: a (2) képlet eredménye, amely az LLM-ek által érintett munkafolyamatok bérköltséggel súlyozott arányát mutatja a teljes GDP-n belül.
- Költségmegtakarítási ráta: az LLM alkalmazásával elérhető munkaerőköltségmegtakarítás, amely a munkaerő-részesedéshez igazított érték.

Mivel nem áll rendelkezésre magyarországi adat az LLM-hatásokkal korrigált munkajövedelem részesedésének részletes számításához, a becsléshez arányosított közelítést alkalmazunk. Az Egyesült Államokban a munkajövedelmek GDP-n belüli részesedése megközelítőleg 60 százalék, az LLM-érintettséggel korrigált változatot pedig Acemoglu (2025) tanulmánya 53,5 százalékra becsüli. Magyarországon a munkajövedelem részesedése 48,2 százalék. Ezeket az adatokat felhasználva a becslésünk:

$$\text{Korrigált bérhányad}_{HU} = \frac{\text{Bérhányad}_{HU}}{\text{Bérhányad}_{USA}} \times \text{Korrigált bérhányad}_{USA}, \quad (4)$$

ahol:

- Bérhányad_{HU}: a munkajövedelem GDP-hez viszonyított aránya Magyarországon.
- Bérhányad_{USA}: a munkajövedelem GDP-hez viszonyított aránya az Egyesült Államokban.
- Korrigált bérhányad_{USA}: az LLM-érintettséggel korrigált munkajövedelem GDP-hez viszonyított aránya az Egyesült Államokban.

A költségmegtakarítási ráta Magyarországra az alábbi képlet alapján számítható:

$$\text{Költségmegtakarítási ráta} = \text{Munkaerőköltség-megtakarítás} \times \text{Korrigált bérhányad}_{HU}, \quad (5)$$

ahol:

- Munkaerőköltség-megtakarítás: az LLM alkalmazásával elérhető átlagos munkaerőköltség-megtakarítás.
- Korrigált bérhányad_{HU}: az LLM-érintettséggel korrigált munkajövedelem GDP-hez viszonyított aránya Magyarországon, a (4) képlet alapján.

A számítás tehát országspecifikusan igazodik a magyar munkaerőpiaci viszonyokhoz, amennyire azt az elérhető adatok lehetővé teszik.

A GDP következő tíz évben várható növekedésének becslése

A TFP növekedésének a GDP-re gyakorolt hatását az Acemoglu (2025) által használt képlet alapján számszerűsítjük:

$$\text{GDP-növekedés a következő tíz évben} = \frac{\Delta TFP}{1 - \text{Tőkerészesedés}}, \tag{6}$$

ahol:

- ΔTFP : a teljes tényezőtermelékenység növekedése, amelyet a korábbi számítások alapján határozunk meg.
- Tőkerészesedés: értéke Magyarországon a rendelkezésre álló statisztikák szerint 48,2 százalék.

Eredmények

Az MI által érintett feladatok GDP-részesedését a magyar munkaerőpiaci struktúrához igazított módszertan szerint számítottuk, amely figyelembe veszi az álláshirdetéseken megjelenő feladatok szerkezetét és az LLM-technológiák alkalmazhatóságát. A GDP-n belüli LLM-érintettség becslése mögötti számításokat a 3. táblázat mutatja be.

3. táblázat

Egyes foglalkozási kategóriák keresettömege és LLM-érintettsége

Foglalkozási kategória	Keresettömeg (millió Ft/hó)	LLM- érintettség (százalék)	Kereset- tömeg-arány (százalék)
Fegyveres szervek felsőfokú képzést igénylő foglalkozásai	11 053	20	1
Fegyveres szervek középfokú képzést igénylő foglalkozásai	8 166	16	0
Fegyveres szervek középfokú képzést nem igénylő foglalkozásai	4 052	16	0
Törvényhozók, igazgatási és érdekképviselői vezetők	17 619	0	1
Gazdasági, költségvetési szervezetek vezetői	35 745	11	2
Termelési és szolgáltatást nyújtó egységek vezetői	114 639	10	6
Gazdasági tevékenységet segítő egységek vezetői	48 807	13	3
Műszaki, informatikai és természettudományi foglalkozások	154 231	13	8
Egészségügyi foglalkozások (felsőfokú képzettséghez kapcsolódó)	72 315	10	4
Szociális szolgáltatási foglalkozások	3 828	16	0
Oktatók, pedagógusok	80 336	6	4
Gazdálkodási jellegű foglalkozások	61 620	16	3
Jogi és társadalomtudományi foglalkozások	24 077	16	1

A 3. táblázat folytatása

Foglalkozási kategória	Keresettömeg (millió Ft/hó)	LLM- érintettség (százalék)	Kereset- tömeg-arány (százalék)
Kulturális, sport-, művészeti és vallási foglalkozások (felsőfokú képzettséghez kapcsolódó)	16 022	22	1
Egyéb magasan képzett ügyintézők	68 028	11	4
Technikusok és hasonló műszaki foglalkozások	85 178	10	5
Szakmai irányítók, felügyelők	15 689	6	1
Egészségügyi foglalkozások	51 413	11	3
Oktatási asszisztensek	4 909	3	0
Szociális gondozási és munkaerőpiaci szolgáltatási foglalkozások	16 039	27	1
Üzleti jellegű szolgáltatások ügyintézői, hatósági ügyintézők	118 749	15	6
Művészeti, kulturális, sport- és vallási foglalkozások	8 912	12	0
Egyéb ügyintézők	35 475	12	2
Irodai, ügyviteli foglalkozások	98 367	13	5
Ügyfélkapcsolati foglalkozások	22 603	15	1
Kereskedelmi és vendéglátóipari foglalkozások	86 946	6	5
Szolgáltatási foglalkozások	77 562	6	4
Mezőgazdasági foglalkozások	6 279	6	0
Erdőgazdálkodási, vadgazdálkodási és halászati foglalkozások	1 158	20	0
Élelmiszeripari foglalkozások	6 004	3	0
Könnyűipari foglalkozások	10 011	4	1
Fém- és villamosipari foglalkozások	77 689	5	4
Kézműipari foglalkozások	1 706	5	0
Építőipari foglalkozások	32 794	3	2
Egyéb ipari és építőipari foglalkozások	6 575	4	0
Feldolgozóipari gépek kezelői	43 723	4	2
Összeszerelők	38 076	3	2
Helyhez kötött gépek kezelői	13 685	5	1
Járművezetők és mobil gépek kezelői	81 284	5	4
Takarítók és hasonló jellegű egyszerű foglalkozások	31 472	4	2
Egyszerű szolgáltatási, szállítási és hasonló foglalkozások	76 637	5	4
Egyszerű ipari, építőipari, mezőgazdasági foglalkozások	68 947	3	4

Megjegyzés: a keresettömegeket a havi bruttó átlagbérek felhasználásával számítottuk ki azon – négy számjegyű FEOR-szintű – foglalkozások esetében, amelyekre a KSH létszám- adatot szolgáltatott.

Forrás: saját szerkesztés a Központi Statisztikai Hivatal (2024a) adatai alapján.

A foglalkozási kategóriák szerinti LLM-érintettségi és keresettömeg-arányokból 9 százalékot kaptunk a bérköltséggel súlyozott LLM-érintettségre.

Az általunk használt két keretrendszer közötti fő különbség az, hogy Acemoglu (2025) feladatalapú megközelítéssel számítja ki az egyes foglalkozások LLM-érintettségét, Aghion és Bunel (2024) viszont képességalapú megközelítést alkalmaz. Mivel a képességalapú módszertannal számított LLM-érintettségek nem álltak rendelkezésünkre, egy harmadik, a kettőt kombináló módszertant alkalmaztunk az LLM termelékenységnövelő hatásának számszerűsítésére: a profitábilisan automatizálható feladatok arányát 50, a munkaerőköltség megtakarítását pedig 40 százaléknak vettük. Az így kapott eredményeket a 4. táblázat foglalja össze.

4. táblázat

Az eredményeink összevetése az eddigi becslésekkel (százalék)

	Acemoglu (2025) alapján feladatalapú módszertan		Aghion és Bunel (2024) alapján képességalapú módszertan	Acemoglu (2025) és Aghion és Bunel (2024) alapján kevert módszertan	
	Egyesült Államok	Magyar- ország*	Egyesült Államok	Egyesült Államok*	Magyar- ország*
Bérköltséggel súlyozott LLM-érintettség	19,90	9,40	60,00	19,90	9,40
Profitábilisan automatizálható feladatok aránya	23,00	23,00	50,00	50,00	50,00
<i>A GDP LLM által érintett része</i>	<i>4,58</i>	<i>2,16</i>	<i>30,00</i>	<i>9,95</i>	<i>4,70</i>
Munkaerőköltség-megtakarítás	27,00	27,00	40,00	40,00	40,00
(Kiigazított) munkaerőpiaci részesedés	53,50	42,82	57,00	53,50	42,82
<i>Költségmegtakarítási ráta</i>	<i>14,45</i>	<i>11,56</i>	<i>22,80</i>	<i>21,40</i>	<i>17,13</i>
A TFP tízéves növekedése	0,66	0,25	6,84	2,13	0,81
Tőkerészesedés	43,00	48,20	43,00	48,20	48,20
A GDP tízéves növekedése	1,16	0,48	12,00	4,11	1,55
<i>Éves GDP-növekedés</i>	<i>0,12</i>	<i>0,05</i>	<i>1,14</i>	<i>0,40</i>	<i>0,15</i>
A TFP éves növekedése	0,07	0,02	0,66	0,21	0,08

* Saját számítás.

Forrás: saját szerkesztés Acemoglu (2025), valamint Aghion és Bunel (2024), továbbá saját számítás alapján.

A GDP LLM által érintett része mutató az LLM által érintett foglalkozások bérköltségének GDP-n belüli súlyát jelzi, figyelembe véve a profitábilisan automatizálható feladatok arányát is. Magyarországon az LLM-ek által érintett és potenciálisan automatizálható munkafolyamatok Acemoglu (2025) megközelítése alapján a GDP mintegy 2 százalékát teszik ki, a kevert módszertant alkalmazva pedig 5 százalékát. Bár ez az arány mérsékeltnek tűnhet, fontos hangsúlyozni, hogy kizárólag

a közvetlen hatásokat ragadja meg, és nem tartalmazza a mesterséges intelligencia hosszabb távon érvényesülő, közvetett gazdasági hatásait. Az eredmény összhangban áll Acemoglu (2025) Egyesült Államokra vonatkozó eredményével, ahol 5 százalékra becsülte az LLM-ek által potenciálisan automatizálható feladatok arányát. Az Egyesült Államokénál alacsonyabb érték a magyar munkaerőpiac kisebb mértékű LLM-érintettségét tükrözi.

Az LLM-ek által érintett munkafolyamatok közvetlen hatást gyakorolnak a gazdaság teljes tényezőtermelékenységére. A TFP növekedésének becsléséhez első lépésben a költségmegtakarítási rátát határoztuk meg. E mutató szerint a mesterséges intelligencia alkalmazásával elérhető munkaerőköltség-megtakarítás Acemoglu (2025) keretrendszere alapján mintegy 12 százalékos költségsökkenést eredményezhet, míg a kevert módszertan szerint ez az érték akár a 17 százalékot is elérheti. A két becslés közötti különbség elsősorban arra vezethető vissza, hogy Aghion és Bunel (2024) magasabb, 40 százalékos munkaerőköltség-megtakarítással számolnak. Ez az arány mindkét esetben számottevően kisebb az Egyesült Államokra becsült 14, illetve 21 százalékos értéknél. A különbség elsődleges oka, hogy Magyarországon a bérhányad kisebb (48 százalék körüli, míg az Egyesült Államokban csaknem 60 százalék), és a munkaerő kisebb hányada végez olyan feladatokat, amelyeket az LLM-ek potenciálisan kiválthatnak. Ennek következtében a költségmegtakarítási lehetőségek nálunk mérsékeltebbek.


A TFP növekedését a (3) egyenlet segítségével számítottuk ki, amely figyelembe veszi az előbbieken említett LLM-ek által érintett feladatok GDP-ből való részeseződését, valamint a munkaerőköltség ezekhez kapcsolódó megtakarítását. A magyar gazdaságra vonatkozó becslések szerint a TFP tízéves időtávon 0,25–0,81 százalékkal növekedhet. Ez lassabb ütem, mint az Acemoglu (2025) és a kevert módszertan által az Egyesült Államokra becsült 0,66 és 2,13 százalékos érték, amit részben a magyar gazdaság mérsékeltebb LLM-érintettsége és a munkajövedelem kisebb részesedése magyaráz.

A TFP javulása közvetlen hatással van a gazdaság hosszú távú növekedésére, amelynek mértékét az 1. ábra szemlélteti.

Az eredmények azt mutatják, hogy az LLM-ek terjedése a következő tíz évben Magyarországon Acemoglu (2025) módszertana szerint átlagosan évi 0,05 százalékpontos GDP-növekedést eredményezhet, míg ez az érték Aghion és Bunel (2024) optimistább feltételeit figyelembe véve elérheti a 0,15 százalékpontot. Az LLM-ek elterjedése hosszú távon tehát mérsékelte, de stabil gazdasági bővülést hozhat, ha az MI-technológiák beépülnek a termelési és üzleti folyamatokba. A hatás nagysága függ attól, hogy 1. milyen ütemben terjed a technológia alkalmazása a különböző ágazatokban; 2. milyen mértékű további költségmegtakarítás érhető el az MI használatával; valamint 3. milyen gyorsan adaptálódik a munkaerőpiac az automatizáláshoz. A 1. ábrán jól megfigyelhető a különbség az Egyesült Államokra vonatkozó becslések értékében, ahol a legpesszimistább számítás is 0,12 százalékpontos éves átlagos GDP-növekedést mutat, és a képességalapú LLM-érintettséget figyelembe vevő Aghion és Bunel (2024) becslése 1,14 százalékpontos növekedést helyez kilátásba.

1. ábra

Az LLM-ek alkalmazásának becsült hatása a GDP-re Magyarországon és az Egyesült Államokban (százalék)



Megjegyzés: az ábrán az 1., a 2. és a 4. oszlop saját számítás.

Forrás: saját szerkesztés Acemoglu (2025), Aghion és Bunel (2024), valamint saját számítás alapján.

Összefoglalás

A tanulmány célja a mesterséges intelligencián alapuló technológiák, különösen a nagy nyelvi modellek magyarországi makrogazdasági hatásainak vizsgálata volt. Az eredmények megerősítik, hogy az LLM-ek elterjedése javíthatja a termelékenységet, és hozzájárulhat a GDP növekedéséhez, ennek mértéke azonban nagyban függ a gazdaság szerkezetétől, a munkaerőpiac rugalmasságától és az MI-technológiák integrálásának képességétől.

A tanulmány becslései szerint az LLM-ekkel jelenleg kiváltható gazdasági tevékenységek a magyar GDP mintegy 2–5 százalékát állítják elő. Ezzel összhangban az LLM-ek alkalmazása a TFP-t 0,25–0,81 százalékkal növelheti, ami a következő évtizedben éves szinten a GDP 0,05–0,15 százalékpontos bővülését alapozhatja meg. Ugyanakkor mind az elérhető költségcsökkentés mértékét, mind pedig a gazdaságilag érdemben helyettesíthető feladatok körét jelentős bizonytalanság övezi. A technológia gyors fejlődési üteme miatt az LLM-ekkel jó minőségben automatizálható feladatok köre várhatóan tovább bővül. Fontos hangsúlyozni, hogy a vizsgálat a jelenlegi feladatstruktúrára épül, és nem veszi figyelembe azokat az új feladat- és munkakör típusokat, amelyek rendszerint csak a technológiai áttöréseket követő években jelennek meg. Ennek megfelelően az eredmények az LLM-ek rövid távú gazdasági hatásainak konzervatív

becsléseként értelmezhetők, amelyek ugyanakkor nagymértékben függenek a gazdasági döntéshozók reakcióitól és a műszaki fejlődés alakulásától.

Kiemelendő továbbá, hogy az Acemoglu (2025) és a jelen tanulmány által alkalmazott LLM-érintettség módszertana alapvetően a technológiai képességekből indul ki. Bár Acemoglu keretrendszere figyelembe veszi, hogy nem minden technológiai-lag kiváltható feladat automatizálása gazdaságos, a modell nem számol olyan korlátokkal (például biztonsági és pszichológiai megfontolásokkal), amelyek miatt egyes feladatokat a technológiai lehetőségek ellenére sem automatizálnának. A Magyarországra becsült, MI által indukált potenciális termelékenységi hatások mérsékeltebbek az Egyesült Államokra vonatkozó előrejelzésekhez képest. Acemoglu (2025) konzervatívnak tekintett becslése szerint is az Egyesült Államokban az MI-nek köszönhető tízéves GDP-növekedés meghaladhatja az 1 százalékot. Ezzel szemben ugyanazzal a módszertannal a jelen tanulmány a magyar gazdaság esetében mintegy 0,5 százalékos tízéves GDP-többletet jelez előre. A különbségek hátterében elsősorban a bérhányadbeli és a munkaerőpiaci szerkezeti eltérések állhatnak.

Az eltérő potenciális növekedési pályák ugyanakkor azt is tükrözik, hogy az MI indukálta gazdasági hatások nagysága jelentős mértékben függ a gazdaság digitalizáltsági szintjétől, valamint attól, hogy a vállalatok és más gazdasági szereplők miként tudják a mesterséges intelligenciát a gyakorlatukba integrálni. Ennek megfelelően a nemzetközi különbségek nem csupán a jelenlegi szerkezeti adottságokat, hanem a technológiaadaptációs képességeket is tükrözik.

A tanulmány legfőbb hozzáadott értéke abban rejlik, hogy kifejezetten Magyarországra szabott kvantitatív becsléseket nyújt a mesterséges intelligencia makrogazdasági hatásaira. Az elemzés egyik egyedi jellemzője, hogy a magyar munkaerőpiac szerkezetét és a hazai foglalkoztatási kategóriákat figyelembe véve határozza meg az MI-adaptáció lehetőségeit. Ezáltal támogatja a döntéshozókat a célzott szakpolitikai beavatkozások kialakításában és frissítésében, valamint hozzájárul az átfogó nemzeti MI-stratégia továbbfejlesztéséhez annak érdekében, hogy a gazdaság szereplői hatékonyan alkalmazkodjanak az MI által előidézett változásokhoz, illetve képesek legyenek proaktívan alakítani őket. Különösen releváns szakpolitikai területek az oktatás, a foglalkoztatáspolitikai, az MI-technológiák szabályozása és az iparpolitika.

A tanulmány összességében arra a következtetésre jut, hogy a mesterséges intelligencia számottevő lehetőségeket kínál a magyar gazdaság számára. A jövőbeli termelékenységnövekedés mértéke Magyarország esetében is jórészt attól függ, hogy a gazdaság szereplői (beleértve az államot, a vállalatokat és az oktatási rendszert) milyen gyorsan és milyen hatékonysággal reagálnak az MI által kínált lehetőségekre. A digitális készségek fejlesztése, a költséghatékonysági előnyök kiaknázása és az MI-vel kapcsolatos innovációk ösztönzése kulcsfontosságú tényezők lehetnek a versenyképesség javításában és a hosszú távú gazdasági növekedés támogatásában. E folyamatban kiemelt szerepet játszhatnak az MI-hez kapcsolódó képzések, a kisvállalkozások technológiai támogatása, valamint a támogató és kiszámítható szabályozási környezet.

Ugyanakkor a mesterséges intelligencia elterjedése új típusú kockázatokat is felvet, többek között a regionális és a társadalmi különbségek mélyülését. Ezért

elengedhetetlen, hogy a termelékenységi potenciál kiaknázása mellett a döntéshozók a társadalmi szempontokat is figyelembe vegyék. A jövőben további országspecifikus kutatásokra lehet szükség annak feltárására, hogy a technológiai diffúzió milyen ütemben és milyen akadályok mellett valósul meg, valamint hogy az MI milyen hosszú távú gazdasági és társadalmi hatásokkal járhat.

Hivatkozások

- Acemoglu, D. (2025). The simple macroeconomics of AI. *Economic Policy*, 40(121), 13–58. <https://doi.org/10.1093/epolic/eiae042>
- Acemoglu, D., & Restrepo, P. (2018). The race between man and machine: Implications of technology for growth, factor shares, and employment. *American Economic Review*, 108(6), 1488–1542. <https://doi.org/10.1257/aer.20160696>
- Acemoglu, D., & Restrepo, P. (2019). Automation and new tasks: How technology displaces and reinstates labor. *Journal of Economic Perspectives*, 33(2), 3–30. <https://doi.org/10.1257/jep.33.2.3>
- Acemoglu, D., & Restrepo, P. (2020). The wrong kind of AI? Artificial intelligence and the future of labour demand. *Cambridge Journal of Regions, Economy and Society*, 13(1), 25–35. <https://doi.org/10.1093/cjres/rsz022>
- Acemoglu, D., & Restrepo, P. (2022). Tasks, automation, and the rise in US wage inequality. *Econometrica*, 90(5), 1973–2016. <https://doi.org/10.3982/ECTA19815>
- Acemoglu, D., Autor, D., & Johnson, S. (2023). Can we have pro-worker AI? *CEPR Policy Insight*, 123.
- Aghion, P., & Bunel, S. (2024). *AI and growth: Where do we stand?* (Policy note.) Federal Reserve Bank of San Francisco. <https://www.frbsf.org/wp-content/uploads/AI-and-Growth-Aghion-Bunel.pdf>
- Baranyai, E., Granat, M., & Szepesi, M. (2024). Large language models and the labour market: Spatial evidence from job ads. SSRN. <https://doi.org/10.2139/ssrn.5176089>
- Baumol, W. J. (1967). Macroeconomics of unbalanced growth: The anatomy of urban crisis. *American Economic Review*, 57(3), 415–426. <https://www.jstor.org/stable/1812111>
- Bresnahan, T. F., & Trajtenberg, M. (1995). General purpose technologies: Engines of growth? *Journal of Econometrics*, 65(1), 83–108. [https://doi.org/10.1016/0304-4076\(94\)01598-T](https://doi.org/10.1016/0304-4076(94)01598-T)
- Brynjolfsson, E., Rock, D., & Syverson, C. (2019). Artificial intelligence and the modern productivity paradox. In A. Agrawal, J. Gans, & A. Goldfarb (Eds.), *The economics of artificial intelligence* (pp. 23–57). University of Chicago Press.
- Brynjolfsson, E., Rock, D., & Syverson, C. (2023). The productivity J-curve: How intangibles complement general purpose technologies. *American Economic Journal: Macroeconomics*, 15(1), 333–372. <https://doi.org/10.1257/mac.20180386>
- Cazzaniga, M., Jaumotte, F., Li, L., Melina, G., Panton, A., Pizzinelli, C., & Tavares, M. (2024). *Gen-AI: Artificial intelligence and the future of work*. International Monetary Fund. <https://www.imf.org/-/media/files/publications/sdn/2024/english/sdnea2024001.pdf>
- Cerutti, E., Garcia Pascual, A., Kido, Y., Li, L., Melina, G., Tavares, M., & Wingender, P. (2025). *The global impact of AI: Mind the gap* (IMF Working Paper, No. 25/76). <https://www.imf.org/en/publications/wp/issues/2025/04/11/the-global-impact-of-ai-mind-the-gap-566129>

- Chui, M., Hazan, E., Roberts, R., Singla, A., & Smaje, K. (2023). *The economic potential of generative AI*. McKinsey. <https://www.mckinsey.com/capabilities/mckinsey-digital/our-insights/the-economic-potential-of-generative-AI-the-next-productivity-frontier>
- Czarnitzki, D., Fernández, G. P., & Rammer, C. (2023). Artificial intelligence and firm-level productivity. *Journal of Economic Behavior & Organization*, 211, 188–205. <https://doi.org/10.1016/j.jebo.2023.05.008>
- Duckworth, P., Graham, L., & Osborne, M. (2019). Inferring work task automatability from AI expert evidence. In *Proceedings of the AAAI/ACM Conference on AI, Ethics, and Society* (pp. 485–491). <https://doi.org/10.1145/3306618.3314247>
- Eloundou, T., Manning, S., Mishkin, P., & Rock, D. (2023). GPTs are GPTs: An early look at the labor market impact potential of Large Language Models. *arXiv*. <https://arxiv.org/abs/2303.10130>
- European Commission. (2022). *DESI 2022: Compare countries' progress*. <https://digital-decade-desi.digital-strategy.ec.europa.eu>
- Felten, E., Raj, M., & Seamans, R. (2021). Occupational, industry, and geographic exposure to artificial intelligence: A novel dataset and its potential uses. *Strategic Management Journal*, 42(12), 2195–2217. <https://doi.org/10.1002/smj.3286>
- Filippucci, F., Gal, P., & Schief, M. (2024). Miracle or myth? Assessing the macroeconomic productivity gains from artificial intelligence. *OECD Artificial Intelligence Papers*, 29. <https://doi.org/10.1787/b524a072-en>
- Frey, C. B., & Osborne, M. A. (2017). The future of employment: How susceptible are jobs to computerisation? *Technological Forecasting and Social Change*, 114, 254–280. <https://doi.org/10.1016/j.techfore.2016.08.019>
- Gerlich, M. (2023). Perceptions and acceptance of artificial intelligence: A multi-dimensional study. *Social Sciences*, 12(9), 502. <https://doi.org/10.3390/socsci12090502>
- Ghose, S. (2023). *Not just LLMs: How generative AI will be used in the enterprise*. UC Berkeley Sutardja Center. <https://scet.berkeley.edu/not-just-llms-how-generative-ai-will-be-used-in-the-enterprise/>
- 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.html>
- Hulten, C. R. (1978). Growth accounting with intermediate inputs. *Review of Economic Studies*, 45(3), 511–518. <https://doi.org/10.2307/2297252>
- Korinek, A. (2024). LLMs level up – Better, faster, cheaper: Update to generative AI for economic research. *Journal of Economic Literature*, 61(4), <https://www.aeaweb.org/articles?id=10.1257/jel.20231736#additionalMaterials>
- Központi Statisztikai Hivatal. (2024a). *A foglalkoztatottak száma foglalkozási főcsoport szerint, nemenként*. Elérhető: 20.1.1.9.
- Központi Statisztikai Hivatal. (2024b). *Teljes munkaidőben alkalmazásban állók bruttó átlagkeresete foglalkozások szerint*. Elérhető: 20.1.1.52.
- Noy, S., & Zhang, W. (2023). Experimental evidence on the productivity effects of generative artificial intelligence. *Science*, 381(6654), 187–192. <https://doi.org/10.1126/science.adh2586>
- Organisation for Economic Co-operation and Development. (2025). *The adoption of artificial intelligence in firms: New evidence for policymaking*. OECD Publishing. <https://doi.org/10.1787/f9ef33c3-en>
- Our World in Data. (2020). *Labor share of gross domestic product (GDP), 2004 to 2020*.

- Peñalvo, F. J. G., & Ingelmo, A. V. (2023). What do we mean by GenAI? A systematic mapping of the evolution, trends, and techniques involved in generative AI. *International Journal of Interactive Multimedia and Artificial Intelligence*, 8(4), 7–16.
- Peng, S., Kalliamvakou, E., Cihon, P., & Demirer, M. (2023). The impact of AI on developer productivity: Evidence from GitHub Copilot. *arXiv*. <https://doi.org/10.48550/arXiv.2302.06590>
- Svanberg, M., Li, W., Fleming, M., Goehring, B., & Thompson, N. (2024). Beyond AI exposure: Which tasks are cost-effective to automate with computer vision? *SSRN*. <https://doi.org/10.2139/ssrn.4700751>
- Zhao, W. X., Zhou, K., Li, J., Tang, T., Wang, X., Hou, Y., & Wen, J. R. (2023). A survey of large language models. *arXiv*. <https://doi.org/10.48550/arXiv.2303.18223>