

NÉZŐPONT

Mesterséges intelligencia a közgazdasági kutatásban

FERTŐ IMRE*

A mesterséges intelligencia (MI) térhódítása alapvetően alakítja át a közgazdasági kutatások módszertani, etikai és szakpolitikai környezetét. A tanulmány három kulcskérdést vizsgál: hogyan egyeztethető össze az MI adaptív, adatvezérelt megközelítése a közgazdaságtan oksági elemző szemléletével; milyen hatással van az MI a munka, a tőke és a tudás eloszlására; valamint milyen intézményi és szabályozási mechanizmusokra van szükség az MI által generált előnyök maximalizálásához és a kockázatok kezeléséhez. Az elemzés rámutat, hogy miközben a gépi tanulási módszerek, mint a kauzális erdők és mélytanulási hálózatok, páratlan elemzési lehetőségeket kínálnak, az algoritmikus átláthatatlanság és az etikai dilemmák (például torzítások és adatvédelem) jelentős kihívásokat jelentenek. Kiemeljük, hogy a sikeres alkalmazás feltétele a módszertani fegyelem, a kutatói kompetenciák fejlesztése és a társadalmi egyenlőtlenségeket kezelő szakpolitikai intézkedések integrálása.

Journal of Economic Literature (JEL) kódok: C55, O33, D31.

Kulcsszavak: mesterséges intelligencia, gépi tanulás, oksági elemzés, adatvezérelt döntéshozatal, algoritmusetika.

* Fertő Imre főigazgató, HUN-REN Közgazdaság- és Regionális Tudományi Kutatóközpont, egyetemi tanár, Budapesti Corvinus Egyetem, Fenntartható Fejlődés Intézet.
ORCID: <https://orcid.org/0000-0002-3742-5964>
E-mail: ferto.imre@krtk.hun-ren.hu

A kézirat 2025. május 20-án érkezett a *Külgazdaság* szerkesztőségébe.

<https://doi.org/10.47630/KULG.2025.69.5-6.63>

Abstract**Artificial intelligence in economic research**

IMRE FERTŐ

The proliferation of artificial intelligence (AI) is fundamentally transforming the methodological, ethical, and policy landscape of economic research. This paper examines three key issues: how the adaptive, data-driven approach of AI can be reconciled with the causal analytic perspective inherent in economics; the impact of AI on the distribution of labour, capital, and knowledge; and the institutional and regulatory frameworks necessary to maximize AI's benefits while mitigating associated risks. The analysis highlights that while machine learning techniques such as causal forests and deep neural networks offer unprecedented analytical opportunities, algorithmic opacity and ethical dilemmas—including biases and data protection—pose significant challenges. The author emphasizes that the successful implementation of AI requires methodological rigour, enhanced researcher competencies, and the integration of policy measures aimed at addressing social inequalities.

Journal of Economic Literature (JEL) codes: C55, O33, D31.

Keywords: artificial intelligence, machine learning, causal analysis, data-driven decision making, algorithm ethics.

Bevezetés

A mesterséges intelligencia (MI) megjelenése a közgazdaságtanban nem pusztán egy újabb technológiai fejlesztés, hanem alapvető rendszerszintű változás. Ahogy a 20. század végén újraértelmeződött az állam és a piac viszonya, úgy formálja át napjainkban a hatalmas adatmennyiség és a megnövekedett számítási kapacitás a tudományos és gazdaságpolitikai döntéshozatalt. A gépi tanulás már nem csupán egy újabb eszköz a statisztikai elemzések során; saját belső működéssel, ösztönzőkkel és jellemző hibákkal lép be a közgazdasági gondolkodásba (Athey & Imbens, 2019; Dell, 2025). Tanulmányunk három kulcskérdést vizsgál a mesterséges intelligencia és a közgazdaságtan találkozási pontjain:

A hagyományos „kevés adat – erős modellfeltételezés” megközelítést felváltja a „sok adat – rugalmas algoritmus” szemlélet, azonban kérdéses, mennyi tudományos értéket képvisel ez, ha nem látunk bele a háttérben zajló folyamatokba. Az új módszerek, mint a kauzális erdők, a diffúziós modellek vagy a műholdas éjszakai fényadatok alapján történő GDP-becslések bővítik elemzési lehetőségeinket, ugyanakkor elhomályosíthatják az ok-okozati összefüggéseket (Haaland et al., 2025). Ezt a hely-

zetet tovább árnyalja, hogy a nagy nyelvi modellek képesek percek alatt áttekinteni a szakirodalmat és kutatási hipotéziseket javasolni (Ash & Hansen, 2023; Ludwig et al., 2025). A kutatók így korábban elképzelhetetlen mennyiségű adathoz és ötlethez jutnak, de növekszik a felelősségük abban, hogy a „feketedoboz” eredményeit közgazdasági elméleti keretek között értelmezzék.

A valós idejű adatfolyamokon alapuló MI-modellek gyorsabb és finomabb gazdaságpolitikai beavatkozásokat tesznek lehetővé, ami csökkentheti a gazdasági ingadozásokat (Acemoglu, 2025; Calvano & Calzolari, 2025). Ugyanakkor az átláthatatlan algoritmusok akár kartellszerű piaci összejátszást is elősegíthetnek (Harrington, 2025; Hagiú & Wright, 2025). A munkaerőpiacon kettős hatás figyelhető meg: egyes régiókban és ágazatokban nő a termelékenység és emelkednek a reálbérek, máshol viszont a rutinfeladatokat tartalmazó munkakörök gyorsan megszűnnek (Bonfiglioli et al., 2025; Albanesi et al., 2025). Az MI így nemcsak hatékonysági, hanem elosztási kérdéseket is felvet, ami szükségessé teszi a célzott szabályozást és a versenyhatóságok felkészültségének növelését (Gans, 2025; Goldfarb, 2024).

A tudás és a számítási kapacitás egyre inkább néhány nagyvállalatnál és intézménynél koncentrálódik (Korinek & Vipra, 2025). Ezt a koncentrációt ellensúlyozhatja a célzott képességfejlesztés, a nyílt forráskódú modellek támogatása és a megbízható ellenőrzési rendszerek kialakítása (Georgieva, 2024; Best et al., 2024). A vezető tudományos folyóiratok már elvárják a kódok és „modellkártyák” közzétételét; a doktori programok pedig olyan kurzusokat indítanak, amelyek ötvözik az ok-okozati következtetések és a modern gépi tanulás módszereit. Közben az automatizált munkafolyamatok átveszik az ismétlődő elemzések jelentős részét, felgyorsítva a kutatást, de növelve a hozzáférési egyenlőtlenségek kockázatát is (Dawid et al., 2025; Feyzollahi & Rafizadeh, 2025).

A tanulmány célja, hogy feltárja, miként alakítja át a mesterséges intelligencia térnyerése a közgazdasági elemzés bevett módszereit, intézményi kereteit és társadalmi-gazdasági összefüggéseit. Nem pusztán technológiai újításról van szó, hanem olyan folyamatokról, amelyek a közgazdasági gondolkodás mélyebb szerkezetét és a gazdaságpolitika lehetőségeit is átförmálják. Írásunk ehhez kapcsolódva három fő területen járul hozzá a szakirodalomhoz: egyrészt bemutatja, hogyan lehet összeegyeztetni a hagyományos oksági elemzést az MI adatvezérelt logikájával, másrészt rámutat az MI által kiváltott gazdasági és társadalmi elosztási kérdések fontosságára, végül pedig áttekinti azokat az intézményi feltételeket, amelyek szükségesek ahhoz, hogy az új technológiák haszna minél szélesebb körben érvényesüljön, miközben kockázataik mérsékelhetők maradnak. Az elemzés így egyszerre gazdagítja

a közgazdaság-tudomány módszertani diskurzusát, és kínál praktikus iránymutatást a szakpolitika és a kutatás számára egyaránt.

A mesterséges intelligencia térhódítása a közgazdaságtanban

A mesterséges intelligencia térhódítása a közgazdaságtanban az elmúlt tíz-tizenöt év során jelentős változásokat hozott, alapjaiban formálva át a kutatások módszertani megközelítéseit, valamint új kérdéseket vetve fel az etika, az egyenlőtlenségek kezelése és a gazdaságpolitikai alkalmazások területén. Az MI alkalmazása kezdetben főként háttértámogatásként jelent meg: nagy méretű adatbázisokat tisztított, kérdőíves válaszokat dolgozott fel, és felgyorsította a hagyományos ökonometriai modellek kalibrálását. Ezek a kezdeti alkalmazások hamarosan bizonyították értéküket, mivel jelentősen megnövelték a kutatók hatékonyságát, akik így több időt fordíthattak az elméleti elemzésekre (Athey & Imbens, 2019).

Az utóbbi években azonban a gépi tanulási módszerek, mint a *random forest*, LASSO, *boosting* algoritmusok vagy a kauzális erdők már központi szerepet töltenek be a modellezési folyamatokban. Különösen értékesnek bizonyultak ezek a technológiák a változóselekción, a nemlineáris összefüggések feltárásában, illetve a heterogén hatások azonosításában, amelyek a hagyományos lineáris modellekkel rejtve maradtak volna (Garg & Fetzer, 2025). A hitelpiaci kutatásokban például ezek az új módszerek tették lehetővé a rejtett minták és kapcsolatok feltárását, javítva ezzel az elemzések pontosságát és megbízhatóságát.

Az MI következő jelentős fejlődési szakasza a mélytanulási módszerek térnyerésével következett be. A konvolúciós és rekurzív neurális hálózatok segítségével korábban nem hasznosított, strukturálatlan adatokból – mint például műholdképekből – sikerült gazdaságilag releváns információkat kinyerni. Ezáltal új kutatási lehetőségek nyíltak, például az éjszakai fénykibocsátás alapján regionális gazdasági aktivitás mérésére vagy vállalati dokumentumokból piaci trendek és stratégiai döntések elemzésére (Dell, 2025).

A nagy nyelvi modellek (LLM-ek), mint a GPT-3 és utódai megjelenése további forradalmi változásokat hozott. Ezek az eszközök képesek automatizáltan összefoglalni és értelmezni a szakirodalmat, ezzel drámai mértékben gyorsítva a kutatói folyamatokat, miközben új, releváns hipotéziseket is képesek generálni (Feyzollahi & Rafizadeh, 2025). Az LLM-ek integrálása a kutatási folyamatba azonban nem problémamentes: a „feketedoboz”-jelleg miatt folyamatos módszertani és etikai felügyeletet igényel.

Korinek (2023, 2024) munkái részletesen vizsgálják, hogy a generatív mesterséges intelligencia (GenAI), különösen a nagy nyelvi modellek, milyen új, innovatív módokon támogathatják az empirikus gazdasági kutatásokat, beleértve a hipotézis-generálást és a nagy adathalmazok gyors áttekintését. Kwon et al. (2024) kiemelik, hogy ezek az LLM-ek különösen hatékonyan alkalmazhatók gazdasági előrejelzések készítésében, ugyanakkor felhívják a figyelmet az adatszivárgás kockázataira, amelyeket megfelelő módszertani óvatossággal kell kezelni.

A pénzügyi elemzések terén Eisfeldt & Schubert (2024) hangsúlyozza, hogy az MI lehetővé teszi a befektetési stratégiák és kockázatkezelési gyakorlatok alapvető megújítását. Obschonka & Levesque (2024) pedig arra figyelmeztet, hogy az MI-technológiák kritikus értékelése elengedhetetlen, mivel ellenkező esetben torzított eredmények és félrevezető következtetések születhetnek.

Zheng et al. (2023) átfogó áttekintése rámutat, hogy a mélytanulási technikák számos gazdaságtudományi elemzésben kulcsfontosságúvá váltak, különösen a komplex, nagy dimenziós adathalmazok értelmezésében, ezzel kitágítva a gazdasági elemzések horizontját és lehetőségeit. Bickley et al. (2022) scientometriai elemzése azt is igazolja, hogy a mesterséges intelligencia térnyerése a közgazdaságtanban nemcsak módszertani újításokat jelent, hanem jelentős változásokat eredményez a tudományos publikációk témaválasztásában és a kutatói érdeklődés irányában is, hangsúlyozva az MI által érintett kutatási területek gyors és szerteágazó növekedését.

Az MI alkalmazásának gyors terjedése azonban nemcsak lehetőségeket, hanem komoly kihívásokat is teremtett. Az egyik legjelentősebb kihívás az intézményi egyenlőtlenségek felerősödése. A vezető egyetemek és központi bankok könnyedén hoznak létre saját MI-infrastruktúrát, miközben sok kisebb vagy fejlődő országbeli intézmény a legalapvetőbb technológiai háttérrel is küzd. Ez hosszú távon kétpólusú kutatási ökoszisztéma kialakulásához vezethet, ha nem kerül sor a technológiai hozzáférés demokratizálására (Korinek & Vipra, 2025).

Ezzel párhuzamosan az etikai kérdések is fokozott figyelmet kapnak. Az MI által generált torzítások, az adatvédelem problémái, valamint az átláthatóság hiánya mind olyan problémák, amelyek kezelése kiemelten fontos. Az algoritmusok által okozott társadalmi egyenlőtlenségek, például a munkaerőpiaci vagy hitelezési diszkrimináció újratermelődése, különösen sürgetővé teszik a modellek folyamatos ellenőrzését és az etikai irányelvek szigorú alkalmazását (Goldfarb, 2024).

Gazdaságpolitikai szempontból az MI alkalmazása új lehetőségeket teremt a gyorsabb és célzottabb intézkedésekre, amelyek mérsékelhetik a gazdasági ingadozásokat. Azonban a technológia által generált piaci torzulások – mint például

az algoritmikus összejátszás – ellen új szabályozói megközelítésekre van szükség (Harrington, 2025). A versenyhatóságoknak aktívabb szerepet kell vállalniuk, és nemcsak megfigyelniük kell az algoritmusokat, hanem szükség esetén közvetlenül be is kell avatkozniuk.

Az oktatás terén is jelentős átalakulásokat látunk. A vezető közgazdasági doktori programok már rutinszerűen kínálnak kurzusokat gépi tanulásról és adatvezérelt döntéshozatalról. Ez a változás azt jelzi, hogy az MI-tudás mára nem csupán plusz képesség, hanem alapvető elvárás lett a közgazdászok számára. Emellett a publikációs normák is átalakulnak: a folyóiratok egyre gyakrabban követelik meg a teljes kutatási folyamat dokumentálását, beleértve a kódokat és adatfeldolgozási lépéseket is, biztosítva a kutatások transzparenciáját és reprodukálhatóságát.

Módszertani átalakulások

A mesterséges intelligencia (MI) megjelenése a közgazdaságtanban nem csupán technikai újítás, hanem alapvető szemléletváltás: egyszerre bővíti az eszköztárat és alakítja át a kutatás szerkezetét. Ez a változás nemcsak módszertani, hanem filozófiai is, mivel újradefiniálja az adatokhoz és modellekhez való viszonyunkat.

A módszertani átalakulás egyik kulcseleme a hagyományos, merev modellfeltevéseken alapuló statisztikai megközelítések helyett az adatvezérelt, rugalmas algoritmusok előtérbe kerülése. A *random forest*, a LASSO vagy a *boosting* technikák olyan komplex minták felismerésére képesek, amelyek korábban láthatatlanok maradtak. Ezek a technikák különösen hasznosak akkor, ha nagyszámú, változókkal rendelkező adatbázisokkal dolgozunk, mivel képesek kiszűrni a releváns változókat és felfedezni a nemlineáris összefüggéseket is (Athey & Imbens, 2019).

Chan & Choi (2025), valamint Cillo & Rubera (2024) a marketing és innováció kutatásában vizsgálja, hogy a generatív MI-technológiák hogyan teremtenek lehetőséget korábban rejtett kapcsolatok feltárására és új hipotézisek kialakítására. Ezek a kutatások azt mutatják, hogy a generatív mesterséges intelligencia alkalmazása túlmutat a predikciós képességen, a kreativitást és új ötletek generálását is elősegíti.

A fogyasztói viselkedés kutatásában Hermann & Puntoni (2024) rámutat, hogy a generatív MI a prediktív elemzésekről egyre inkább a generatív megközelítésekre helyezi át a hangsúlyt, ezzel új módszertani kereteket és etikai dilemmákat teremtve, különösen a fogyasztói döntéshozatal megértésében.

Korinek (2023, 2024) mellett Ludwig et al. (2025) hangsúlyozzák, hogy a mélytanulás és nagy nyelvi modellek alkalmazása során a módszertani rigorozitás fenntartása kulcsfontosságú. Kifejlesztettek egy olyan alkalmazott ökonometriai keretrendszert, amely lehetővé teszi ezen eszközök validált integrálását empirikus kutatásokba, így csökkentve a torzítás kockázatát és fenntartva az eredmények reprodukálhatóságát és megbízhatóságát. Asatryan et al. (2025) tanulmánya szintén fontos módszertani példát nyújt arra, hogyan használhatók a nagy nyelvi modellek a szakpolitikai értékelések metaelemzésében. Tanulmányuk rámutat arra, hogy az LLM-ek alkalmazása jelentősen javíthatja a szakpolitikai intézkedések hatékonyságának empirikus értékelését, ugyanakkor figyelmeztet arra is, hogy ezen technológiák megbízható alkalmazása csak megfelelő validációs és ellenőrzési mechanizmusokkal lehetséges.

Egy további jelentős előrelépés a kettős gépi tanulás (*double machine learning* – DML) módszer alkalmazása. A DML képes kezelni az összetett és nagy mintájú adatokat, miközben megbízható becsléseket ad a különböző beavatkozások oksági hatásáról. A módszer hatékonyságának kulcsa az, hogy rugalmasan tudja kezelni a kontrollváltozókat, valamint minimalizálja a túlillesztés kockázatát keresztvalidációs és mintaszegmentációs technikák segítségével.

A kettős gépi tanulás alapvetően két kulcsfontosságú komponensen alapul: a Neyman-ortogonalitáson és a keresztvalidáción. A Neyman-ortogonalitás azt biztosítja, hogy a becslések kevésbé érzékenyek a segédváltozók becslésének pontatlanságaira, míg a keresztvalidáció (*cross-fitting*) csökkenti a túlillesztésből eredő torzítást. Ezáltal a DML lehetővé teszi, hogy még magas dimenziós segédváltozók esetén is pontos következtetéseket lehessen levonni (Ahrens et al., 2025). A módszer alkalmazhatósága széles körű, legyen szó keresztmetszeti vagy paneladatokról, és különösen előnyös olyan esetekben, amikor a segédváltozók becslése bonyolult vagy magas dimenziós struktúrájú adatokkal történik.

A mélytanulás (*deep learning*) az utóbbi években kiemelkedő szerepet kapott a gazdasági kutatásokban, különösen a strukturálatlan, nagy méretű adatbázisok elemzésében. Dell (2025) kiemeli, hogy a mély neurális hálózatok képesek komplex, nagy dimenziós adatokat – például műholdképeket, dokumentumszkenneléseket vagy szöveges adatokat – értelmezhető, strukturált információvá alakítani. A mélytanulás alapja, hogy a neurális hálózatok több rétegben, egyre absztraktabb reprezentációkat tanulnak meg, amelyek végül alacsony dimenziós, könnyen feldolgozható vektorokká alakulnak. Ezek a vektorok jelentősen leegyszerűsítik a további elemzéseket, lehetővé téve például gazdasági tevékenységek azonosítását műhold-

képekből, vagy konkrét témák, személyek felismerését vállalati dokumentumokban és a közösségi médiában.

A mélytanulás módszerei között kiemelt szerepük van a konvolúciós neurális hálózatoknak (CNN) és a transzformeralapú modelleknek, amelyek az adattípusok széles skáláján alkalmazhatók. Ezek a modellek különösen alkalmasak a képek és szövegek automatizált elemzésére, és gyakran jelentős előrejelzési pontosságnövekedést érnek el a hagyományos statisztikai módszerekkel szemben. Dell (2025) példája szerint a CNN-alapú gazdasági indikátorok akár több mint 20 százalékkal képesek csökkenteni az előrejelzési hibákat a hagyományos indikátorokhoz képest, különösen azokon a területeken, ahol az adatgyűjtés nehézkes, vagy az adatok késéssel érkeznek. E módszerek széles körű elterjedését tovább segíti az a gyakorlat, hogy a mélytanulási modellek sok esetben előre betanított paraméterekkel érkeznek, jelentősen leegyszerűsítve azok alkalmazhatóságát a közgazdasági kutatásokban.

Ugyancsak fontos a nagy nyelvi modellek (LLM-ek), mint például a GPT-típusú rendszerek térhódítása. Az LLM-ek közgazdasági elemzésekben való felhasználásának módszertani keretét Ludwig et al. (2025) dolgozták ki részletesen. A szerzők egy olyan alkalmazott ökonometriai keretet mutatnak be, amely lehetővé teszi a nagy nyelvi modellek kimeneteinek integrálását empirikus kutatásokba anélkül, hogy veszélyeztetné azok tudományos rigorozitását. A kidolgozott keretrendszer két fő feladatkört különböztet meg: predikciós és becslési problémákat. A predikciós feladatok, mint például hipotézisek generálása, akkor tekinthetők érvényesnek, ha az LLM-ek tanítási adata és a kutató saját adatai között nincs átfedés (*data leakage*), ami garantálható nyílt forráskódú, dokumentált tanítási adatokkal rendelkező modellek használatával. Becslési problémák esetén viszont, amikor a modellek gazdasági fogalmak automatikus mérését végzik el szöveges vagy humán válaszokból, elengedhetetlen a validációs adatok gyűjtése, amelyek segítségével mérhető és korrigálható az LLM-ek automatikus feldolgozásából eredő hiba.

Ludwig et al. (2025) szerint az LLM-ek hatékony integrációja a közgazdasági elemzésekbe csak akkor valósítható meg sikeresen, ha betartjuk ezeket a feltételeket, mivel enélkül az LLM-ek által generált eredmények torzításokat okozhatnak a predikciókban és paraméterbecslésekben. Ezt különösen két empirikus példán keresztül szemléltetik: pénzügyi elemzésekben és politikai gazdaságtani kutatásokban alkalmazva megmutatják, hogy az LLM-ek megfelelő validálás nélkül bizonytalan empirikus eredményeket hozhatnak. Ez a módszertani útmutatás kiemeli az LLM-ek potenciálját abban, hogy akár kis mennyiségű szöveges adatot is hatékonyan fel-

használhassanak a közgazdasági kutatásokban, amennyiben a fent említett feltételeket szigorúan betartják.

Az önálló, agentikus munkafolyamatok megjelenése további forradalmat jelent a gazdasági kutatásokban. Dawid et al. (2025) szerint ezek az AI-asszisztált folyamatok autonóm módon, iteratíván képesek lefedni a teljes kutatási ciklust, az ötlettől a szakirodalmi áttekintésen át a gazdasági modellezésig és empirikus elemzésekig, miközben stratégiai emberi felügyeletet biztosítanak. Ezen agentikus rendszerek képesek reagálni a kutatási igények változásaira, folyamatosan finomítva a kutatási folyamatokat, jelentősen növelve a kutatás hatékonyságát és reprodukálhatóságát (Dawid et al., 2025). Az ilyen agentikus munkafolyamatok további előnye, hogy a gazdasági elemzők azokra a kreatív és elméleti kérdésekre fordíthatják figyelmüket, amelyek valóban emberi ítélőképességet igényelnek. Mindez jelentősen fokozhatja a gazdasági kutatások mélységét, átláthatóságát és alkalmazhatóságát, miközben csökkenti az adatkezelésből és az ismétlődő elemzési feladatokból adódó terheket.

A minőségi (kvalitatív) adatok feldolgozása is fejlődik. Haaland et al. (2025) fejlett szövegfeldolgozási technikákkal tárják fel a nyitott válaszok rejtett tematikus szerkezetét; a transzformeralapú szövegelemzés olyan finom viselkedési mintázatokat – mint a bizalmi attitűdök vagy kockázatszelés – tesz mérhetővé, amelyeket a hagyományos kérdőívek nem képesek megragadni.

Az ilyen típusú nyitott válaszok elemzése nemcsak a szöveg tartalmát, hanem a válaszadás során alkalmazott érzelmi és hangulati elemeket is képes rögzíteni. Például a beszédalapú válaszgyűjtés révén megragadhatók olyan nem verbális jelzések, mint a beszélő érzelmei vagy bizonytalansága, ami további mélységet ad a kvalitatív elemzésnek. Az AI-alapú interjúk további előnye, hogy adaptív módon, akár valós időben is reagálhatnak az interjúalany által elmondottakra, tisztázó és mélyítő kérdéseket téve fel, ezáltal jelentősen növelve a válaszok részletgazdagságát és minőségét.

E fejlesztések ellenére az új technológiák alkalmazása kihívásokkal is jár. Például a szövegfeldolgozó modellek pontossága erősen függ a betanításhoz használt adatok minőségétől és az elemzési keretrendszerek kidolgozottságától. Így kulcsfontosságúvá válik a kódolási sémák gondos kialakítása, hogy pontosan megragadhatók legyenek az elemzett jelenségek finom árnyalatai. Mindemellett a transzparencia érdekében ajánlott a teljes elemzési folyamat – ideértve a használt AI-modell paramétereit és az elemzési sémákat – dokumentálása, hogy az eredmények reprodukálhatósága és hitelessége hosszú távon is biztosított legyen.

A módszertani kihívások azonban továbbra is jelentősek. Kis minták esetén a gépi tanulás hajlamos a túlillesztésre; a rendkívüli pontosság gyakran az értelmezhetőség rovására megy. E feszültség enyhítésére terjed a magyarázható mesterséges intelligencia (*explainable AI*) koncepciója, amely feltárja az egyes változók hozzájárulását a modell előrejelzéseéhez, segítve ezzel a döntéshozók számára történő kommunikációt.

Az oktatás is alkalmazkodik: a vezető doktori programok „gépi tanulás közgazdászoknak” kurzusokat indítanak; a hallgatóknak egyszerre kell elsajátítaniuk különböző programozási eszközöket (scikit-learn, TensorFlow, DoubleML), miközben verziókezelési és kutatásetikai ismeretekre is szükségük van.

Összefoglalva: a mesterséges intelligencia által vezérelt módszertani forradalom egyesíti a rugalmas, adattalkalmazkodó algoritmusokat a közgazdaságtan hagyományos oksági megközelítésével. A kihívás ma már nem a technológia elutasítása, hanem annak biztosítása, hogy az innovációt az átláthatóság, a reprodukálhatóság és az értelmezhetőség elvei vezéreljék.

Az adat- és elemzőkapacitások fejlesztésének fontossága

A 21. század elején a közpolitikai és vállalati döntéshozatal adatintenzív tevékenységgé vált: a robusztus adat-infrastruktúra a gazdasági számviteli rendszerekhez hasonlóan alapfeltétele annak, hogy megértsük a szakpolitikai beavatkozások és piaci sokkok összetett hatásait. A komplex adathalmazok szakszerű gyűjtése és elemzése pontosabb képet ad a termelékenység, a munkaerőpiaci dinamika és a társadalmi jólét alakulásáról, ami rendkívüli helyzetekben nélkülözhetetlen a gyors reakcióhoz (Autor et al., 2003).

A gazdasági rendszerek növekvő komplexitása – a globalizáció, a technológiai váltások és a rugalmas foglalkoztatási formák térnyerése – soha nem látott mennyiségű, heterogén adatot termel (Brynjolfsson, 2014). A hagyományos források – nemzeti statisztikák, vállalati jelentések – továbbra is fontosak, de az igazi versenyelőnyt az adminisztratív nyilvántartások, a műholdképek és a digitális platformok valós idejű információi hozzák, amelyek finom tér- és időbeli felbontásban mutatják a gazdasági aktivitás változásait (Chetty et al., 2014).

E sokszínűség azonban könnyen kaotikus adatszaggá válhat, ha nem épül rá egységes szabvány- és jogi környezet. A statisztikai hivataloknak, adatkezelő vállalatoknak és kutatóintézeteknek olyan megbízható, interoperábilis adattárakat kell lét-

rehozniuk, ahol az adatvédelem és a kutatói hozzáférés egyszerre garantált (Groshen et al., 2017). A megfelelő szabályozás védi a személyes információkat, ugyanakkor nem bénítja a kutatást, így az adatvagyon valódi közjósággá válhat (Acemoglu & Restrepo, 2019).

Az adatok mellé fejlett elemzőeszközök szükségesek. A klasszikus statisztikai módszerek ma is a közgazdasági elemzés gerincét adják, ám egyre gyakrabban egészülnek ki a gépi tanulás és az adattudomány rugalmas technikáival (Varian, 2014). Az olyan algoritmusok, mint a *random forest* vagy a mély neurális hálózatok képesek feltárni a nemlineáris mintázatokat, finomítva ezzel a szakpolitikai döntéshozatalt (Athey & Imbens, 2019), ugyanakkor gazdaságelméleti kontextus nélkül az eredmények nehezen értelmezhetők (Mullainathan & Spiess, 2017).

A módszertani forradalom egyik sarokköve a magyarázható mesterséges intelligencia: a túlillesztésre hajlamos gépi tanulási modellek esetében a SHAP-, partial-dependence vagy kettős gépi tanulás technikák segítik feltárni, mely változók mozgatják az eredményeket (Ahrens et al., 2025). A nagy nyelvi és képfeldolgozó modellek műholdképekből vagy szöveges korpuszokból másodpercek alatt állítanak elő strukturált inputot, ám az elemzők feladata, hogy a feketedoboz kimeneteit oksági keretbe illesszék (Haaland et al., 2025; Dell, 2025).

Mindez csak akkor működik, ha rendelkezésre áll a megfelelő emberi tőke. A vezető doktori programok gépi tanulás közgazdászoknak kurzusokat indítanak, a hallgatóknak pedig a programozástól a verziókezelésen át a kutatásetikáig széles eszköztárat kell elsajátítaniuk. A T-alakú készségprofil – széles technikai horizont, egy területen mély szakértelem – válik normává, amelyet gyakran munkahelyi akadémiák és mikroképzések támogatnak (Dawid et al., 2025).

A köz- és magánszféra együttműködése kulcsfontosságú: a titkosított vagy álnevesített vállalati adatállományok kutatási célú megosztása csökkenti a gyűjtési költségeket, miközben olyan részletgazdag információkhoz juttatja a döntéshozókat, amelyek nélkülözhetetlenek a célzott szakpolitikákhoz (Card et al., 2020). Cserébe a cégek benchmarking-elemzéseket kapnak, illetve befolyást gyakorolhatnak a szakpolitikai diskurzusra (Chetty et al., 2014).

Az adatvezérelt megközelítés etikai oldala sem hagyható figyelmen kívül. Mivel az algoritmusok korábbi adatokon tanulnak, könnyen újratermelhetik a múltbeli torzításokat, ami különösen érzékeny területeken – például hitelbírálathoz vagy munkaerő-felvételhez – igazságtalan kimenetekhez vezethet (Goldfarb, 2024). A mesterséges intelligenciára épülő árazási algoritmusok akár kartellszerű összejátszást is

elősegíthetnek, ezért a versenyhatóságoknak aktívan tesztelniük és – szükség esetén – korlátozniuk kell ezeket a megoldásokat (Harrington, 2025).

Ha a részletes adatok és a fejlett módszerek igazolhatóan jobb szakpolitikai beavatkozásokhoz – például célzottabb készségfejlesztéshez vagy hatékonyabb szociális programokhoz – vezetnek, akkor önmagát erősítő, tényeken alapuló döntéshozatali ciklus alakul ki (Card et al., 2010). A hatékonyságot olyan kulcsmutatók mérhetik, mint az adathozzáférés átlagos ideje, a reprodukálhatósági arány vagy a beavatkozások reakcióideje; a rendszeres külső audit pedig biztosítja, hogy a beruházások ne váljanak öncéllá.

Összességében az adat- és elemzőkapacitások fejlesztése nem luxus, hanem a modern közgazdasági kutatás és gazdaságirányítás sine qua nonja. A big data és a gépi tanulás páratlan lehetőséget kínál a gazdasági folyamatok mélyebb megértésére, de csak akkor válik valódi társadalmi haszonná, ha a technikai beruházások kéz a kézben járnak a humán kompetenciák bővítésével, a szigorú módszertani fegyelemmel és a bizalomépítő etikai keretekkel (Varian, 2014).

Etikai és társadalmi kérdések

A mesterséges intelligencia közgazdasági kutatásokba való beépülése új lehetőségeket teremt, ugyanakkor számos etikai és társadalmi feszültséget is okoz, amit nem hagyhatunk figyelmen kívül. Amennyiben a közgazdaság-tudomány nem vállalja fel az ezekkel kapcsolatos dilemmák feltárását, a technológiai fejlődés könnyen a meglévő egyenlőtlenségek megszilárdítójává válhat ahelyett, hogy a közjót szolgálja.

A legégetőbb kérdések egyike a torzítás problémája. Az MI-modellek korábbi adatmintákon tanulnak, így a múltbeli megkülönböztetések sokszor „beépülnek” a döntési szabályokba. A hitelbírálatban vagy a munkaerő-felvételben ez azzal fenyeget, hogy a pontos előrejelzés ürügyével folytatódik a hátrányos helyzetű csoportok kizárása (Goldfarb, 2024). Szabályozói és kutatói oldalról ezért standardizált torzításmérő mutatókra, rendszeres auditokra és olyan újraszűzőzési technikákra van szükség, amelyek csökkentik a diszkriminációt anélkül, hogy a predikciós teljesítményt drámaian visszafognák. A gyakorlatban eredményesnek bizonyultak az ún. árnyékmodellek, ahol a hagyományos ökonometria és az MI párhuzamosan fut, lehetővé téve a konzisztencia ellenőrzését.

Az adatvédelem képezi a második etikai pillért. A gazdasági elemzések rohamosan növekvő része érzékeny, személyes mikroadatokra támaszkodik; ezért az eti-

kai minimum az átlátható adatkezelési protokoll, a titkosítás és az álnevesítés. A szabályok be nem tartása nemcsak jogi kockázat, hanem reputációs veszteség is (Gans, 2025). Az eddigi tapasztalatok szerint a legnagyobb bizalomerősítő hatása annak van, ha a kutatók már a projekt kezdetén bevonják a felhasználói képviselőket, és nyilvános adat-hatásvizsgálatot készítenek a várható kockázatokról.

A harmadik fontos terület az átláthatóság és értelmezhetőség kérdése. A mélytanuló hálózatok és nagy nyelvi modellek – bár kiváló előrejelzők – gyakran feketedobozként működnek. Ha a szakpolitikus nem látja, milyen változók és milyen irányban mozgatják a kimenetet, a felelősségi lánc is elmosódik. Ez különösen kockázatos a költségvetési előrejelzéseknél, ahol a túlzott memorizálás félrevezető eredményt adhat (Lopez-Lira et al., 2025). Az interpretálhatósági kötelezettség ma már szaklapoknál is megjelenik: a tanulmányt csak akkor fogadják el, ha Shapley-vagy ellenpélda-alapú magyarázat társul hozzá (Head et al., 2023).

Negyedik szempontként említendő az előrejelzési képesség korlátainak felismerése. Az MI-modellek memorizálási hajlama – vagyis a múltbeli mintákhoz való túlzott igazodás – torzíthatja a jövőbeli gazdasági folyamatokat (Lopez-Lira et al., 2025). A kutatónak ezért nem engedhető meg a modellek kritikátlan elfogadása; folyamatos visszaméréssel kell ellenőriznie az előrejelzések érvényességét.

Az egyenlőtlenségek kérdése az ötödik kulcsfontosságú probléma. Az MI-technológiák fejlesztése és haszna elsősorban a nagyvállalatoknál és a fejlett országokban összpontosul, ami tovább mélyítheti a jövedelmi és vagyoni különbségeket (Korinek & Vipra, 2025). Ezzel párhuzamosan az automatizáció főként az alacsonyabb képzettséget igénylő, rutinszerű munkaköröket szorítja ki (Albanesi et al., 2025). A szakpolitika ezért kettős feladatot kap: a célzott átképzésekkel és hordozható szociális juttatásokkal csökkenteni kell a vesztesek kitettségét, miközben a piaci verseny biztosítása érdekében elő kell segíteni a kisebb szereplők MI-hozzáférését.

A hatodik dimenzió a versenyjogi kérdéseket érinti. Az MI-vezérelt árazási algoritmusok láthatatlan összejátszást eredményezhetnek, amely a fogyasztók kárára csökkenti a piaci verseny hatékonyságát (Harrington, 2025). A felügyeleti hatóságoknak aktívan kell tesztelniük ezeket a modelleket, és szükség esetén kötelezniük kell a készítőket a paraméterek vagy tanítási adatok átadására. A technológia határokön átvelő természete miatt azonban a nemzeti szintű szabályozás önmagában kevés: ha nincs koordináció, a cégek a legengedékenyebb jogrendszerbe menekülnek.

A bizalom mindezen kérdések szintéziseként jelenik meg. Ha az állampolgárok úgy érzik, hogy az MI-alapú döntések átláthatatlanok, igazságtalanok vagy tolagodók, a közpolitikai célkitűzések elveszítik legitimitásukat. A kutatóknak ezért

nemcsak technikai, hanem kommunikációs feladataik is vannak: közérthetően kell ismertetniük a módszerek korlátait és a kockázatsökkentő intézkedéseket.

Ezeknek a problémáknak a kezelése nem maradhat nemzeti keretek között. A technológia globális jellegű, így a szabályozás összehangolása – Georgieva (2024) megfogalmazásában – elengedhetetlen annak érdekében, hogy elkerüljük a legalacsonyabb etikai közös nevező felé haladó versengést. A nemzetközi együttműködés jelenti az egyetlen utat a kiegyensúlyozott, igazságos MI-használat felé.

Az MI-alapú beavatkozások hatását nem egyszeri hatástanulmányok, hanem folyamatos, valós idejű mérések alapján kell értékelni. Ha a jobb adatok valóban jobb döntésekhez vezetnek – például a célzott készségfejlesztésnél vagy a juttatási rendszerek finomhangolásánál –, akkor önfenntartó, adatvezérelt ciklus alakul ki (Card et al. 2010). Ehhez azonban fejlett adat-infrastruktúrára, közös szabványokra és a reprodukálhatóság kultúrájára van szükség (Varian, 2014).

A közgazdasági kutatás felelőssége tehát kettős természetű: egyidejűleg kell kihasználni a mesterséges intelligencia által kínált elemzési lehetőségeket, és örködni az etikai, társadalmi korlátokon. Csak így biztosítható, hogy a technológiai újítás ne a torzulásokat növelje, hanem a közjót szolgálja – miközben megőrzi a tudomány és a társadalom közös értékeit.

Gazdaságpolitikai következmények

A mai összefonódó világgazdaságban, ahol a technológia gyorsan fejlődik, és a foglalkoztatás szerkezete tartósan átalakul, olyan szakpolitikára van szükség, amely egyszerre támaszkodik megbízható tapasztalati tényekre és alaposan kidolgozott elméleti megfontolásokra. A gazdaságpolitikának alkalmazkodnia kell a munkavégzés változó formáihoz, az emberi képességek fejlesztésének új igényeihez és a termelékenység változásaihoz, hogy a jólét széles körben növekedhessen (Solow, 1957). A gazdasági növekedés fenntarthatósága szempontjából kulcsfontosságú, hogy a gazdaságpolitika rugalmasan reagáljon a gyorsan változó környezeti feltételekre, miközben biztosítja a társadalmi kohéziót és méltányosságot is.

A technológiai fejlődés és a globalizáció kettős hatással jár: egyrészt növeli a gazdasági teljesítményt a termelékenység javításával és új feladatok létrehozásával, másrészt átalakítja a hagyományos ágazatokat, és polarizálja a munkaerőpiacot a magas és alacsony képzettséget igénylő munkakörök között (Autor et al., 2003). A robotika és a mesterséges intelligencia jelentősen emelheti a hatékonyságot, ugyanakkor kiszoríthat rutinfeladatokat végző dolgozókat (Brynjolfsson, 2014). Bár az automa-

tizálás bizonyos munkaköröket megszüntet, új feladatokat is teremt, így részben el-lensúlyozza a munkahelyvesztéséget (Acemoglu & Restrepo, 2019). A döntéshozók feladata olyan átmeneti mechanizmusok kialakítása, amelyek segítik a munkavállalókat az ágazatok és foglalkozások közötti váltásban, miközben fenntartják az újí-tásokra ösztönző környezetet. Az új technológiák bevezetése során különös figyelmet kell fordítani arra, hogy a társadalom minden rétege részesülhessen az előnyökből, elkerülve a digitális szakadék további mélyülését (Goldin & Katz, 2010).

A munkaerőpiaci intézmények, mint a minimálbér, a kollektív tárgyalási rend-szerek és a foglalkoztatást védő szabályok kulcsszerepet játszanak a technológiai és globális változások elosztási hatásainak mérséklésében. A jól megtervezett bér-rendszer javíthatja az alacsony keresetűek helyzetét anélkül, hogy túlzott terhet róna a munkáltatókra. A túl magas vagy kiegészítő intézkedések nélküli bérminimum azonban gátolhatja a foglalkoztatás bővülését, és gyorsíthatja az automatizációt (Card et al., 2010). A bérszabályozást ezért össze kell hangolni a célzott készségfej-lesztéssel és a mobilitási támogatásokkal. Innovatív eszközként szolgálhat a bérki-egészítés vagy az átvihető juttatások rendszere a gyorsan változó ágazatokban (Autor et al., 2020). A kollektív szerződések új generációja figyelembe veheti a rugalmas munkavégzés sajátosságait, biztosítva a méltányos bérezést a hagyományostól eltérő foglalkoztatási formákban is.

Az oktatás régóta a növekedés és a társadalmi mobilitás alapköve (Goldin & Katz, 2008), de a gyors innováció miatt a megszerzett tudás gyorsabban elértékte-lenedik, így az élethosszig tartó tanulás vált normává. A technológiai előnyök a ma-gasabb képzettséggel rendelkezőket jutalmaznak, növelve a bérkülönbségeket (Autor et al., 2003). A képzési rendszereknek túl kell lépniük a hagyományos iskolai kere-teken, támogatva az átképzést, a pályaközepe továbbképzést és a moduláris képesí-téseket (Chetty et al., 2014). A helyi munkaadói igényekhez igazított programok és a növekvő ágazatok felé irányított képzés csökkenti a strukturális munkanélküliséget, miközben élénkíti a gazdaságot (Athey & Imbens, 2019). A tantervekben egyaránt fontos a szakmai és az emberi készségek fejlesztése, ami növeli a munkavállalók alkalmazkodóképességét. Az új oktatási technológiák és az online platformok lehe-tőséget nyújtanak a költséghatékony és személyre szabott tanulásra, csökkentve az elhelyezkedési nehézségek hosszú távú költségeit.

A rugalmas munkapiac, a gyakoribb munkahelyváltás és az alkalmi munkák („gig-gazdaság”) terjedése miatt újra kell gondolnunk a foglalkoztatáshoz kötött juttatások rendszerét. A munkanélküli-biztosítás, az étel-miszer-támogatás és az egészségügyi ellátás rövid távú védelmet nyújt, és stabilizálja a keresletet gazdasági

visszaesések idején (Card et al., 2010). A juttatások hordozhatósága csökkenti a váltásokból eredő bizonytalanságot anélkül, hogy akadályozná a mobilitást.

A feltörekvő ágazatok – például a tiszta energia és a fejlett gyártás – támogatása stratégiai megfontolást igényel. Ezek a beavatkozások magas hozzáadott értékű munkahelyeket és pozitív externáliákat teremthetnek, de magukban hordozzák a nyertesek kiválasztásának kockázatát is (Autor et al., 2020). A randomizált vagy kvázikísérleti módszerek segítik a programok hatékonyságának mérését, míg a gyenge eredményű beavatkozások rendszeres megszüntetése javítja az erőforrások elosztását (Mullainathan & Spiess, 2017).

A szabályozás minőségét egyre inkább az adat-infrastruktúra határozza meg. A valós idejű, álnevesített mikroadatbázisok lehetővé teszik a gyors hatásbecslést és a szabályozói tanulás felgyorsítását (Varian, 2014). Az állami és akadémiai intézményeknek együtt kell gyűjteniük az adminisztratív mikroadatokat, a vállalati paneladatokat és a longitudinális háztartási felméréseket, hogy pontos képet kapjanak a munkaerő-áramlásról, a bérek alakulásáról és a szociális transferek hatásáról (Groshen et al., 2017). E rendszerek természetes kísérletekkel és MI-alapú oksági gráfokkal kombinálva hónapokról napokra rövidítik a visszacsatolási ciklust, így a sikertelen programok gyorsan korrigálhatók, a sikeresek pedig skálázhatók (Athey & Imbens, 2019).

Az MI-vezérelt gazdasági átmenet kettős arcot mutat: hatékonysági nyereséget ígér, de a nyereségek elosztásától függ, hogy politikai konszenzust teremt-e, vagy ellenreakciókat vált ki. A munkaerőpiaci intézmények modernizálása, a célzott oktatáspolitikai, a versenybarát iparpolitika és az adatvezérelt kormányzás együtt képes a technológiai gyorsulást társadalmilag elfogadható pályára terelni. Ha e négy pillér koherens rendszert alkot, a produktív nyereség nem csupán a részvényesi értéket, hanem a széles értelemben vett társadalmi jólétet is növeli, megerősítve a technológia és a közjó közötti társadalmi szerződést.

Összefoglalás, következtetések

Az áttekintett tanulmányok egybehangzó következtetése szerint a mesterséges intelligencia (MI) nem tekinthető sem csodafegyvernek, amely egy csapásra feleslegessé tenné a közgazdaság-tudományi hagyományt, sem olyan veszélyforrásnak, amely alapjaiban kérdőjelezné meg a tudományterület létjogosultságát. Az MI sokkal inkább katalizátorként működik: miközben kitágítja az empirikus kutatás lehe-

tősegeit, egyúttal fel is erősíti a régóta fennálló problémákat – különösen az oksági azonosítás, a társadalmi egyenlőtlenség és a kormányzás területén.

Az első fontos tanulság, hogy a pontos előrejelzés nem feltétlenül jelent megbízható oksági következtetést. A munkaerőpiaci kutatások rámutatnak arra, hogy a transzformálandó neurális hálózatok ugyan pontosabban jelzik előre a munkakörök átalakulását, mint a készségeitől építő hagyományos mutatók, a jóléti hatások értékelése továbbra is kvázikísérleti rugalmassági becsléseken múlik. Hasonlóképpen, a makrogazdasági valós idejű előrejelzések (*nowcasting*) területén a *sequence-to-sequence* modellek kisebb hibával működnek az állapottermodelleknél, azonban paramétereik millióit nem lehet közvetlenül értelmezhető strukturális együtthatókká alakítani. A szakpolitikai döntésekhez szükséges diagnózis tehát továbbra is átlátható kutatási módszertanra és elméletileg megalapozott ellentényekre épül, függetlenül az alkalmazott programkód összetettségétől. A közgazdászoknak ezért egyfajta kétnyelvűséget kell elsajátítaniuk: ismerniük kell a mélytanulás technikáit, de érteniük kell az oksági elemzés logikáját is.

A második tanulság az ösztönzők rendszerének fontosságát emeli ki. Az iparági elemzések azt mutatják, hogy a profitmaximalizálásra programozott megerősítéses tanulás alapú algoritmusok akár hallgatólagos összejátszást is eredményezhetnek – még olyan piacokon is, amelyek elvileg versengőek. A közzféra sem mentes hasonló kockázatoktól: ha egy támogatási rendszer algoritmusában olyan történeti adatokon tanul, amelyek hátrányos helyzetű csoportokkal szemben diszkriminatívak voltak, akkor újratermeli ezeket a hátrányokat. A technikai megoldások – mint az audit-adatbázisok, méltányossági korlátok vagy magyarázhatósági eszközök – szükségessé ugyan, de önmagukban nem elegendőek. Valódi elszámoltathatóságot csak a nyilvánosság, a rendszeres algoritmikus hatásvizsgálatok, valamint a verseny- és antidiszkriminációs szabályok hatékony érvényesítése teremthet.

A harmadik tanulság az egyenlőtlenség hozzáférés problémája. A felhőalapú neurális előrejelző rendszerek jelentős előnyt biztosítanak azoknak a jegybankoknak és intézményeknek, amelyek bőséges valós idejű adatforrásokhoz és szakképzett elemzői gárdához férnek hozzá, miközben számos alacsony jövedelmű ország még az alapvető adatok digitalizálásával is küzd. Ha a nyílt forráskódú megoldások, a számítási kapacitás és a gyakorlatorientált képzés nem válik széles körben elérhetővé, az MI tovább mélyítheti az intézményi szakadékokat. Az MI-eszközök demokratizálása tehát nem pusztán jótétemény, hanem az adatintenzív kormányzás alapvető feltétele.

E tapasztalatok alapján három kutatási prioritás körvonalazódik: (i) Módszertani szempontból világos szabályokat kell kialakítani annak megítélésére, mikor haladja meg egy rugalmas modell átláthatatlansága annak előrejelzési előnyeit; a kauzális erdők, az ellentényeken alapuló szimulációk és a Shapley-attribúciók rendszerszintű értékelést igényelnek. (ii) Intézményi szinten a tudományos folyóiratoknak érdemes olyan bírálati rendszert alkalmazniuk, amely egyaránt épít a klasszikus ökonometriai és a modern gépi tanulási szakértelemre, hogy a tanulmányokat mind az azonosítási robusztusság, mind a számítástechnikai megoldások minősége szerint értékelhessék. (iii) A doktori képzésben integrálni kell az oksági következtetés, a nagy teljesítményű számítástechnika és az etikai reflexió területeit: a jövő közgazdászainak képesnek kell lenniük kinyitni az algoritmusok feketedobozát – és tudniuk kell azt is, mikor célszerű zárva hagyni.

Összefoglalva: az MI már most is jelentősen átalakítja, hogy a közgazdászok mit és hogyan figyelnek, jósolnak és ajánlanak; azonban nem teszi feleslegessé a szakma hagyományos erősségeit az oksági elemzés, az intézményi sajátosságok feltárása és a jóléti hatások értékelése terén. Ha a közgazdaságtan kiegészítő eszközként – nem pedig pótlékként – tekint az MI-re, miközben folyamatosan figyelemmel kíséri a potenciális torzítások, az átláthatatlanság és a hozzáférési egyenlőtlenségek kockázatait, a technológia társadalmi haszna valóban kiaknázható. A kihívás – ahogy azt a teljes áttekintés hangsúlyozza – abban rejlik, hogy ezek az új eszközök tágítsák perspektívánkat anélkül, hogy elhomályosítsanak azt az intézményi-etikai környezetet, amelyben a gazdasági folyamatok végső soron zajlanak.

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. (2019). Automation and new tasks: How technology displaces and reinstates labor. *Journal of Economic Perspectives*, 33(2), 3–30. <https://www.aeaweb.org/articles/pdf/doi/10.1257/jep.33.2.3>
- Ahrens, A., Chernozhukov, V., Hansen, C., Kozbur, D., Schaffer, M., & Wiemann, T. (2025). An Introduction to Double/Debiased Machine Learning. *arXiv preprint arXiv:2504.08324*. <https://doi.org/10.48550/arXiv.2504.08324>
- Albanesi, S., da Silva, A. D., Jimeno, J. F., Lamo, A., & Wabitsch, A. (2025). *AI and women's employment in Europe* (Working Paper No. w33451). National Bureau of Economic Research. https://www.nber.org/system/files/working_papers/w33451/w33451.pdf
- Albanesi, S., da Silva, A. D., Jimeno, J. F., Lamo, A., & Wabitsch, A. (2025). New technologies and jobs in Europe. *Economic Policy*, 40(121), 71–139. <https://doi.org/10.1093/epolic/eiae058>

- Asatryan, Z., Birkholz, C., & Heinemann, F. (2025). Evidence-based policy or beauty contest? An LLM-based meta-analysis of EU cohesion policy evaluations. *International Tax and Public Finance*, 32(2), 625–655. <https://doi.org/10.1007/s10797-024-09875-4>
- Ash, E., & Hansen, S. (2023). Large language models for economic research: Four key questions. *VOX CEPR Policy Portal*. <https://www.research-collection.ethz.ch/handle/20.500.11850/652077>
- Athey, S., & Imbens, G. W. (2019). Machine learning methods that economists should know about. *Annual Review of Economics*, 11, 685–725. <https://doi.org/10.1146/annurev-economics-080217-053433>
- Autor, D., Goldin, C., & Katz, L. F. (2020, May). Extending the race between education and technology. *AEA Papers and Proceedings*, 110, 347–351. <https://doi.org/10.1257/pandp.20201061>
- Autor, D., Levy, F., & Murnane, R. (2003). The skill content of recent technological innovation: An empirical investigation. *Quarterly Journal of Economics*, 118(4), 1279–1333. <https://doi.org/10.1162/003355303322552801>
- Best, E., Robles, P., & Mallinson, D. J. (2024). The future of AI politics, policy, and business. *Business and Politics*, 26(2), 171–179. <https://doi.org/10.1017/bap.2024.6>
- Bickley, S. J., Chan, H. F., & Torgler, B. (2022). Artificial intelligence in the field of economics. *Scientometrics*, 127(4), 2055–2084. <https://doi.org/10.1007/s11192-022-04294-w>
- Bonfiglioli, A., Crinò, R., Gancia, G., & Papadakis, I. (2025). Artificial intelligence and jobs: Evidence from US commuting zones. *Economic Policy*, 40(121), 145–194. <https://doi.org/10.1093/epolic/eiae059>
- Brynjolfsson, E. (2014). *The second machine age: Work, progress, and prosperity in a time of brilliant technologies*. W. W. Norton & Company.
- Calvano, E., & Calzolari, G. (2025). AI and policy: What makes AI different? *Economic Policy*, 40(121), 1–8. <https://doi.org/10.1093/epolic/eiae067>
- Card, D., Kluve, J., & Weber, A. (2010). Active labour market policy evaluations: A meta-analysis. *The Economic Journal*, 120(548), F452–F477. <https://doi.org/10.1111/j.1468-0297.2010.02387.x>
- Chan, H. L., & Choi, T. M. (2025). Using generative artificial intelligence (GenAI) in marketing: Development and practices. *Journal of Business Research*, 191, 115276. <https://doi.org/10.1016/j.jbusres.2025.115276>
- Chetty, R., Hendren, N., Kline, P., & Saez, E. (2014). Where is the land of opportunity? The geography of intergenerational mobility in the United States. *The Quarterly Journal of Economics*, 129(4), 1553–1623. <https://doi.org/10.1093/qje/qju022>
- Cillo, P., & Rubera, G. (2024). Generative AI in innovation and marketing processes: A roadmap of research opportunities. *Journal of the Academy of Marketing Science*, 1–18. <https://doi.org/10.1007/s11747-024-01044-7>
- Dawid, H., Harting, P., Wang, H., Wang, Z., & Yi, J. (2025). Agentic workflows for economic research: Design and implementation. *arXiv Preprint*, arXiv:2504.09736. <https://doi.org/10.48550/arXiv.2504.09736>
- Dell, M. (2025). Deep learning for economists. *Journal of Economic Literature*, 63(1), 5–58. <https://doi.org/10.1257/jel.20241733>
- Eisfeldt, A. L., & Schubert, G. (2024). *AI and finance* (Working Paper No. w33076). National Bureau of Economic Research. https://www.nber.org/system/files/working_papers/w33076/w33076.pdf
- Feyzollahi, M., & Rafizadeh, N. (2025). The adoption of large language models in economics research. *Economics Letters*, 250, 112265. <https://doi.org/10.1016/j.econlet.2025.112265>
- Gans, J. S. (2025). How learning about harms impacts the optimal rate of artificial intelligence adoption. *Economic Policy*, 40(121), 199–219. <https://doi.org/10.1093/epolic/eiae053>
- Garg, P., & Fetzer, T. (2025). Causal claims in economics. *arXiv Preprint*, arXiv:2501.06873. <https://arxiv.org/pdf/2501.06873>
- Georgieva, K. (2024). AI will transform the global economy. Let’s make sure it benefits humanity. *IMF Blog*. <https://www.imf.org/en/Blogs/Articles/2024/01/14/ai-will-transform-the-global-economy-lets-make-sure-it-benefits-humanity>

- Goldfarb, A. (2024). Pause artificial intelligence research? Understanding AI policy challenges. *Canadian Journal of Economics*, 57(2), 363–377. <https://doi.org/10.1111/caje.12705>
- Goldin, C., & Katz, L. F. (2008). *The race between education and technology*. Harvard University Press.
- Haaland, I., Roth, C., Stantcheva, S., & Wohlfart, J. (2025). *Understanding economic behavior using open-ended survey data* (Discussion Paper No. 362). ECONtribute. https://www.econtribute.de/RePEc/ajk/ajkdps/ECONtribute_362_2025.pdf
- Hagi, A., & Wright, J. (2025). Artificial intelligence and competition policy. *International Journal of Industrial Organization*, 103134. <https://doi.org/10.1016/j.ijindorg.2025.103134>
- Harrington Jr., J. E. (2025). An economic test for an unlawful agreement to adopt a third-party's pricing algorithm. *Economic Policy*, 40(121), 261–295. <https://doi.org/10.1093/epolic/eiae054>
- Head, C. B., Jasper, P., McConnachie, M., Raftree, L., & Higdon, G. (2023). Large language model applications for evaluation: Opportunities and ethical implications. *New Directions for Evaluation*, 2023(178–179), 33–46. <https://doi.org/10.1002/ev.20556>
- Hermann, E., & Puntoni, S. (2024). Artificial intelligence and consumer behavior: From predictive to generative AI. *Journal of Business Research*, 180, 114720. <https://doi.org/10.1016/j.jbusres.2024.114720>
- Korinek, A. (2023). Generative AI for economic research: Use cases and implications for economists. *Journal of Economic Literature*, 61(4), 1281–1317. <https://doi.org/10.1257/jel.20231736>
- Korinek, A. (2024). LLMs learn to collaborate and reason: December 2024 update to “Generative AI for economic research: Use cases and implications for economists.” *Journal of Economic Literature*, 61(4). <https://www.aeaweb.org/content/file?id=21904>
- Korinek, A., & Vipra, J. (2025). Concentrating intelligence: Scaling and market structure in artificial intelligence. *Economic Policy*, 40(121), 225–256. <https://doi.org/10.1093/epolic/eiae057>
- Kwon, B., Park, T., Perez-Cruz, F., & Rungcharoenkitkul, P. (2024). Large language models: A primer for economists. *BIS Quarterly Review*, 37. https://www.bis.org/p/s0/embargo/qt2412b_emb.pdf
- Lopez-Lira, A., Tang, Y., & Zhu, M. (2025). The memorization problem: Can we trust LLMs' economic forecasts? *arXiv Preprint*, arXiv:2504.14765. <https://arxiv.org/abs/2504.14765>
- Ludwig, J., Mullainathan, S., & Rambachan, A. (2025). *Large language models: An applied econometric framework* (Working Paper No. w33344). National Bureau of Economic Research. https://www.nber.org/system/files/working_papers/w33344/w33344.pdf
- Mullainathan, S., & Spiess, J. (2017). Machine learning: An applied econometric approach. *Journal of Economic Perspectives*, 31(2), 87–106. <https://www.aeaweb.org/articles/pdf/doi/10.1257/jep.31.2.87>
- Obschonka, M., & Levesque, M. (2024). A market for lemons? Strategic directions for a vigilant application of artificial intelligence in entrepreneurship research. *arXiv Preprint*, arXiv:2409.08890. <https://arxiv.org/pdf/2409.08890>
- Solow, R. M. (1957). Technical change and the aggregate production function. *Review of Economics and Statistics*, 39(3), 312–320. <https://doi.org/10.2307/1926047>
- Varian, H. R. (2014). Big data: New tricks for econometrics. *Journal of Economic Perspectives*, 28(2), 3–28. <https://www.aeaweb.org/articles/pdf/doi/10.1257/jep.28.2.3>
- Zheng, Y., Xu, Z., & Xiao, A. (2023). Deep learning in economics: A systematic and critical review. *Artificial Intelligence Review*, 56(9), 9497–9539. <https://doi.org/10.1007/s10462-022-10272-8>