

A BANKSEKTOR SAJÁT AI-LÁBNYOMA

A mesterségesintelligencia-alkalmazás energia- és karbonhatásai a hitelintézeti működésben

Bagó Péter¹

ABSZTRAKT

A bankszektor az elmúlt évtizedben a finanszírozott kibocsátások (Scope 3) mérésével és a portfóliók dekarbonizációjával a fenntarthatósági átmenet egyik kulcsszereplőjévé vált. Ezzel párhuzamosan azonban a hitelintézetek saját működésében robbanásszerűen terjednek a mesterségesintelligencia- (AI-) megoldások – az ügyfélszolgálati chatbotoktól a hitelkockázati modelleken át az ágensalapú, több munkafolyamat-lépést automatizáló rendszerekig –, amelyek energia- és erőforrásigénye a szektor saját környezeti lábnyomának eddig alig vizsgált, dinamikus növekvő komponensét képezi. A tanulmány célja hármas: egyrészt áttekinti az AI-rendszerek életciklus-alapú környezeti hatásainak (tanítás, következtetés, beágyazott kibocsátások, víz- és erőforrás-felhasználás) nemzetközi szakirodalmát és mérési módszertanait; másrészt bemutatja, hogy a banki AI-adopció jelenlegi trendjei – különösen a generatív és ágensalapú AI térnyerése – hogyan hatnak a hitelintézetek Scope 2 és Scope 3 kibocsátási kategóriáira, és kilenc hitelintézet 2025. évi közzétételének feltáró dokumentumelemzésével empirikusan igazolja, hogy az AI-hoz köthető energiafelhasználás a jelenlegi jelentéstételi gyakorlatban nem azonosítható; harmadrészt módszertani keretet javasol a „banki AI-lábnyom” számszerűsítésére és a fenntarthatósági jelentéstételbe (CSRD/ESRS) történő integrálására. A tanulmány mellett érvel, hogy a szektornak a „zöldítés AI-jal” (greening by AI) narratívája mellett a „zöld AI” (greening of AI) szempontrendszerét is intézményesítenie kell: az AI-beszerzési döntésekben, a modell-méretezésben és a felhőszolgáltatói szerződésekben megjelenő energetikai kritériumok nélkül a digitális transzformáció alááshatja a bankok saját klímacéljainak hitelességét.

JEL-kódok: G21, O33, Q54, Q56, M14

Kulcsszavak: mesterséges intelligencia, bankszektor, karbonlábnyom, adatközpontok, ESG, fenntarthatósági jelentéstétel, CSRD, EU AI-rendelet

¹ Bagó Péter egyetemi adjunktus, Budapesti Corvinus Egyetem, Vállalkozás és Innováció Intézet, Innováció és Üzleti Inkubáció Tanszék. E-mail: peter.bago@uni-corvinus.hu.

1. BEVEZETÉS

A pénzügyi szektor klímapolitikai szerepéről szóló diskurzus az elmúlt évtizedben szinte kizárólag a bankok *közvetett*, finanszírozási tevékenységen keresztüli környezeti hatására összpontosított. Ez érthető: a hitelintézetek üvegházhatásúgáz- (ÜHG-) profilját túlnyomórészt a hitel- és befektetési portfóliókhoz kapcsolódó, úgynevezett finanszírozott kibocsátások (Scope 3, 15. kategória) dominálják, míg a saját működésből származó közvetlen (Scope 1) és az energiafelhasználáshoz kötődő közvetett (Scope 2) kibocsátások aránya jellemzően elenyésző (PCAF, 2022). A hazai nagybankok ESG-közzétételi gyakorlatát elemző korábbi kutatások is elsősorban a portfóliószintű kockázatok és a közzétételek tartalmi érettsége felől közelítettek (Vőneki–Lamanda, 2020), miközben a zöld pénzügyi innovációk irodalma a technológiát jellemzően a fenntarthatósági célok *eszközeként*, nem pedig környezeti hatások *forrásaként* tárgyalja (Horváth, 2022).


Ez a megközelítés azonban egyre kevésbé teljes. A bankszektor digitális transzformációja – amelynek stratégiai kereteit a hazai szakirodalom már a generatív AI megjelenése előtt kijelölte (Vives, 2019) – a 2022 végén megindult generatív mesterségesintelligencia-hullámmal új szakaszába lépett, és a pénzügyi szektort a technológia egyik legintenzívebb vállalati alkalmazójává tette (ECB, 2024). Az AI banki felhasználásának lehetőségeit és kockázatait a nemzetközi intézményi irodalom már korán feltérképezte (EBA, 2020; FSB, 2017; Königstorfer–Thalmann, 2020; OECD, 2021), a legújabb szisztematikus áttekintések pedig a csődelőrejelzéstől a kockázatkezelésen át az ügyfélkapcsolatok optimalizálásáig terjedő alkalmazási spektrumot dokumentálnak (Aldasoro et al., 2024; Cao, 2022; Fares et al., 2023; Lülök–Sebestyén, 2025). A világ legnagyobb bankjainak AI-érettségét mérő Evident AI Index adatai szerint a nyilvánosan bejelentett banki AI-alkalmazások száma negyedévről negyedévre nő, és 2026 első negyedévében már az új használati esetek közel harmada úgynevezett ágensalapú (agentic) alkalmazás volt, amely nem egyetlen feladatot, hanem több munkafolyamat-lépést automatizál (Evident, 2026).

Az AI-alkalmazások mögött álló számítási infrastruktúra energiaigénye eközben a globális villamosenergia-kereslet egyik leggyorsabban növekvő tételévé vált. Az infokommunikációs technológiák (IKT) energiafelhasználásának hosszú távú növekedési pályáját a szakirodalom már a 2010-es évek közepén jelezte (Andrae–Edler, 2015; Belkhir–Elmeligi, 2018; Jones, 2018; Malmodyn–Lundén, 2018), a hatékonysági tartalékok kimerülésére és a becslések módszertani vitáira pedig többen felhívták a figyelmet (Freitag et al., 2021; Koomey et al., 2011; Masanet et al., 2020; Mytton–Ashtine, 2022). A generatív AI ezt a pályát megtörte: a Nemzetközi Energiaügynökség (IEA) becslése szerint az adatközpontok globális villamosenergia-fogyasztása a 2024. évi mintegy 415 TWh-ról 2030-ra megközelítőleg 945

TWh-ra emelkedhet, és e növekedés legnagyobb részét az AI-munkaterhelések adják (IEA, 2025); az Egyesült Államokban az adatközpontok részaránya a nemzeti villamosenergia-fogyasztásból 2028-ra a 2023. évi 4,4%-ról akár 12%-ra nőhet (Shehabi et al., 2024). A várható pályát az 1. ábra szemlélteti.

1. ábra

Az adatközpontok globális villamosenergia-fogyasztása és várható pályája, 2020–2030 (TWh/év)



Forrás: IEA (2025) alapján saját szerkesztés; a 2024. és 2030. évi érték az IEA becslése, a közbenső évek interpolált pályát jelölnek.

E két trend metszéspontjában áll a jelen tanulmány tárgya: a bankszektor saját AI-lábnyma, vagyis az a környezeti – mindenekelőtt energia-, karbon-, víz- és erőforrás- – hatás, amely a hitelintézetek által fejlesztett, beszerzett és üzemeltetett AI-rendszerek teljes életciklusából ered. A kérdés több szempontból is aktuális. Először: a bankok saját működési kibocsátása abszolút értékben ugyan kicsi a finanszírozott kibocsátásokhoz képest, de az AI-adopció üteme mellett a Scope 2 és a beszerzett szolgáltatásokhoz köthető Scope 3 kategóriák szerkezete és dinamikája is átalakulhat, ami a karbonsemlegességi vállalások (net zero own operations) teljesíthetőségét érinti. Másodszor: az Európai Unió fenntarthatósági jelentéstételi (CSRD/ESRS) és AI-szabályozási keretei (2024/1689/EU rendelet, a továbbiakban: AI-rendelet) egyaránt tartalmaznak – részben még formálódó – energetikai transzparenciakövetelményeket, amelyek a bankokat mint AI-alkalmazókat (deployereket) is elérik. Harmadszor: a szektor reputációs kockázata szempontjából nem tartható fenn tartósan az az aszimmetria, hogy a bankok ügyfeleiktől részletes klímaadatokat és átállási terveket várnak el, miközben saját digitális működésük környezeti hatásáról nem vagy csak töredékesen számolnak

be. A tanulmány központi kutatási kérdése ennek megfelelően a következő: miként határozható meg és integrálható a banki AI-portfólió környezeti lábnyoma a vállalati ÜHG-számvitelbe és a fenntarthatósági jelentéstételbe? E kérdést három alkérdés bontja ki: (i) hol húzódnak a számbavétel határai, azaz mely életciklus-elemek és mely hatáscsatornák tartoznak a banki lábnyomba (2. és 5.1. *alfejezetek*); (ii) milyen adatforrások állnak ténylegesen rendelkezésre, és ezek milyen módszertani korlátokkal terheltek (2.3., 2.4. *alfejezetek*); (iii) hogyan tér el a számbavétel az AI-hoz való hozzáférés módja – saját infrastruktúra, felhő, illetve API-alapú modellszolgáltatás – szerint (5.1. *alfejezet*).

Fontos rögzíteni a tanulmány empirikus státuszát. A 3.3. *alfejezet* feltáró dokumentumelemzést tartalmaz: kilenc hitelintézet 2025. üzleti évre vonatkozó közzétételének egységes szempontok szerinti elemzését. Ez a minta kicsi, nem véletlen kiválasztású és nem reprezentatív a hazai bankszektorra; célja annak megállapítása, hogy a jelenlegi közzétételi gyakorlat *elvben* láthatóvá teszi-e az AI-lábnyomot – nem pedig annak mérése, hogy az mekkora. Banki energiaszolgáltatási vagy kibocsátási adatokon végzett mérést a tanulmány nem tartalmaz, és a javasolt keretrendszer empirikus validálása sem történt meg. Az 5.2. *alfejezetben* szereplő, 5000 fős bankcsoportra vonatkozó számpélda kizárólag stilizált illusztráció, amely a keretrendszer alkalmazhatóságát és a paraméterbizonytalanság nagyságrendjét hivatott bemutatni; értékei nem tekintendők sem becslésnek egy konkrét intézményre, sem szektorszintű adatnak.

A tanulmány elsődleges hozzájárulása ennek megfelelően fogalmi és módszertani, és két elemből áll. Egyrészt a három irodalmi hagyomány szétszórt eredményeinek szintéziséből. Másrészt – és ez a tanulmány gerince – az 5. *fejezetben* kifejtett, hozzáférési mód szerinti háromszintű számbavételi keretrendszerből (saját infrastruktúra, felhő, API-alapú modellszolgáltatás), a hozzá rendelt Scope-besorolással, explicit rendszerhatárokkal és a sávós, forgatókönyv-alapú becslési eljárással, valamint ennek fenntarthatósági jelentéstételbe történő beillesztésére vonatkozó javaslatból. A 3.3. *alfejezet* empirikus áttekintése ezt a javaslatot nem validálja, hanem a szükségességét indokolja.

A tanulmány felépítése a következő. Az 1.1. *alfejezet* a forrásgyűjtés módszertanát dokumentálja. A 2. *fejezet* az AI-rendszerek környezeti lábnyomának fogalmi kereteit és mérési módszertanait tekinti át, külön alfejezetben értékelve a felhőszolgáltatók ügyfélszintű karbonallokációs gyakorlatát. A 3. *fejezet* a banki AI-adopció nemzetközi és hazai trendjeit elemzi a környezeti hatás szempontjából releváns dimenziók mentén, és kilenc hitelintézet 2025. évi közzétételének áttekintésével empirikusan is vizsgálja az AI-lábnyom láthatóságát. A 4. *fejezet* a szabályozási környezetet – az AI-rendelet, a CSRD/ESRS és a kapcsolódó adatközponti szabályozás – vonatkozó rendelkezéseit rendszerezi. Az 5. *fejezet* módszertani keretet javasol a banki AI-lábnyom becslésére, illusztratív számpéldával.

A 6. fejezet a nettó hatás kérdését – az AI fenntarthatósági alkalmazásainak és saját lábnyomának egyenlegét – tárgyalja, a 7. fejezet a várható fejlődési pályákat, valamint az ezekből következő vezetési és szabályozási javaslatokat tárgyalja, a 8. fejezet összegez.

1.1. A tanulmány módszertana és a forrásgyűjtés folyamata

A tanulmány műfaja célzott narratív szakirodalmi áttekintés (targeted narrative literature review), amely fogalmi keretalkotásra és módszertani javaslatlételle irányul; nem szisztematikus áttekintés, és nem törekszik a releváns irodalom teljes körű, protokoll szerinti feltárására. E műfajválasztást a tárgy interdiszciplináris jellege indokolja: a vizsgált kérdés három, egymással eddig alig érintkező irodalmi hagyomány – az AI környezeti hatásaival foglalkozó számítástechnikai és energetikai kutatás, a banki AI-adopció pénzügyi szakirodalma, valamint az ESG-jelentéstétel és a klímaszabályozás irodalma – metszetében helyezkedik el, ahol egységes kulcsszókészlettel dolgozó szisztematikus keresés nem vezetne teljes lefedettséghez.

A forrásgyűjtés a Scopus, a Web of Science és a Google Scholar adatbázisokban, valamint az érintett intézmények (IEA, OECD, BIS, EKB, EBH, Európai Bizottság, MNB) hivatalos közzétételi felületein történt. A keresés angol és magyar nyelvű kulcsszavakkal, azok kombinációiban zajlott. A főbb keresőkifejezések: *AI energy consumption, carbon footprint of machine learning, green AI, data centre electricity demand, inference energy, embodied emissions computing, AI in banking, generative AI financial services, Scope 3 financial institutions, CSRD ESRS climate disclosure, EU AI Act energy*, illetve magyarul *mesterséges intelligencia bankszektor, karbonlábnyom, ESG-közzététel*. A magyar nyelvű irodalom feltárása kiegészült a *Hitelintézeti Szemle*, a *Gazdaság és Pénzügy* és a *Vezetéstudomány* archívumainak tematikus áttekintésével.

Az időhatár differenciált. A technológiai és energetikai forrásoknál a 2015–2026 közötti időszakra szorítkoztunk, mivel a mély tanulás energiaigényére vonatkozó mérések ennél korábban nem relevánsak a mai modellméretek mellett; a fogalmi és számviteli alpművek (például az ÜHG Protokoll) esetében nem alkalmaztunk időhatárt; a banki AI-adopcióra és a szabályozási környezetre vonatkozó forrásoknál pedig – a terület gyors változása miatt – elsősorban a 2020 utáni, ezen belül is a legfrissebb elérhető kiadványokat vettük figyelembe.

A kiválasztás elve a *releváns metszet* volt: bekerült minden olyan forrás, amely (i) az AI-rendszerek energia- vagy kibocsátási hatásának mérésével, (ii) a pénzügyi szektor AI-alkalmazásával, vagy (iii) a kettő szabályozási-jelentéstételi kapcsolódásával foglalkozik, és amelynek megállapításai a hitelintézeti működés szintjére

értelmezhetők. Kizártuk a csak modellarchitektúrával, algoritmikus teljesítménnyel vagy a finanszírozott kibocsátások módszertanával foglalkozó munkákat, amennyiben környezeti, illetve saját működési vonatkozásuk nem volt.

A tanulmány három forrástípust különböztet meg, és ezeket eltérő bizonyító erővel kezeli. (a) *Lektorált tudományos források* – folyóiratcikkek és konferenciaközlemények –, amelyek az érvelés empirikus és fogalmi alapját adják. (b) *Intézményi és szabályozási dokumentumok* (IEA, OECD, BIS, EKB, MNB, uniós jogforrások, szabványok), amelyek elsődleges forrásként szolgálnak a szabályozási környezet és az energetikai aggregátumok bemutatásához. (c) *Iparági és tanácsadói elemzések* (Evident, McKinsey), amelyek nem esnek át tudományos lektoráláson, adatgyűjtési módszertanuk csak részben nyilvános, teljes adatbázisuk pedig előfizetéshez kötött; ezeket kizárólag a piaci adopcio mértékének és irányának illusztrálására használjuk, önálló bizonyító erőt nem tulajdonítva nekik. A megkülönböztetést az irodalomjegyzék szögletes zárójeles jelöléssel is tükrözi.

Az áttekintés korlátai a műfajból következnek: a forráskiválasztás nem protokollvezérelt, ezért a szerzői szelekció torzítása nem zárható ki; a gyorsan változó szabályozási dokumentumok (különösen a 2026-os bizottsági konzultáció és a kapcsolódó szabványosítási folyamat) státusza a kézirat lezárásakor érvényes állapotot tükrözi; a fajlagos energiaértékekre vonatkozó irodalmi adatok pedig – amint azt a 2.3. alfejezet részletezi – maguk is jelentős módszertani bizonytalansággal terheltek.

2. AZ AI-RENDSZEREK KÖRNYEZETI LÁBNYOMA: FOGALMI KERETEK ÉS MÉRÉSI KIHÍVÁSOK

2.1. Az AI-életciklus energiaigénye: tanítás és következtetés

Az AI-rendszerek környezeti hatásának elemzése célszerűen az életciklus-szemléletből indul ki. A gépi tanulási modellek – és különösen a nagy nyelvi modellek (large language models, LLM) – életciklusában energetikai szempontból két fő működési fázis különíthető el: a tanítás (training) és a következtetés (inference).


A tanítási fázis energiaigénye a modellek méretének növekedésével látványosan emelkedett. A természetesnyelv-feldolgozó modellek tanításának karbonköltségére elsőként Strubell et al. (2019) hívta fel széles körben a figyelmet, kimutatva, hogy egyetlen nagy modell hiperparaméter-kereséssel kombinált tanítása több személyautó teljes életciklus-kibocsátásával összemérhető ÜHG-kibocsátással járhat. A jelenség hátterében a gépi tanulás számítási igényének exponenciális – a 2010-es évektől néhány havonta megduplázódó – növekedése áll (Sevilla et

al., 2022), miközben a pontosságjavulás határkölsége számítási és energetikai értelemben egyre meredekebben emelkedik (Thompson et al., 2021). A „mindig nagyobb modell” fejlesztési paradigma környezeti és társadalmi költségeit a kritikai irodalom is korán tematizálta (Bender et al., 2021; Crawford, 2021), és ennek nyomán fogalmazódott meg a „zöld AI” kutatási programja, amely a pontosság mellett a számítási hatékonyságot is elsőrendű tudományos értékelési szemponttá emelné (Schwartz et al., 2020). A számszerűsítést módszertani eszközök is támogatják: a gépi tanulási kísérletek kibocsátásának becslésére kalkulátorok (Lacoste et al., 2019) és szisztematikus riportolási keretek (Henderson et al., 2020) születtek. Későbbi becslések szerint a GPT-3 modell tanítása nagyságrendileg 1 300 MWh villamos energiát igényelt, ami – a felhasznált villamosenergia-mix karbonintenzitásától függően – több száz tonna CO₂-kibocsátásnak felelt meg (Patterson et al., 2021); a nyílt fejlesztésű BLOOM modell részletes életcikluselemzése pedig azt is megmutatta, hogy a működési energián túl a beágyazott és az üresjáratú fogyasztás is érdemi tétel (Luccioni et al., 2023). A tanítás azonban egyszeri (illetve modellverzióként ismétlődő) tétel, amely az alapmodell-fejlesztőknél (foundation model providers) jelentkezik; a bankok túlnyomó többsége nem tanít saját alapmodellt, hanem előtanított modelleket finomhangol, illetve API-n vagy felhőszolgáltatáson keresztül vesz igénybe.

A banki AI-lábnym szempontjából ezért a következtetési fázis a meghatározó: minden egyes lekérdezés, dokumentumelemzés, kódgenerálás vagy chatbot-interakció számítási kapacitást és energiát fogyaszt, és e fogyasztás a felhasználásszám növekedésével lineárisnál gyorsabban is skálázódhat (például hosszabb kontextusablakok, többlépéses ágensfolyamatok esetén). Luccioni et al. (2024) mérései szerint a generatív, általános célú modellek egy-egy következtetési művelete nagyságrendekkel energiaigényesebb lehet a hagyományos, feladat-specifikus modellekénél, a kutatói becslések pedig már a technológia korai szakaszában jelezték, hogy tömeges elterjedés esetén az inferencia összesített energiafelhasználása meghaladja a tanítást (de Vries, 2023; Desislavov et al., 2023; Wu et al., 2022). Az IEA (2024) sokat idézett összehasonlítása szerint egy generatív AI-lekérdezés fajlagos villamosenergia-igénye közel egy nagyságrenddel haladhatja meg egy hagyományos internetes keresését; bár az egyes becslések módszertana és pontos számértéke vitatott (Dhar, 2020; Freitag et al., 2021), az irány – az inferencia dominanciája a kumulált fogyasztásban – a szakirodalomban széles körben elfogadott. A feladattípusok közötti, több nagyságrendet átfogó fajlagos energiakülönbségeket a 2. ábra szemlélteti; ez egyben a banki modellportfólió-menedzsment (lásd 5.3. alfejezet) energetikai tétjét is érzékelteti.

2. ábra

A következtetés fajlagos energiaigénye feladattípusonként
(kWh/1000 inferencia, logaritmikus skála)



Forrás: Luccioni et al. (2024) mérési eredményei alapján saját szerkesztés.

2.2. A közvetlen energiafogyasztáson túl: beágyazott kibocsátások, víz- és erőforrásfelhasználás

Az AI-lábnym nem szűkíthető le a működési villamosenergia-fogyasztásra. Legalább három további hatáscsatorna azonosítható.

Először: a *beágyazott (embodied) kibocsátások*, amelyek a speciális hardverek (grafikus processzorok /GPU-k/, gyorsítók, szerverek, hálózati és hűtési infrastruktúra) gyártásából, szállításából és életciklusvégi kezeléséből származnak. Az iparági elemzések szerint az informatikai eszközök teljes életciklus-kibocsátásán belül a gyártási fázis részaránya folyamatosan nő, és a hiperskálázott AI-infrastruktúrában a beágyazott kibocsátások súlya a hálózatok dekarbonizációjával párhuzamosan tovább emelkedik (Gupta et al., 2021; Wu et al., 2022), miközben a gyorsuló hardverciklusok (az AI-gyorsítók gyakori generációváltása) tovább növelik e tétel súlyát, a gyártói életciklus-adatok pedig csak korlátozottan állnak rendelkezésre (Green Software Foundation, 2026). Az AI anyagi infrastruktúrájának tágabb, a ritkaföldfém-kitermeléstől az elektronikai hulladékig terjedő, erőforrás-vonzatait a kritikai irodalom részletesen dokumentálja (Crawford, 2021).

Másodszor: a *vízfelhasználás*. Az adatközpontok hűtése, technológiától és földrajzi elhelyezkedéstől függően, jelentős közvetlen vízfogyasztással járhat, amit a

villamosenergia-termelés közvetett vízigénye egészíti ki (Mytton, 2021; Siddik et al., 2021). Li et al. (2023) becslése szerint a nagy nyelvi modellek tanítása és kiszolgálása globálisan több milliárd köbméteres nagyságrendű vízlábnyomot generálhat az évtized közepére; a vízstressznek kitett régiókban telepített kapacitások esetében ez lokális fenntarthatósági és társadalmi konfliktusforrás is lehet.

Harmadszor: a *hálózati és rendszerszintű hatások*. Az adatközpontok területi koncentrációja egyes régiókban a villamosenergia-hálózat terhelésének strukturális tényezőjévé vált; Írországból például az adatközpontok a nemzeti villamosenergia-fogyasztás ötödét is elérő részarányt képviselnek, az Egyesült Államokban pedig az adatközponti kereslet a szövetségi energiapolitika önálló tervezési tényezője lett (Shehabi et al., 2024). Rendszerszinten az IEA előrejelzése szerint a 2030-ig terjedő időszakban az adatközponti többletkereslet jelentős részét még fosszilis forrásokból fedezik majd, így az AI-expanzió – tiszta energiával való ki-egyensúlyozás nélkül – nehezhítheti a klímacélok elérését (IEA, 2025).

2.3. Mérési módszertanok és a számbavétel nehézségei

Az AI-lábnyom vállalati szintű mérésére jelenleg nincs egységesen elfogadott, kötelező módszertan; több, egymást részben átfedő keretrendszer verseng, a mérési és jelentéstételi hiányosságokat pedig a nemzetközi szakpolitikai irodalom is a terület fő korlátjaként azonosítja (OECD, 2022).

A vállalati karbonszámbavétel általános keretét az ÜHG Protokoll (GHG Protocol) adja, amely a kibocsátásokat közvetlen (Scope 1), vásárolt energiához kötődő (Scope 2) és egyéb közvetett (Scope 3) kategóriákba sorolja (WRI–WBCSD, 2004). A banki AI-lábnyom e keretben elvileg elhelyezhető, a gyakorlati allokáció azonban nem triviális: a saját szerverparkon futtatott AI-munkaterhelés Scope 2 tétel, a felhőben vagy API-n keresztül igénybe vett AI-szolgáltatás viszont a Scope 3 1. kategóriájába tartozik (vásárolt áruk és szolgáltatások); éppen abba a kategóriába, amelyet a szolgáltatásintenzív vállalatok jellemzően a legdurvább, költségalapú becslésekkel fednek le. Az AI-adopció tehát a banki kibocsátási leltár szempontjából részben „láthatatlan”: a felhőalapú AI-fogyasztás növekedése a jelenlegi közzétételi gyakorlatban jellemzően nem jelenik meg elkülönített, mennyiségi adatokra épülő tételként.

A szoftverspecifikus mérés irányába mutat a Green Software Foundation által gondozott, ISO/IEC 21031:2024 szabványra épülő szoftver karbonintenzitásmódszertan (Software Carbon Intensity, SCI), amelynek AI-kiterjesztése (SCI for AI) az energiafogyasztást helyspecifikus hálózati karbonintenzitási tényezőkkel kibocsátássá konvertálja, figyelembe veszi a hardver-életciklus beágyazott kibocsátásait, és szabványosított funkcionális egységeket definiál az AI-rendszerek

összehasonlíthatósága érdekében (Green Software Foundation, 2026). A kutatási oldalon a „zöld AI” irodalom szisztematikus áttekintései a mérési eszközök, hatékonysági technikák és riportolási gyakorlatok gyorsan bővülő, de fragmentált ökoszisztémáját dokumentálják (Verdecchia et al., 2023), a következőket pedig a gépi tanulási kutatás minőségi standardjaként javasolják intézményesíteni (Henderson et al., 2020). Az AI-megoldások teljes életciklus-értékelésének (LCA) módszertani adaptációja ugyancsak megtörtént, kifejezetten a környezeti célú AI-alkalmazások rejtett hatásainak feltárására (Ligozat et al., 2022).

A mérés gyakorlati akadályai közül kiemelendő az *átláthatósági aszimmetria*: a banki AI-fogyasztás túlnyomó része néhány nagy felhő- és modellszolgáltatón keresztül realizálódik, amelyek ügyfélszintű energia- vagy kibocsátási adatokat csak korlátozottan, eltérő módszertannal (piaci alapú vs. helyalapú Scope 2) és eltérő granularitással szolgáltatnak. A bank mint alkalmazó így tipikusan becslésekre kényszerül, amelyek bemenő paraméterei (token-, lekérdezés- vagy GPU-óra-alapú fajlagos energiaértékek) maguk is jelentős bizonytalansággal terheltek (Luccioni et al., 2024; OECD, 2022).

2.4. A felhőszolgáltatói karbonallokáció: az elméletileg mérhető és a gyakorlatban elérhető adat

Mivel a banki AI-lábnym túlnyomó része felhőben vagy modellszolgáltatáson keresztül realizálódik, a mérhetőség gyakorlati kérdése végső soron az: milyen adatot ad a szolgáltató az ügyfélnek, és az milyen módszertannal készül. A három nagy felhőszolgáltató ügyfélszintű karbonallokációs eszközeinek összevetése azt mutatja, hogy az elméleti mérhetőség és a gyakorlati adathozzáférés között jelentős, a bankok szempontjából sem semleges rés húzódik.

Az allokáció alapproblémája. A felhőszolgáltató saját kibocsátása aggregált: adatközpont-, klaszter- vagy régiószinten mért energiafogyasztásból és beszerzett villamos energiából áll. Ezt kell valamilyen kulcs mentén az egyes ügyfelekre szétosztani, jellemzően az igénybe vett erőforrás-órák arányában. Az allokációs döntések azonban nem semlegesek: az AWS 2.0 verziójú módszertana például a *kihasználatlan kapacitás* becsült kibocsátását is arányosan felosztja az összes ügyfél között (AWS, 2025) – ami módszertanilag védhető, de azt jelenti, hogy az ügyfél lábnyoma részben olyan tényezőktől függ, amelyekre semmilyen ráhatása nincs.

A piaci alapú számbavétel mint kulcskérdés. A legnagyobb módszertani tétel a Scope 2 piaci alapú (market-based) és helyalapú (location-based) számbavétel közötti választás. A piaci alapú megközelítés a szolgáltató megújulóenergia-vásárlásait (PPA-k, származási garanciák) beszámítja, így a megújuló szerződés-

sekkel lefedett régiókban az ügyfélre allokált Scope 2 kibocsátás akár nullára is csökkenhet – miközben a munkaterhelés fizikailag ugyanabból a hálózathoz fogyaszt, változatlan karbonintenzitás mellett. A bank szempontjából ez azt jelenti, hogy a jelentett AI-lábnymom drasztikusan csökkenthető pusztán szolgáltató- vagy régióváltással, a tényleges fizikai kibocsátás csökkenése nélkül. A CSRD éppen ezért írja elő a kettős – piaci és helyalapú – Scope 2 közzétételt; a jelen tanulmány javaslata szerint a banki AI-lábnymom becslésénél is mindkét értéket indokolt ki-mutatni, és a kettő különbségét önálló, értelmezendő információként kezelni.

Az elérhetőség aszimmetriái. A három szolgáltató gyakorlata érdemben eltér. A Google Cloud Carbon Footprint mindkét Scope 2-megközelítést párhuzamosan közli, a helyalapú számításhoz órás felbontású hálózati kibocsátási tényezőket és gépszintű fogyasztási adatokat használ, és projekt-, termék- és régiószintű bontást, valamint adatbázisexportot kínál – ugyanakkor a szolgáltató maga jelzi, hogy ezek az ügyfélszintű jelentések, szemben a vállalat auditált, felülről lefelé építkező lábnymóval, harmadik fél általi hitelesítésen nem estek át (Google Cloud, 2026). Az AWS eszköze hosszú ideig kizárólag piaci alapú Scope 1–2 adatot közölt, a beágyazott és egyéb upstream kibocsátásokat pedig nem tartalmazta; a 3.0 verziójú, harmadik fél által hitelesített módszertan 2025-ben terjesztette ki a közlést a Scope 3 lényeges kategóriáira – az energiabeszerzéshez kapcsolódó upstream kibocsátásokra, az IT-hardver bölcstől kapuig számított beágyazott kibocsátására, valamint az épületekre és berendezésekre –, a beágyazott tételeket az eszközök élettartamára (IT-hardver esetében hat, épületeknél ötven évre) amortizálva (AWS, 2025). Az adatok időbeli késleltetése ugyanakkor számottevő: a Scope 2 adat havi frissítésű, mintegy háromhavi késéssel. A Microsoft Emissions Impact Dashboardja mindhárom hatókört és mindkét Scope 2-megközelítést kínálja, hozzájárása azonban szerződéstípushoz és külön licenchez kötött, ami a kisebb intézményeknél gyakorlati korlátot jelenthet.

Következmények a banki gyakorlatra. Ebből három megállapítás adódik. Először: a különböző szolgáltatóktól származó ügyfélszintű adatok nem összegezhetőek módszertani harmonizáció nélkül, mivel eltérő allokációs kulcs, eltérő Scope 2-definíció, eltérő hatókörön és eltérő hitelesítési státuszon nyugszanak; a bank kibocsátási leltárában ezért az adatforrást és a módszertani választást tételesen dokumentálni kell. Másodszor: az adatok múltbeliek és késleltetettek, így operatív döntéstámogatásra – például a modellfuttatás régiójának megválasztására – önmagukban alkalmatlanok; erre a 7.2. alfejezetben tárgyalt karbontudatos ütemezés, illetve a hálózati karbonintenzitás valós idejű adatai adnak alapot. Harmadszor (és ez a legfontosabb korlát): a szolgáltatói eszközök az infrastruktúra-szintű (IaaS/PaaS) igénybevételre készültek, az 5.1. alfejezetben harmadikként azonosított, API-n keresztül igénybe vett modellszolgáltatásokra jelenleg nem terjednek ki. Márpedig a banki generatív AI-használat éppen ebben a rétegben

koncentrálódik. Az elméletileg mérhető és a gyakorlatban elérhető adat közötti rés tehát pontosan ott a legnagyobb, ahol a banki AI-lábnyom a leggyorsabban nő – ez az a hiány, amelynek pótlására a 7.4. alfejezet a szerződéses adatszolgáltatási kikötést és a kollektív, szektorszintű fellépést javasolja.

3. AI-ADOPCIÓ A BANKSEKTORBAN: A LÁBNYOM KERESLETI OLDALA

3.1. Nemzetközi trendek


A bankszektor a generatív AI vállalati alkalmazásának egyik éllovasa. Az AI pénzügyi rendszerre gyakorolt transzformatív hatását a nemzetközi intézmények már a jelenlegi hullám előtt elemezték (FSB, 2017; OECD, 2021), az Európai Központi Bank pedig a generatív AI gyors banki adopciónak a pénzügyi stabilitás szempontjából is releváns fejleményként azonosította (ECB, 2024). Az akadémiai irodalom szisztematikus áttekintései a kereskedelmi banki alkalmazások (Königstorfer–Thalmann, 2020), az ügyfélkapcsolati megoldások (Hentzen et al., 2022) és a pénzügyi AI-technikák (Cao, 2022; Milana–Ashta, 2021) gyorsan bővülő kutatási területét dokumentálják, a banki operációkutatás és az AI metszéspontját pedig önálló diszciplínaként azonosítják (Doumpos et al., 2023). Aldasoro et al. (2024) a jegybanki kutatás oldaláról amellet érvel, hogy az AI a pénzügyi közvetítés teljes értékláncát – a hitelezéstől a fizetési rendszereken át a szabályozói megfelelésig – átalakítja. Az ötven legnagyobb globális bank AI-érettségét négy pillér (tehetség, innováció, vezetés, transzparencia) mentén értékelő Evident AI Index 2025. évi kiadása a szektor egészében gyorsuló adopciónak dokumentál (Evident, 2025). Megjegyzendő, hogy az Evident és a McKinsey anyagai iparági, illetve tanácsadói elemzések, amelyek nem esnek át tudományos lektoráláson; a jelen tanulmány ezeket a piaci adopciónak mértékének illusztrálására, nem pedig módszertani bizonyítékként használja, és részletes adatbázisaik csak előfizetéssel érhetők el. *A környezeti lábnyom szempontjából három részjelenség érdemel kiemelt figyelmet.*

Először: az *ágensalapú AI térnyerése*. A 2026 első negyedében nyilvánosan bejelentett banki AI-alkalmazások közel harmada ágensalapú volt, szemben az előző negyedév 15%-ával (Evident, 2026). Az ágensrendszerek energetikai szempontból minőségi ugrást jelentenek: egyetlen felhasználói kérés több tucat modellhívást, eszközhasználatot és iterációt indíthat el, így a fajlagos (feladategységre jutó) energiafogyasztás a hagyományos, egykörös lekérdezésekhez képest többszörösi-re nőhet. A banki AI-lábnyom előrejelzésekor ezért a használati esetek darabszáma önmagában félrevezető indikátor; a számítási intenzitás (compute intensity)

szerinti súlyozás elengedhetetlen. Az ágensalapú alkalmazások részarányának alakulását a 3. ábra mutatja.

3. ábra

Az ágensalapú alkalmazások részaránya az újonnan bejelentett banki AI-használati esetek között



Forrás: Evident (2026) alapján saját szerkesztés.

Másodszor: a *szélesedő felhasználói bázis*. A generatív AI a korai, adattudós-központú alkalmazásokból a teljes munkavállalói állományt elérő, általános célú asszisztensek (copilotok) irányába mozdult, majd – a legfrissebb trendek szerint – a vállalati szintű copilotoktól a funkcióspecifikus, munkafolyamatba ágyazott megoldások felé (Evident, 2026). Egy több tízezer munkavállalót foglalkoztató banknál a napi szintű, széles körű AI-használat összesített inferenciafogyasztása már nagyságrendileg összemérhetővé válhat a hagyományos irodai IT-infrastruktúra fogyasztásával.

Harmadszor: a *kockázatkezelési és megfelelési alkalmazások* súlya. A bankok az AI-t kiterjedten alkalmazzák szabályozói megfelelésre, pénzügyi bűnözés elleni küzdelemre és csalásfelderítésre – amelynek költséghatékonysági előnyeit a hazai empirikus irodalom is igazolja (Benedek-Nagy, 2023) –, hitelkockázat-elemzésre, valamint, nem mellékesen, éppen az ESG-adatfeldolgozásra és a Scope 3 kibocsátások becslésére (BIS, 2024; McKinsey, 2024). Ez utóbbi paradox helyzetet teremt: a fenntarthatósági jelentéstétel automatizálása maga is energiaigényes AI-folyamatokra épül, amit a Nemzetközi Fizetések Bankja (BIS) innovációs

központjának kutatói is jeleztek a Symbiosis projekt kapcsán, megjegyezve, hogy az AI bármilyen alkalmazása érdemi kibocsátással jár, miközben a villamos-energia-hálózatok dekarbonizációja csak lassan halad (BIS, 2024). A banki AI-beruházások értéktéremtéséről szóló kommunikáció megbízhatóságát önálló kockázatként kezeli a hazai irodalomban meghonosított „AI-washing” fogalom (Prisznýák, 2023); a jelen tanulmány érvelése szerint e jelenség környezeti dimenzióval is bővül, amennyiben a bankok az AI fenntarthatósági hasznait saját AI-lábnymuk számbavétele nélkül kommunikálják.

3.2. A hazai és regionális kontextus

A közép-kelet-európai, ezen belül a magyar bankszektor AI-adopciója a nemzetközi élmézőnyhöz képest időbeli késleltetéssel, de hasonló szerkezetben zajlik: az ügyfélszolgálati automatizáció, a csalásfelderítés, a dokumentumfeldolgozás és a belső hatékonysági (fejlesztéstámogató, jelentéskészítő) alkalmazások dominálnak (Bagó, 2023a; MNB, 2025). A hazai szakirodalom az AI pénzügyi alkalmazásainak lehetőségei (Bagó, 2023a) mellett a kiberbiztonsági vonatkozásokat (Bagó, 2023b), a megfelelőségbiztosítási funkció átalakulását (Harkácsi-Szegfű, 2021) is feldolgozta; a technológiai óriásvállalatoktól való függés rendszerkockázati kérdéseit pedig a „Too Big(Tech) to Fail” problémakör kapcsán elemezte a hazai irodalom (Bódi et al., 2023). A környezeti lábnyom dimenziója ugyanakkor e munkákban legfeljebb érintőlegesen jelenik meg – a jelen tanulmány ezt a rést kívánja szűkíteni, a 3.3. alfejezetben empirikus áttekintéssel is.

A lábnyom szempontjából a hazai sajátosságok közül három emelendő ki. Egyrészt a hazai hitelintézetek AI-fogyasztása szinte kizárólag *importált* számítási kapacitásra épül: a nagy nyelvi modellek inferenciája jellemzően külföldi – nyugat-európai vagy egyesült államokbeli – adatközpontokban történik, így a kapcsolódó kibocsátás a magyar leányvállalatok leltárában Scope 3 tételként, a fogadó országok energiamixének karbonintenzitásával jelenik meg (ha egyáltalán megjelenik). Ez a függőség egyben a Bódi et al. (2023) által elemzett bigtech-koncentrációs kockázat környezeti vetülete is: a banki AI-lábnym mérhetősége néhány globális szolgáltató adatszolgáltatási hajlandóságán múlik. Másrészt a régiós villamosenergia-mixek karbonintenzitása jelentősen szór, ami az adatrezidencia- és lokalizációs döntéseknek (például EU-n belüli, alacsony karbonintenzitású régiókban történő feldolgozás választása) mérhető kibocsátási következményeket ad. Harmadrészt a hazai bankcsoportok anyavállalati ESG-keretrendszerei – összhangban a Magyar Nemzeti Bank zöld pénzügyi programjának elvárásaival (MNB, 2024) – egyre inkább csoportszintű digitális karbonlábnyom-célokat is tartalmaznak, amelyek a leánybanki AI-beszerzési döntésekre is hatással lehetnek.

3.3. A hazai banki fenntarthatósági közzétételek empirikus áttekintése

A minta és a módszertan korlátai

A 3.2. *alfejezet* állítása – hogy az AI-hoz köthető energiafelhasználás a jelentés-tételben láthatatlan marad – empirikus ellenőrzést igényel. Ennek érdekében kilenc hitelintézet nyilvánosan elérhető, 2025. üzleti évre vonatkozó dokumentumát tekintettük át dokumentumelemzéssel. A minta összeállításának három korlátját előljáróban rögzíteni kell, mert ezek maguk is a vizsgálat eredményének részét képezik.

Először: nem minden hitelintézetnek van fenntarthatósági jelentése. A fióktelepi formában működő intézmények a hatályos szabályozás szerint mentesülnek az egyedi ESG-közzétételi kötelezettség alól – az ING magyarországi fióktelepe ezt kifejezetten rögzíti is, megjegyezve, hogy az ESRS-t az ING Csoport önkéntesen alkalmazza (ING Bank N.V. Magyarországi Fióktelepe, 2026) –, a kisebb intézmények pedig csak később válnak kötelezetté: a MagNet Bank saját közlése szerint kisméretű, nem összetett intézményként először a 2028-as üzleti évről lesz köteles integrált, csoportszintű fenntarthatósági jelentést közzétenni (MagNet Bank Zrt., 2026).

Másodszor: ahol van jelentés, ott sem feltétlenül önálló dokumentum. A mintában a jellemző forma az éves jelentésbe, illetve a konszolidált üzleti jelentésbe ágyazott fenntarthatósági nyilatkozat (MBH Bank Nyrt., 2026; GRÁNIT Bank Nyrt., 2026); egyetlen különálló fenntarthatósági jelentés szerepel, a CIB Banké, amely ugyanakkor maga jelzi, hogy nem minősül CSRD szerinti ESG-beszámolóknak, mivel azt az anyavállalat, az Intesa Sanpaolo készíti csoportszinten, a helyi dokumentum pedig önkéntes, a magyarországi érintetteknek szóló transzparenciacélt szolgál (CIB Bank Zrt., 2026).

Harmadszor: nem minden intézménynek van 2025-re vonatkozó, letölthető dokumentuma. A csoportszintű jelentések gyakran csak az anyavállalati közzétételben érhetők el, a több száz oldalas éves jelentések letöltése és feldolgozása technikai korlátokba ütközik, egyes intézményekről pedig csak eltérő műfajú anyag állt rendelkezésre; befektetői prezentáció (Oberbank AG, 2026) vagy fenntarthatósági finanszírozási keretrendszer (Deutsche Bank, 2026). A minta ezért nem reprezentatív a hazai bankszektorra; célja illusztratív és feltáró: annak vizsgálata, hogy a jelenlegi közzétételi gyakorlatban *elvből* megjelenhet-e az AI-lábnym.

A dokumentumokat öt egységes szempont mentén elemeztük: (i) elkülönül-e a digitális, IT- vagy adatközponti energiafelhasználás, illetve kibocsátás; (ii) mely Scope 3 kategóriákat és milyen módszertannal közlik; (iii) megjelenik-e felhasználói adat; (iv) említik-e az AI-t energiaigény összefüggésében; (v) van-e digitális lábnymra vonatkozó célkitűzés.

Eredmények

1. táblázat

A vizsgált hitelintézetek fenntarthatósági közzétételeinek elemzése (2025. üzleti év)

Intézmény	Dokumentum típusa	Elkülönített digitális/IT-energia	Scope 3 közzététel	AI energiaigénye
MBH Bank Nyrt.	éves jelentésbe ágyazott konszolidált fenntarthatósági jelentés	nincs	csak 15. kategória (PCAF)	nincs
GRÁNIT Bank Nyrt.	üzleti jelentésbe ágyazott fenntarthatósági nyilatkozat	nincs (E1-5 „nem lényeges”)	nem közöl (fokozatos bevezetés)	nincs
CIB Bank Zrt.	önálló, önkéntes fenntarthatósági jelentés	nincs	nem közöl	nincs
UniCredit Bank Hungary Zrt.	éves jelentés	nincs	nem szerepel a dokumentumban	nincs
MagNet Bank Zrt.	CRR szerinti nyilvánosságra hozatali dokumentum	nincs	önkéntes, nem auditált (PCAF, 2025-től)	nincs
ING Bank N.V. Mo.-i Fióktelepe	IFRS egyedi beszámoló	mentesül a közzététel alól	–	nincs
Bank of China Mo.-i Fióktelepe	IFRS különálló kimutatások	nincs ESG-közzététel	–	nincs
Oberbank AG	befektetői prezentáció	nincs	–	nincs
Deutsche Bank	fenntartható finanszírozási keretrendszer	eszközoldali PUE-küszöb	–	nincs

Forrás: saját szerkesztés a hivatkozott dokumentumok alapján.

Az áttekintés első és legfontosabb megállapítása, hogy a mintában egyetlen dokumentum sem különíti el a digitális, informatikai vagy adatközponti energiafelhasználást, illetve az ahhoz köthető kibocsátást. A hiány nem az adatok szűkösségéből ered: a részletesebb közzétételt adó intézmények energetikai adatai kifejezetten gazdagok, csak éppen más dimenzió mentén bontottak.

Ezt jól szemlélteti a leginkább kidolgozott közzététel. Az MBH Csoport 2025-ös teljes energiafogyasztása 76 467,19 MWh volt (2024: 82 054,23 MWh), amelyet a jelentés fosszilis, nukleáris és megújuló forrás szerint bont, felhasználási cél szerint azonban nem. A szöveg maga rögzíti, hogy az energiafelhasználás nagy részét az épületek közüzemi fogyasztása adta, amelyet a gépjárműflotta üzemanyag-felhasználása követett; az informatika mint fogyasztási kategória meg sem jelenik. A Csoport emellett a csoportszintű energiaadat-konszolidációt maga is kihívásként nevezi meg, egységes informatikai támogatású rendszert 2026-ra ígérve (MBH Bank Nyrt., 2026). Hasonló mintázat rajzolódik ki a CIB Banknál: a 2025-ös villamosenergia-felhasználás 4 921 960 kWh, a 383 836 kWh-s megtakarításhoz vezető intézkedések pedig kivétel nélkül épületüzemeltetési jellegűek (hőszivattyúk, LED-világítás, épületfelügyeleti rendszer, nyílászáró-fóliázás), informatikai tétel viszont egy sem (CIB Bank Zrt., 2026).

A második megállapítás a Scope 3 szerkezetére vonatkozik, és megerősíti az 5.1. alfejezet allokációs elemzését: ahol egyáltalán van Scope 3 közzététel, ott az kizárólag a 15. kategóriát jelenti. Az MBH Scope 3 táblázata egyetlen tételt tartalmaz, a beruházásokat (4 615 674,55 tCO₂e); az 1. kategória (vásárolt áruk és szolgáltatások), amelybe a felhőalapú AI-fogyasztás tartozna, nem szerepel. Ennek nagyságrendi következménye, hogy a Csoport teljes, 4 630 535,72 tCO₂e-s lábnyomán belül a saját működés (Scope 1–2) mindössze 0,32%-ot tesz ki, vagyis pontosan az a tétel marad módszertanilag kidolgozatlan, amelyben az AI-fogyasztás növekedne. A GRÁNIT Bank az ESRS fokozatos bevezetési lehetőségével élve Scope 3 kibocsátást egyáltalán nem közöl, azt a 2026-os jelentésre halasztva, az E1-5 energiafogyasztási közzétételt pedig „nem lényegesnek” minősíti (GRÁNIT Bank Nyrt., 2026). A MagNet Bank 2025-től alkalmazza a PCAF módszertanát, de kifejezetten önkéntes és nem auditált kibocsátási adatokként (MagNet Bank Zrt., 2026).

A harmadik – és a tanulmány érvelése szempontjából legbeszédesebb – megállapítás, hogy az AI-adopció ugyanezen dokumentumokban részletesen dokumentált, energiaigénye viszont sehol nem jelenik meg. A legélesebb kontrasztot a GRÁNIT Bank mutatja: a bank Magyarországon elsőként vezetett be mesterséges intelligenciára épülő szelfis számlanyitást, 2024-ben elindította generatív AI-vezérelt jelzáloghitel-asszisztensét, generatív AI-alapú fejlesztésbe kezdett hitelezési folyamataiban, AI-megoldásokat használ az Otthon Start hitelek feldolgozásában, és 2025-ben elnyerte „Az év mesterséges intelligencia alapú innovációja” díjat – miközben ugyanez az intézmény sem energiafogyasztási, sem Scope 3 adatot nem közöl (GRÁNIT Bank Nyrt., 2026). A CIB Bank az AI-alapképzésen 492, a haladó képzésen 196 munkavállaló részvételét jelenti (CIB Bank Zrt., 2026), az UniCredit a Genesys-projekt keretében AI-alapú hangrobotokat és digitális asszisztenseket vezetett be az ügyfélszolgálatban (UniCredit Bank Hungary Zrt., 2026), mindkét esetben a digitalizációs, illetve humánerőforrás-fejlesztésben, a környezeti fejezet-

től elkülönítve. Az Oberbank befektetői prezentációjában a jelenség vizuálisan is megragadható: az AI-t hatékonysági eszközként bemutató dia és a fenntarthatósági dia egymást követi, minden tartalmi kapcsolat nélkül – az AI a hatékonysági, a fenntarthatóság pedig a portfóliónarratíva része (Oberbank AG, 2026).

Végül a negyedik megállapítás a 4.3. alfejezetben tárgyalt kettős pozíció dokumentált esete. A Deutsche Bank fenntartható finanszírozási keretrendszere az IKT-fejezetben az adatközpontok építését, korszerűsítését és üzemeltetését finanszírozható fenntartható tevékenységként sorolja fel, meghatározott PUE-küszöb teljesülése esetén (Deutsche Bank, 2026). Az energiahatékonysági mutató tehát megjelenik, de *eszközoldalon*, ügyfélminősítési kritériumként, nem pedig a bank saját működésének mérőszámaként. Ugyanez a keretrendszer záró nyilatkozatában elismeri, hogy nincs egységes piaci standard, korlátozott a megbízható adatok elérhetősége, és eltérő, de egyaránt elfogadható mérési technikák lényegesen különböző eredményre vezethetnek; mindez a 2.3. és 2.4. alfejezetben tárgyalt mérési bizonytalanság vállalati elismerése.

Összességében az áttekintés a tanulmány központi állítását empirikusan is alátámasztja: a vizsgált intézmények közül több dokumentáltan intenzív AI-alkalmazó, ám egyikük fenntarthatósági közzétételében sem azonosítható az AI-hoz köthető energiafelhasználás vagy kibocsátás. A hiány maga a lelet. Nem mulasztásról van szó – a jelenlegi ESRS-adatpontok és a bevett banki gyakorlat nem is kéri ezt az információt –, hanem strukturális vakfoltról, amelynek jelentősége az adopcio ütemével párhuzamosan nő. Az 5. fejezetben javasolt keretrendszer éppen ennek a vakfoltnak a megszüntetésére kínál eljárást.

4. SZABÁLYOZÁSI KÖRNYEZET: TRANSPARENCIA-KÖVETELMÉNYEK TÖBB IRÁNYBÓL

4.1. Az EU AI-rendeletének energetikai rendelkezései

Az AI-rendelet – a világ első átfogó, horizontális AI-szabályozása – a kettős (digitális és zöld) átmenet jegyében több energetikai vonatkozású rendelkezést tartalmaz, ezek azonban elsősorban a modellszolgáltatókat terhelik. Az általános célú AI-modellek (GPAI) szolgáltatói a rendelet XI. melléklete szerinti műszaki dokumentációban kötelesek rögzíteni a modell ismert vagy becsült energiafogyasztását; ahol a tényleges fogyasztás nem ismert, a becslés a felhasznált számítási erőforrásokon alapulhat (Európai Parlament és Tanács, 2024). A rendelet 40. cikke a Bizottságot harmonizált szabványok kidolgozásának kezdeményezésére hatalmazza fel az AI-rendszerek erőforrás-hatékonyságának – köztük energiahatékonyságának – javítására, a 95. cikk pedig önkéntes magatartási kódexek

kidolgozását irányozza elő, kiterjedően a környezeti fenntarthatóságra és az energiahatékony programozásra.

A szakirodalom ugyanakkor a rendelet környezeti rendelkezéseinek jelentős hiányosságaira mutat rá: a közzététel a hatóságok felé történik, nem nyilvános; a rendelet az energiafogyasztást és nem a tényleges kibocsátást méri, így a villamosenergia-mixek karbonintenzitása közötti, akár nagyságrendi, különbségeket figyelmen kívül hagyja; a beágyazott kibocsátások kívül maradnak a hatókörön; egységes mérési módszertan hiányában pedig az adatok nem összehasonlíthatók (Green Software Foundation, 2026). A banki AI-lábnym szempontjából külön jelentőséggel bír, hogy a GPAI magatartási kódex (amely a XI. melléklet követelményeit modelldokumentációs űrlap formájában operacionalizálja, és a tanítási mellett az inferenciafázis fogyasztására is kiterjed) kivételt enged: a szolgáltató mentesülhet az energiaadat közlése alól, ha nem rendelkezik a szükséges információval a számítási kapacitást vagy a hardvert biztosító partnerétől (Green Software Foundation, 2026). Ez a kivételszabály éppen azt az átláthatósági aszimmetriát intézményesíti, amelyet a 2.3. alfejezet a banki lábnymbecslés fő akadályaként azonosított: az adathiány a beszállítói lánc mentén továbbhárítható, a lánc végén álló alkalmazó bank pedig becslésre kényszerül. A Bizottság 2026 tavaszán célzott konzultációt indított az AI-modellek és -rendszerek energiafogyasztásának és kibocsátásának mérési keretrendszeréről, amely egy lehetséges uniós AI-energia- és kibocsátási címke előkészítését is szolgálja (Európai Bizottság, 2026). A bankok szempontjából mindez azt jelenti, hogy középtávon a *beszállítói oldalon* szabványosított energetikai adatok válhatnak elérhetővé, ami a saját lábnymbecslés adatminőségét érdemben javíthatja – az alkalmazói oldali (deployeri) kötelezettségek azonban egyelőre közvetettek.

4.2. CSRD, ESRS és a kettős lényegesség

A fenntarthatósági jelentéstételről szóló (EU) 2022/2464 irányelv (CSRD) és az európai fenntarthatósági jelentéstételi standardok (ESRS) a nagy hitelintézetek számára kötelezővé teszik – a kettős lényegesség elve mentén – a lényeges környezeti hatások, kockázatok és lehetőségek közzétételét, ideértve az energiafogyasztást és az ÜHG-kibocsátások Scope 1–3 szerinti bontását (Európai Parlament és Tanács, 2022). Az AI-lábnym szempontjából a kulcskérdés a *lényegesség*: amennyiben egy bank AI-hoz köthető energiafogyasztása és beszerzett szolgáltatás kibocsátása a saját működési lábnym érdemi és növekvő hányadát teszi ki, a kettős lényegességi elemzésben ez hatáslényegességi szempontból nehezen megkerülhető. A jelenlegi közzétételi gyakorlatban ugyanakkor a digitális, ezen belül az AI-specifikus fogyasztás jellemzően nem elkülönített tétel – ami a hazai nagybanki közzétételek korábbi tartalomelemzési tapasztalataival (Vőneki-Lamanda, 2020)

összhangban azt jelzi, hogy a jelentéstételi gyakorlat a szabályozási minimum-követelményeket követi, az emergens hatásterületeket késleltetéssel integrálja. A tanulmány 5. fejezetében javasolt keretrendszer ennek a láthatóvá tételére kínál gyakorlati megoldást.

4.3. Adatközponti és taxonómiai kapcsolódások

A banki AI-lábnym szabályozási környezetét harmadik irányból az adatközponti energiahatékonysági szabályozás formálja. Az uniós energiahatékonysági irányelv felülvizsgálata nyomán a nagyobb adatközpontok energetikai kulcsindikátorainak (például az energiafelhasználási hatékonyságot mérő PUE-mutató) jelentése kötelezővé vált, egyes tagállamok – például Németország az energiahatékonysági törvényével – pedig megújulóenergia-részarányra és hulladék hőhasznosításra vonatkozó követelményeket is bevezettek. Az EU-taxonómia klímadelegált rendelete az adatközponti tevékenységek taxonómiai megfelelésének értékelési keretét is meghatározza. A bankok kettős pozícióban vannak: egyszerre *fogyasztói* az adatközponti szolgáltatásoknak (a saját AI-lábnymuk révén) és *finanszírozói* a gyorsan bővülő adatközponti beruházásoknak – ez utóbbi a finanszírozott kibocsátások oldalán jelentkezik, és önálló elemzést érdemelne.

5. A BANKI AI-LÁBNYOM SZÁMBAVÉTELE: MÓDSZERTANI KERETJAVASLAT

5.1. Számbavételi határok és allokáció

A javasolt keretrendszer kiindulópontja a banki AI-portfólió háromszintű tipizálása a hozzáférési mód szerint, mivel ez determinálja a kibocsátás számviteli helyét:


1. *Saját infrastruktúrán futtatott (on-premise) AI*: a fogyasztás mérhető (szerverszintű teljesítménymérés, GPU-óra-nyilvántartás), a kibocsátás Scope 2 tétel, a bank saját villamosenergia-szerződéseinek (helyalapú, illetve piaci alapú) karbonintenzitásával.
2. *Felhőben futtatott, saját kezelésű munkaterhelés (IaaS/PaaS)*: a fogyasztás a felhőszolgáltató ügyfélszintű riportjaiból vagy erőforrás-használati adatokból (vCPU-, GPU-órák) becsülhető; a kibocsátás Scope 3, 1. kategória, a szolgáltató régióspecifikus karbonintenzitásával és PUE-értékével korrigálva.
3. *Modellszolgáltatás API-n keresztül (SaaS/MaaS)*: a legnehezebben mérhető szint; a becslés token- vagy lekérdezésalapú fajlagos energiaértékekre épülhet,

amelyeket a szakirodalomból (de Vries, 2023; Luccioni et al., 2024) vagy – ahogy elérhetővé válnak – a szolgáltatói közzétételekből kell származtatni. Scope 3, 1. kategória.

A beágyazott kibocsátások számviteli helye a hozzáférési módtól függően eltér, és a pontos besorolás elmulasztása a leltár rendszeres alulbecsléséhez vezet. Saját infrastruktúra esetén a bank a hardver tulajdonosa, ezért a szerverek, GPU-k és a kapcsolódó hálózati, illetve hűtési berendezések gyártásából és szállításából eredő kibocsátás a Scope 3, 2. kategóriájába (tőkejavak) tartozik, a beszerzés évében teljes egészében elszámolva, az élettartam végi kezelés pedig az 5. kategóriába; ez tehát nem pusztán kvalitatív megjegyzés, hanem számszerűsítendő és a leltárban megjelenítendő tétel, amennyiben lényeges. Felhő- és API-alapú igénybevétel esetén ezzel szemben a hardver a szolgáltató tulajdonában van, így a beágyazott kibocsátás annak tőkejavai között jelentkezik, és a bankhoz – ha egyáltalán – a szolgáltatói allokáción keresztül, a Scope 3, 1. kategóriájában érkezik vissza; a 2.4. alfejezetben tárgyalt szolgáltatói módszertanok éppen ezért érdemi különbséget hordoznak abban, hogy a beágyazott tételt tartalmazzák-e, és milyen amortizációs feltevéssel. Mindhárom szinten indokolt továbbá – a lényegességtől függően – a vízfelhasználás jelzőszámként való követése (Li et al., 2023; Mytton, 2021), valamint a beágyazott kibocsátásokra vonatkozó adathiány explicit dokumentálása (Luccioni et al., 2023; Wu et al., 2022). A javasolt számbavételi keretet a 4. ábra foglalja össze.

4. ábra

A banki AI-lábnym háromszintű számbavételi kerete: hozzáférési módok, mérési megközelítések és ÜHG-számviteli kategóriák



Forrás: saját szerkesztés

5.2. Illusztratív becslési modell

A keretrendszer alkalmazhatóságát egy stilizált számpélda szemlélteti. Tekintsünk egy 5 000 szellemi foglalkozású munkavállalót foglalkoztató, közepes méretű bankcsoportot, amely általános célú AI-asszisztenst vezet be. A becsléshez szükséges paraméterek: az egy munkavállalóra jutó napi lekérdezésszám (q), az egy lekérdezésre jutó átlagos villamosenergia-igény a teljes kiszolgálási láncsal – adatközponti segédfogyasztással (PUE) – együtt (e), a munkanapok száma (d), valamint a releváns villamosenergia-mix karbonintenzitása (c). Az éves AI-inferenciakibocsátás ekkor:

$$E = (Nqdec)/10^6, \quad (1)$$

ahol E az éves kibocsátás 't' CO₂e-ben, 'N' a felhasználók száma (fő), 'q' a napi lekérdezésszám (db/fő/nap), 'd' a munkanapok száma (nap), 'e' a fajlagos energiaigény (Wh/lekérdezés), 'c' pedig a hálózati karbonintenzitás (kg CO₂e/kWh). A 10⁶-os osztó a két mértékegység-átváltást egyesíti: a Wh→kWh (10³) és a kg→tonna (10³) konverziót. Az 'e' paraméter értelmezése önálló módszertani döntést igényel, mivel a rendszerhatár megválasztása a végeredményt nagyságrendileg befolyásolja. A jelen tanulmányban 'e' a következőket foglalja magában: (i) a modellt kiszolgáló szerver és gyorsító tényleges elektromos fogyasztása a lekérdezés feldolgozása alatt; (ii) az adatközponti segédfogyasztás a PUE-szorozón keresztül (hűtés, tápellátási veszteségek); valamint (iii) az üresjárat és készenléti fogyasztás, illetve a redundanciából és a lefoglalt, de ki nem használt kapacitásból eredő fogyasztás alokált része. Nem tartalmazza ugyanakkor (iv) a végponttól az adatközpontig tartó hálózati adatforgalom energiaigényét, (v) a felhasználói végberendezés fogyasztását, valamint (vi) a szolgáltatói infrastruktúra tágabb, nem közvetlenül a munkaterheléshez rendelhető elemeit. Hangsúlyozandó, hogy a szakirodalomból átvehető fajlagos értékek nem egységes rendszerhatárok mentén készültek: egyes mérések kizárólag a gyorsító fogyasztását rögzítik, mások a teljes szerverét, ismét mások a PUE-t is beszámítják, és az üresjárat fogyasztás kezelése is eltérő. A BLOOM-modell életciklus-elemzése például éppen azt mutatta ki, hogy az üresjárat tétel önmagában is érdemi nagyságrendű (Luccioni et al., 2023). A becslés dokumentálásakor ezért a felhasznált 'e' érték rendszerhatárát tételelesen meg kell adni, és a különböző forrásokból származó fajlagos értékek nem keverhetők harmonizáció nélkül. A rögzíthető paraméterek: $q=30$ lekérdezés/nap, $d=230$ munkanap, $N=5\,000$ fő, azaz éves szinten mintegy 34,5 millió lekérdezés; $c=0,2-0,4$ kg CO₂e/kWh a kiszolgáló régió villamosenergia-mixétől függően.

Az e fajlagos érték megválasztása ezzel szemben önmagában egy három nagyságrendet átfogó bizonytalansági sávot nyit, és éppen ezért nem kezelhető egyetlen „átlagos” értéként. A szakirodalomban két, egymástól élesen elváló mérési

család létezik. Az egyik – a nyílt modellek kontrollált mérésén alapuló irodalom – szöveggenerálásra nagyságrendileg 0,05 Wh/lekérdezés fajlagos értéket ad (Luccioni et al., 2024; lásd a 2. ábrát). A másik (a nagy, tömegesen üzemeltetett általános célú asszisztensekre vonatkozó, felülről lefelé becsült irodalom) ennél két nagyságrenddel magasabb, néhány wattórás értékekkel számol (IEA, 2024). Az eltérés nem mérési hiba, hanem három tényező együttes következménye: a *modellméret* (a mért nyílt modellek lényegesen kisebbek a piacvezető asszisztensek mögötti modelleknél), a *rendszerhatár* (a fentebb tárgyalt üresjárat, redundancia- és PUE-tételek eltérő kezelése), valamint a *kiszolgálási hatékonyság* (kötegelés, gyorsítótárazás, kvantálás).

A jelen tanulmány ezért nem egyetlen sávval, hanem négy, explicit módon levezetett forgatókönyvvel dolgozik:

1. *Kis, feladat-specifikus modell*: – $e \approx 0,05$ Wh: osztályozás, kivonatolás, rövid szöveggenerálás desztillált modellel, a kontrollált mérésekkel összhangban (Luccioni et al., 2024).
2. *Közepes modell*: – $e \approx 0,5$ Wh: nagyobb kontextusablak, hosszabb válasz, közepes méretű modell; egy nagyságrenddel a mért alapérték felett.
3. *Nagy, általános célú asszisztens*: – $e \approx 3$ Wh: a tömegesen üzemeltetett asszisztensekre közölt becslésekkel összhangban (IEA, 2024).
4. *Ágensalapú folyamat*: – $e \approx 30$ Wh: egyetlen felhasználói kérés itt nem egy modellhívást jelent. Konzervatív levezetéssel: egy ágensfolyamat tipikusan 10–20 modellhívást indít (tervezés, eszközhasználat, iteratív ellenőrzés), és mivel minden lépés újratölti a növekvő kontextust, a feldolgozott tokenek száma lépésként emelkedik. A 3. forgatókönyv szerinti nagymodell-hívást alapul véve 10 hívás $\times$ átlagosan a kiindulási kontextus egyszerese ≈ 30 Wh adódik; ez az érték tehát nem feltevés, hanem a 3. forgatókönyvből származtatott, hívás- és lépésszámon alapuló becslés.

A négy forgatókönyv paramétereit és eredményeit a 2. táblázat foglalja össze.

2. táblázat

A stilizált számpélda négy forgatókönyve (N=5 000 fő; q=30 lekérdezés/nap; d=230 nap; összesen 34,5 millió lekérdezés/év)

Forgatókönyv	Tipikus banki felhasználás	e (Wh/lekérdezés)	Éves fogyasztás (MWh)	Éves kibocsátás (t CO ₂ e, c = 0,2–0,4)
1. Kis, feladat-specifikus modell	osztályozás, kivonatolás, rövid sablonos generálás	0,05	1,7	0,3–0,7
2. Közepes modell	normál szövegenerálás, hosszabb kontextus	0,5	17,3	3,5–6,9
3. Nagy általános célú asszisztens	vállalati copilot, nyílt végű kérdések	3	103,5	20,7–41,4
4. Ágensalapú folyamat	10–20 modellhívás, iteratív eszközhasználat	30	1 035,0	207,0–414,0


Forrás: saját számítás. A rendszerhatár mindegyik forgatókönyvben: szerver- és gyorsítófogyasztás + PUE + allokált üresjárat és redundanciátétel.

E forgatókönyvek mellett az éves fogyasztás 1,7 MWh-tól 1 035 MWh-ig, az éves kibocsátás pedig 0,3 t CO₂e-től 414 t CO₂e-ig terjed (5. ábra). A három nagyságrendnyi szórás önmagában is a tanulmány egyik fő megállapítása: a banki AI-lábnym nagyságrendjét nem a felhasználószám, hanem a modell- és folyamatarchitektúra választása határozza meg. Ugyanaz az 5 000 fős intézmény, azonos felhasználási intenzitás mellett, a modellméretezési és ágensesítési döntéseitől függően nagyságrendekkel eltérő lábnymot produkál: ez adja az 5.3. *alfejezetben* tárgyalt hatékonysági kar gyakorlati jelentőségét.

A példa ugyanakkor három okból sem teljes. Egyrészt csak az általános célú asszisztens használatát fedi le, a dokumentumfeldolgozó és kódgeneráló alkalmazásokat nem. Másrészt a beágyazott kibocsátásokat és a finomhangolási tételeket nem tartalmazza. Harmadrészt a lekérdezésszám maga is dinamikusan nő. A becslést ezért mindig sávosan, a forgatókönyv és a rendszerhatár megjelölésével, érzékenységvizsgálattal együtt indokolt közölni (Henderson et al., 2020; OECD, 2022).

5. ábra

A stilizált számpélda érzékenységvizsgálata négy forgatókönyvre: éves kibocsátás ($t\ CO_2e$, logaritmusos skála) a fajlagos energiaigény (e) és a hálózati karbonintenzitás (c) függvényében ($N = 5\ 000$ fő; $q = 30$ lekérdezés/nap; $d = 230$ nap)



Forrás: saját számítás és szerkesztés; az e értékek forrása és levezetése az 5.2. alfejezetben.

A módszertani javaslat lényege ezért nem a pontszerű becslés, hanem a *folyamat* intézményesítése: (i) az AI-alkalmazásportfólió energetikai szempontú leltárának felállítása; (ii) a mérhető (on-premise, IaaS) tételek tényadat-alapú, a nem mérhető (API-alapú) tételek sávós becslése; (iii) a becslés éves aktualizálása és a fenntartathatósági jelentésbe – legalább a módszertani megjegyzések szintjén – történő beépítése; (iv) az AI-beszerzési és architektúradöntésekben energetikai kritériumok (modellméret-arányosság, régióválasztás, szolgáltatói energiaadat-szolgáltatás szerződéses kikötése) alkalmazása.

5.3. A modellméretezés mint hatékonysági kar

A banki gyakorlat szempontjából a legnagyobb rövid távú kibocsátáscsökkentési potenciál a *feladat és modell illesztésében* rejlik. A használati esetek jelentős része – osztályozás, kivonatolás, sablonos szöveggenerálás – kisebb, feladat-specifikus vagy desztillált modellekkel is magas minőségben kiszolgálható, amelyek fajlagos energiaigénye a legnagyobb általános célú modellekének töredéke (Luccioni et al., 2024; Schwartz et al., 2020). A „mindent a legnagyobb modellel” alapértel-

mezés helyett a modellportfólió-menedzsment – amely a kockázati, adatvédelmi és költség szempontok mellett az energetikai dimenziót is tartalmazza – a banki AI-governance természetes bővítése, és illeszkedik a zöld AI irodalmában dokumentált hatékonysági technikák (kvantálás, desztilláció, gyorsítótárazás, köteget feldolgozás) alkalmazási irányába (Verdecchia et al., 2023). Ugyanide tartozik a redundáns hívások kiszűrése és az ágensfolyamatok lépésszámának optimalizálása.

6. NETTÓ HATÁS: ZÖLDÍTÉS AI-JAL ÉS ZÖLD AI

Az AI banki alkalmazásának környezeti mérlege nem egyoldalú. A gépi tanulás klímavédelmi alkalmazási lehetőségeit a kutatói közösség szisztematikusan feltérképezte az energiarendszer-optimalizálástól a klímamodellezésig (Rolnick et al., 2022; Vinuesa et al., 2020), és a pénzügyi szektorban is ígéretes alkalmazások dokumentálhatók: a Scope 3 adatgyűjtés automatizálása, a klímakockázat-elemzés, az energiahatékonysági optimalizáció és a zöldrefestés (greenwashing) felderítése terén a szakirodalom és a jegybanki gyakorlat egyaránt előrelépést jelez (BIS, 2024; Nishant et al., 2020). A fintech- és blokklánc-alapú zöld pénzügyi megoldások hazai áttekintése ugyancsak a technológia fenntarthatósági potenciálját hangsúlyozza (Horváth, 2022).

A „zöldítés AI-jal” (greening by AI) narratívája azonban módszertanilag nem számolható el a „zöld AI” (greening of AI) követelménye ellenében. A fogalompár – az AI mint a fenntarthatóság eszköze és az AI mint fenntarthatósági probléma – a nemzetközi etikai irodalomban is bevett elemzési keret (Cowls et al., 2023; Taddeo et al., 2021; van Wynsberghe, 2021), és a klímapolitikai mérlegkészítés módszertani feltételeit Kaack et al. (2022) rendszerezte: az AI rendszer-szintű klímahatása csak a közvetlen (számítási), a közvetett (alkalmazási) és a strukturális (viselkedési, piaci) hatások együttes figyelembevételével értékelhető. A vállalati számvitel szintjén a két hatás eltérő kategóriákban jelentkezik: az AI-alkalmazások révén elért kibocsátáscsökkentés jellemzően elkerült kibocsátás (avoided emissions), amely a vállalati leltárban nem nettósítható a tényleges Scope 2–3 tételekkel szemben. A hitelintézeti kommunikációban ezért a két dimenzió szigorú szétválasztása indokolt; ennek elmulasztása – a fenntarthatósági állítások szigorodó felügyeleti kontrollja és az AI-washing jelenség (Prisznýák, 2023) mellett – zöldrefestési kockázatot hordoz. A kritikai irodalom emellett arra figyelmeztet, hogy az AI „zöld” narratívája gyakran elfedi a technológia saját környezeti költségeit és az ellátási láncok politikai gazdaságtanát (Brevini, 2020; Dauvergne, 2022), és egyelőre nyitott kérdés, hogy az AI összességében gyorsítja vagy lassítja a nettó zero átmenetet (Luers et al., 2024). A visszapattanó hatás

további óvatosságra int: a Jevons-paradoxon logikája szerint a hatékonyságnövekedés a felhasználás volumenének növekedésén keresztül az össz fogyasztást akár emelheti is (Alcott, 2005; Sorrell, 2009), amit az IKT-szektor korábbi hatékonysági ciklusainak tapasztalatai is alátámasztanak (Freitag et al., 2021).

7. MERRE TARTUNK? VÁRHATÓ PÁLYÁK, KÖVETKEZTETÉSEK ÉS JAVASLATOK

7.1. A keresleti pálya: strukturális növekedés

A rendelkezésre álló előrejelzések egybehangzóan a banki AI-lábnym gyors, strukturális növekedését valószínűsítik. A keresleti oldalon az adatközponti villamosenergia-fogyasztás 2030-ig várható közel megduplázódása (IEA, 2025) és az Egyesült Államokban a nemzeti fogyasztás akár 12%-át elérő adatközponti részarány (Shehabi et al., 2024) jelöli ki a makropályát, amelyen belül a fogyasztás súlypontja a tanításról tartósan a következtetésre helyeződik át (de Vries, 2023; Desislavov et al., 2023). A bankszektorban ezt a pályát az ágensalapú alkalmazások részarányának ugrásszerű – egyetlen negyedév alatt 15%-ról közel egyharmadra történő – emelkedése (Evident, 2026) tovább meredekíti, mivel az ágensfolyamatok feladategységenkénti számítási igénye a hagyományos lekérdezésekének többszöröse. Mindezek alapján reális az a forgatókönyv, hogy a hitelintézetek AI-hoz köthető Scope 2–3 tételei az évtized hátralévő részében évi több tíz százalékos ütemben bővülnek, miközben a működési lábnym többi eleme (épületenergia, utazás, papírfelhasználás) stagnál vagy csökken – vagyis az AI részaránya a saját működési kibocsátásán belül akkor is folyamatosan nő, ha abszolút értéke egyelőre mérsékelt marad.

7.2. Technológiai ellenerők: hatékonyság és karbantudatos működtetés

A növekedési pályát technológiai ellenerők fékezhetik. A hardver- és algoritmus hatékonyság javulása történetileg is jelentős volt (Koomey et al., 2011), és a zöld AI kutatási programja – a modellméret-csökkentéstől a kvantáláson át a desztillációig – ma is gyors ütemben bővíti a hatékonysági eszköztárat (Schwartz et al., 2020; Verdecchia et al., 2023). Ígéretes irány a *karbantudatos számítástech-nika* (carbon-aware computing): a munkaterhelések időbeli és térbeli átütöztetése a villamosenergia-hálózat pillanatnyi karbonintenzitásához igazodva, amelyet a hiperskálázott szolgáltatók már üzemszerűen alkalmaznak (Radovanović et al., 2023), az adatközpont-tervezés szintjén pedig a beágyazott és működési kibocsá-

tások együttes optimalizálása is megjelent (Acun et al., 2023). A banki AI-lábnym szempontjából ez azt jelenti, hogy a szolgáltatóválasztás és a szerződéses feltételek (karbontudatos ütemezés igénylése, alacsony karbonintenzitású régiók előnyben részesítése) a következő években valódi, mérhető differenciáló tényezővé válnak. A hatékonyságjavulás azonban önmagában nem garantálja az abszolút kibocsátás csökkenését: a visszapattanó hatás irodalma (Alcott, 2005; Sorrell, 2009) és az AI klímahatásáról szóló aktuális vita (Luers et al., 2024) egyaránt arra figyelmeztet, hogy az olcsóbbá váló számítás historikusan a felhasználás volumenének még gyorsabb bővülésével járt együtt.

7.3. Szabályozási pálya és a bankokra váró következmények

A szabályozási környezet a következő három-öt évben kiszámíthatóan szigorodik. Az AI-rendelet 40. cikke szerinti harmonizált energiahatékonysági szabványok kidolgozása és a Bizottság által előkészített AI-energia- és kibocsátási címke (Európai Bizottság, 2026; Európai Parlament és Tanács, 2024) középtávon szabványosított beszállítói adatokat tesz elérhetővé. A menetrend is ismert: a Bizottságnak 2028. augusztus 2-ig kell jelentést tennie a szabványosítás előrehaladásáról, és e jelentés – amennyiben az önkéntes megközelítés elégtelennek bizonyul – jogilag kötelező korrekciós intézkedéseket is előírandozhat (Green Software Foundation, 2026). Ez a szabványosított adatkinálat, a CSRD-adatlánc (Európai Parlament és Tanács, 2022) pedig a nagyvállalati ügyfelek oldaláról közvetíti ugyanezt az elvárást a bankok felé; a felügyeleti érdeklődés az AI banki alkalmazásának koncentrációs és működési kockázatai iránt már ma is kimutatható (ECB, 2024). A bankokra nézve mindebből három következmény adódik. Először: az az intézmény, amely a transzparencia-infrastruktúrát (AI-leltár, becslési módszertan, szolgáltatói adatkapcsolatok) előre kiépíti, a kötelezővé váló közzétételeknek alacsony határköltséggel felel meg, míg a kivárok utólagos, költséges rekonstrukcióra kényszerülnek. Másodszor: az energiaköltség és a karbonár fokozatosan beépül az AI-alkalmazások üzleti esetébe, így a modellméret-arányosság ma még önkéntes elve középtávon egyszerű költségracionalitássá válik. Harmadszor: a saját AI-lábnymát mérni és kommunikálni képes bank hitelesebben lép fel a fenntarthatósági átmenet finanszírozójaként – és fordítva: az AI-washing (Prisznýák, 2023) környezeti változata, a mérés nélküli zöld AI-kommunikáció, növekvő felügyeleti és reputációs kockázatot hordoz.

7.4. Következtetések és javaslatok

A fentiekből a tanulmány érvelése öt pontban összegezhető, amelyek egyben a banki gyakorlat és a szabályozás számára megfogalmazott javaslatok is.

Először: a banki AI-lábnymom ma még abszolút értékben kicsi, de a szektor leggyorsabban növekvő működési kibocsátási tétele, amelynek szerkezete (felhőalapú, Scope 3 jellegű, szolgáltatói adatoktól függő), a hagyományos működési kibocsátás-menedzsment eszközeivel nem kezelhető. A hitelintézeteknek célszerű az AI-alkalmazásportfólió energetikai leltárát már most, az adopció felfutó szakaszában felállítaniuk, mert az utólagos rekonstrukció költségesebb és pontatlanabb.

Másodszor: az AI-governance kereteket – amelyeket a bankok az AI-rendeletnek való megfelelés jegyében amúgy is kiépítenek (Harkácsi–Szegeő, 2021) – indokolt energetikai és környezeti dimenzióval bővíteni: modellméret-arányossági elv, régió- és szolgáltatóválasztási kritériumok, a szolgáltatói energia- és kibocsátási adatszolgáltatás szerződéses kikötése.

Harmadszor: a fenntarthatósági jelentéstételben a kettős lényegességi elemzés terjedjen ki explicit módon a digitális, ezen belül az AI-hoz köthető lábnymomra; ahol a lényegességi küszöböt még nem éri el, ott is javasolt a trend önkéntes, módszertanilag dokumentált bemutatása.

Negyedszer: a szabályozói és szakmai közösség szintjén a legfontosabb hiányzó elem a *szabványosított, alkalmazói (deployeri) szintű energiaadat*. Az uniós AI-energiacímke előkészítése (Európai Bizottság, 2026) és a GPAI-szolgáltatók dokumentációs kötelezettségei jó irányba mutatnak, de a bankok mint nagyfogyasztó vállalati ügyfelek kollektív alkuereje – például bankszövetségi szintű, egységes szolgáltatói adatszolgáltatási elvárások megfogalmazásával – önmagában is katalizálhatja a transzparenciát.

Ötödször: a kutatás számára nyitott kérdés a banki AI-lábnymom empirikus mérése: a jelen tanulmányban javasolt keretrendszer hazai banki mintán történő alkalmazása, a fajlagos energiaértékek validálása és az ágensalapú alkalmazások fogyasztási profiljának feltárása a következő lépések.

8. ÖSSZEGZÉS

A bankszektor a klímaátmenet finanszírozójaként megtanulta mérni azt, amit korábban mérhetetlennek gondolt: ügyfelei kibocsátásait. A következő, kisebb léptékű, de szimbolikus jelentőségű feladat a saját digitális működés környezeti lábnymomának átlátható számbavétele. A tanulmány erre fogalmi és módszertani keretet javasolt: a hozzáférési mód szerinti hármas tipológiát, a hozzá rendelt

Scope-besorolást és rendszerhatárokat, valamint a sávós, érzékenységvizsgálattal közölt becslés gyakorlatát. Az elemzés fő állítása, hogy a mérhetőség korlátja ma nem elméleti, hanem adathozzáférési: a szolgáltatói allokációs módszertanok éppen ott a leghiányosabbak (az API-alapú modellszolgáltatásoknál), ahol a banki AI-lábnyom a leggyorsabban nő. A bankok saját AI-lábnyoma ma még lábjegyzet a kibocsátási leltárban; az adopcio jelenlegi üteme mellett a lábjegyzetből néhány éven belül fejezet lehet.

AI-használati nyilatkozat

A tanulmány elkészítése során az OpenAI ChatGPT szolgáltatás GPT-5.6 SOL Thinking modelljét használtam a forrásgyűjtés támogatására, valamint a szöveg nyelvi és stilisztikai ellenőrzésére. Az eszközt releváns szakirodalmi keresőkifejezések, kutatási irányok és lehetséges források azonosítására, továbbá egyes mondatok nyelvi pontosítására, stílárís javítására és a szöveg szerkesztésének támogatására alkalmaztam. A ChatGPT által javasolt forrásokat minden esetben önállóan ellenőriztem, eredeti lelőhelyükön megtekintettem, és kizárólag az ellenőrzött, szakmailag megfelelő forrásokat használtam fel. A mesterséges intelligencia által javasolt nyelvi és stilisztikai módosításokat szintén felülvizsgáltam. A tanulmány tartalmáért, az elemzésért, az eredmények értelmezéséért és a következtetésekért vállalom a felelősséget.

HIVATKOZÁSOK

- Acun, B. – Lee, B. – Kazhamiaka, F. – Maeng, K. – Gupta, U. – Chakkaravarthy, M. – Brooks, D. – Wu, C.-J. (2023): Carbon Explorer: A holistic framework for designing carbon aware datacenters. In *Proceedings of the 28th ACM International Conference on Architectural Support for Programming Languages and Operating Systems (ASPLOS 2023)*, 118–132). ACM. <https://doi.org/10.1145/3575693.3575754>.
- Alcott, B. (2005): Jevons' paradox. *Ecological Economics*, 54(1), 9–21. <https://doi.org/10.1016/j.ecolecon.2005.03.020>.
- Aldasoro, I. – Gambacorta, L. – Korinek, A. – Shreeti, V. – Stein, M. (2024): Intelligent financial system: How AI is transforming finance. Bank for International Settlements. *BIS Working Papers* No. 1194. <https://www.bis.org/publ/work1194.htm>.
- Andrae, A. S. G. – Edler, T. (2015): On global electricity usage of communication technology: Trends to 2030. *Challenges*, 6(1), 117–157. <https://doi.org/10.3390/challe6010117>.
- AWS – Amazon Web Services (2025). AWS customer carbon footprint methodology – Model 3.0. *Amazon*. <https://sustainability.aboutamazon.com/aws-customer-carbon-footprint-methodology.pdf>.
- Bagó, P. (2023a): A mesterséges intelligencia lehetőségei a pénzügyekben. *Gazdaság és Pénzügy*, 10(1), 21–38. <https://doi.org/10.33926/GP.2023.1.2>.
- Bagó, P. (2023b): Kiberbiztonság és a mesterséges intelligencia. *Gazdaság és Pénzügy*, 10(2), 196–221. <https://doi.org/10.33926/GP.2023.2.5>.

- Bank of China Limited Magyarországi Fióktelepe* (2026): Különálló pénzügyi kimutatások az Európai Unió által befogadott IFRS-ekkel összhangban, 2025. december 31.
- Belkhir, L. – Elmeligi, A. (2018): Assessing ICT global emissions footprint: Trends to 2040 & recommendations. *Journal of Cleaner Production*, 177, 448–463. <https://doi.org/10.1016/j.jclepro.2017.12.239>.
- Bender, E. M. – Gebru, T. – McMillan-Major, A. – Shmitchell, S. (2021): On the dangers of stochastic parrots: Can language models be too big? In *Proceedings of the 2021 ACM Conference on Fairness, Accountability, and Transparency (FAccT '21)*, 610–623. ACM. <https://doi.org/10.1145/3442188.3445922>.
- Benedek, B. – Nagy, B. Zs. (2023): Hagyományos versus MI-alapú csalásfelderítés: Költséghatékonyság a gépjármű-biztosítások területén. *Hitelintézeti Szemle*, 22(2), 77–100. <https://doi.org/10.25201/HSZ.22.2.77>.
- BIS – Bank for International Settlements. (2024). Project Gaia: Enabling climate risk analysis using generative AI. *BIS Innovation Hub*. <https://www.bis.org/publ/othp84.htm>.
- Bódi, R. – Fáykiss, P. – Nyikes, Á. (2023): A technológiai óriásvállalatok rendszerkockázatai és szabályozásuk – „Too Big(Tech) To Fail?” *Hitelintézeti Szemle*, 22(1), 5–21. <https://doi.org/10.25201/HSZ.22.1.5>.
- Brevini, B. (2020): Black boxes, not green: Mythologizing artificial intelligence and omitting the environment. *Big Data & Society*, 7(2). <https://doi.org/10.1177/2053951720935141>.
- Cao, L. (2022): AI in finance: Challenges, techniques, and opportunities. *ACM Computing Surveys*, 55(3) 64. <https://doi.org/10.1145/3502289>.
- CIB Bank Zrt. (2026). *Fenntarthatósági jelentés 2025*.
- Cowls, J. – Tsamados, A. –, Taddeo, M. – Floridi, L. (2023): The AI gambit: Leveraging artificial intelligence to combat climate change – opportunities, challenges, and recommendations. *AI & Society*, 38(1), 283–307. <https://doi.org/10.1007/s00146-021-01294-x>.
- Crawford, K. (2021): Atlas of AI: Power, politics, and the planetary costs of artificial intelligence. *Yale University Press*.
- Dauvergne, P. (2022): Is artificial intelligence greening global supply chains? Exposing the political economy of environmental costs. *Review of International Political Economy*, 29(3), 696–718. <https://doi.org/10.1080/09692290.2020.1814381>.
- de Vries, A. (2023): The growing energy footprint of artificial intelligence. *Joule*, 7(10), 2191–2194. <https://doi.org/10.1016/j.joule.2023.09.004>.
- Desislavov, R. – Martínez-Plumed, F. – Hernández-Orallo, J. (2023): Trends in AI inference energy consumption: Beyond the performance-vs-parameter laws of deep learning. *Sustainable Computing: Informatics and Systems*, 38, 100857. <https://doi.org/10.1016/j.suscom.2023.100857>.
- Deutsche Bank* (2026): Sustainable Finance Framework (hatályos 2026. január 1-től).
- Dhar, P. (2020): The carbon impact of artificial intelligence. *Nature Machine Intelligence*, 2(8), 423–425. <https://doi.org/10.1038/s42256-020-0219-9>.
- Doumpos, M. – Zopounidis, C. – Gounopoulos, D. – Platanakis, E. – Zhang, W. (2023): Operational research and artificial intelligence methods in banking. *European Journal of Operational Research*, 306(1), 1–16. <https://doi.org/10.1016/j.ejor.2022.04.027>.
- EBA – European Banking Authority (2020): Report on big data and advanced analytics (EBA/REP/2020/01). <https://www.eba.europa.eu>.
- ECB – European Central Bank (2024): The rise of artificial intelligence: Benefits and risks for financial stability. In *Financial Stability Review, May 2024*. <https://www.ecb.europa.eu>.
- Európai Bizottság (2026): Targeted consultation on measuring energy consumption and emissions of AI models and systems. *Európai Bizottság, DG CNECT. Közzétéve: 2026. 04.07. A konzultáció le-*

- zárva: 2026.05.10. <https://digital-strategy.ec.europa.eu/en/consultations/targeted-consultation-measuring-energy-consumption-and-emissions-ai-models-and-systems>.
- Európai Parlament és Tanács (2022): Az (EU) 2022/2464 irányelv a fenntarthatósággal kapcsolatos vállalati beszámolókról (CSRD). Az *Európai Unió Hivatalos Lapja*, L 322.
- Európai Parlament és Tanács (2024): Az (EU) 2024/1689 rendelet a mesterséges intelligenciára vonatkozó harmonizált szabályok megállapításáról (AI-rendelet). Az *Európai Unió Hivatalos Lapja*, L sorozat.
- Evident (2025): The Evident AI Index for Banks: Key findings report 2025. *Evident Insights*. <https://evidentinsights.com/insights>.
- Evident (2026): AI use case trends in banking: Q1 2026. *Evident Insights*. <https://evidentinsights.com/insights/banking-use-case-trends-q1-2026>.
- Fares, O. H. – Butt, I. – Lee, S. H. M. (2023): Utilization of artificial intelligence in the banking sector: A systematic literature review. *Journal of Financial Services Marketing*, 28(4), 835–852. <https://doi.org/10.1057/s41264-022-00176-7>.
- Freitag, C. – Berners-Lee, M. – Widdicks, K. – Knowles, B. – Blair, G. S – Friday, A. (2021): The real climate and transformative impact of ICT: A critique of estimates, trends, and regulations. *Patterns*, 2(9), 100340. <https://doi.org/10.1016/j.patter.2021.100340>.
- FSB – Financial Stability Board: (2017). Artificial intelligence and machine learning in financial services: Market developments and financial stability implications. <https://www.fsb.org>.
- Google Cloud (2026): Carbon Footprint reporting methodology. Google. <https://docs.cloud.google.com/carbon-footprint/docs/methodology>.
- GRÁNIT Bank Nyrt. (2026): Az Igazgatóság jelentése a 2025. évi üzleti tevékenységről: konszolidált üzleti jelentés és fenntarthatósági nyilatkozat.
- Green Software Foundation (2026): Software Carbon Intensity for AI and EU AI Act environmental compliance: A framework for measuring and reducing AI's climate impact (1.0, 2026.02.15.). *Software Standards Working Group, Green Software Foundation*. <https://greensoftware.foundation/policy/research/sci-ai-eu-ai-act/>.
- Gupta, U. – Kim, Y. G. – Lee, S. – Tse, J. – Lee, H.-H. S. – Wei, G.-Y. – Brooks, D. – Wu, C.-J. (2021): Chasing carbon: The elusive environmental footprint of computing. In *2021 IEEE International Symposium on High-Performance Computer Architecture (HPCA)* (854–867). IEEE. <https://doi.org/10.1109/HPCA51647.2021.00076>.
- Harkácsi, G. J. – Szegfű, L. P. (2021): A megfelelőségbiztosítási funkció szerepe a digitalizáció, mesterséges intelligencia és robotizáció idején a pénzügyi szektorban. *Hitelintézeti Szemle*, 20(1), 152–170. <https://doi.org/10.25201/HSZ.20.1.152170>.
- Henderson, P. – Hu, J. – Romoff, J. – Brunskill, E. – Jurafsky, D. – Pineau, J. (2020): Towards the systematic reporting of the energy and carbon footprints of machine learning. *Journal of Machine Learning Research*, 21(248), 1–43. <https://doi.org/10.48550/arXiv.2002.05651>.
- Hentzen, J. K. – Hoffmann, A. – Dolan, R. – Pala, E. (2022): Artificial intelligence in customer-facing financial services: A systematic literature review and agenda for future research. *International Journal of Bank Marketing*, 40(6), 1299–1336. <https://doi.org/10.1108/IJBM-09-2021-0417>.
- Horváth, D. (2022): FinTech és blokklánc alapú megoldások alkalmazási lehetőségei a zöld pénzügyekben. *Vezetéstudomány / Budapest Management Review*, 53(4), 41–54. <https://doi.org/10.14267/VEZTUD.2022.04.04>.
- IEA – International Energy Agency (2024): Electricity 2024: Analysis and forecast to 2026. IEA. <https://www.iea.org>.
- IEA – International Energy Agency (2025). *Energy and AI*. IEA. <https://www.iea.org>.
- ING Bank N.V. Magyarországi Fióktelepe. (2026). IFRS egyedi beszámoló, 2025. december 31.

- Jones, N. (2018): How to stop data centres from gobbling up the world's electricity. *Nature*, 561(7722), 163–166. <https://doi.org/10.1038/d41586-018-06610-y>.
- Kaack, L. H. – Donti, P. L. – Strubell, E. – Kamiya, G. – Creutzig, F. – Rolnick, D. (2022): Aligning artificial intelligence with climate change mitigation. *Nature Climate Change*, 12(6), 518–527. <https://doi.org/10.1038/s41558-022-01377-7>.
- Königstorfer, F. – Thalmann, S. (2020): Applications of artificial intelligence in commercial banks – A research agenda for behavioral finance. *Journal of Behavioral and Experimental Finance*, 27, 100352. <https://doi.org/10.1016/j.jbef.2020.100352>.
- Koomey, J. – Berard, S. – Sanchez, M. – Wong, H. (2011): Implications of historical trends in the electrical efficiency of computing. *IEEE Annals of the History of Computing*, 33(3), 46–54. <https://doi.org/10.1109/MAHC.2010.28>.
- Lacoste, A. – Luccioni, A. – Schmidt, V. – Dandres, T. (2019): Quantifying the carbon emissions of machine learning. *arXiv*. <https://doi.org/10.48550/arXiv.1910.09700>.
- Li, P. – Yang, J. – Islam, M. A. – Ren, S. (2023): Making AI less “thirsty”: Uncovering and addressing the secret water footprint of AI models. *arXiv*. <https://doi.org/10.48550/arXiv.2304.03271>.
- Ligozat, A.-L. – Lefèvre, J. – Bugeau, A. – Combaz, J. (2022): Unraveling the hidden environmental impacts of AI solutions for environment: Life cycle assessment of AI solutions. *Sustainability*, 14(9), 5172. <https://doi.org/10.3390/su14095172>.
- Luccioni, A. S. – Jernite, Y. – Strubell, E. (2024): Power hungry processing: Watts driving the cost of AI deployment? In *Proceedings of the 2024 ACM Conference on Fairness, Accountability, and Transparency (FAccT '24)* (pp. 85–99). *ACM*. <https://doi.org/10.1145/3630106.3658542>.
- Luccioni, A. S. – Viguier, S. – Ligozat, A.-L. (2023): Estimating the carbon footprint of BLOOM, a 176B parameter language model. *Journal of Machine Learning Research*, 24(253), 1–15. <https://doi.org/10.48550/arXiv.2211.02001>.
- Luers, A. – Koomey, J. – Masanet, E. – Gaffney, O. – Creutzig, F. – Lavista Ferres, J. – Horvitz, E. (2024): Will AI accelerate or delay the race to net-zero emissions? *Nature*, 628(8009), 718–720. <https://doi.org/10.1038/d41586-024-01137-x>.
- Lülök, G. – Sebestyén, Z. (2025): A mesterséges intelligencia legújabb alkalmazási trendjei a bank-szektorban. *Hitelintézetí Szemle*, 24(2), 47–74. <https://doi.org/10.25201/HSZ.24.2.47>.
- MagNet Bank Zrt. (2026). A MagNet Bank Zrt. egyedi és csoporthoz tartozó, valamint a Polgári Bank Zrt. egyedi szintű nyilvánosságra hozatali dokumentuma az 575/2013/EU rendelet alapján, 2025. december 31.
- Malmodin, J. – Lundén, D. (2018): The energy and carbon footprint of the global ICT and E&M sectors 2010–2015. *Sustainability*, 10(9), 3027. <https://doi.org/10.3390/su10093027>.
- Masanet, E. – Shehabi, A. – Lei, N. – Smith, S. – Koomey, J. (2020): Recalibrating global data center energy-use estimates. *Science*, 367(6481), 984–986. <https://doi.org/10.1126/science.aba3758>.
- MBH Bank Nyrt. (2026). Éves jelentés a 2025. december 31-vel zárult évről (benne: Konszolidált fenntarthatósági jelentés).
- McKinsey & Company (2024). How generative AI can help banks manage risk and compliance. *McKinsey Risk & Resilience Practice*.
- Microsoft (2026): Emissions Impact Dashboard for Azure: Methodology and access. *Microsoft*. <https://www.microsoft.com/en-us/sustainability/emissions-impact-dashboard>.
- Milana, C. – Ashta, A. (2021): Artificial intelligence techniques in finance and financial markets: A survey of the literature. *Strategic Change*, 30(3), 189–209. <https://doi.org/10.1002/jsc.2403>.
- MNB – Magyar Nemzeti Bank. (2024): Zöld pénzügyi jelentés. *Magyar Nemzeti Bank*. <https://www.mnb.hu>.

- MNB – Magyar Nemzeti Bank (2025): Fintech és digitalizációs jelentés. *Magyar Nemzeti Bank*. <https://www.mnb.hu>.
- Mytton, D. (2021): Data centre water consumption. *npj Clean Water*, 4, Article 11. <https://doi.org/10.1038/s41545-021-00101-w>.
- Mytton, D. – Ashtine, M. (2022): Sources of data center energy estimates: A comprehensive review. *Joule*, 6(9), 2032–2056. <https://doi.org/10.1016/j.joule.2022.07.011>.
- Nishant, R. – Kennedy, M. – Corbett, J. (2020): Artificial intelligence for sustainability: Challenges, opportunities, and a research agenda. *International Journal of Information Management*, 53, 102104. <https://doi.org/10.1016/j.ijinfomgt.2020.102104>.
- Oberbank AG. (2026): Bond investor presentation, June 2026.
- OECD (2021): Artificial intelligence, machine learning and big data in finance: Opportunities, challenges, and implications for policy makers. *OECD Publishing*. <https://www.oecd.org>.
- OECD (2022): Measuring the environmental impacts of artificial intelligence compute and applications: The AI footprint (OECD Digital Economy Papers No. 341). *OECD Publishing*. <https://doi.org/10.1787/7babf571-en>.
- Patterson, D. – Gonzalez, J. – Le, Q. – Liang, C. – Munguia, L.-M – Rothchild, D. – So, D. – Texier, M. – Dean, J. (2021): Carbon emissions and large neural network training. *arXiv*. <https://doi.org/10.48550/arXiv.2104.10350>.
- PCAF – Partnership for Carbon Accounting Financials (2022): The global GHG accounting and reporting standard for the financial industry (2nd ed.). *PCAF*.
- Prisznayák, A. (2023): A bankrobotika horizontális és vertikális értékteremtése és az AI-washing jelenség. *Hitelintézeti Szemle*, 22(3), 97–122. <https://doi.org/10.25201/HSZ.22.3.97>.
- Radovanović, A. – Koningstein, R. – Schneider, I. – Chen, B. – Duarte, A. – Roy, B. – Xiao, D. – Haridasan, M. – Hung, P. – Care, N. – Talukdar, S. – Mullen, E. – Smith, K. – Cottman, M. – Cirne, W. (2023): Carbon-aware computing for datacenters. *IEEE Transactions on Power Systems*, 38(2), 1270–1280. <https://doi.org/10.1109/TPWRS.2022.3173250>.
- Rolnick, D. – Donti, P. L. – Kaack, L. H. – Kochanski, K. – Lacoste, A. – Sankaran, K. – Ross, A. S. – Milojevic-Dupont, N. – Jaques, N. – Waldman-Brown, A. – Luccioni, A. S. – Maharaj, T. – Sherwin, E. D. – Mukkavilli, S. K. – Kording, K. P. – Gomes, C. P. – Ng, A. Y. – Hassabis, D. – Platt, J. C. – Bengio, Y. (2022): Tackling climate change with machine learning. *ACM Computing Surveys*, 55(2), Article 42. <https://doi.org/10.1145/3485128>.
- Schwartz, R. – Dodge, J. – Smith, N. A. – Etzioni, O. (2020): Green AI. *Communications of the ACM*, 63(12), 54–63. <https://doi.org/10.1145/3381831>.
- Sevilla, J. – Heim, L. – Ho, A. – Besiroglu, T. – Hobbhahn, M. – Villalobos, P. (2022): Compute trends across three eras of machine learning. In *2022 International Joint Conference on Neural Networks (IJCNN)* (pp. 1–8). IEEE. <https://doi.org/10.1109/IJCNN55064.2022.9891914>.
- Shehabi, A. – Smith, S. J. – Hubbard, A. – Newkirk, A. – Lei, N. – Siddik, M. A. B. – Holecsek, B. – Koomey, J. – Masanet, E. – Sartor, D. (2024): 2024 United States data center energy usage report (LBNL-2001637). *Lawrence Berkeley National Laboratory*.
- Siddik, M. A. B. – Shehabi, A. – Marston, L. (2021): The environmental footprint of data centers in the United States. *Environmental Research Letters*, 16(6), 064017. <https://doi.org/10.1088/1748-9326/abfba1>.
- Sorrell, S. (2009): Jevons' Paradox revisited: The evidence for backfire from improved energy efficiency. *Energy Policy*, 37(4), 1456–1469. <https://doi.org/10.1016/j.enpol.2008.12.003>.
- Strubell, E. – Ganesh, A. – McCallum, A. (2019): Energy and policy considerations for deep learning in NLP. In *Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics* (3645–3650). ACL. <https://doi.org/10.18653/v1/P19-1355>.

- Taddeo, M. – Tsamados, A. – COWLS, J. – Floridi, L. (2021): Artificial intelligence and the climate emergency: Opportunities, challenges, and recommendations. *One Earth*, 4(6), 776–779. <https://doi.org/10.1016/j.oneear.2021.05.018>.
- Vőneki, T. Zs. – Lamanda, G. (2020): Az ESG-kockázatokkal kapcsolatos banki közzétételek tartalomlemzése – Pillanatkép a hazai nagybankok közzétételi gyakorlatáról. *Gazdaság és Pénzügy*, 7(4), 420–433. <https://doi.org/10.33926/GP.2020.4.3>.
- Thompson, N. C. – Greenewald, K. – Lee, K. – Manso, G. F. (2021): Deep learning’s diminishing returns: The cost of improvement is becoming unsustainable. *IEEE Spectrum*, 58(10), 50–55. <https://doi.org/10.1109/MSPEC.2021.9563954>.
- UniCredit Bank Hungary Zrt. (2026): Éves jelentés és beszámoló a 2025-ös évről.
- van Wynsberghe, A. (2021): Sustainable AI: AI for sustainability and the sustainability of AI. *AI and Ethics*, 1(3), 213–218. <https://doi.org/10.1007/s43681-021-00043-6>.
- Verdecchia, R. – Sallou, J. – Cruz, L. (2023): A systematic review of Green AI. *WIREs Data Mining and Knowledge Discovery*, 13(4), e1507. <https://doi.org/10.1002/widm.1507>.
- Vinuesa, R. – Azizpour, H. – Leite, I. – Balaam, M. – Dignum, V. – Domisch, S. – Felländer, A. – Langhans, S. D. – Tegmark, M. – Fuso Nerini, F. (2020): The role of artificial intelligence in achieving the Sustainable Development Goals. *Nature Communications*, 11, Article 233. <https://doi.org/10.1038/s41467-019-14108-y>.
- Vives, X. (2019): Digital disruption in banking. *Annual Review of Financial Economics*, 11, 243–272. <https://doi.org/10.1146/annurev-financial-100719-120854>.
- WRI–WBCSD (2004). The greenhouse gas protocol: A corporate accounting and reporting standard (Rev. ed.). World Resources Institute – World Business Council for Sustainable Development.
- Wu, C.-J. – Raghavendra, R. – Gupta, U. – Acun, B. – Ardalani, N. – Maeng, K. – Chang, G. – Aga, F. – Huang, J. – Bai, C. – Gschwind, M. – Gupta, A. – Ott, M. – Melnikov, A. – Candido, S. – Brooks, D. – Chauhan, G. – Lee, B. – Lee, H.-H. S. – Hazelwood, K. (2022): Sustainable AI: Environmental implications, challenges and opportunities. In *Proceedings of Machine Learning and Systems* (Vol. 4, pp. 795–813). MLSys. <https://doi.org/10.48550/arXiv.2111.00364>.

