



Területi Statisztika

Közzététel: 2025. november 21.

A tanulmány címe:

Az Európai Unió tagállamainak rangsorolása a mesterséges intelligencia vállalati alkalmazása alapján, 2023

Szerzők:

Lülök Gergely–Dobos Imre

<https://doi.org/10.15196/TS650604>

Az alábbi feltételek érvényesek minden, a Központi Statisztikai Hivatal (a továbbiakban: KSH) Területi Statisztika c. folyóiratában (a továbbiakban: Folyóirat) megjelenő tanulmányra. Felhasználó a tanulmány, vagy annak részei felhasználásával egyidejűleg tudomásul veszi a jelen dokumentumban foglalt felhasználási feltételeket, és azokat magára nézve kötelezőnek fogadja el. Tudomásul veszi, hogy a jelen feltételek megszegéséből eredő valamennyi kárért felelősséggel tartozik.

- 1) A jogszabályi tartalom kivételével a tanulmányok a szerzői jogról szóló 1999. évi LXXVI. törvény (Szt.) szerint szerzői műnek minősülnek. A szerzői jog jogosultja a KSH.
- 2) A KSH földrajzi és időbeli korlátozás nélküli, nem kizárólagos, nem átadható, térítésmentes felhasználási jogot biztosít a Felhasználó részére a tanulmány vonatkozásában.
- 3) A felhasználási jog keretében a Felhasználó jogosult a tanulmány:
 - a) oktatási és kutatási célú felhasználására (nyilvánosságra hozatalára és továbbítására a 4. pontban foglalt kivétellel) a Folyóirat és a szerző(k) feltüntetésével;
 - b) tartalmáról összefoglaló készítésére az írott és az elektronikus médiában a Folyóirat és a szerző(k) feltüntetésével;
 - c) részletének idézésére – az átvevő mű jellege és célja által indokolt terjedelemben és az eredetihez híven – a forrás, valamint az ott megjelölt szerző(k) megnevezésével.
- 4) A Felhasználó nem jogosult a tanulmány továbbértékesítésére, haszonszerzési célú felhasználására. Ez a korlátozás nem érinti a tanulmány felhasználásával előállított, de az Szt. szerint önálló szerzői műnek minősülő mű ilyen célú felhasználását.
- 5) A tanulmány átdolgozása, újra publikálása tilos.
- 6) A 3. a)–c.) pontban foglaltak alapján a Folyóiratot és a szerző(ke)t az alábbiak szerint kell feltüntetni:

„Forrás: Területi Statisztika c. folyóirat 65. évfolyam 6. számában megjelent, Lülök Gergely–Dobos Imre által írt, Az Európai Unió tagállamainak rangsorolása a mesterséges intelligencia vállalati alkalmazása alapján, 2023 c. tanulmány”

- 7) A Folyóiratban megjelenő tanulmányok kutatói véleményeket tükröznek, amelyek nem esnek szükségképpen egybe a KSH, vagy a szerzők által képviselt intézmények hivatalos álláspontjával.

Az Európai Unió tagállamainak rangsorolása a mesterséges intelligencia vállalati alkalmazása alapján, 2023

Ranking of European Union member states by business application of artificial intelligence, 2023

Lülök, Gergely

Budapesti Műszaki és
Gazdaságtudományi Egyetem,
Menedzsment és
Vállalatgazdaságtan Tanszék
E-mail: lulok.gergely@edu.bme.hu

Dobos, Imre

Budapesti Műszaki és
Gazdaságtudományi Egyetem,
Közgazdaságtan Tanszék
E-mail: dobos.imre@gtk.bme.hu

A mesterséges intelligencia (MI) és az automatizáció technológiai fejlődése jelentős hatással volt az Európai Unió (EU) tagállamainak előrehaladására, de alkalmazásukban és hatékonyságukban jelentős különbségek vannak. A tanulmány három módszertani keretrendszer segítségével elemzi az EU-s országok technikai képességeit: adatburok-elemzés (Data Envelopment Analysis – DEA), többszintű adatburok-elemzés (Tiered Data Envelopment Analysis – TDEA) és Pareto-optimalitás. A DEA és a TDEA módszerek lehetővé teszik az MI-alapú technológiák, például a robotizált folyamatautomatizálás, a képfeldolgozás, a természetes nyelvfeldolgozás és az autonóm drónok relatív hatékonyságának tanulmányozását, míg a Pareto-optimalitás segít az erőforrás-allokáció és a döntéshozatal optimalizálásában. Az eredmények azt mutatják, hogy míg az észak- és nyugat-európai tagállamok, például Finnország, Dánia és Hollandia kiemelkedő technológiai fejlődést értek el, addig a kelet- és dél-európai országok, például Románia és Bulgária jelentősen lemaradtak. Az eredmények hasznos iránymutatást nyújtanak a politikai döntéshozóknak és a kutatóknak, kiemelve a digitális infrastruktúrába, az MI-vel kapcsolatos innovációba és a regionális együttműködésbe történő célzott beruházások fontosságát. Ezen túlmenően hozzájárulhat a fenntartható technológiai fejlődéshez is az EU-ban.

Kulcsszavak:

mesterséges intelligencia,
statisztikai elemzés,
Európai Unió,
DEA,
TDEA,
Pareto-analízis

Technological developments in artificial intelligence (AI) and automation have had a significant impact on the progress of the member states of the European Union, but there are significant differences in their application and effectiveness. The study analyses the technical capabilities of European countries using three methodological frameworks: data envelopment analysis (DEA), tiered data envelopment analysis (TDEA) and Pareto-optimality. DEA and TDEA methods allow studying the relative efficiency of AI-based technologies such as robotic process automation, image processing, natural language processing and autonomous drones, while Pareto-optimality helps to optimize resource allocation and decision-making. The results show that northern and western member states, such as Finland, Denmark and the Netherlands, have achieved outstanding technological progress, while eastern and southern European countries, such as Romania and Bulgaria, have significantly lagged behind. The results provide useful guidance for policymakers and researchers, highlighting the importance of targeted investments in digital infrastructure, AI innovation and regional cooperation. Furthermore, it can contribute to sustainable technological progress in the EU.

Keywords:
artificial intelligence,
statistical analysis,
European Union,
DEA,
TDEA,
Pareto analysis

Beküldve: 2024. december 20.

Elfogadva: 2025. május 17.

Bevezetés

Az MI és az automatizáció fejlődése kulcsfontosságú szerepet játszik az EU gazdasági és technológiai stratégiájában. Az EU-tagállamok azonban eltérő ütemben alkalmazzák ezeket a technológiákat, ami jelentős különbségeket idéz elő a digitális fejlettség és az innovációs teljesítmény terén. A kutatás célja az EU tagállamainak MI-elfogadását és annak eltéréseit meghatározó tényezők elemzése, különös tekintettel az MI vállalati alkalmazására és az országok MI-fejlettségének összehasonlítására a DEA, a

Pareto-optimalitás és a TDEA módszerek segítségével. A vizsgálat alapját a 2023-ban végzett, az EU tagállamaiban működő vállalatokat célzó felmérés adatai képezik, amelyeket a nemzeti statisztikai hivatalok vettek fel. A reprezentatív minta 150 400 vállalatot foglalt magában, különös tekintettel az információs és kommunikációs technológia (IKT), valamint az MI alkalmazásaira. Az adatok megbízhatóságát és összehasonlíthatóságát az Eurostat (az EU statisztikai hivatala) biztosította, lehetővé téve az országok részletes elemzését.

A kutatás három fő módszertani megközelítést alkalmaz. Elsőként a DEA modell segítségével vizsgáljuk az MI-fejlettség és az országok technológiai hatékonyságának relatív értékeit. Ezt követően a Pareto-optimalitás és a TDEA modellek kombinált alkalmazása révén az országok fejlettségi szintjeit csoportosítjuk, azonosítva azokat, amelyek kiemelkedően teljesítenek, illetve azokat, amelyekben fejlesztési potenciál mutatkozik.

A három módszer alkalmazásával átfogóan értékelhetők a technológiai fejlődés különböző dimenziói. Míg a DEA az országok relatív hatékonyságát méri, addig a Pareto-optimalitás és a TDEA pedig lehetővé teszik az országok közötti teljesítménybeli eltérések strukturált elemzését. Az eredmények segítenek meghatározni azokat a stratégiákat, amelyekkel az egyes tagállamok hatékonyabban integrálhatják az MI-technológiákat, és hozzájárulhatnak az EU digitális transzformációjának előmozdításához.

Szakirodalmi áttekintés

Az MI alkalmazása az EU-ban jelentős regionális eltéréseket mutat, amelyek gazdasági és hatékonysági jellemzői figyelemre méltók. Ez a fejezet a szakirodalmat a DEA, a TDEA és a Pareto-optimalitás módszertanán keresztül vizsgálja, valamint rávilágít az egyes országok és iparágak teljesítményének különbségeire és azok okaira.

A mesterséges intelligencia hatása és alkalmazása az EU-ban

Az MI és a digitális technológiák alkalmazása terén jelentősek a különbségek az EU-tagállamok között: míg Svédország lakosságának 97%-a rendelkezik digitális készségekkel, addig Magyarországon ez az arány csak 57% (Vasilescu et al. 2020). Ehhez hasonlóan Dániában a vállalatok 23,9%-a alkalmaz MI-t, jelentős mértékben meghaladva az uniós átlagot (Daroń–Górska 2023), míg Finnország és Dánia magas MI-használati arányaival szemben Bulgáriában ez mindössze 3%-os (Brodny–Tutak 2021). A Big Data elterjedtsége is eltérő: míg a nagyvállalatok 33,5%-a alkalmazza ezt a technológiát, addig a kis- és középvállalkozások (kkv-k) csupán 10,57%-a (Pejić Bach et al. 2020). E különbségek arra utalnak, hogy az MI és a Big Data széles körű alkalmazása a fejlettebb országokban – például Luxemburgban és Hollandiában, ahol a digitális készségek magas szintűek (Chan–Meunier–Aitsahalia 2020) – gazdasági előnyökkel és fokozott innovációs képességgel jár. Ezzel szemben az olyan országok,

mint Bulgária és Románia, elmaradnak ezen technológiák alkalmazásában, bár Románia bizonyos fejlődést mutatott (Pripoaie et al. 2024). Míg a skandináv országok élen járnak az ipar 4.0 és az MI-rendszerek bevezetésében (Juhász et al. 2022), addig Németország vezető szerepe a robotikában gyengül, miközben Dánia és Spanyolországé erősödik (Duch-Brown et al. 2022).

Az MI európai iparágakban való alkalmazása kifejezi a technológia hatékonyságot és gazdasági fejlődést elősegítő szerepét, akár a közlekedés, az egészségügy, a távközlés, a gyártás vagy a pénzügyi szolgáltatások esetében. A közlekedésben az autonóm járművek és az MI-alapú forgalomirányítás jelentős eredményekhez vezethet. Guo–Wang (2021) szerint a prediktív vezérlés és a mély tanulás kombinálása csökkentheti a torlódásokat, akár 26 milliárd ausztrál dollárt is megtakarítva, míg a többszörös MI-rendszerek 20–35%-os javulást hozhatnak a forgalomirányításban (Abduljabbar et al. 2019, Haydari–Yilmaz 2022). Az egészségügyben a mély tanulási modellek, különösen a konvolúciós neurális hálózatok (convolutional neural network – CNN), kiemelkedő pontossággal diagnosztizálják a bőrrákot és a diabéteszes retinopátiát, javítva ezzel a prediktív egészségügyi rendszerek hatékonyságát (Agarwal et al. 2024, Esteve et al. 2019, Tong et al. 2020).

Az MI alkalmazása az 5G hálózatokban is ígéretes: Fu et al. (2018) és Morocho-Cayamcela et al. (2019) szerint az MI-alapú forgalomirányítás optimalizálja a hálózati erőforrásokat, javítja az energiahatékonyságot, továbbá csökkenti a késleltetést. Míg Baryannis et al. (2018) és Wang et al. (2020) rámutatnak az MI kiemelt szerepére az ellátási láncok kockázatkezelésében, ahol az gyorsabb és adaptívabb döntéseket tesz lehetővé. A gyártás és a pénzügyek terén az MI jelentősen javíthatja a hatékonyságot és a minőséget: akár 82%-os hatékonyságnövekedéshez is vezethet az okosgyártásban (Kullaya Swamy–Sarojamma 2020). A pénzügyi szektorban pedig a hibrid gépi tanulási algoritmusok pontosabb előrejelzéseket tesznek lehetővé, különösen a banki tranzakciók esetében (Wang et al. 2018, Balmer et al. 2020). E kutatások eredményei együttesen rávilágítanak arra, hogy az MI széles körű alkalmazása nemcsak növeli a hatékonyságot, hanem jelentős gazdasági előnyökkel is jár. Miközben javítja az előrejelző (prediktív) rendszerek pontosságát és a döntéshozatali folyamatokat, elősegíti az iparágak technológiai és gazdasági fejlődését is.

A DEA és a TDEA alkalmazása: európai és nemzetközi perspektívák

Az EU-s országokban az iparágak között jelentősek a különbségek a digitális fejlődés és a hatékonyság terén, amelyeket számos tanulmány elemzett a DEA és a TDEA módszerekkel. Bánhidi–Dobos (2023a, 2023b) három különböző módszerrel, köztük DEA- és klaszterelemzéssel vizsgálták az EU digitális fejlettségét, kimutatva, hogy az országok digitális teljesítménye szorosan kapcsolódik gazdasági fejlettségükhöz. Míg Jurickova et al. (2019) a nemzeti innovációs rendszerek hatékonyságát, addig Athanassopoulos (1996) és Andrijauskiene et al. (2023) az innováció hatékonyságát, vala-

mint a régiók közötti térbeli egyenlőtlenségeket elemezték, rámutatva, hogy a térbeli különbségek nagymértékben befolyásolják az innovációs teljesítményt.

A közlekedési szektorban Sternad–Grofelnick (2023) a Covid19-járvány hatását vizsgálták a vasúti szállítás hatékonyságára, amely technikai fejlesztéseket követelt. Szintén ezen a területen Jaržemskis–Jaržemskienė (2018) a repülőterek termelékenységét hasonlították össze, kimutatva az észak-európai repterek kiemelkedő teljesítményét.

A környezetvédelmi és a gazdasági teljesítmény kapcsolatával szintén több tanulmány foglalkozott. Míg Janicka–Sajnog (2023), valamint Kujawska (2021) az egészségügyi rendszerek hatékonyságát elemezték, addig Chioatto et al. (2024), továbbá Taboada et al. (2020) a hulladékgazdálkodási rendszerek fenntarthatóságát és hatékonyságát vizsgálták az EU régióiban, rámutatva a konvergenciára a fenntarthatósági célok terén. Lu–Lu (2018) a CO₂-kibocsátás és az energiahatékonyság összefüggésének kutatásából megállapították, hogy az uniós tagállamok teljesítménye jelentősen eltér a környezetbarát gazdasági fejlesztések terén.

A TDEA módszer a hatékonyság elemzésében olyan megközelítést tesz lehetővé, amely a vizsgált egységeket hierarchikus, hatékonysági szintek szerinti csoportokra osztja. Ez a módszer különösen hasznos az azonos hatékonysági határon lévő egységek hasonló szintek alapján történő rangsorolásában. A beszállítók és a vállalatok hatékonysági szempontból történő csoportosítása is számos tanulmány tárgya volt. Dobos (2023), valamint Dobos–Vörösmarty (2022) a beszállítói klaszterezés és a TDEA módszer alkalmazását vizsgálták, amelyek lehetővé teszik a beszállítók hatékonyság alapján történő rétegezését. Barr et al. (2000) rámutattak, hogy a TDEA az azonos hatékonysági határon elhelyezkedő döntési egységeket (decision making unit – DMU) hasonló hatékonysági szintű csoportokba rendezi, ezáltal elősegítve azok hierarchikus rangsorolását. Cheon (2009) a globális terminálok üzemeltetőinek hatását vizsgálta a kikötői hatékonyságra, míg Den et al. (2016) az orosz és a dél-koreai kikötők konténertermináljainak hatékonyságát elemezték. Ezek a kutatások rávilágítanak arra, hogy a hatékonyságon alapuló csoportosítási módszerek segíthetik a teljesítmény és a versenyképesség javítását mind a logisztikai, mind az ipari szektorban.

A kutatások eredményei azt mutatják, hogy a DEA és a TDEA módszerek sokoldalúan alkalmazhatók az EU-s gazdaság különböző szektoraiban, például a közlekedés, az egészségügy, a környezetvédelem, a logisztika vagy a beszállítói hálózatok esetében. Ezek a módszerek segítenek feltárni a különböző országok és iparágak teljesítményének eltéréseit, továbbá azonosítani a fejlesztési lehetőségeket, valamint támogatják a fenntartható és versenyképes gazdasági környezet kialakítását az EU-ban.

Pareto-optimalitás: elméleti és alkalmazott perspektívák

A Pareto-optimalitás kérdésével számos tanulmány foglalkozik, amelyekben különböző perspektívákból vizsgálják annak alkalmazhatóságát, kompromisszumait és a stratégiai manipulációval szembeni ellenállóságát. Az elemzés a különféle modellek és

preferencia-rendszerek hatását mutatja be, amelyek szorosan összefonódnak a hatékonysági célokkal és a társadalmi jólét maximalizálásával.

Goswami et al. (2014) kvázilineáris cseregazdaságokban mutatják be azt, hogy a Pareto-optimalitás és a stratégiai manipulálhatatlanság együttes elérése diktatórikus megoldásokat igényel. Ez kapcsolódik Lavi–May (2012) vizsgálataihoz, akik arra a következtetésre jutottak, hogy költségvetési korlátok jelenlétében a Pareto-optimalitás fenntartása szintén kompromisszumot követel meg. Ehhez szorosan illeszkedik Awad et al. (2017) elemzése, amely a Pareto-optimalitás és a stratégiai manipulálhatatlanság közötti kompromisszumokat emeli ki az érvelési aggregációs modellekben, amelyeket a kollektív döntéshozatalban alkalmaznak. Mindhárom említett tanulmány közös nevezője, hogy a Pareto-optimalitás elérése gyakran más fontos kritériumok korlátozását vagy feláldozását igényli. Bíró–Csáji (2024) szintén a Pareto-optimalitás kérdését vizsgálják többpartneres egyeztetési problémák lexikografikus preferenciái között. Rávilágítottak arra, hogy ezekben a modellekben a Pareto-hatékony és stabil megoldások megtalálása számítási kihívásokkal jár, ami tovább bonyolítja a kompromisszumok kezelését.

Ezt a kompromisszumos dinamikát tovább erősítik van der Stel (2000), valamint Karmokar et al. (2019) elemzései. Előbbi arra a következtetésre jutott, hogy a szigorúan konvex normák alapján meghatározott térben a koalíciós struktúrák stabilitásának fenntartása nehézkessé válhat. Utóbbiak pedig azt bizonyítják, hogy csak bizonyos preferenciaterületeken lehetséges egyszerre a Pareto-optimalitás és a csoport-szintű stratégiai manipulálhatatlanság elérése. Quartieri (2011) koalícióbiztos Nash-egyensúlyokat vizsgál gyenge és erős Pareto-túlsúly mellett, és bemutatja, hogy az isotone és antitone externáliák hatással vannak a koalíciós stabilitásra. Ezek az eredmények egyaránt azt sugallják, hogy a preferenciaterületek szerkezete, az egyéni preferenciák ismeretének szintje, illetve a koalíciók struktúrája alapvető fontosságúak a Pareto-optimalitás stabilitásának biztosításához.

A Pareto-optimalitás és az erőforrások közötti kapcsolat bemutatásában Montecano (2017), valamint Davtalab-Olyaie–Asgharian (2021) tanulmányai hasonlóságot mutatnak. Előbbi kettős optimalizációs modellje megvilágítja az erőforrás-pazarlás és a társadalmi jólét kapcsolatát, amely összefüggés a Pareto-hatékonyság új mérési módjának tekinthető. Utóbbi ezen megközelítésre építve mutat be egy többcélú programozási modellt a DEA-alapú kereszt-hatékonysági értékeléshez, amely egyetlen lineáris modell alkalmazásával generál Pareto-optimalizált pontszámokat. Ez a megközelítés különösen érdekes lehet a Tisdell (1966) által vizsgált csoportos viselkedési modellek értelmezésében, ahol az erőforrások elosztása és a preferenciák figyelembevétele korlátozó tényezőként jelenik meg a Pareto-optimalitás elérésében.

Az említett tanulmányok együttesen rámutatnak arra, hogy a Pareto-optimalitás megközelítései különféle módon járulnak hozzá az erőforrás-elosztás és döntéshozatal hatékonyságának növeléséhez. Az elemzés végül azt sugallja, hogy a különféle modellekben rejlő strukturális és preferenciális különbségek elengedhetetlenek a

Pareto-optimalitás fenntartásához, és egyúttal új kutatási irányokat nyitnak az optimális döntéshozatali mechanizmusok kialakítása érdekében.

Az adatfelvétel módja és a minta jellemzői

A kutatás alapjául szolgáló adatokat az EU tagállamaiban működő vállalatok körében 2023 elején végzett felmérés biztosította, amelyet a nemzeti statisztikai hivatalok készítettek el. A felmérés célja a vállalatok információs IKT-eszközhasználatának átfogó jellemzése, kiemelve az MI alkalmazását. A statisztikai hivatalok által alkalmazott módszertan garantálta, hogy az adatok megbízhatóak és reprezentatívak legyenek az EU vállalati szférája vonatkozásában. A vizsgálat körülbelül 1,47 millió, az EU-ban működő, legalább 10 főt foglalkoztató vállalatot ölelt fel, amelyből 150 400 céget választottak ki véletlenszerű mintavétellel.

A mintavétel során külön figyelmet fordítottak arra, hogy a különböző vállalatméret-kategóriák és gazdasági ágazatok megfelelő arányban képviselve legyenek, így az eredmények széles körben általánosíthatók és összehasonlíthatók. A vállalatokat a gazdasági tevékenységek ágazati osztályozási rendszere (Nomenclature des activités économiques dans les Communautés européennes – NACE Rev.2) alapján csoportosították, belefoglalva többek között a feldolgozóipart, az informatikai ágazatot, az energiát, a kiskereskedelmet és a tudományos, műszaki szolgáltatásokat. Így részletesen bemutatták, hogyan használják az IKT és az MI technológiákat a különböző iparágakban és vállalati méretekben.

Az adatgyűjtést és -feldolgozást a statisztikai hivatalok egységes módszertan alapján végezték, gondoskodva arról, hogy a mintában szereplő vállalatok az EU különböző régióit és szektorait is képviseljék. Az MI elterjedtségének elemzésére több mutatót használtak, például a vállalatok MI-alkalmazásának százalékos arányát és az egyes MI-technológiák felhasználását. Az adatokat az Eurostat hivatalos adatbázisában rögzítették, amely biztosítja az EU-szintű összehasonlíthatóságot és az egyes országokra vonatkozó részletes adatokhoz való hozzáférést (Eurostat 2023). A felmérés eredményeit gazdasági elemzésekhez, döntéshozatalhoz és tudományos kutatásokhoz egyaránt felhasználják.

A vizsgálat szerint az MI-technológiákat működtető vállalatok aránya országonként eltérő. Észtországban a vállalatok 23,1%-a alkalmazott valamilyen MI-megoldást, míg Németországban ez az arány 15,4% volt, ami az eltérő digitalizációs stratégiákra és szabályozási környezetre vezethető vissza. Az iparágak között is jelentős különbségek mutatkoztak: míg az informatikai szektorban az MI-alkalmazás elérte a 35%-ot, addig a hagyományos feldolgozóiparban csupán 10% körül mozgott. A pénzügyi szektorban az MI elterjedtsége 28%-os volt, ami a fejlett automatizációs rendszerek bevezetésével magyarázható.

Az elemzés kimutatta, hogy a vállalatméret is lényeges szerepet játszik az MI-elfogadásban: míg a 250 főnél nagyobb vállalatok körében az MI-használat aránya

40% feletti, addig a kkv-knél 12–18% közötti. Az MI-technológiák közül a természetes nyelvfeldolgozás (natural language processing – NLP) és a gépi tanulás (machine learning – ML) voltak a leggyakoribbak, illetve kevésbé terjedtek el az arcfelismerési és az autonóm döntéshozatali rendszerek.

A kutatás módszertana

A kutatás során alkalmazott módszertan matematikai részleteinek, köztük a lépcsőzetes DEA és a Pareto-hatékonysági elemzés elméleti hátterét Bánhidi–Dobos (2023a, 2023c) részletesen is kifejtették, így tartalmazzák a kapcsolódó modellek matematikai levezetéseit és képleteit is, amelyek jelen tanulmányunk alapjául szolgálnak. Célunk elsősorban az elemzések eredményeinek bemutatása, így a módszerek elméleti és technikai részleteinek ismertetésétől eltekintettünk, azokat az imént hivatkozott források részletesen magyarázzák.

A kutatás során alkalmazott módszerek az elemzett adatok feldolgozását különbözően közelítik meg, valamint mindegyik saját előnyökkel és korlátokkal rendelkezik. Az 1. táblázatban röviden összefoglaljuk a Pareto-elemzés, a TDEA és a DEA közös súlyok főbb jellemzőit, kiemelve az egyes eljárások előnyeit és hátrányait, valamint a közöttük kimutatható legfontosabb különbségeket.

1. táblázat

Az alkalmazott módszerek összehasonlítása

Comparison of the methods used

Módszer	Előnyök	Hátrányok
Pareto-hatékonyság	Az összes releváns kritériumot figyelembe veszi, lehetővé téve az objektív csoportosítást.	Bizonyos kritériumvektorok esetében előfordulhat, hogy az összehasonlítás nem egyértelmű (nem összehasonlítható).
	A Hasse-diagram vizualizálható és intuitív eszközt biztosít a döntési egységek rangsorolására.	A részleges rendezés korlátozhatja az országok teljes rangsorolását, azok csak csoportosíthatók.
TDEA	Lehetővé teszi minden ország (DMU) közvetlen összehasonlítását egy szekvenciális algoritmus segítségével.	Ha egy ország egy kritériumban kiemelkedik, a többi szempont figyelmen kívül hagyható (torzítás veszélye).
	Részleges hatékonysági csoportosítást biztosít, alkalmas többdimenziós elemzésekre.	A módszer nem mindig találja meg az összes Pareto-hatékony elemet, így az eredmények korlátozottak lehetnek.
DEA közös súlyok	Minden országhoz hozzárendelhető egy relatív hatékonysági index, amely objektíven méri a teljesítményt.	A hatékonysági index korlátos, azaz nem ad lehetőséget a hatékony egységek közötti finomhangolt elemzésre.
	A digitális fejlettséget többdimenziós módon, explicit input nélkül (DEA–WEI) méri.	A módszer nem mindig alkalmas többdimenziós stratégiák összehasonlítására egyéni szinteken.

A Pareto-hatékonyság az országok közötti relatív teljesítményt értékeli, figyelembe véve azokat a dimenziókat, amelyekben egy országot nem múl felül egy másik. Egy ország Pareto-hatékony, ha nincs olyan másik ország, amely minden vizsgált dimenzióban jobban teljesít nála. A módszer előnye, hogy az összes releváns kritériumot figyelembe veszi, objektív csoportosítást biztosít, és a Hasse-diagram segítségével vizualizálhatóak a vezető szerepek. Hátránya, hogy bizonyos kritériumvektorok esetén nem hasonlítható össze, és a részleges rendezés miatt pedig nem biztosít teljes rangsort.

A TDEA a döntési egységek (országok) közvetlen összehasonlítását teszi lehetővé lépésről lépésre. Az elemzés során először azonosítják a leghatékonyabb döntési egységeket, majd azokat eltávolítják a halmazból, és a folyamatot ismétlik a fennmaradó elemekkel. A módszer előnye, hogy részleges hatékonysági csoportosítást biztosít, amely lehetővé teszi többdimenziós elemzések elvégzését, és hozzájárul homogén országcsoportok kialakításához. Hátránya azonban, hogy ha egy ország egyetlen kritériumban kiemelkedik, a többi szempont figyelmen kívül maradhat, ami torzításhoz vezethet. Emellett a TDEA nem mindig találja meg az összes Pareto-hatékony elemet, így az eredmények korlátozottak lehetnek.

A DEA minden ország számára egy relatív hatékonysági indexet számít ki, amely objektíven méri a teljesítményt, és kizárólag outputokra támaszkodva elemzi a digitális fejlettséget, ezáltal egyetlen mérőszámba integrálja a többdimenziós szempontokat. Hátránya, hogy az index nem teszi lehetővé a hatékony egységek közötti finomhangolt elemzést, továbbá a rögzített paraméterek korlátozhatják a rugalmasságot. A DEA több modellváltozatot biztosít, köztük a maximin, az euklideszi és Csebisev-módszert, amelyek az objektív rangsorolás érdekében a közös súlyok alkalmazását is lehetővé teszik:

1. Maximin: Ez a modell maximalizálja az adott súlyvektor által elért minimális hatékonyságot. A módszer garantálja, hogy a legrosszabb teljesítményű döntési egység is optimális helyzetbe kerüljön az adott súlyozás mellett, azaz a méltányos értékelést.
2. Euklideszi: Az országok hatékonyságát az ideális ponttól való négyzetes eltérés minimalizálásával méri. Ez a módszer kiegyensúlyozott megközelítést tesz lehetővé, mivel figyelembe veszi az összes dimenzió közötti eltéréseket.
3. Csebisev: Ez a modell az ideális ponttól való maximális eltérést minimalizálja, különös figyelmet fordítva a legnagyobb hiányosságra. Ezáltal kiemeli a legkritikusabb fejlesztési területeket, amelyeket az országoknak javítaniuk kell.

Eredmények

Az ordinalitáson alapuló módszerek eredményei

A következő elemzés az EU-s országok MI-integrációját vizsgálja ordinalitáson alapuló módszerekkel, amelyekkel megállapítják az országok sorrendi viszonyait. Első-

ként a Pareto-hatékonyság alkalmazásával az országokat lépcsőzetesen csoportosítjuk, azaz közülük azonosítjuk azokat, amelyeket más országok nem előznek meg a vizsgált dimenziók mentén. Ezt követően a TDEA módszerrel tovább pontosítjuk az országok rangsorát, rétegekre bontva a teljesítményüket. Végül az eredmények összevetésével értelmezzük a két megközelítés közötti különbségeket, valamint következtetéseket vonunk le az MI-integráció sajátosságairól Európában.

Az országok lépcsőzetes csoportosítása a Pareto-hatékonysággal

Ennek célja, hogy ordinalitáson alapuló Pareto-hatékonysággal vizsgálja az EU-s országok MI-alkalmazásait. A Pareto-hatékonyság elve alapján az országokat úgy rendezzük, hogy azonosítsuk közülük azokat, amelyeket egyetlen más ország sem előz meg, ezáltal meghatározva a fejlettségi szinteket és a technológiai teljesítmény viszonyrendszerét. A vizsgálat az MI különböző alkalmazási területeire – például szövegbányászat, beszédfelismerés, NLP, képfelismerés, ML, robotizált folyamatautomatizálás, autonóm drónok, ipari gyártás, logisztika, marketing és IKT-biztonság – terjed ki. Az eredményeket a Függelék F1. táblázatban mutatjuk be, amely rávilágít az egyes országok közötti különbségekre és az ordinalitáson alapuló csoportosításra.

Szövegbányászat: Luxemburg (6,7) és Dánia (5,3) magas fejlettségi szintűek, ami arra utal, hogy ezek az országok jelentős erőforrásokat fektetnek az adatbányászati technológiákba, különösen a szövegbányászat területén. Ezzel szemben Bulgária (0,5) és Észtország (0,4) alacsony értékei a technológiai infrastruktúra, valamint az MI-alkalmazások viszonylag alacsony fejlettségére utalnak ezen a területen.

Beszédfelismerés: Luxemburg (4,3) és Dánia (3,1) ismételten kiemelkednek, ami arra enged következtetni, hogy ezen országokban fejlettebb beszédfelismerő technológiák működnek, valószínűleg az ügyfélszolgálati és -kapcsolati rendszerek területén. Ezzel szemben Lengyelország és Bulgária (egyenként 0,3) alacsony értékei azt jelzik, hogy ezekben az országokban kevésbé elterjedtek ezen technológiai megoldások.

Természetes nyelvfeldolgozás (NLP): Szlovénia (5,5) élen jár ebben, ami azt jelzi, hogy az országban előrehaladott nyelvfeldolgozó rendszerek működnek, amelyek valószínűleg a többnyelvűség kezelésében is hasznosak lehetnek. Bulgária és Ciprus (egyenként 0,3) viszont az alsó tartományban helyezkednek el, jelezve e technológiák viszonylagos alulfejlettségét.

Képfelismerés, képfeldolgozás: Málta (6,8) és Szlovénia (7,4) kimagasló értékei azt mutatják, hogy ezen országokban fejlett képfelismerő és képfeldolgozó rendszerek érhetők el, amelyeket az egészségügyi diagnosztikától az ipari alkalmazásokig széleskörűen használnak. Bulgária (0,6) és Horvátország (1,0) ezzel szemben alacsonyabb szintet képviselnek.

Gépi tanulás (ML): Belgium (6,2) és Dánia (5,4) vezetnek e téren, ami olyan technológiai fejlesztésekre és innovációkra utal, amelyek támogatják az adatintenzív megoldásokat. Románia (0,2) legalacsonyabb értéke azt mutatja, hogy ott az ML alkalmazása és fejlesztése kevésbé elterjedt.

Robotizált folyamatautomatizálás: Finnország (8,0) és Hollandia (5,4) ezen a területen is vezető szerepet tölt be, ami fejlett ipari automatizációra és termelékenységre utal. Románia (0,4) alacsony értéke azt jelzi, hogy a robotizáció és a folyamatautomatizálás kevésbé fejlett.

Autonóm drónok: Hollandia (5,1) és Belgium (3,4) jelentős fejlettséget értek el a technológia alkalmazásában, ami a mezőgazdasági, a logisztikai és a biztonsági szektor előnyére válhat. Románia (0,2) és Görögország (0,5) alacsony pontszámai kevésbé fejlett autonóm drón-rendszerekre utalnak.

Ipari gyártás: Finnország (5,8) és Ausztria (5,0) kiemelkedő pontszámai fejlett gyártási technológiára és automatizálásra utalnak. Románia (0,3) és Bulgária (0,9) alacsony értékeik alapján kevésbé fejlett gyártási technológiai infrastruktúrával rendelkeznek.

Logisztika: Hollandia (2,5) és Dánia (2,7) e téren is magas fejlettségi szintet ért el, ami a hatékony szállítási és logisztikai rendszerek jelenlétét jelzi. Bulgária (0,1) és Görögország (0,2) viszont kevésbé fejlett logisztikai rendszereket alkalmaz.

Marketing: Finnország (3,2) és Írország (2,1) kiemelkedik a digitálismarketing-technológiák területén, ami fejlett adatvezérelt marketingstratégiák alkalmazását tükrözi. Románia (0,2) és Észtország (0,5) alacsony értékei korlátozottabb digitálismarketing-infrastruktúrára engednek következtetni.


IKT-biztonság: Szlovénia (8,6) és Belgium (5,3) vezető szerepet töltenek be ezen a területen, ami magas szintű kiberbiztonsági intézkedéseket és infrastruktúrát takar. Románia és Bulgária egyaránt (0,2) a legalsó tartományban helyezkedik el, ez alacsonyabb szintű IKT-biztonsági intézkedésekre utalhat.

Az eredményekből arra következtethetünk, hogy a nyugat- és észak-európai országok – különösen Luxemburg, Finnország, Dánia és Hollandia – kiemelkedően magas szintű fejlettséget értek el az MI és az automatizáció különböző területein. Ezzel szemben több dél- és kelet-európai ország – mint Bulgária, Románia és Görögország – kevésbé fejlett ezen technológiák alkalmazásában, ami technológiai fejlődési potenciált sugall számukra a jövőben.

A Pareto-hatékonysági elemzés lépcsőzetes csoportosítása után a Hasse-diagram (1. ábra) alkalmazása további strukturális információt nyújt az országok közötti kapcsolatokról.

A Hasse-diagram strukturált formában mutatja be az országok azon szintjeit, ahol az egyes szintek részlegesen rendezett halmazt alkotnak. Ez azt jelenti, hogy az országok közötti kapcsolatokat úgy értelmezzük, hogy az egyik ország fejlettségi szintje felülmúlhatja a másikat, amennyiben az összes vizsgált technológiai területen magasabb pontszámot ér el. Az ábra vonalai az országok közötti rendezési viszonyokat mutatják, azaz azt, hogy mely országok állnak kapcsolatban egymással a technológiai fejlettség tekintetében. Az egyes szinteken belüli összeköttetések hiánya arra utal, hogy az azonos szinten lévő országok nem múlják felül egymást, így mindegyikük egyedi fejlettségi profillal rendelkezik, saját előnyökkel és korlátokkal.

1. ábra



Megjegyzés: az országrövidítéseket lásd a 2. táblázatban.

Forrás: saját szerkesztés (DART-application).

A 4. szinten elhelyezkedő országok – például Ausztria, Belgium, Dánia és Finnország – Pareto-hatékonyak, ami azt jelenti, hogy egyetlen másik ország sem előzi meg őket. Ezek az országok az MI és az automatizáció területén kiemelkedően fejlettek, és technológiai szempontból olyan szintet képviselnek, amelyet a többi ország nem tud felülmúlni. Ez a szint a MI-integráció és az ipari digitalizáció szempontjából is élen jár. A fejlett kutatás-fejlesztési környezet, az erős állami támogatás és a magasan kvalifikált munkaerő együttesen biztosítják azt, hogy ezek az országok vezető szerepet töltsenek be a MI-vezérelt iparágakban.

A 3. szint országai, mint Németország, Írország, Spanyolország és Svédország, szintén fejlettnak tekinthetők, de eredményeik bizonyos területeken alacsonyabbak a 4. szint országainál. Ezek az országok általában magas szintű technológiai infrastruktúrával rendelkeznek, de néhány kiemelt területen elmaradnak a legmagasabb szintet képviselő országok mögött. Így, bár jelentős szerepet töltenek be az MI és az automatizáció alkalmazásában, összességében nem érik el a legmagasabb fejlettségi szintet. Ezen országok között is jelentősek az eltérések. Írország például a multinacionális vállalatok MI-adaptációja révén került erre a szintre, míg Svédország az állami és a vállalati szektor együttműködésével fejlesztette digitális ökoszisztémáját. Németország ipari MI-megoldásai kiemelkedőek, míg Spanyolország inkább a fogyasztói MI-megoldások és a szolgáltató szektor digitalizációja révén építette fel technológiai fejlettségét.

A 2. szint országai, például Magyarország, Franciaország, Olaszország és Lettország közepes fejlettségi szinten helyezkednek el. Ezek az országok részlegesen rendezett kapcsolatban állnak a magasabb szintű országokkal, de számos területen lemaradnak. A 2. szinten lévő országok jellemzően már alkalmaznak különféle MI- és auto-

matizációs megoldásokat, de azok nem olyan kifinomultak és kiterjedtek, mint a 3. vagy a 4. szint országai esetében. Ebből adódóan jelentős potenciállal rendelkeznek további technológiai fejlesztések és innovációk terén. Fontos különbség figyelhető meg Magyarország és Franciaország között: míg Magyarország az MI-alapú automatizálás ipari alkalmazásait fejleszti gyors ütemben, Franciaország inkább az etikai és jogi szabályozás kialakításában élenjáró. Eltérések vannak az MI-adaptáció stratégiájában is, hiszen míg Olaszország a vállalati digitalizáció támogatására helyezi a hangsúlyt, addig Lettország főként az oktatási és kutatási szektorban igyekszik előre lépni.

Az 1. szint országai, mint Bulgária, Észtország és Lengyelország, az ábrán a legalacsonyabb fejlettségi szinten helyezkednek el, azt jelezve, hogy az MI és az automatizáció alkalmazása, fejlesztése ezekben az országokban viszonylag korlátozott. Ezen országok technológiai szempontból nem múlnak felül más országokat, és a Hasse-diagram szerint jelentős fejlődési tér áll előttük. Számukra a technológiai innováció és fejlesztés további lehetőségeket teremt arra, hogy felzárkózzanak a fejlettebb európai országokhoz. Azonban az 1. szint országai között is akadnak sajátos esetek. Észtország például a digitális szolgáltatásokban és az MI-kutatásban kiemelkedik (23,1%-os MI-elterjedés), de a hagyományos feldolgozóipari szektorban jelentős az elmaradása. Ez a belső kettősség azt mutatja, hogy az MI-fejlettség nem egységes az ország egészében, hanem szektorális eltérések figyelhetők meg. Bulgária és Lengyelország esetében az MI-adaptáció alacsony szintje elsősorban a kisebb kutatás-fejlesztési ráfordításokkal és az ipari innováció lassabb ütemével magyarázható.

A Hasse-diagram tehát nem csupán egy hierarchikus struktúrát mutat be, hanem a különböző országok technológiai fejlődési útvonalainak sajátosságait is feltárja. Az országok között fennálló kapcsolatokat vizsgálata lehetővé teszi az MI-fejlesztések főbb irányvonalainak azonosítását, valamint az egyes államok számára releváns fejlesztési területek kiemelését. Az eredmények alapján megállapítható, hogy a technológiai fejlettség nem homogén Európában, hanem jelentősek az eltérések mind az országok, mind az iparági szektorok között.

Az EU-s országok MI-fejlettségének rétegekbe sorolása (hagymahéjazása)

A Függelék F2. táblázata a DEA hatékonysági mutatóin alapuló elemzés eredményeit tartalmazza. Az országokat iteratív módon rangsoroltuk a relatív hatékonyságuk alapján. Az elemzés első lépéseiben a legjobb (1,000 értékű) hatékonysági mutatóval rendelkező országokat azonosítottuk, majd fokozatosan tértünk át az alacsonyabb hatékonyságúak értékelésére. Ennek során a hatékonyság csökkenésével járó „lépcsőket” hoztunk létre, amelyek az országokat teljesítményük szerint csoportosították.

A 2. táblázatot a Függelék F2. táblázata alapján állítottuk össze, és az országokat öt fejlettségi rétegbe soroltuk. A besorolás a DEA hatékonysági mutatóira épül, és MI-integrációjuk alapján átlátható módon csoportosítja az országokat. Ez lehetővé teszi a relatív pozíciók értelmezését és az országok közötti különbségek strukturált megjelenítését.

2. táblázat

A rétegek értékelése, 2023

Evaluation of layers, 2023

1. réteg	2. réteg	3. réteg	4. réteg	5. réteg
Belgium (BE)	Ausztria (AT)	Horvátország (HR)	Franciaország (FR)	Bulgária (BG)
Finnország (FI)	Németország (DE)	Ciprus (CY)	Magyarország (HU)	Észtország (EE)
Luxemburg (LU)	Portugália (PT)	Csehország (CZ)	Lettország (LV)	
Hollandia (NL)	Spanyolország (ES)	Görögország (EL)	Lengyelország (PL)	
Dánia (DK)	Írország (IE)	Olaszország (IT)	Románia (RO)	
Málta (ML)		Litvánia (LT)		
Szlovénia (SI)		Szlovákia (SK)		
		Svédország (SE)		

1. réteg – Az élenjáró országok: Az első rétegben található országok – Belgium, Finnország, Luxemburg, Hollandia, Dánia, Málta és Szlovénia – a technológiai fejlettség legmagasabb szintjét képviselik. Kimagasló eredményeket értek el az MI különböző alkalmazási területein, ideértve az ML-t, a robotizációt és az IKT-biztonságot. Kiemelkedő teljesítményük a gazdasági stabilitásukkal és a digitális innovációba történő jelentős beruházásokkal magyarázható. Luxemburg és Finnország például az MI és a digitális infrastruktúra terén vezető szerepet tölt be, míg Dánia és Hollandia az ipari alkalmazásokban, különösen az ipari gyártás és a logisztika területén ért el kiemelkedő eredményt.

2. réteg – Fejlett, de nem élenjáró országok: A második réteghez tartozó országok – Ausztria, Németország, Portugália, Spanyolország és Írország – magasabb szintű technológiai képességekkel rendelkeznek, de bizonyos területeken – például a logisztikában vagy az NLP-ben – alacsonyabb szintű fejlettséget mutatnak az első réteghez képest. Németország például továbbra is vezető az ipari automatizáció terén, de az MI-innovációk egyes területein (például a beszédfelismerés vagy az ML) kevésbé emelkedik ki. Portugália és Spanyolország dinamikusan fejlődik a Big Data és az MI-alapú elemzések alkalmazásaiban, ami hozzájárul a versenyképességük növeléséhez.

3. réteg – Közepesen fejlett országok: A harmadik réteg országai – Horvátország, Ciprus, Csehország, Görögország, Olaszország, Litvánia, Szlovákia és Svédország – közepes technológiai fejlettségi szinten állnak. Már rendelkeznek bizonyos MI- és automatizációs alkalmazásokkal, de ezek gyakran kevésbé kiterjedtek vagy fejlettek, mint a magasabb rétegek országaiban. Svédország például erős digitális infrastruktúrával rendelkezik, de az MI alkalmazásának szélesebb körű elterjedésében még nem érte el a vezető országok szintjét. Görögország és Ciprus további innovációs és infrastrukturális fejlesztésekre szorul annak érdekében, hogy felzárkózzék a technológiai élmezőnyhöz.

4. réteg – Fejlesztési potenciállal rendelkező országok: A negyedik réteg országainak technológiai fejlettsége alacsonyabb szintű. Bár már alkalmaznak bizonyos MI-alapú rendszereket, ezek általában kevésbé fejlettek és nem annyira széles

körben elterjedtek. Franciaország gazdasági erőforrásai ellenére nem érte el az MI alkalmazásában a vezető országok szintjét, míg Magyarország és Románia bizonyos területeken, például a robotizációban mutat némi fejlődést.

5. réteg – A legkevésbé fejlett országok: Az ötödik rétegbe tartozó Bulgária és Észtország a technológiai fejlettség legalacsonyabb szintjét képviseli, az MI és az automatizáció alkalmazása esetükben még gyerekcipőben jár, ami a technológiai infrastruktúra hiányosságaiból és a digitalizáció korlátozott elterjedtségéből fakad. Ezek az országok azonban nagy fejlődési potenciállal rendelkeznek, különösen abban az esetben, ha célzott beruházásokat hajtanak végre a digitális készségek és az innováció fejlesztésére.

Az ordinalitáson alapuló módszerek eredményeinek összegzése

Az elemzés során két ordinalitáson alapuló módszert alkalmaztunk az EU-s országok MI-integrációjának vizsgálatára: a Pareto-hatékonyság alapján történő lépcsőzetes csoportosítást és a TDEA módszert.

A Pareto-hatékonyság segítségével azokat az országokat azonosítottuk, amelyeket más országok nem múltak felül a vizsgált dimenziók mentén. Ez lehetővé tette az MI különböző területein elért teljesítmények szerinti csoportosítást, anélkül hogy explicit rangsort állítottunk volna fel közöttük. A Hasse-diagram segítségével strukturáltan jelenítettük meg a részleges vezető szerepeket (dominanciaviszonyokat), ezáltal feltárva az országok közötti technológiai különbségeket.

A TDEA-módszer ezzel szemben egy iteratív eljárással tovább részletezte az országok rangsorát, rétegekre bontva a teljesítményüket. A módszer lehetővé tette az országok relatív hatékonyságának fokozatos értékelését és a teljesítménybeli eltérések finomhangolt vizsgálatát. Az eredmények alapján az országokat öt fejlettségi rétegbe soroltuk, amely pontosabban jellemezte az MI-integráció fokozatait és az egyes országok relatív pozícióit.

A két módszer kiegészíti egymást: míg a Pareto-hatékonysági megközelítés inkább a dominanciaalapú viszonyokra és csoportosításra helyezi a hangsúlyt, a TDEA részletesebb differenciálást tesz lehetővé az országok között. Az eredmények összevetése rávilágított arra, hogy bizonyos országok – például Finnország, Hollandia és Luxemburg – mindkét módszer szerint az élmezőnybe tartoznak, míg mások (például Bulgária és Románia) következetesen az alsóbb fejlettségi kategóriákba kerültek.

A Cramér-féle V mutató értéke (0,782) továbbá azt jelzi, hogy a Pareto-alapú és a TDEA-alapú módszerek eredményei nagyon erős kapcsolatot mutatnak. Ez azt jelenti, hogy a két módszer által kialakított rangsoroknak és rétegeknek nagyfokú az egyezősége, azok azonos trendeket és struktúrákat tükröznek. Az erős asszociáció arra utal, hogy az ordinalitás elvén alapuló módszerek következetesen azonosítják az országok MI-integrációjának mintázatait, és az alkalmazott módszerek közötti különbségek nem vezetnek eltérő következtetésekhez. Ez megerősíti, hogy a Pareto-

hatékonyság és a TDEA egyaránt megbízható eszköz az MI-fejlettség összehasonlító elemzésében.

Az EU-s országok MI-fejlettsége DEA közös súlyokkal

Ebben a fejezetben az EU-s országok MI-fejlettségét DEA közös súlyokon alapuló módszerekkel (maximin, euklideszi és Csebisev-metrika) vizsgáljuk. Az egyes módszerek az országok relatív technológiai teljesítményét értékelik eltérő matematikai megközelítéssel. Az eredmények összevetése lehetőséget nyújt a különböző DEA-modellek által azonosított fejlettségi szintek közötti hasonlóságok és különbségek feltárására. A részletes eredményeket a Függelék F3. táblázat tartalmazza.

A maximin DEA eredményeinek elemzése

A maximin DEA-módszer célja, hogy egyensúlyban tartsa a dimenziók közötti különbségeket, és egységes szempontrendszer alapján értékelje az országok teljesítményét. Ez a módszer egy objektív súlyozási technikát alkalmaz, amely minimalizálja a leggyengébben teljesítő országok közötti különbségeket, miközben az erősebb országokat nem emeli ki túlzottan. A módszer kiegyensúlyozottsága miatt különösen alkalmas olyan területek elemzésére, ahol a fejlettségi szintek közötti eltérések egyenetlenek.

- Hollandia és Dánia érte el a maximális, 1,000-es DEA-hatékonysági értéket, ami azt mutatja, hogy erőforrásaikat optimálisan hasznosítják. Mindkét ország kiemelkedik a robotizáció, az autonóm dróntechnológia és az IKT-biztonság területén.
- Finnország (0,959), Belgium (0,920) és Ausztria (0,673) szintén magas hatékonysági értékkel rendelkeznek, de bizonyos dimenziókban – például a logisztikában vagy az autonóm drónok alkalmazásában – alacsonyabb szintű eredményeket értek el, ezért hatékonyságuk valamelyest elmarad a vezető országokéi mögött.
- Bulgária és Románia (egyenként 0,130) az utolsó helyeken szerepelnek, jelezve azt, hogy technológiai fejlődésük és MI-integrációjuk jelentősen lemaradt. Ezek az országok különösen az automatizáció és a robotizált folyamatautomatizálás területén mutattak alacsony értékeket.

Az euklideszi DEA eredményeinek elemzése

Az euklideszi DEA az ideális (maximálisan hatékony) országokhoz viszonyítva méri a különböző országok technológiai fejlettségi szintje közötti távolságokat. Ez a módszer tehát az országokat egy olyan referencialalmazhoz viszonyítja, amelyben a legfejlettebb országok állnak, és minden más országot az ettől való eltérés alapján rangsorol.

- A legerősebb országok itt is Finnország, Hollandia, Dánia és Szlovénia (1,000-es értékkel), amelyek az összes vizsgált technológiai dimenzióban jól teljesítenek, és alig maradnak el a legjobb eredménytől.
- Románia (0,099) és Bulgária (0,182) jelentősen elmaradnak, ami azt mutatja, hogy a legfejlettebb országokhoz képest technológiai és innovációs lemaradásuk kiemelkedően nagy.
- A közepesen fejlett országok rangsora itt részben eltér a maximin DEA eredményeitől, mivel az euklideszi DEA érzékenyebb az egyes dimenziók közötti különbségekre. Például Spanyolország és Írország helyezése csökkent, mivel ezen országok egyes területeken kiemelkedően teljesítenek (például NLP vagy képfelismerés), de más dimenziókban jelentős lemaradást mutatnak.

A Csebisev DEA eredményeinek elemzése

A Csebisev DEA-módszer eltér a másik két módszertől, mivel a leggyengébb teljesítményű dimenziókra helyezi a hangsúlyt. Ez azt jelenti, hogy ha egy ország egy vagy több kulcsterületen jelentős hátrányban van, akkor ez az értékelés során meghatározóbb lesz, mint az átlageredményei.

- Az élen Dánia, Finnország, Hollandia és Szlovénia (1,000) állnak, ami azt mutatja, hogy ezen országok nem csak összességében kiemelkedőek, hanem egyetlen dimenzióban sem mutatnak jelentős lemaradást.
- Románia és Bulgária (egyenként 0,169) a leggyengébb eredményt érték el, ami azt jelzi, hogy egy vagy több kritikus technológiai területen nagyon alacsony értéket mutattak. Ezen országokban például az IKT-biztonság, az MI-alapú ipari gyártás vagy az autonóm drónok fejlesztése alacsony szinten áll.
- A közepesen fejlett országok itt más sorrendben jelennek meg, mint az euklideszi DEA-nál, mivel a Csebisev-módszer azokat az országokat „bünteti”, amelyeknek van egy-egy rendkívül gyenge dimenziójuk. Például Málta és Írország hátrébb kerülhetett a rangsorban, ha egyes dimenziókban gyenge eredményt is értek el, még akkor is, ha egyébként több területen jól teljesítenek.

A különböző módszerrel kapott eredmények összevetése

A különböző DEA-módszerek eltérő megközelítéseket alkalmaznak a technológiai fejlettség mérésére, ezért szükséges annak vizsgálata, hogy az általuk generált eredmények mennyire hasonlóak vagy eltérőek. A *Pearson-féle korrelációs együtthatók* segítségével számszerűsíthető a maximin, az euklideszi és a Csebisev-módszerek közötti kapcsolat, ami rávilágít arra, hogy az egyes módszerek rangsorai mennyire esnek egybe. A 3. táblázat bemutatja, hogy milyen mértékben szignifikáns a kapcsolat a különböző megközelítések szerinti eredmények között.

3. táblázat

A különböző módszerekkel kapott eredmények összevetése, 2023

Comparison of results obtained with different methods, 2023

Megnevezés		Euklideszi	Csebisev
Maximin	Pearson-korreláció	0,947**	0,948**
	Sig. (2-oldali)	0,000	0,000
	N	27	27
Euklideszi	Pearson-korreláció		0,987**
	Sig. (2-oldali)		0,000
	N		27

Maximin és euklideszi módszer: A Pearson-féle korreláció értéke 0,947, amely erős pozitív kapcsolatot jelez. Ez azt mutatja, hogy a két módszer által kapott eredmények között nagyfokú a hasonlóság.

Maximin és Csebisev-módszer: A korrelációs együttható 0,948, amely szintén nagyon szoros pozitív kapcsolatot mutat a két módszer között.

Euklideszi és Csebisev-módszer: A legmagasabb korreláció 0,9870, ami kiemelkedően szoros kapcsolatot jelez a két megközelítés között. Ez arra utal, hogy az euklideszi és a Csebisev-módszer hasonló eredményeket ad az elemzett dimenziókban.

Minden korreláció szignifikáns a $p=0,001$ szinten, ami a statisztikai összefüggések megbízhatóságát jelzi. Ez alátámasztja, hogy az egyes módszerek közötti kapcsolatok nem véletlenszerűek, hanem erős statisztikai összefüggések vannak közöttük.

A maximin módszer alapján Dánia, Hollandia és Finnország érte el a maximális 1,000 értéket, ami azt mutatja, hogy ezek az országok minden dimenzióban kiegyensúlyozottan magas teljesítményt nyújtanak. Belgium (0,920) és Luxemburg (0,586) is kiemelkednek, ami alátámasztja fejlett digitális infrastruktúrájukat és humán tőkéjüket. Az alsóbb régiókban Bulgária és Románia 0,130 értéket kaptak, ami alacsony teljesítményt jelez minden dimenzióban.

Az euklideszi módszer az országok átlagos teljesítményét tükrözi. Ez alapján Dánia, Hollandia, Finnország és Szlovénia szintén az élen szerepelnek 1,000-es értékkel. Belgium (1,000) és Málta (0,812) kiemelkedően magas eredményeket értek el, amelyek arra utalnak, hogy a többi ország nagy részével szemben nagyobb a teljesítményük. Ezzel szemben Románia (0,099) és Bulgária (0,182) a lista legalján helyezkednek el, ami a gyenge digitális mutatókra vezethető vissza.

A Csebisev-módszer a legrosszabb teljesítményű dimenziókat emeli ki, így a leggyengébb láncszemek elemzésére fókuszál. Az eredmények szerint Dánia, Hollandia, Finnország és Szlovénia ismét kiemelkedő teljesítményt mutatnak (1,000). Málta (0,895) és Belgium (0,913) szintén magas értékűek, és azt jelzik, hogy a legrosszabb dimenzióik is viszonylag erősek. Az alsó szinteken viszont Románia és Bulgária (egyenként 0,169) azonos értékűek, ami az országok fejlesztésre szoruló területeire világít rá.

Az eredmények azt mutatják, hogy bár a három módszer eltérő matematikai megközelítést alkalmaz, az általuk kapott értékeknek nagyfokú az egységessége. Az euklideszi és a Csebisev-módszerek közötti különbségek minimálisak, ami arra utalhat, hogy ezek a módszerek jól alkalmazhatók hasonló típusú elemzésekhez.

Diszkusszió

A kutatás eredményei megerősítik, hogy az MI-elfogadás mértéke jelentősen eltér egymástól az egyes EU-tagállamokban. Míg Dánia, Finnország és Hollandia kiemelkedő MI-adoptálási rátával rendelkezik, addig Bulgária jelentősen lemarad. Ez összhangban áll Daroń–Górska (2023) és Brodny–Tutak (2021) eredményeivel, valamint a Big Data alkalmazásában megfigyelt területi eltérésekkel (Pejić Bach et al. 2020).

A Pareto-hatékonysági elemzés kimutatta, hogy az északi és a nyugati tagállamok erőteljes MI-integrációval rendelkeznek, míg a kelet- és dél-európai országok hatékonysága elmarad tőlük. Ez egybeesik Jurickova et al. (2019) és Andrijauskiene et al. (2023) eredményeivel, akik az innovációs hatékonyság regionális eltéréseit vizsgálták. A technológiai teljesítmény elemzésére a DEA-módszerek alkalmazása releváns eszköznek bizonyult, amint azt Dobos (2023) és Dobos–Vörösmarty (2022) is igazolták.

Fontos megemlíteni Cherchye et al. (2008) kutatását is. A szerzők rávilágítottak arra, hogy a kompozit mutatók alkalmazásánál jelentkező egyik fő probléma a normalizáció és a súlyozás szubjektív jellege, amely befolyásolhatja az országok rangsorát. A Benefit of the Doubt (BoD) alapú DEA-módszerük éppen ezt a problémát kezeli azzal, hogy az egyes országok relatív teljesítményére alapozva határozza meg a súlyokat. Kutatásunk ezen elveket követve alkalmazza a DEA-modellt, ami lehetővé teszi az országok teljesítményének objektív értékelését, elkerülve a szubjektív súlyozásból eredő torzításokat. E módszer különösen releváns az MI-elfogadás vizsgálatában, ahol a különböző országok digitális fejlettsége és innovációs stratégiái jelentősen eltérhetnek egymástól, és ahol a kompozit mutatók alkalmazása torzíthatja a valós teljesítmények összehasonlítását.

A Cramér-féle V mutató (0,782) azt jelzi, hogy a Pareto-hatékonysági és a DEA-alapú eredmények szorosan összefüggenek, alátámasztva e módszerek megbízhatóságát az MI-fejlettség vizsgálatában. Ez egybeesik Dobos (2023) és Dobos–Vörösmarty (2022) következtetéseivel is, akik különböző területeken szintén kimutatták a DEA-alapú hatékonysági mérések konzisztens alkalmazhatóságát. Ezen túlmenően, a DEA-módszerek eredményei szerint a maximin, az euklideszi és a Csebisev-metrika közötti erős korreláció (0,947–0,987) azt jelzi, hogy az MI-fejlettség dimenziói összefüggő mintázatokat követnek. Ez megerősíti Bánhidi–Dobos (2023d) elemzését, ami az MI-integráció szoros kapcsolatát mutatta ki a gazdasági fejlettséggel és a digitális infrastruktúrába történő beruházásokkal.

Az eredmények alátámasztják, hogy a DEA-keret objektív módon képes kezelni az MI-fejlettséget befolyásoló tényezőket, hasonlóan ahhoz, ahogyan más kutatások-

ban is igazolták a módszer alkalmazhatóságát a technológiai hatékonyság elemzésére. Az MI-fejlettségi mutatók közötti korrelációk megerősítik, hogy a digitális fejlettség dimenziói szorosan összefüggenek, és a DEA-modell segítségével ezek az összefüggések számszerűsíthetők.

Eredményeink azt sugallják, hogy a DEA- és a Pareto-alapú módszerek megbízható eszközök az országok technológiai teljesítményének értékelésére, továbbá hatékonysan képesek az MI-adoptálási eltérések kimutatására is az EU-ban.

Következtetések

A kutatás eredményei részletesen jellemezték az EU tagállamainak MI-alkalmazását a vállalati szektorban. A DEA, a TDEA és a Pareto-optimalitás módszerek használata lehetővé tette az egyes országok MI-fejlettségének összehasonlítását és az MI-integráció hatékonyságának vizsgálatát.

Az eredmények alapján az élenjáró országok közé tartozik Finnország, Dánia, Hollandia, Luxemburg és Belgium, amelyek a Pareto-optimalitási elemzés során a legmagasabb MI-hasznosítási hatékonyságot érték el. Ezen országokban az MI-technológiák alkalmazási aránya meghaladja a 20%-ot a vállalatok körében, miközben az MI-alapú automatizált folyamatok és az adattudomány terén is kiemelkedő eredményeket mutatnak.

Ezzel szemben a leggyengébben teljesítő országok (Bulgária, Románia és Lengyelország) az MI-alkalmazás elterjedtségében jelentősen lemaradtak. Ezen országok vizsgált vállalatainak csupán 3–5%-a használ MI-alapú technológiákat, ami jelentősen elmarad az EU-s átlagtól (12,4%). Különösen alacsony a fejlett MI-technológiák, például a robotizált folyamatautomatizálás és a természetes nyelvfeldolgozás alkalmazásának aránya.

A DEA-elemzés alapján a hatékonysági mutatók is jelentős eltéréseket mutattak. A legmagasabb DEA-hatékonysági értéket Hollandia ($\theta = 1,000$) és Dánia ($\theta = 1,000$) érte el, ami azt jelzi, hogy ezek az országok optimálisan használják ki az MI-technológiák nyújtotta lehetőségeket. A közepesen teljesítő országok, mint Franciaország ($\theta = 0,623$) és Magyarország ($\theta = 0,594$), egyes területeken még nem érik el az élenjárók szintjét, de az MI-alapú megoldások fejlődésében már előrehaladás figyelhető meg. A leggyengébben teljesítő országok, mint Bulgária ($\theta = 0,185$) és Románia ($\theta = 0,130$), az MI-fejlesztésben további beruházásokat és stratégiai lépéseket igényelnek.

A TDEA-módszer eredményei szerint az MI-integráció terén a fejlett országok tovább csökkentették a középcsoporttól való lemaradásukat. A skandináv és a nyugat-európai tagállamok erős MI-fejlesztési dinamikát mutatnak, amely az adatalapú döntéshozatal és a digitális automatizálás térnyerésével magyarázható.

A Pareto-analízis által feltárt MI-hasznosítási modellek szerint az első szintű Pareto-hatékony csoportba Hollandia, Finnország és Dánia kerültek, amelyek az MI-alkalmazások szinte minden vizsgált dimenziójában vezető szerepet töltenek be.

A második szintre olyan országok (mint Franciaország és Olaszország) kerültek, amelyek egyes területeken még nem használják ki teljesen az MI lehetőségeit. A harmadik szintű csoportba a kelet- és dél-európai országok tartoznak, amelyeknek jelentős fejlődési potenciáljuk van, és a jelenlegi MI-integrációs szintjük alacsonyabb.

Az eredmények szerint az EU MI-integrációja nem egységes, hanem jelentős regionális eltéréseket mutat. Az MI-hasznosítási lehetőségek kiaknázása szorosan összefügg a vállalatok innovációs hajlandóságával és a meglévő digitális infrastruktúrával. A kutatás további lehetőségeket biztosít arra, hogy az MI-adoptáció eltéréseit befolyásoló tényezőket részletesebben elemezzük, valamint javaslatokat dolgozzunk ki a fejlesztési irányok meghatározására.

Függelék

F1. táblázat

Az induló adatállomány The starting data set

Ország	Szöveg- bányászat	Beszéd- felismerés	Természetes nyelv- feldolgozás	Kép- felismerés, kép- feldolgozás	Gépi tanulás	Robotizált folyamat- automatizálás
Ausztria	4,7	2,6	2,0	3,3	5,0	3,9
Belgium	4,2	1,9	2,4	4,0	6,2	6,9
Bulgária	0,5	0,3	0,3	0,6	0,3	1,2
Ciprus	0,0	0,4	0,3	1,4	0,4	1,8
Csehország	2,2	0,4	0,4	2,2	2,0	2,4
Dánia	5,3	3,1	3,1	4,4	5,4	5,9
Észtország	0,4	0,3	0,7	0,7	0,5	0,7
Finnország	5,2	1,7	2,0	4,1	4,7	8,0
Franciaország	1,3	0,7	0,8	1,3	1,3	1,6
Görögország	1,4	0,5	0,9	1,7	0,7	2,7
Hollandia	2,7	1,6	1,9	2,9	3,6	5,4
Horvátország	2,6	0,7	1,2	1,0	1,1	1,9
Írország	2,3	1,8	1,7	1,9	2,9	3,4
Lengyelország	0,4	0,3	0,5	1,0	0,7	1,4
Lettország	1,7	1,1	1,1	1,7	0,0	0,8
Litvánia	2,4	0,8	1,1	2,2	1,0	2,5
Luxemburg	6,7	4,3	1,0	5,1	2,3	4,8
Magyarország	1,0	0,9	0,7	1,7	0,9	2,0
Málta	1,5	1,7	1,6	6,8	0,8	3,3
Németország	2,5	3,0	1,8	2,4	2,0	3,7
Olaszország	1,5	1,0	0,9	1,5	1,3	2,6
Portugália	1,5	0,6	0,8	5,8	1,0	2,6
Románia	0,9	0,6	0,8	0,8	0,2	0,4
Spanyolország	1,6	1,4	1,3	3,9	2,4	3,6
Svédország	1,9	1,2	1,5	2,5	2,6	3,7
Szlovákia	2,6	1,1	1,0	1,8	1,5	2,1
Szlovénia	1,1	2,0	5,5	7,4	2,4	2,6

(A táblázat a következő oldalon folytatódik.)

(Folytatás.)

Ország	Autonóm drónok	Marketing	Ipari gyártás	Logisztika	IKT-biztonság
Ausztria	1,9	1,9	5,0	1,7	4,2
Belgium	3,4	1,4	5,2	2,3	5,3
Bulgária	0,7	0,3	0,9	0,1	0,2
Ciprus	1,9	0,2	2,4	1,0	1,3
Csehország	1,4	0,7	3,4	1,2	1,8
Dánia	3,3	2,4	4,8	2,7	5,2
Észtország	0,6	0,5	1,2	0,6	0,7
Finnország	2,4	3,2	5,8	1,9	3,2
Franciaország	1,5	0,6	1,8	0,3	1,3
Görögország	0,5	0,5	0,7	0,2	3,3
Hollandia	5,1	1,8	3,8	2,5	2,9
Horvátország	1,2	1,1	1,4	0,2	0,7
Írország	1,5	2,1	2,8	1,4	1,8
Lengyelország	0,7	0,6	1,4	0,8	1,1
Lettország	0,9	0,3	1,6	0,3	0,9
Litvánia	1,0	0,8	1,9	0,9	0,9
Luxemburg	1,9	0,6	4,2	1,6	1,6
Magyarország	1,3	0,9	2,2	0,8	0,8
Málta	2,8	1,0	3,3	1,4	2,3
Németország	1,7	1,0	2,4	0,9	2,4
Olaszország	1,1	0,9	2,6	0,9	1,1
Portugália	1,3	0,9	4,8	1,8	2,7
Románia	0,2	1,0	0,3	0,2	0,2
Spanyolország	2,5	1,1	3,6	1,2	2,3
Svédország	1,5	0,6	2,6	1,1	2,1
Szlovákia	1,3	1,2	1,6	0,9	0,9
Szlovénia	1,9	1,8	5,7	1,5	8,6

Forrás: saját szerkesztés Eurostat (2023) adatai alapján.

F2. táblázat

**A rétegekbe sorolás (hagymahéjazás) eredményei
a DEA-hatékonyságokkal együtt, 2023**

Onion peeling and layering results along with DEA efficiencies, 2023

Réteg (hagymahéj)									
1.		2.		3.		4.		5.	
Belgium	1,000								
Finnország	1,000								
Luxemburg	1,000								
Hollandia	1,000								
Dánia	1,000								
Málta	1,000								
Szlovénia	1,000								
Ausztria	0,977	Ausztria	1,000						
Portugália	0,924	Portugália	1,000						
Németország	0,820	Németország	1,000						
Spanyolország	0,760	Spanyolország	1,000						
Írország	0,750	Írország	1,000						
Csehország	0,599	Svédország	0,949	Svédország	1,000				
Svédország	0,552	Ciprus	0,787	Ciprus	1,000				
Görögország	0,507	Görögország	0,786	Görögország	1,000				
Ciprus	0,496	Csehország	0,721	Csehország	1,000				
Szlovákia	0,478	Olaszország	0,667	Olaszország	1,000				
Horvátország	0,474	Szlovákia	0,662	Szlovákia	1,000				
Olaszország	0,470	Litvánia	0,649	Litvánia	1,000				
Litvánia	0,450	Franciaország	0,623	Horvátország	1,000				
Magyarország	0,418	Horvátország	0,617	Magyarország	0,958	Magyarország	1,000		
Franciaország	0,380	Magyarország	0,594	Franciaország	0,942	Franciaország	1,000		
Lettország	0,351	Lettország	0,550	Lettország	0,917	Lettország	1,000		
Románia	0,332	Románia	0,476	Románia	0,833	Románia	1,000		
Lengyelország	0,296	Lengyelország	0,455	Lengyelország	0,724	Lengyelország	1,000		
Észtország	0,239	Észtország	0,353	Észtország	0,584	Észtország	0,881	Bulgária	1,000
Bulgária	0,185	Bulgária	0,320	Bulgária	0,450	Bulgária	0,600	Észtország	1,000

F3. táblázat

A közös súlyokkal kapott eredmények összevetése, 2023

Comparing results obtained with common weights, 2023

Ország	Maximin	Euklideszi	Csebisev
Ausztria	0,673	0,840	0,752
Belgium	0,920	1,000	0,913
Bulgária	0,130	0,182	0,169
Ciprus	0,349	0,466	0,383
Csehország	0,409	0,547	0,465
Dánia	1,000	1,000	1,000
Észtország	0,193	0,209	0,192
Finnország	0,959	1,000	1,000
Franciaország	0,255	0,378	0,353
Görögország	0,201	0,178	0,226
Hollandia	1,000	1,000	1,000
Horvátország	0,267	0,312	0,337
Írország	0,576	0,540	0,561
Lengyelország	0,254	0,248	0,237
Lettország	0,175	0,311	0,281
Litvánia	0,350	0,368	0,379
Luxemburg	0,586	0,806	0,716
Magyarország	0,342	0,418	0,396
Málta	0,589	0,812	0,895
Németország	0,463	0,529	0,500
Olaszország	0,370	0,435	0,381
Portugália	0,522	0,773	0,730
Románia	0,130	0,099	0,169
Spanyolország	0,559	0,738	0,718
Svédország	0,448	0,495	0,456
Szlovákia	0,375	0,370	0,410
Szlovénia	0,660	1,000	1,000

IRODALOM

- ABDULJABBAR, R.–DIA, H.–LIYANAGE, S.–BAGLOEE, S. A. (2019): Applications of artificial intelligence in transport: an overview *Sustainability* 11 (1): 189.
<https://doi.org/10.3390/su11010189>
- AGARWAL, V.–LOHANI, M.–BIST, A. S. (2024): A novel deep learning technique for medical image analysis using improved optimizer *Health Informatics Journal* 30 (2).
<https://doi.org/10.1177/14604582241255584>
- ANDRIJAUSKIENE, M.–IOANNIDIS, D.–DUMCIUVIENE, D.–DIMARA, A.–BEZAS, N.–PAPAIIOANNOU, A.–KRINIDIS, S. (2023): European Union innovation efficiency assessment based on data envelopment analysis *Economies* 11 (6): 163.
<https://doi.org/10.3390/economies11060163>
- ATHANASSOPOULOS, A. D. (1996): Assessing the comparative spatial disadvantage (CSD) of regions in the European Union using non-radial data envelopment analysis methods *European Journal of Operational Research* 94 (3): 439–452.
[https://doi.org/10.1016/0377-2217\(95\)00114-x](https://doi.org/10.1016/0377-2217(95)00114-x)
- AWAD, E.–CAMINADA, M. W. A.–PIGOZZI, G.–PODLASZEWSKI, M.–RAHWAN, I. (2017): Pareto optimality and strategy-proofness in group argument evaluation *Journal of Logic and Computation* 27 (8): 2581–2609. <https://doi.org/10.1093/logcom/exx017>
- BALMER, R. E.–LEVIN, S. L.–SCHMIDT, S. (2020): Artificial intelligence applications in telecommunications and other network industries *Telecommunications Policy* 44 (6): 101977. <https://doi.org/10.1016/j.telpol.2020.101977>
- BÁNHIDI, Z.–DOBOS, I. (2023a): Measurement of digital development with partial orders, Tiered DEA, and cluster analysis for the European Union *International Review of Applied Sciences and Engineering* 14 (3): 392–401.
<https://doi.org/10.1556/1848.2023.00612>
- BÁNHIDI, Z.–DOBOS, I. (2023b): Országok digitális fejlettségének megállapítása lépcsőzetes DEA, lépcsőzetes Pareto-hatékonyság és klaszteranalízis felhasználásával, a 2020-as nemzetközi digitális gazdasági és társadalmi index adatai alapján *Statisztikai Szemle* 101 (11): 978–998. <https://doi.org/10.20311/stat2023.11.hu0978>
- BÁNHIDI, Z.–DOBOS, I. (2023c): Országgrangsorolás a nemzetközi digitális gazdaság és társadalom index 2020-as adatai alapján, DEA- és TOPSIS-módszerrel *Területi Statisztika* 63 (4): 515–532. <https://doi.org/10.15196/ts630405>
- BÁNHIDI, Z.–DOBOS, I. (2023d): A data envelopment analysis model for ranking digital development in the countries of the European Union without explicit inputs and common weights analysis *Decision Analytics Journal* 6: 100167.
<https://doi.org/10.1016/j.dajour.2023.100167>
- BARR, R. S.–DURCHHOLZ, M. L.–SEIFORD, L. (2000): Peeling the DEA onion: layering and rank-ordering DMUs using tiered DEA *Southern Methodist University Technical Report* 5: 1–24.
- BARYANNIS, G.–VALIDI, S.–DANI, S.–ANTONIOU, G. (2018): Supply chain risk management and artificial intelligence: state of the art and future research directions *International Journal of Production Research* 57 (7): 2179–2202.
<https://doi.org/10.1080/00207543.2018.1530476>

- BIRÓ, P.–CSÁJI, G. (2024): Strong core and Pareto-optimality in the multiple partners matching problem under lexicographic preference domains *Games and Economic Behavior* 145: 217–238. <https://doi.org/10.1016/j.geb.2024.03.010>
- BRODNY, J.–TUTAK, M. (2021): Assessing the level of digitalization and robotization in the enterprises of the European Union Member States *PLOS ONE* 16 (7): e0254993. <https://doi.org/10.1371/journal.pone.0254993>
- CHAN, Z.–MEUNIER-AITSAHALIA, S. (2020): Behind the screen: understanding national support for a foreign investment screening mechanism in the European Union *SSRN Electronic Journal* <https://doi.org/10.2139/ssrn.3726973>
- CHEON, S. (2009): Impact of global terminal operators on port efficiency: a tiered data envelopment analysis approach *International Journal of Logistics Research and Applications* 12 (2): 85–101. <https://doi.org/10.1080/13675560902749324>
- CHERCHYE, L.–MOESEN, W.–ROGGE, N.–VAN PUYENBROECK, T.–SAISANA, M.–SALTELLI, A.–LISKA, R.–TARANTOLA, S. (2008): Creating composite indicators with DEA and robustness analysis: the case of the Technology Achievement Index *Journal of the Operational Research Society* 59 (2): 239–251.
- CHIOATTO, E.–FEDELE, A.–CIRO LISCIO, M.–SOSPIRO, P. (2024): Testing data envelopment analysis models on the performance of European Union regions in sustainable waste management *Waste Management* 175: 170–182. <https://doi.org/10.1016/j.wasman.2024.01.008>
- DAROŃ, M.–GÓRSKA, M. (2023): Enterprises development in context of artificial intelligence usage in main processes *Procedia Computer Science* 225: 2214–2223. <https://doi.org/10.1016/j.procs.2023.10.212>
- DAVTALAB-OLYAIE, M.–ASGHARIAN, M. (2021): On Pareto-optimality in the cross-efficiency evaluation *European Journal of Operational Research* 288 (1): 247–257. <https://doi.org/10.1016/j.ejor.2020.05.040>
- DEN, M.–NAH, H. S.–SHIN, C. H. (2016): An empirical study on the efficiency of container terminals in Russian and Korean ports using DEA models *Journal of Navigation and Port Research* 40 (5): 317–328. <http://dx.doi.org/10.5394/KINPR.2016.40.5.317>
- DOBOS, I. (2023): Tiered Data Envelopment as method for clustering suppliers *Croatian Operational Research Review* 14 (2): 99–110. <https://doi.org/10.17535/crorr.2023.0009>
- DOBOS, I.–VÖRÖSMARTY, G. (2022): Supplier segmentation with partial orders, tiered DEA and cluster analysis *SSRN Electronic Journal* <https://doi.org/10.2139/ssrn.4059392>
- DUCH-BROWN, N.–GÓMEZ LOSADA, A.–MIGUEZ, S.–ROSETTI, F.–VAN ROY, V. (2022): *AI watch evolution of the EU market share of robotics data and methodology* EUR 31471 EN, Publications Office of the European Union, Luxembourg. <https://doi.org/10.2760/07667>
- ESTEVA, A.–ROBICQUET, A.–RAMSUNDAR, B.–KULESHOV, V.–DEPRISTO, M.–CHOU, K.–CUI, C.–CORRADO, G.–THRUN, S.–DEAN, J. (2019): A guide to deep learning in healthcare *Nature Medicine* 25 (1): 24–29. <https://doi.org/10.1038/s41591-018-0316-z>
- EUROSTAT (2023): *Artificial intelligence by NACE rev. 2 activity (isoc_eb_ain2)* European Commission, Luxembourg. https://doi.org/10.2908/isoc_eb_ain2

- FU, Y.–WANG, S.–WANG, C.-X.–HONG, X.–MCLAUGHLIN, S. (2018): Artificial intelligence to manage network traffic of 5G wireless networks *IEEE Network* 32 (6): 58–64.
<https://doi.org/10.1109/mnet.2018.1800115>
- GOSWAMI, M. P.–MITRA, M.–SEN, A. (2014): Strategy proofness and Pareto efficiency in quasilinear exchange economies *Theoretical Economics* 9 (2): 361–381.
<https://doi.org/10.3982/te1214>
- GUO, G.–WANG, Y. (2021): An integrated MPC and deep reinforcement learning approach to trans-priority active signal control *Control Engineering Practice* 110: 104758.
<https://doi.org/10.1016/j.conengprac.2021.104758>
- HAYDARI, A.–YILMAZ, Y. (2022): Deep reinforcement learning for intelligent transportation systems: a survey *IEEE Transactions on Intelligent Transportation Systems* 23 (1): 11–32.
<https://doi.org/10.1109/tits.2020.3008612>
- JANICKA, M.–SAJNÓG, A. (2023): Do environmental and economic performance go hand in hand? An industrial analysis of European Union companies with the non-parametric data envelopment analysis method *Corporate Social Responsibility and Environmental Management* 30 (5): 2590–2605. <https://doi.org/10.1002/csr.2504>
- JARŽEMSKIS, A.–JARŽEMSKIENĖ, I. (2018): Upgraded data envelopment analysis model application for total productivity comparison in major airports of the European Union *Economic Research-Ekonomska Istraživanja* 31 (1): 1273–1288.
<https://doi.org/10.1080/1331677x.2018.1456349>
- JUHÁSZ, T.–KÁLMÁN, B.–TÓTH, A.–HORVÁTH, A. (2022): Digital competence development in a few countries of the European Union *Management & Marketing. Challenges for the Knowledge Society* 17 (2): 178–192. <https://doi.org/10.2478/mmcks-2022-0010>
- JURICKOVA, E.–PILIK, M.–KWARTENG, M. A. (2019): Efficiency measurement of national innovation systems of the European Union countries: DEA model application *Journal of International Studies* 12 (4): 286–299.
<https://doi.org/10.14254/2071-8330.2019/12-4/19>
- KARMOKAR, M.–ROY, S.–STORCKEN, T. (2019): A characterization of possibility domains under Pareto optimality and group strategy-proofness *Economics Letters* 183: 108567. <https://doi.org/10.1016/j.econlet.2019.108567>
- KUJAWSKA, J. (2021): Health system efficiency in European countries: network data envelopment analysis approach *European Research Studies Journal* 24 (2): 1095–1117.
<https://doi.org/10.35808/ersj/2176>
- KULLAYA SWAMY, A.–SAROJAMMA, B. (2020): Bank transaction data modeling by optimized hybrid machine learning merged with ARIMA *Journal of Management Analytics* 7 (4): 624–648. <https://doi.org/10.1080/23270012.2020.1726217>
- LAVI, R.–MAY, M. (2012): A note on the incompatibility of strategy-proofness and Pareto-optimality in quasi-linear settings with public budgets *Economics Letters* 115 (1): 100–103. <https://doi.org/10.1016/j.econlet.2011.11.043>
- LU, C.-C.–LU, L.-C. (2018): Evaluating the energy efficiency of European Union countries: The dynamic data envelopment analysis *Energy & Environment* 30 (1): 27–43.
<https://doi.org/10.1177/0958305x18787257>
- MONTESANO, A. (2017): A dual characterization of Pareto optimality *Italian Economic Journal* 4 (1): 153–188. <https://doi.org/10.1007/s40797-017-0061-3>

- MOROCHO-CAYAMCELA, M. E.–LEE, H.–LIM, W. (2019): Machine learning for 5G/B5G mobile and wireless communications: potential, limitations, and future directions *IEEE Access* 7: 137184–137206. <https://doi.org/10.1109/access.2019.2942390>
- PEJIĆ BACH, M.–BERTONCEL, T.–MEŠKO, M.–SUŠA VUGEC, D.–IVANČIĆ, L. (2020): Big data usage in European countries: cluster analysis approach *Data* 5 (1): 25. <https://doi.org/10.3390/data5010025>
- PRIPOAIE, R.–SCHIN, G.–C.–MATIC, A.–E. (2024): Post-pandemic exploratory analysis of the Romanian public administration digitalization level in comparison to the most digitally developed states of the European Union *Sustainability* 16 (11): 4652. <https://doi.org/10.3390/su16114652>
- QUARTIERI, F. (2011): Coalition-proofness under weak and strong Pareto dominance *Social Choice and Welfare* 40 (2): 553–579. <https://doi.org/10.1007/s00355-011-0618-2>
- STERNAD, M.–GROFELNIK, I. (2023): Comparison of railway performance in the European Union based on DEA analysis during Covid crisis *Transport Problems* 18 (4): 201–210. <https://doi.org/10.20858/tp.2023.18.4.16>
- TABOADA, G. L.–SERUCA, I.–SOUSA, C.–PEREIRA, Á. (2020): Exploratory data analysis and data envelopment analysis of construction and demolition waste management in the European economic area *Sustainability* 12 (12): 4995. <https://doi.org/10.3390/su12124995>
- TISDELL, C. (1966): Some bounds upon the Pareto optimality of group behavior *Kyklos* 19(1): 81–105. <https://doi.org/10.1111/j.1467-6435.1966.tb02493.x>
- TONG, Y.–LU, W.–YU, Y.–SHEN, Y. (2020): Application of machine learning in ophthalmic imaging modalities *Eye and Vision* 7: 22. <https://doi.org/10.1186/s40662-020-00183-6>
- VAN DER STEL, H. (2000): Strategy-proofness, Pareto optimality and strictly convex norms *Mathematical Social Sciences* 39 (3): 277–301. [https://doi.org/10.1016/s0165-4896\(99\)00031-1](https://doi.org/10.1016/s0165-4896(99)00031-1)
- VASILESCU, M. D.–SERBAN, A. C.–DIMIAN, G. C.–ACELEANU, M. I.–PICATOSTE, X. (2020): Digital divide, skills and perceptions on digitalisation in the European Union – towards a smart labour market *PLOS ONE* 15 (4): e0232032. <https://doi.org/10.1371/journal.pone.0232032>
- WANG, C.–X.–RENZO, M. D.–STANCZAK, S.–WANG, S.–LARSSON, E. G. (2020): Artificial intelligence enabled wireless networking for 5G and beyond: recent advances and future challenges *IEEE Wireless Communications* 27 (1): 16–23. <https://doi.org/10.1109/mwc.001.1900292>
- WANG, J.–MA, Y.–ZHANG, L.–GAO, R. X.–WU, D. (2018): Deep learning for smart manufacturing: methods and applications *Journal of Manufacturing Systems* 48: 144–156. <https://doi.org/10.1016/j.jmsy.2018.01.003>