



Közzététel: 2025. március 28.

A tanulmány címe:

**A mesterséges intelligencia alkalmazási területei az EU-tagországok vállalatainál**

Szerzők:

**LÜLÖK GERGELY**

a Budapesti Műszaki és Gazdaságtudományi Egyetem Menedzsment és Vállalatgazdaságtan Tanszékének PhD-hallgatója

E-mail: [lulok.gergely@edu.bme.hu](mailto:lulok.gergely@edu.bme.hu)

**DOBOS IMRE**

a Budapesti Műszaki és Gazdaságtudományi Egyetem Közgazdaságtan Tanszékének egyetemi tanára

E-mail: [dobos.imre@gtk.bme.hu](mailto:dobos.imre@gtk.bme.hu)

**SEBESTYÉN ZOLTÁN**

a Budapesti Műszaki és Gazdaságtudományi Egyetem Menedzsment és Vállalatgazdaságtan Tanszékének egyetemi docense

E-mail: [sebestyen.zoltan@gtk.bme.hu](mailto:sebestyen.zoltan@gtk.bme.hu)

DOI: <https://doi.org/10.20311/stat2025.03.hu0203>

**Az alábbi feltételek érvényesek minden, a Központi Statisztikai Hivatal (a továbbiakban: KSH) *Statisztikai Szemle* 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 (Sztj.) szerint szerzői műnek minősülnek. A szerzői jog jogosultja a KSH.
2. A KSH földrajzi és időbeli korlátozás nélküli, nem kizárólagos, nem átdadható, 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, hasznoszerzési célú felhasználására. Ez a korlátozás nem érinti a tanulmány felhasználásával előállított, de az Sztj. 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: Statisztikai Szemle* c. folyóirat 103. évfolyam 3. számában megjelent, **Lülök Gergely – Dobos Imre – Sebestyén Zoltán** által írt, **A mesterséges intelligencia alkalmazási területei az EU-tagországok vállalatainál** című tanulmány (link csatolása)”

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

Lülök Gergely – Dobos Imre – Sebestyén Zoltán

## **A mesterséges intelligencia alkalmazási területei az EU-tagországok vállalatainál**

### **Applications of artificial intelligence in companies in EU member states**

Lülök Gergely, a Budapesti Műszaki és Gazdaságtudományi Egyetem Menedzsment és Vállalatgazdaságtan Tanszékének PhD-hallgatója

E-mail: lulok.gergely@edu.bme.hu

Dobos Imre, a Budapesti Műszaki és Gazdaságtudományi Egyetem Közgazdaságtan Tanszékének egyetemi tanára

E-mail: dobos.imre@gtk.bme.hu

Sebestyén Zoltán, a Budapesti Műszaki és Gazdaságtudományi Egyetem Menedzsment és Vállalatgazdaságtan Tanszékének egyetemi docense

E-mail: sebestyen.zoltan@gtk.bme.hu

A mesterséges intelligencia (MI) által fémjelzett technológiák az utóbbi években az innováció és a versenyképesség egyik kulcsfontosságú tényezőjévé váltak, különösen az Európai Unióban, ahol az MI-integráció mértéke jelentős eltéréseket mutat a tagállamok között. Tanulmányunk célja, hogy feltárja az MI-technológiák elterjedtségét az EU-ban, és elemezze az alkalmazásuk mögött álló gazdasági, digitalizációs és ipari tényezőket. Kutatásunk az Eurostat adatbázisán alapul, és 150 400 uniós vállalat adatait dolgozza fel, vizsgálva az olyan MI-technológiák közötti összefüggéseket, mint a gépi tanulás, a folyamatautomatizálás és a szövegbányászat. Korrelációelemzés, faktorelemzés és főkomponens-elemzés segítségével azonosítjuk a technológiai integráció mértékét és a gazdasági fejlettséggel való kapcsolatát. Eredményeink azt mutatják, hogy az MI-technológiák elterjedtsége szorosan összefügg az országok gazdasági fejlettségével és digitalizációs szintjével. A kutatás különbségeket mutat ki a technológiai fejlettség terén az EU különböző régiói között, és fontos iránymutatásokat nyújt az MI-technológiák integrációjának elősegítéséhez, különös tekintettel a közép- és a kelet-európai országokra. A klaszterelemzés három fő csoportot különít el az MI-használat intenzitása alapján, és a többdimenziós skálázás (MDS) alátámasztja a regionális eltérések meglétét. Tanulmányunk reményeink szerint hozzájárul a mesterséges intelligencia hatékony ipari alkalmazásának és stratégiáinak megértéséhez, valamint támogatja a jövőbeli fejlesztési irányok meghatározását.

Kulcsszavak: mesterséges intelligencia, Európai Unió, Eurostat

Artificial Intelligence (AI) technologies have become a key driver of innovation and competitiveness in recent years, especially in the European Union, where the degree of AI integration varies significantly between Member States. Our study aims to explore the diffusion of AI technologies across EU countries and to analyse the economic, digitalisation and industrial factors behind their deployment. Our research is based on the Eurostat database and analyses data from 150,400 EU companies, looking at the interrelationships between AI technologies such as machine learning, process automation and text mining. Correlation analysis, factor analysis and principal component

analysis are used to identify the degree of technological integration and its relationship with economic development. Our results show that the uptake of AI technologies is closely correlated with countries' economic development and level of digitalisation. The research reveals differences in technological development between different regions of the EU and provides important guidelines for promoting the integration of AI technologies, particularly in Central and Eastern European countries. The cluster analysis distinguishes three main clusters based on the intensity of AI use, and multidimensional scaling (MDS) confirms the existence of regional differences. Our study contributes to the understanding of effective industrial applications and strategies of artificial intelligence and supports the definition of future development directions.

Keywords: artificial intelligence, European Union, Eurostat

A mesterséges intelligencia (MI) fémjelezte technológiák egyre meghatározóbb szerepet töltenek be a globális gazdaságban, különösen az ipari, a pénzügyi és a digitális szektorban. Az Európai Unió (EU) tagállamai számára az MI-integráció nem csupán technológiai fejlődést jelent, hanem gazdasági versenyképességi tényezővé is vált. Az MI-alapú megoldások alkalmazása azonban jelentős eltéréseket mutat az EU különböző régióiban, a használatát olyan tényezők befolyásolják, mint a gazdasági fejlettség, a digitalizációs szint, az ipari szerkezet és a vállalati innovációs hajlandóság. Az Európai Bizottság és több nemzetközi kutatás is rámutatott arra, hogy a mesterséges intelligencia átfogó elterjedése hozzájárulhat a termelékenység növekedéséhez, az üzleti hatékonyság fokozásához, valamint a versenyképesség erősítéséhez az egységes piacon belül.

Jelen kutatás célja, hogy átfogó képet adjon az MI-technológiák vállalati szintű elterjedéséről az Európai Unióban, és feltárja azokat a makro- és mikrogazdasági tényezőket, amelyek meghatározzák az MI-integráció különbségeit az egyes tagállamokban. Az Eurostat adatbázisán alapuló vizsgálatunk 150 400 uniós vállalat adatait elemzi, és olyan kulcsfontosságú MI-technológiák alkalmazására fókuszál, mint a Gépi tanulás, a folyamatautomatizálás és a Szövegbányászat.

A kutatás az alábbi kérdésekre keresi a választ:

- [K1]: Milyen összefüggés figyelhető meg egy ország gazdasági fejlettsége és az MI-technológiák vállalati szintű alkalmazásának aránya között az Európai Unió tagállamaiban?
- [K2]: Milyen hatással van egy ország digitalizációs fejlettsége az MI-technológiák integrációjára?
- [K3]: Hogyan befolyásolja az MI-technológiák elterjedtsége az EU tagállamainak regionális különbségeit?

A kutatás az alábbi hipotéziseket vizsgálja:

- [H1]: A gazdaságilag fejlettebb országokban magasabb az MI-technológiákat alkalmazó vállalatok aránya.
- [H2]: Az MI-technológiák integrációja pozitív összefüggést mutat az adott ország digitalizációs szintjével.
- [H3]: Az MI-technológiák elterjedtsége jelentős regionális eltéréseket mutat, és a fejlettebb nyugat-európai országokban lényegesen nagyobb mértékű az alkalmazásuk, mint a közép- és a kelet-európai régiókban.

A kutatás további célja, hogy feltárja az MI-technológiák vállalati alkalmazásának eltéréseit az Európai Unió államaiban. Az MI-adoptáció eloszlásának vizsgálata azért kiemelten fontos, mert jelenleg nem áll rendelkezésre átfogó elemzés arról, hogy ezek a tényezők milyen mértékben befolyásolják a vállalatok MI-használatát. A kutatás hipotézisei ezeket az összefüggéseket vizsgálják: egyrészt, hogy a fejlettebb gazdaságokban magasabb-e az MI-alkalmazás aránya, másrészt, hogy a digitalizációs szint milyen hatással van az integrációra, végül pedig, hogy az MI-technológiák elterjedése mutat-e jelentős regionális eltéréseket.

A kutatás előzetes eredményei azt mutatják, hogy az MI használata jelentősen elterjedtebb a fejlettebb tagállamokban, mint például Dániában (15,2%) és Finnországban (15,1%), míg a kevésbé fejlettekben, például Romániában (1,5%) és Bulgáriában (3,6%), lényegesen kevésbé bevett a mesterséges intelligencia vállalati alkalmazása.

## 1. Szakirodalmi áttekintés

A mesterséges intelligencia és a kapcsolódó digitális technológiák, mint például a Big Data és a robotika, alapvetően átalakítják a gazdaságokat és a társadalmakat világszerte. Az Európai Unióban ezek a technológiák kulcsszerepet játszanak az ipar modernizációjában, a versenyképesség növelésében, valamint a gazdasági növekedés előmozdításában. Az MI alkalmazása azonban jelentős különbségeket mutat az egyes tagállamok között, amit számos tényező befolyásol, többek között az adott ország gazdasági fejlettsége, digitalizációs szintje, kutatás-fejlesztési beruházásai, valamint a nemzeti stratégiák és szabályozások.

E fejezet célja, hogy átfogó képet adjon a mesterségesintelligencia-technológiák uniós belüli elterjedtségéről, a digitalizáció és a robotizáció szintjéről, valamint az ezekből eredő gazdasági és társadalmi hatásokról. A vonatkozó tudományos szakirodalomra támaszkodva mutatja be a mesterséges intelligencia és a kapcsolódó technológiák szerepét a különböző iparágakban és régiókban, kiemelve a

logikai összefüggéseket, hasonlóságokat és különbségeket. Ez az összefoglaló segít megérteni, hogy az MI-technológiák használata hogyan járulhat hozzá az EU gazdasági és társadalmi céljainak eléréséhez, és milyen kihívásokkal kell szembenézni a digitális szakadék csökkentése érdekében.

### 1.1. A mesterséges intelligencia helyzete, gyakorlata, tendenciái az Európai Unióban

Az európai országok között a mesterséges intelligencia és a digitális technológia alkalmazásában megfigyelhető különbségeket több tanulmány is részletesen elemzi. *Zoumpikas és szerzőtársai (2021)* Görögország innovációs teljesítményét hasonlították össze az uniós átlaggal, és megállapították, hogy egyes mutatókban jobban teljesített, de a technológiai infrastruktúra terén lemaradt. *Juhász és szerzőtársai (2022)* a digitális kompetencia fejlődését vizsgálták az uniós országokban, és arra a következtetésre jutottak, hogy egyes skandináv országok, így Dánia és Svédország élen járnak az ipar 4.0 és az MI-alapú rendszerek bevezetésében. *Duch-Brown és szerzőtársai (2022)* kiemelték Németország dominanciáját az uniós robotikai piacon, ugyanakkor rámutatott arra, hogy piaci részesedése csökken, míg Dánia és Spanyolország növekvő szerepet tölt be.

A digitális készségek fejlettsége meghatározza az MI bevezetésének lehetőségeit és sikerességét. *Chan és Meunier-Aitsahalia (2020)* szerint Luxemburg és Hollandia vezető szerepet tölt be a digitális készségek fejlettsége szempontjából, miközben Bulgária és Románia jelentős lemaradásban van. *Vasilescu és szerzőtársai (2020)* kimutatták, hogy míg Svédországban a lakosság 97%-a rendelkezik megfelelő digitális készségekkel, addig Magyarországon ez az arány csupán 57%.

A mesterséges intelligencia vállalati alkalmazása szoros összefüggést mutat az adott ország fejlettségével. *Brodny és Tutak (2021)* részletes elemzést végzett az EU-tagállamokban az MI és a robotizáció szintjéről, és megállapította, hogy Finnországban a vállalatok 16%-a használ mesterséges intelligenciát, míg Bulgáriában csak 3%-uk. *Brodny és Tutak (2022)* tovább vizsgálta az MI használatát, és különbséget tett az országok között „szakértői” és „kezdő” szinten. A „szakértői” kategóriába tartozó országokban, például Dániában és Finnországban az MI-használat 24,0 és 15,8%, míg a „kezdő” országokban, például Romániában és Bulgáriában csupán 1,4 és 3,3%. *Daroń és Górska (2023)* kimutatta, hogy a dán vállalatok 23,9%-a használ mesterséges intelligenciát, ami jóval az uniós átlag felett van. Ezek az eltérések az MI alkalmazásának különbségeit tükrözik, amelyek közvetlen hatással vannak a gazdasági növekedésre és versenyképességre.

A technológiai innováció és az adatvezérelt alkalmazások térnyerése szintén jelentős különbségeket jelez az egyes országok között. *Pejić Bach és szerzőtársai*

(2020) a Big Data használatát vizsgálták Európában, és kimutatták, hogy a nagyvállalatok 33,5%-a használja ezeket az eszközöket, míg a kkv-knak csak 10,57%-a. *Malinowski (2021)* szerint a Big Data használata Európában a tudomány és a technológia fejlődésének egyik fő tényezője, különösen Litvániában, valamint Szlovéniában. *Pripoai és szerzőtársai (2024)* a mesterséges intelligencia romániai fejlődését vizsgálták, és megállapították, hogy Románia előrelépést tesz ezen a területen, de elmarad a fejlettebb európai országoktól. Ez a megállapítás összhangban van *Botlíková és Botlík (2020)* eredményeivel, akik szerint Németország, Franciaország és az Egyesült Királyság vezet az EU-ban az MI-re fordított K + F-ráfordítások terén, míg a kevésbé fejlett régiók még nem érték el a hasonló szintet.

Összességében a kutatások jelentős különbségeket mutattak ki az európai országok között az MI és a digitalizáció szintje tekintetében. Az olyan fejlett országok, mint Dánia, Finnország és Németország, kiemelkednek az MI és a digitális technológiák alkalmazása terén, míg a kelet-európai régiók, például Románia és Bulgária, jelentős lemaradásban vannak. A tanulmányok hangsúlyozzák, hogy a technológiai fejlődés és különösen az MI integrálása létfontosságú a gazdasági növekedés és versenyképesség szempontjából. Emellett rávilágítottak arra, hogy a digitalizáció és az MI fejlesztése elengedhetetlen az európai gazdaság hosszú távú stabilitása érdekében.

## 1.2. A mesterséges intelligencia alkalmazásának iparági hatásai és perspektívái

Miután elemeztük a mesterséges intelligencia európai országokban történő alkalmazásáról szóló szakirodalmat, a konkrét iparágakra és ágazatokra összpontosítottunk. Közelebbről megvizsgáltuk, hogyan alkalmazzák a mesterséges intelligenciát különböző ágazatokban, többek között a közlekedésben, az egészségügyben, a távközlésben, a gyártásban és a pénzügyi területeken. Azt is megvizsgáltuk, hogy a mesterséges intelligencia hogyan járul hozzá a hatékonyság növeléséhez, valamint a gazdasági és technológiai fejlődéshez ezekben az iparágakban.

A közlekedési rendszerben az autonóm járművek és az MI-alapú forgalomirányítási rendszerek jelentős hatékonyságjavulást hoznak, ahogyan azt *Abduljabbar és szerzőtársai (2019)*, illetve *Haydari és Yilmaz (2022)* tanulmánya is kimutatta. Az MI akár 26 milliárd ausztrál dollárra is csökkentheti a forgalmi torlódások költségeit, és a DRL- (Deep reinforcement learning) algoritmusok akár 40%-kal is csökkenthetik a várakozási időt. *Guo és Wang (2021)* tanulmánya is megerősítette, hogy a modellalapú prediktív vezérlés és a mélytanulás kombinálása javíthatja a

forgalomirányítást. Az MI forgalomirányítási rendszerek, különösen a többágenses rendszerek 20–35%-os javulást eredményezhetnek.

Az egészségügyi alkalmazások területén *Agarwal és szerzőtársai (2024)*, valamint *Esteva és szerzőtársai (2019)* tanulmánya kimutatta, hogy az olyan mélytanulási modellek, mint a CNN-ek (Convolutional Neural Network), nagy pontossággal képesek diagnosztizálni olyan állapotokat, mint a bőrrák és a diabéteszes retinopátia. Ezzel párhuzamosan, *Miotto és szerzőtársai (2017)* szerint a struktúrátlan orvosbiológiai adatok feldolgozása jelentős előrelépést eredményezhet a prediktív egészségügyi rendszerekben, és az MI-rendszerek javíthatják a diagnosztikai előrejelzések pontosságát. *Tong és szerzőtársai (2020)* is megerősítették, hogy az MI alkalmazása a szemészeti diagnosztikában, különösen a diabéteszes retinopátiában, kiváló eredményeket hozott.

A távközlési és hálózati iparági szinten *Balmer és szerzőtársai (2020)*, illetve *Fu és szerzőtársai (2018)* az 5G hálózatokban a mesterséges intelligencia alkalmazásában rejlő lehetőségeket vizsgálták, a forgalomirányításra összpontosítva. Az MI-alapú forgalomirányítási rendszerek optimalizálhatják a hálózati erőforrásokat, miközben csökkentik a késleltetési időt. Optimalizálhatók, és az adatvezérelt megközelítések felválthatják a hagyományos modellalapú módszereket. *Morocho-Cayamcela és szerzőtársai (2019)* szintén kiemelték az MI- és az ML-technológiák szerepét a frekvenciahasználat és az energiahatékonyság javításában az 5G/B5G-hálózatokban. Hasonlóképpen, *Baryannis és szerzőtársai (2018)*, valamint *Wang és szerzőtársai (2020)* az MI-alapú kockázatkezelést elemezték az ellátási láncokban és az 5G-hálózatokban. Az MI felhasználható a gyorsabb és adaptívabb döntéshozatalra az ellátási láncok kockázatkezelésében, az MI/ML algoritmusok pedig lehetővé teszik az 5G-csatornák méréseinek hatékonyabb kezelését.

A gyártási és pénzügyi alkalmazások kapcsán *Wang és szerzőtársai (2018)*, továbbá *Kullaya Swamy és Sarojamma (2020)* rámutattak, hogy az MI és a mélytanulási technológiák akár 82%-os hatékonyságnövekedést is eredményezhetnek az okosgyártásban, és jelentősen javítják a termékminőséget. A hibridizált gépi tanulási algoritmusok szintén jelentős pontosságjavulást hoztak a banki tranzakciók előrejelzésében.

Ezek a kutatások együttesen rávilágítanak arra, hogy az MI alkalmazása számos iparágban – beleértve a közlekedést, az egészségügyet, a telekommunikációt, a gyártást és a pénzügyeket – nemcsak hatékonyságnövekedést eredményez, hanem komoly gazdasági előnyökkel is jár, miközben javítja a prediktív rendszerek pontosságát és a döntéshozatali folyamatok minőségét.

## 2. Anyag és módszer

A kutatás alapjául szolgáló adatok az Európai Unió tagállamaiban működő vállalkozások IKT (információs és kommunikációs technológiák) -használatát vizsgáló, 2023. eleji, a nemzeti statisztikai hivatalok által végzett felmérésből származnak (Eurostat, 2023). A felmérés célja az MI-technológiák alkalmazásának vizsgálata volt különböző iparágakban és vállalati méretkategóriákban. Az eredeti adatbázis 150 400 vállalkozás válaszait tartalmazza, azonban az elemzés során az adatok aggregált formában kerültek feldolgozásra, így az elemzett minta 27 elemű statisztikai egységet foglal magában, amely az egyes országok MI-használati jellemzőinek összesítéséből áll. A kutatás során alkalmazott iparági besorolás a NACE Rev. 2 osztályozási rendszer szerint történt, ami lehetővé teszi az ágazati szintű összehasonlításokat. Utóbbi biztosítja, hogy az egyes iparágak MI-használati mintázatai egységesen értelmezhetők legyenek, és az eredmények összevethetők maradjanak más gazdasági statisztikákkal. Az MI-technológiák alkalmazásának ágazati sajátosságait az egyes szektorok digitalizációs érettsége és technológiai integrációja határozza meg, amit az elemzés során figyelembe vettünk.

A felmérés adatait a nemzeti statisztikai hivatalok reprezentatív, stratifikált, véletlen mintavételi módszerekkel gyűjtötték, biztosítva az egyes országok és szektorok közötti összehasonlíthatóságot. Az adatgyűjtési eljárások megfelelnek az Eurostat által kidolgozott éves modellkérdőívek előírásainak, amelyeket a tagállami statisztikai hivatalok standardizált módon alkalmaznak. Az adatfelvétel során a vállalatok különböző méretkategóriákba (mikro-, kis-, közép- és nagyvállalatok) történő besorolását az alkalmazotti létszám és az éves árbevétel alapján határozták meg. A vizsgált MI-technológiák kategóriáit – többek között a Gépi tanulás, a Természetes nyelvfeldolgozás, a Robotizált folyamatautomatizálás (RPA) és a Képfeldolgozás – előre meghatározott, egységes definíciók szerint rögzítették, biztosítva a válaszok konzisztenciáját. A kutatás során alkalmazott adataggregációs és normalizálási eljárások célja az országok és a szektorok közötti különbségek azonosítása volt, figyelembe véve az MI-technológiák elterjedtségét és az azokat befolyásoló gazdasági tényezőket. Az adatok feldolgozása során standardizálási és normalizálási technikákat alkalmaztunk az országok és az iparágak közötti torzítások csökkentése érdekében. Az országonkénti eltéréseket kiegyenlítő súlyozásokat alkalmaztunk, hogy az elemzés során a nagyobb országok vállalati struktúrája ne dominálja a mintát. Az így előállított adatstruktúra lehetővé tette az MI-használat makroszintű elemzését és a trendek azonosítását az Európai Unió egészére vonatkozóan.

Az 1. táblázat részletesen bemutatja az egyes országokban az MI-technológiákat használó vállalkozások százalékos arányát.



1. táblázat

**A mesterséges intelligencia vállalatoknál történő alkalmazásának  
százalékos megoszlása országok szerint, 2023**

*The percentage distribution of artificial intelligence adoption  
in companies by country, 2023*

(%)

Ország	Vállalatok, amelyek legalább egy mesterséges- intelligencia-technológiát alkalmaznak
Európai Unió	8,0
Ausztria	10,8
Belgium	13,8
Bosznia és Hercegovina	5,3
Bulgária	3,6
Horvátország	7,9
Ciprus	4,7
Csehország	5,9
Dánia	15,2
Észtország	5,2
Finnország	15,1
Franciaország	5,9
Németország	11,6
Görögország	4,0
Magyarország	3,7
Írország	8,0
Olaszország	5,0
Lettország	4,5
Litvánia	4,9
Luxemburg	14,4
Málta	13,2
Montenegró	5,6
Hollandia	13,4
Norvégia	9,2
Lengyelország	3,7
Portugália	7,9
Románia	1,5
Szerbia	8,0
Szlovákia	7,0
Szlovénia	11,4
Spanyolország	9,2
Svédország	10,4
Törökország	5,5

Forrás: Eurostat (2023) alapján saját szerkesztés.

A táblázat azt mutatja, hogy az egyes országokban milyen mértékben használják a vállalatok a mesterségesintelligencia-technológiákat: az uniós átlag 8,0%, de az egyes tagállamok között jelentős különbségek vannak, például Dániában (15,2%) és Finnországban (15,1%) kiemelkedően magas a mesterséges intelligencia alkalmazásának aránya, míg Románia a lista végén áll, mindössze 1,5%-kal. A táblázatból az is leolvasható, hogy néhány közép- és kelet-európai országban, például Magyarországon (3,7%) és Lengyelországban (3,7%) az átlagosnál alacsonyabb a mesterséges intelligenciát alkalmazó vállalatok aránya.

A kutatás módszertana különböző statisztikai technikák alkalmazását foglalja magában, amelyek segítségével az MI-technológiák vállalati alkalmazását, terjedését és szerkezeti jellemzőit elemeztük. A módszerek kombinált alkalmazása lehetővé teszi az adatok mélyebb összefüggéseinek feltárását és a trendek pontosabb meghatározását. Az elemzési eljárások kidolgozásához és alkalmazásához a többek között *Kovács (2014)* művében bemutatott módszertani megközelítéseket használtuk, amelyek alapvető útmutatást nyújtottak a módszerek megfelelő alkalmazásához.

- Korrelációelemzés: Az MI-technológiák közötti kapcsolatokat és együttjárásukat vizsgáltuk. Ez a módszer segített azonosítani, hogy mely megoldások fordulnak elő gyakran együtt egy adott iparágban vagy vállalati szegmensben. Például a Robotizált folyamatautomatizálás és a Gépi tanulás gyakran párhuzamosan alkalmazott technológiák, amelyek kombinációja növelte a vállalatok hatékonyságát. Az így kapott korrelációs mátrixok lehetővé tették annak feltárását, hogy mely technológiák elterjedtsége között van szignifikáns kapcsolat, és ezek milyen tényezőktől függttek.
- Főkomponens-elemzés (PCA): Ez a módszer csökkentette az adatok dimenzióit, miközben megőrizte a lehető legtöbb információt. Segítségével meghatároztuk az MI-használat strukturális tényezőit, például a gazdasági fejlettséget, a digitalizációs szintet és az iparági sajátosságok szerinti főbb összetevőket. A PCA lehetővé tette az MI-használati mintázatok közötti főbb eltérések megértését és vizualizálását. Az első néhány főkomponens alapján az MI-technológiák közötti kapcsolatokat és azok domináns hajtóerejeit azonosítottuk.
- Klaszterelemzés: Az országok és a vállalati szektorok MI-alkalmazási mintázatait az adatok statisztikai hasonlóságai alapján csoportosítottuk. Ez a módszer segített megkülönböztetni az MI-intenzív gazdaságokat (pl. Észak-Európa), a mérsékelten fejlett országokat (pl. Dél-Európa) és a kevésbé digitalizált régiókat (pl. Közép- és Kelet-Európa). Az eredmények hozzájárultak a célzott fejlesztési politikák meghatározásához. A klaszterelemzés eredményei segítettek azonosítani, hogy mely régiókban szükséges célzott támogatás az MI-adopció előmozdításához.

- **Többdimenziós skálázás (MDS):** Az MDS vizuális eszközt biztosított az MI-integráció földrajzi és iparági különbségeinek feltérképezéséhez. Az országokat és a vállalati szektorokat úgy rendeztük el egy többdimenziós térben, hogy a közöttük lévő távolságok tükrözzék az MI-használati mintázatok különbségeit. Ez lehetővé tette, hogy az eltéréseket nemcsak numerikus, hanem vizuális formában is értelmezzük. Az MDS segítségével az MI-adopció mintázatait intuitív módon ábrázoltuk, ami megkönnyítette a fejlesztési stratégiák megfogalmazását.

Az adatfeldolgozás és a statisztikai elemzések az SPSS 28 szoftver segítségével történtek. Minden korrelációs elemzés, faktorelemzés, főkomponens-elemzés és klaszterelemzés ezen program segítségével került kiszámításra, az Európai Unió vállalkozásainak mesterségesintelligencia-használatát vizsgáló 2023-as felmérés adatai alapján. A korrelációs mátrixban szereplő értékeket az SPSS korreláció-elemzési modulja generálta, amely az egyes technológiák előfordulási gyakoriságát és azok együttjárását vizsgálta az adatbázisban.

### 3. Statisztikai elemzés az egyes országok tekintetében

Ez a fejezet a mesterséges intelligencia elterjedését vizsgálja az Európai Unió országában 2023-ban. Statisztikai és klaszterelemzési módszereket alkalmaztunk. Célunk az volt, hogy feltárjuk a mesterséges intelligencia használatának különbségeit és hasonlóságait a vállalatok esetében az uniós tagállamok között. Megvizsgáltuk továbbá a mesterséges intelligencia alkalmazását befolyásoló gazdasági és technológiai tényezőket. Az elemzés hozzájárult az országok közötti különbségek jobb megértéséhez. A tanulmány segít azonosítani azokat a regionális kihívásokat, amelyek akadályozhatták a mesterséges intelligencia alkalmazását.

#### 3.1. Korrelációelemzés

A korrelációs mátrix (2. táblázat) Pearson-féle korrelációs együtthatók alapján mutatja a különböző mesterségesintelligencia-technológiák közötti kapcsolatokat, segítve azok elemzését és összefüggéseik megértését. Fontos megjegyezni, hogy a „Marketing”, a „Gyártás”, a „Logisztika” és az „ICT-biztonság” nem mesterségesintelligencia-technológiát, hanem azok alkalmazási területeit jelöli, ahol az MI különböző formái hasznosulnak. A következőkben az erős, a közepes és a gyenge korrelációkat, azok lehetséges okait és az általános következtetéseket dolgoztuk ki.

2. táblázat

**Korrelációs mátrix**  
*Correlation matrix*

Változók	Beszéd-felis- merés	Termé- szetes nyelv generá- lása	Kép- felis- merés és -fel- dolgo- zás	Gépi tanulás	Robo- tizált folya- mat- automa- tizálás	Auto- nóm drónok	Mar- keting	Gyártás	Logisz- tika	ICT- bizton- ság
Szöveg- bányászat	<b>0,801*</b>	0,325	<b>0,402*</b>	<b>0,750*</b>	<b>0,779*</b>	<b>0,469*</b>	<b>0,583*</b>	<b>0,613*</b>	<b>0,624*</b>	0,346
Beszéd- felismerés		0,524*	0,562*	0,610*	0,633*	0,494*	0,460*	0,594*	0,591*	0,470*
Természetes nyelv generálása			<b>0,667*</b>	<b>0,572*</b>	<b>0,461*</b>	<b>0,463*</b>	<b>0,630*</b>	<b>0,653*</b>	<b>0,537*</b>	<b>0,900*</b>
Képfelis- merés és -feldolgozás				<b>0,418*</b>	<b>0,522*</b>	<b>0,514*</b>	<b>0,421*</b>	<b>0,807*</b>	<b>0,661*</b>	<b>0,724*</b>
Gépi tanulás					<b>0,878*</b>	<b>0,696*</b>	<b>0,763*</b>	<b>0,773*</b>	<b>0,817*</b>	<b>0,655*</b>
Robotizált folyamat- automa- tizálás						<b>0,749*</b>	<b>0,726*</b>	<b>0,771*</b>	<b>0,818*</b>	<b>0,550*</b>
Autonóm drónok							<b>0,536*</b>	<b>0,662*</b>	<b>0,828*</b>	<b>0,504*</b>
Marketing								<b>0,670*</b>	<b>0,673*</b>	<b>0,556*</b>
Gyártás									<b>0,865*</b>	<b>0,763*</b>
Logisztika									1	<b>0,637*</b>

\* Korreláció 0,01 szinten szignifikáns.

Forrás: Eurostat (2023) alapján saját szerkesztés.

Először a három leginkább korreláló technológia közötti kapcsolatot elemeztük. A korrelációs együtthatók statisztikai szignifikanciáját  $p < 0,01$  szinten teszteltük, és minden vizsgált kapcsolat esetében szignifikáns összefüggést találtunk, ami alátámasztja az eredmények stabilitását. A nagyobb mintaméret csökkenti a véletlen ingadozások hatását, így a kapott korrelációs értékek megfelelően megbízhatóak. A Gépi tanulás és a Robotizált folyamatautomatizálás közötti erős korreláció ( $r = 0,878$ ) arra utal, hogy a két technológia egymás kiegészítője. Az RPA lehetőséget nyújt ismétlődő és strukturált feladatok automatizálására a Gépi tanulás által tanult minták és algoritmusok segítségével. Az erős korreláció azt jelenti,

hogy azok a vállalatok, amelyek alkalmazzák az egyik technológiát, nagy valószínűséggel a másikat is bevezették. Például a gyártóiparban az ML-alapú prediktív karbantartás és az RPA kombinációja csökkentheti a nem tervezett állásidőt, miközben optimalizálja az erőforrások felhasználását. Egy tipikus esetben az RPA-szoftverek ML-modellek által előrejelzett meghibásodások alapján automatikusan ütemezik a karbantartást, ezáltal megelőzve a termelési leállásokat, ami jelentős költségmegtakarítást és hatékonyságnövekedést eredményez az ipari automatizációban. A második kiemelkedő korreláció a Gyártás és a Logisztika között ( $r = 0,865$ ) tapasztalható, összhangban azzal a megfigyeléssel, hogy az MI-alapú ellátási lánc-menedzsmentet elsősorban a termelési folyamatok támogatására fejlesztik. Végül az Autonóm drónok és az ICT-biztonság közötti kapcsolat ( $r = 0,828$ ) azt jelzi, hogy az autonóm rendszerek védelmét biztosító MI-technológiák fejlődése egyre nagyobb szerepet kap.

A közepes korrelációk között elsőként a Képfelismerés és -feldolgozás és a Logisztika közötti kapcsolat ( $r = 0,661$ ) emelendő ki, amely megerősíti a gépi látás szerepét a logisztikai szektorban, például a csomagok azonosítása és a minőségellenőrzés során. A Marketing és a Gyártás korrelációja ( $r = 0,670$ ) arra utal, hogy a termékgyártás és a marketingtechnológiák, például az ajánlórendszerek és az MI-alapú termékelemzés között kapcsolat van, bár ez a kapcsolat nem olyan erős, mint az egyes iparágakon belüli alkalmazásoknál. Egy másik érdekes összefüggés a Természetes nyelv generálása és a Beszédfelismerés ( $r = 0,653$ ) között tapasztalható, arra utal, hogy a nyelvi MI-modellek erősen kapcsolódnak a hangalapú interakciós rendszerekhez.

A gyenge kapcsolatokat tekintve a Szövegbányászat és az ICT-biztonság közötti korreláció ( $r = 0,346$ ) nem szignifikáns, ami azt mutatja, hogy e két terület közvetlen kapcsolata minimális. Az alacsony érték azt jelzi, hogy bár a Szövegbányászat az információk feldolgozásában és elemzésében hasznos lehet, az ICT-biztonság alkalmazásai ennél specifikusabbak, például kiberbiztonsági fenyegetések detektálására épülnek.

Fontos megjegyezni, hogy a korreláció nem feltétlenül jelent ok-okozati összefüggést. Két változó közötti erős korreláció nem feltétlenül jelenti azt, hogy az egyik változó módosulása közvetlenül okozza a másik változó alakulását. Az is lehetséges, hogy egy harmadik változó (pl. technológiai fejlődés vagy iparági trendek) is szerepet játszik a megfigyelt kapcsolatban. A  $p$ -érték azt fejezi ki, hogy statisztikailag mennyire megbízható az összefüggés. A 0,05-nél kisebb  $p$ -értékek azt jelzik, hogy az összefüggés szignifikánsnak tekinthető, ami azt jelenti, hogy nem valószínű, hogy a véletlen műve. 0,01 alatti  $p$ -értékek még szigorúbb szignifikanciát jelentenek. A szignifikáns korrelációk arra utalnak, hogy a megfigyelt kapcsolat feltehetően valós, és érdemes további vizsgálatokat végezni annak pontos kiderítésére. A különböző mesterségesintelligencia-technológiák

közötti korrelációk segíthetnek megérteni, hogy mely technológiák kompatibilisek, és hogyan támogatják egymást az ipari alkalmazásokban. Például a Gépi tanulás és a Robotizált folyamatautomatizálás közötti erős korreláció arra utal, hogy e technológiák kombinálásával hatékonyabbá tehetők a folyamatok.

A korrelációs mátrix vizsgálata után közelebbről megvizsgáltuk a mátrix determinánsának értékeit, mivel ez alapvető szerepet játszik a mátrixok tulajdonságainak és viselkedésének megértésében. Ez az érték különösen fontos a faktorelemzés előkészítésében, mivel a mátrix invertálhatóságának mértékét jelenti. Maga a korrelációs mátrix megmutatja a változók közötti kapcsolatokat, míg a determináns értéke egy számszerűsített mutató, amely segít megérteni, hogy mennyire stabil a mátrix, és hogyan használható fel a további elemzésekhez. A vizsgált korrelációs mátrix determinánsa nagyon alacsony értékű volt ( $4,83 \times 10^{-7}$ ), ami arra utal, hogy a mátrix szinte szinguláris. Ez a majdnem szingularitás azt jelzi, hogy a változók között erős multikollinearitás van, azaz jelentősen korrelálnak egymással. Az ilyen erős korrelációk problémákat okozhatnak a faktorelemzésben, mivel megnehezítik a faktorok egyértelmű elkülönítését és az eredmények stabilitásának garantálását. A determinánsok alacsony értékei figyelmeztető jelek arra, hogy a faktorelemzésben kihívások merülhetnek fel, különösen akkor, ha a mátrix információtartalma redundáns, és a változók közötti korrelációk túlságosan hasonlóak.

*Haitovsky (1969)* egy formális tesztet javasolt a determináns nullához való közelségének ellenőrzésére, amely azt vizsgálja, hogy a mátrix szignifikánsan különbözik-e egy szinguláris mátrixtól. Ha a Haitovsky-teszt nem szignifikáns, akkor a korrelációs mátrix súlyosan degeneráltnak tekinthető, ami arra utal, hogy a változók közötti extrém magas korreláció miatt az adatok nem alkalmasak faktorelemzésre. A multikollinearitás csökkentése érdekében kiszámítottuk a Variance Inflation Factor (VIF) -értékeket, amelyek a változók egymásra gyakorolt hatását mutatják.

Az elemzés során a multikollinearitás diagnosztikai eredményei azt mutatták, hogy a különböző dimenziók eltérő hatással vannak a független változók varianciájára. Az első dimenzió esetében, ahol a sajátértékek kiemelkedően magasak, az összes változó varianciaarányai nulla közeli értékeket mutatnak, ami azt jelzi, hogy ez a dimenzió nem járul hozzá a független változók varianciájának magyarázatához. A második dimenzió állapotindexei némi kapcsolatot mutatnak, különösen a Természetes nyelv generálása és a Gépi tanulás változók esetében, de ezeknek a kapcsolatoknak a mértéke még mindig alacsony. Ez annak a jele, hogy ebben a dimenzióban ezek a változók csak minimális hatással vannak a modell varianciájára. A harmadik dimenzióban a Természetes nyelv generálása nagyobb varianciát mutat, ami arra utal, hogy ez a változó szorosabb kapcsolatban áll, míg a többi változó csak mérsékelt kapcsolatban van. A kapcsolat fontos lehet a modell

további elemzése szempontjából. A negyedik dimenzió esetében a Beszédfelismerés magas varianciaaránya arra utal, hogy ez a változó erősen korrelál ezen a dimenzióval. Ez egyértelműen jelzi, hogy a Beszédfelismerés változó szerepe fontos ebben az összefüggésben. Az ötödik dimenzióban a Gépi tanulás és az Autonóm drónok változók hasonló arányban kapcsolódnak ehhez a dimenzióhoz, ami a változók közötti multikollinearitásra utal. Az e változók közötti erős korrelációk azt jelzik, hogy ha ezeket a változókat nem megfelelően kezeljük, az eredmények torzítottak lehetnek. A hatodik dimenzióban a legerősebb korrelációk elsősorban a Gyártás és a Marketing változók esetében figyelhetők meg.

A Gyártás változó különösen nagy varianciát és erős korrelációt mutat a dimenzió többi változójával, ami tovább erősíti a multikollinearitás lehetőségét. Végül a hetedik dimenzióban a Gépi tanulás és a Gyártás magas varianciaarányokat mutat, ami erős kapcsolatot jelez e változók között. Ez arra utal, hogy ezek a változók erősen korrelálnak egymással, ami szintén multikollinearitási problémához vezethet a modellben.

Összességében az elemzésből világosan látszik, hogy egyes változók, mint például a Gépi tanulás és a Gyártás, erős kapcsolatot mutattak egyes dimenziókkal, ami multikollinearitásra utal.

### 3.2. Főkomponens-elemzés

A főkomponens-elemzés (PCA) olyan statisztikai módszer, amely egy adathalmaz varianciáját kis számú főkomponensre csökkenti, miközben megtartja az adatok legfontosabb információit. A módszer különösen akkor hasznos, ha nagyszámú változóval van dolgunk, mivel célja a dimenziók számának csökkentése és a mögöttes struktúra feltárása. A PCA során az eredeti változók közötti kapcsolatokat új, független komponensekbe szervezik, amelyek az adatok varianciájának minél nagyobb részét magyarázzák.

A főkomponensek kiválasztásának egyik fő kritériuma az volt, hogy a kiválasztott főkomponensek legalább 66%-ban visszaadják (reprodukálják) az adatok varianciáját, biztosítva ezzel, hogy az adatstruktúra legfontosabb információi megmaradjanak az elemzés során. A komponensszám meghatározásához Kaiser-kritériumot és könyökgörbe-elemzést alkalmaztunk. A Kaiser-kritérium alapján csak azok a főkomponensek kerültek kiválasztásra, amelyek sajátértéke meghaladja az 1-et, mivel ezek képesek jelentős információmennyiséget megtartani. Ezt kiegészítette a könyökgörbe-elemzés, amely az igenértékek csökkenési mintázatát vizsgálta, és segített meghatározni azt a töréspontot, ahol a variancia jelentős csökkenése tapasztalható. A két módszer együttes alkalmazása biztosította, hogy az optimális számú főkomponens kerüljön kiválasztásra a dimenziócsökkentés során.

A főkomponens-elemzés első komponensének sajátértéke 7,317, ami azt jelenti, hogy ez a komponens a teljes variancia 66,5%-át magyarázza. Ez arra utal, hogy az első komponens a legfontosabb dimenzió az adatok magyarázatában. A második komponens sajátértéke 1,261, és a variancia 11,5%-át magyarázza. Az első két komponens együttesen a teljes variancia 78%-át magyarázza, ami azt jelenti, hogy ezek a komponensek dominálnak az adatszerkezet magyarázatában.

A rotált négyzetek összege alapján az első komponens 44,8%-ot, míg a második komponens 33,2%-ot magyaráz. Így a rotációs megoldásban az első két komponens együttesen a magyarázóerő 78,0%-át adja, ami a teljes adatszerkezet jelentős részét lefedi. A rotációs megoldás segít jobban elkülöníteni a magyarázóerőt a komponensek között, így javítva az egyes komponensek értelmezhetőségét az elemzésben.

3. táblázat

**Rotált komponensmátrix***Rotated component matrix*

Változók	Komponens	
	1	2
Természetes nyelv generálása	<b>0,903</b>	0,158
Képfelismerés és -feldolgozás	<b>0,810</b>	0,244
Marketing	<b>0,611</b>	0,483
Autonóm drónok	<b>0,596</b>	0,445
Szövegbányászat	0,174	<b>0,956</b>
Beszéd felismerés	0,372	<b>0,825</b>

Forrás: Eurostat (2023) alapján saját szerkesztés.

A rotált komponensmátrix statisztikai elemzése (3. táblázat) két főkomponenst azonosított, amelyek jól megkülönböztetik a változókat a magyarázóvarianciájuk alapján. Az eredeti elemzéshez képest néhány változót eltávolítottunk, így a végső elemzésben csak a rotált komponensmátrix két összetevője által képviselt, legrelevánsabb és leginformatívabb változók maradtak. Mivel az eltávolított változók nem járultak hozzá jelentősen a variancia magyarázatához, a megmaradt változók képezik az elemzés alapját. Az egy komponensbe tartozó elemeket félkövér kiemeléssel jelöltük.

Az 1. komponenst a Természetes nyelv generálása változó uralja (0,903), ami azt jelzi, hogy ez a dimenzió a nyelvi technológiákhoz kapcsolódik. Hasonlóképpen, a Képfelismerés és -feldolgozás változó magas értéket mutat (0,810), ami jelzi, hogy ez a komponens részben vizuális technológiákat is tartalmaz. A Marketing (0,611) és az Autonóm drónok (0,596) közepes terhelést mutat, jelezve, hogy ezek a területek összetett kapcsolatban állnak az 1. komponenst alkotó technológiákkal.



A 2. komponenst a Szövegbányászat (0,956) és a Beszédfelismerés (0,825) magyarázza a legnagyobb mértékben, vagyis ezek a technológiák szorosan kapcsolódnak egymáshoz és egy önálló nyelvi technológiai klasztert alkotnak.

A komponensek szerkezetének elemzése alapján a technológiai kategóriák részben elkülönülnek, de nem tökéletesen. A Természetes nyelv generálása a vizuális és a nyelvi technológiák határterületén helyezkedik el, míg a Szövegbányászat és a Beszédfelismerés egyértelműen a nyelvi technológiákhoz kapcsolódik. Ez az eredmény arra utal, hogy a nyelvi és a vizuális technológiák között átfedések is létezhetnek, amelyeket a jövőbeli kutatások részletesebben vizsgálhatnak.

### 3.3. Klaszterelemzés

A klaszterelemzés során hierarchikus klaszterezési módszert alkalmaztunk az adatok csoportosítására, amely lehetővé teszi az MI-technológiák vállalati alkalmazásának különböző mintázatainak feltárását az európai országokban. A módszer előnye, hogy nem szükséges előre meghatározni a klaszterek számát, hanem az adatok struktúrája alapján alakítja ki az optimális klaszterszámot. Az elemzés során az egyes országokat hasonlósági alapon rendeztük csoportokba, figyelembe véve az MI-használat mértékét és a gazdasági fejlettség különböző dimenzióit.

Az optimális klaszterszám meghatározására a dendrogram vizuális elemzését és az agglomerációs együttthatók töréspontjának vizsgálatát alkalmaztuk. Az általunk használt SPSS szoftver nem számolja ki automatikusan a Silhouette-értéket, amely az egyes klaszterek elkülönülését és koherenciáját értékelné. Ennek ellenére a klaszterstruktúra stabilitásának ellenőrzésére a csoportok közötti távolságokat és az egyes országok hozzárendelésének konzisztenciáját is elemeztük. Az eredmények azt mutatták, hogy az egyes klaszterek jól elkülöníthetők, és a kialakított csoportosítás megbízható alapot nyújt az MI-használat eltérő szintjeinek összehasonlítására az EU tagállamaiban.

Az inverz korrelációs mátrix elemzése (4. táblázat) hat változóra szűkítette a vizsgálatot: Szövegbányászat, Beszédfelismerés, Természetes nyelv generálása, Képfelismerés és -feldolgozás, Autonóm drónok és Marketing. Az elemzés során a változók skáláit 0-1 intervallumra változtattuk, annak érdekében, hogy a változók közötti kapcsolatokat értelmesebbé tegyük, és hogy csökkentsük a skálakülönbségekből adódó torzításokat.

4. táblázat

**Inverz korrelációs mátrix**  
*Inverse correlation matrix*

Változók	Szöveg- bányászat	Beszéd- felismerés	Természetes nyelv generálása	Kép- felismerés és -feldolgozás	Autonóm drónok	Marketing
Szövegbányászat	<b>4,475</b>	-3,475	1,772	-0,153	-0,026	-2,047
Beszédfelismerés	-3,475	<b>4,386</b>	-1,617	-0,403	-0,312	1,362
Természetes nyelv generálása	1,772	-1,617	<b>3,198</b>	-1,213	0,101	-1,847
Képfelismerés és -feldolgozás	-0,153	-0,403	-1,213	<b>2,194</b>	-0,502	0,384
Autonóm drónok	-0,026	-0,312	0,101	-0,502	<b>1,702</b>	-0,606
Marketing	-2,047	1,362	-1,847	0,384	-0,606	<b>2,893</b>

Forrás: Eurostat (2023) alapján saját szerkesztés.

A mátrixokban az inverz korrelációs értékek azt mutatják, hogy a változók közötti kapcsolat hogyan változik, ha más változókat kontrollálunk. Az átlóelemek a változók „autokorrelációját” jelzik, vagyis azt, hogy a változók mennyire függetlenek a többi változótól. Az összes diagonális érték nagyobb, mint 1, ami azt jelzi, hogy az egyes változók jelentős információval rendelkeznek a többi változóval kapcsolatban.

1. Szövegbányászat: A saját korrelációs értéke 4,475, ami erős kapcsolatot mutat, míg a Beszédfelismeréssel (-3,475) és a Marketinggel (-2,047) negatív kapcsolatban áll. Ez azt jelenti, hogy amikor a Szövegbányászatot kontrolláljuk, ezek a változók egymással ellentétesen viselkednek.
2. Beszédfelismerés: A saját korrelációs értéke 4,386, ami szintén erős információtartalmat jelez. A Szövegbányászattal (-3,475) és a Természetes nyelv generálásával (-1,617) szoros, de negatív kapcsolatban áll, vagyis amennyiben az egyiket kontrolláljuk, a másik kevésbé magyarázható.
3. Természetes nyelv generálása: Ennek a változónak a saját korrelációs értéke 3,198, ami közepesen erős függetlenséget jelez. A Képfelismerés és -feldolgozással (-1,213) és a Marketinggel (-1,847) mutat szoros, de negatív kapcsolatot.
4. Képfelismerés és -feldolgozás: A saját értéke 2,194, ami viszonylag alacsonyabb, mint a többi változóé, de még mindig jelentős. Ez a változó kisebb mértékben kapcsolódik a többi változóhoz, de a Beszédfelismeréssel (-0,403) és a Szövegbányászattal (-0,153) negatív korrelációt mutat.

5. Autonóm drónok: Ennek a változónak a saját korrelációs értéke 1,702, amely a legkisebb a többi változóhoz képest, ami arra utal, hogy ez a változó kisebb mértékben függ a többi változótól. Enyhe negatív korrelációt mutat a Beszéd-felismeréssel (-0,312) és a Képfelismerés és -feldolgozással (-0,502).
6. Marketing: Ez a változó a saját korrelációs értékével (2,893) közepesen erős, és szoros kapcsolatban áll a Szövegbányászattal (-2,047) és a Természetes nyelv generálásával (-1,847), amelyekkel szignifikáns, de negatív kapcsolatban van.

Az uniós országokat a mesterségesintelligencia-technológia használatának szintje alapján is értékelhetjük. Az 1. ábrán látható dendrogram egy hierarchikus klaszterezési eljárás eredményeit mutatja be, amelyet a csoportok közötti átlagos kapcsolatok módszerével hoztak létre. Ez az ábra a különböző országok közötti hasonlóságok és különbségek elemzését mutatja, és az országok közötti távolságokat átméretezték, hogy csatlakozzanak a klaszterekhez.

A dendrogram célja, hogy vizuálisan bemutassa, hogyan csoportosíthatók az országok közös jellemzők szerint, és mennyire különböznek egymástól. Az egyes klaszterek és a klaszterezési folyamat közötti kapcsolat tükröződik a függőleges tengelyen megjelenített távolságértékekben.

Az uniós országokban a mesterségesintelligencia-technológiák használatának klaszterelemzésének eredményeit bemutató dendrogram három fő klasztert azonosított. Ezek a klaszterek azt tükrözik, hogy az országok milyen különböző szinteken alkalmazzák és integrálják a mesterségesintelligencia-technológiákat gazdaságukba és vállalkozásaikba.

Az első klaszterbe tartozó országok (Ausztria, Belgium, Dánia, Finnország, Luxemburg, Hollandia, Svédország és Dánia) mind fejlett gazdaságok, amelyek kiemelkedő technológiai infrastruktúrával és jelentős innovációs kapacitással rendelkeznek. Ezek az országok vezető szerepet töltenek be a mesterségesintelligencia-technológiák bevezetésében és alkalmazásában, ami előnyt jelent számukra a globális piacon való versenyképesség megőrzésében. Az MI-technológiák integrációja ezekben az országokban már számos iparágba és szolgáltatásba beépült, és kulcsszerepet játszik az automatizálásban, a prediktív analitikában, valamint a személyre szabott szolgáltatások nyújtásában.

A második klaszterbe tartozó országok, például Magyarország, Olaszország, Franciaország és Lengyelország, jellemzően lazábban integrálják az MI-technológiákat. Gazdaságilag ezek az országok sokszínűbbek, de különböző akadályokkal szembesülnek a mesterséges intelligencia elterjedése előtt. Ezek közé az akadályok közé tartozik a fejletlen technológiai infrastruktúra, a munkaerőpiacon a digitális készségek alacsony szintje és a rugalmatlan szabályozási környezet. Az MI-technológia alkalmazása ezekben az országokban gyakran korlátozottabb, mint az


első klaszter országaiban, és a fejlesztés főként néhány kulcsfontosságú ágazatra, például a pénzügyekre és az autóiparra koncentrálódik.

A harmadik klaszterbe csupán Szlovénia tartozik, ami arra utal, hogy ez az ország bizonyos szempontból nagyon különbözik a többi vizsgált országtól, az ország az MI-technológiák alkalmazásában kiemelkedő helyzetben van. 2021-ben az elsők között vezette be nemzeti MI-stratégiáját, és világszinten is a felelősségteljes MI-használat egyik élénjárója. A jól kiépített technológiai infrastruktúra és a digitális fejlettség eredményeként Szlovénia eltérő fejlődési pályát követ más európai országokhoz képest, ami magyarázatot adhat az önálló klaszterként való megjelenésére.

1. ábra

**Dendrogram**

*Dendrogram*



Forrás: Eurostat (2023) alapján saját szerkesztés.

A Visegrádi Négyek (V4) – Magyarország, Lengyelország, Csehország és Szlovákia – az MI-technológiák alkalmazásában egy átmeneti pozíciót foglalnak el az európai klaszterelemzésben. Ezek az országok gazdasági és digitalizációs fejlettségük tekintetében a nyugat-európai országok és a kevésbé fejlett délkelet-európai államok között helyezkednek el. A V4-ek technológiai infrastruktúrája változó képet mutat: míg Csehország és Lengyelország viszonylag fejlett digitális ökoszisztémával rendelkezik, addig Magyarország és Szlovákia esetében a fejlődés lassabb ütemű, és a szabályozási környezet kiszámíthatatlansága akadályozhatja az MI-integrációt. A skandináv országokkal összevetve a V4-régió jelentős lemaradásban van az MI elfogadását és integrációját illetően. Finnország, Svédország és Dánia erős innovációs környezettel, stabil kormányzati támogatással és jelentős kutatás-fejlesztési (K + F-) beruházásokkal támogatja az MI bevezetését. Ezzel szemben a V4-országokban az MI alkalmazása szűkebb iparágakra koncentráliódik, elsősorban a gyártás, a pénzügyi szektor és az autóipar területén, míg a szolgáltatási szektorban vagy a közigazgatásban kevésbé elterjedt.


A klaszterek kialakulása mögött számos tényező állhat, többek között a gazdasági fejlődés, az oktatási rendszer minősége, a kormányzati politikák támogatása, valamint az üzleti szektor nyitottsága a mesterséges intelligencia iránt. Az első klaszterbe tartozó országok valószínűleg vezető szerepet játszanak majd a mesterséges intelligencia alapú innováció globális piacán, és technológiai képességeik folyamatos fejlesztésével tovább erősíthetik pozíciójukat. A második klaszterbe tartozó országok számára kulcsfontosságú lehet az infrastruktúra és a digitális készségek fejlesztése, valamint a mesterségesintelligencia-technológiák fokozott alkalmazása a különböző gazdasági ágazatokban. Szlovénia egyedi helyzete további kutatásokat indokolhat annak érdekében, hogy jobban megértsük a térségben a mesterséges intelligenciával kapcsolatos technológiák bevezetésével összefüggő kihívásokat és lehetőségeket. Összességében a klaszterelemzés eredményei segíthetnek célzottabb stratégiák kidolgozásában a mesterséges intelligencia integrációjának fokozása érdekében az egyes országokban, figyelembe véve az országspecifikus körülményeket és lehetőségeket. A klaszterek így tükrözik az európai országok között az MI-technológiák elfogadásában mutatkozó különbségeket, amelyek a gazdasági fejlettség, az iparági struktúra és az innovációs ökoszisztéma érettségének függvényében változnak.

A jövőbeni kutatásokban javasoljuk az egyes klaszterekbe tartozó országok mesterségesintelligencia-technológiákra való felkészültségét befolyásoló konkrét tényezők vizsgálatát.

### 3.4. Többdimenziós skálázás

A többdimenziós skálázás (MDS; 2. ábra) az országokat egy kétdimenziós térben elhelyezve ábrázolja, ami segít vizualizálni és értelmezni a gazdasági és technológiai mutatók közötti különbségeket az MI integrációjának szintje alapján.

2. ábra



Forrás: Eurostat (2023) alapján saját szerkesztés.

Az ábra a többdimenziós skálázási módszer eredményeit mutatja, az euklideszi távolság modelljén alapul, és az európai országokat két dimenzió mentén helyezi el. Az elemzés során az eredeti változókat hat fő változóra csökkentettük, ami egyszerűsítette az adatokat, és lehetővé tette az országok közötti különbségek átláthatóbb elemzését.

A többdimenziós skálázási (MDS-) modell illeszkedésének értékelésére a Kruskal-féle stresszmutatót és az  $R^2$ -értéket használtuk. Az eredmények szerint a stresszérték 0,104, amely a szakirodalomban jó illeszkedési szintként elfogadott tartományba esik (Kruskal, 1964). Az MDS-modell  $R^2$ -értéke 0,965, ami azt jelzi, hogy a modell megfelelően reprezentálja az országok közötti hasonlóságokat és eltéréseket az MI-integráció szempontjából. Az eredmények alátámasztják, hogy a vizualizáció megbízhatóan tükrözi az országok közötti különbségeket az MI-használat terén.

Az  $x$  tengelyen (1. dimenzió) az országok technológiai fejlettségét és mesterséges intelligenciához való hozzáférését méri. Az ábrán látható, hogy a pozitív tartományba tartozó országok, mint Luxemburg, Hollandia, Ausztria, Finnország, Belgium és Dánia, magas szintű mesterségesintelligencia-technológiai penetrációval rendelkeznek. A bal oldalon elhelyezkedő országok, például Bulgária, Románia és Észtország, alacsony szintű MI-penetrációval bírnak.

Az  $y$  tengely (2. dimenzió) értelmezése több szempontból is megközelíthető. Az eredmények alapján azonban nem kizárólag a gazdasági fejlettség határozza meg az országok elhelyezkedését ezen a tengelyen. Noha a fejlett gazdaságok általában kedvezőbb technológiai és innovációs környezetet biztosítanak az MI alkalmazásához, a konkrét elhelyezkedést egyéb tényezők, például az MI bevezetésének sebessége, a vállalati stratégiák, valamint a szabályozási környezet is befolyásolják. Emiatt az  $y$  tengely értelmezése egy összetettebb képet mutat, amely magában foglalja az innovációs hajlandóságot és az MI-hez kapcsolódó iparágak fejlődési ütemét is.

Az ábra elemzése alapján kiemelhető, hogy Szlovénia az egyik legmagasabb pozícióban található, ami arra utal, hogy az innovációs hajlandóság és az MI-iparágak fejlődési üteme kiemelkedő lehet az országban. Portugália és Málta is kedvező helyen helyezkednek el ezen a tengelyen, ami azt jelezheti, hogy bár technológiai fejlettségük nem kiemelkedő, az MI-adoptációhoz kapcsolódó stratégiáik és szabályozási környezetük támogatja az innovációt.

A középső tengelyek mentén található országok, például Magyarország, Csehország és Svédország, kiegyensúlyozott helyzetet mutatnak az MI-integráció és az innovációs képesség között. Ezek az országok fokozatosan építik ki mesterségesintelligencia-infrastruktúrájukat, miközben gazdasági fejlettségük és innovációs potenciáljuk is közepesen magas szinten áll.

Érdekes módon Németország az ábra középső régiójában található, ami azt sugallja, hogy bár technológiai fejlettsége és az MI-hozzáférése magas, az innovációs képessége és gazdasági fejlettsége nem emelkedik ki olyan erőteljesen, mint például Luxemburg vagy Dánia esetében. Ez összhangban állhat azzal a megfigyeléssel, hogy Németország ipari és üzleti szektorai sok esetben óvatosabb ütemben integrálják az MI-technológiákat.

Összességében az ábra világosan bemutatja az országok közötti eltéréseket a mesterségesintelligencia-integráció terén. Míg egyes országok (pl. Luxemburg, Dánia, Finnország) erős MI-adoptációt és gazdasági fejlettséget mutatnak, addig mások (pl. Bulgária, Románia, Észtország) lemaradnak a technológiai fejlettség és az MI-hozzáférés tekintetében.

## 4. Következtetések

A tanulmány átfogó statisztikai elemzést nyújt a mesterségesintelligencia-technológiák különböző uniós iparágakban történő alkalmazásáról, különös tekintettel az üzleti szektorra. Az alapját képező, *2023 ICT use in business and e-commerce* felmérésben 150 400 uniós vállalat vett részt. A tanulmány újdonsága, hogy a különböző MI-technológiák, például a Gépi tanulás (ML), a Robotizált folyamatautomatizálás, a Szövegbányászat és a Beszédfelismerés közötti összefüggéseket vizsgálja. Az elemzés során különböző statisztikai technikákat, például korrelációelemzést, faktorelemzést és főkomponens-elemzést (PCA) alkalmaztunk, hogy feltárjuk a technológiák közötti kapcsolatokat, szinergiákat és redundanciákat.

Az eredmények azt mutatták, hogy bizonyos MI-technológiák, mint például a Gépi tanulás és az RPA, szorosan kapcsolódnak egymáshoz, jelentős hatékonyságnövekedést hozva. A tanulmány kiemeli a korrelációs mátrix és a Kaiser–Meyer–Olkin (KMO) -teszt szerepét a multikollinearitás feltárásában és a technológiák közötti kapcsolatok pontosabb elemzésében. A KMO-teszt értéke 0,808, a faktorelemzés alkalmazhatóságának megítélésében kulcsfontosságú. A hüvelykujjszabály szerint a 0,8–1,0 közötti értékek erős faktormodellt jeleznek, amely alapján a kapott faktorstruktúra megfelelő (*meritorious*) és alkalmas a változók közötti kapcsolatok feltárására. Egy másik elterjedt szabályozás szerint a 0,7 alatti értékek gyenge, a 0,8 feletti értékek kiváló faktormodellt jeleznek, így a jelenlegi eredmény a „majdnem kiváló” kategóriába esik. Ennek fényében a faktorelemzés alkalmazása indokolt, mivel a változók közötti struktúra kellően erős és megfelelően elkülöníthető a főkomponens-elemzés és egyéb dimenziócsökkentő módszerek segítségével. A faktorelemzés során a rotációs technikák alkalmazása hozzájárult a faktorok közötti kapcsolatok egyértelműbbé tételéhez. A varimax rotációt alkalmaztuk, amely ortogonális módszerként maximalizálja a faktorok közötti variancia különbségeit, ezáltal tisztább faktorstruktúrát eredményezve. Emellett megvizsgáltuk, hogy az oblimin rotáció, amely ferde szögű kapcsolatokat enged meg a faktorok között, javítana-e az interpretáción, azonban az eredmények azt mutatták, hogy az ortogonális rotáció megfelelőbb volt a technológiai változók csoportosítására.

A feltételek teljesülésének vizsgálata során figyelembe vettük a Bartlett-féle szfericitási tesztet, amely szignifikáns eredményt mutatott ( $p < 0,001$ ), igazolva, hogy az adatok alkalmasak faktorelemzésre. A közös variancia (*communality*) értékei szintén megfelelőek voltak, így a faktorstruktúra értelmezhető módon tükrözte az MI-technológiák közötti kapcsolatokat.

Az elemzés szerint az uniós országok között jelentős különbségek mutatkoztak az MI-technológiák elfogadásában: míg a gazdaságilag fejlettebb országok, mint



Dánia és Finnország, élen járnak, addig a kevésbé fejlett régiók, mint Románia, komoly kihívásokkal néznek szembe.

A klaszterelemzés során az uniós országokat a mesterséges intelligencia alkalmazásának intenzitása alapján csoportosítottuk. Az elemzés eredményeként két módszert alkalmaztunk: a hierarchikus klaszterelemzést (dendrogram) és a quick klaszterezést, hogy pontosabb és megbízhatóbb eredményeket kapjunk. A hierarchikus klaszterelemzésnél a négyzetes euklideszi távolságot alkalmaztuk az egyes pontok közötti különbségek meghatározására, míg a klaszterek közötti távolság meghatározására a csoportok közötti távolságot vettük figyelembe. A dendrogram három klasztert azonosított, azonban az egyik klaszterben csupán egy ország, Szlovénia szerepelt. A quick klaszterelemzés célja az volt, hogy finomítsa a hierarchikus klaszterezés eredményeit, és az egyetlen elemből álló klaszterhez hozzárendeljen hasonló országokat. Az eredmények alapján Szlovénia mellé Portugália és Málta is bekerült a quick klaszterbe, amely így egy gazdasági és digitalizációs szempontból hasonlóbb csoportot eredményezett. A quick klaszter és a dendrogram összehasonlítására Krammer-féle asszociációs számot használtunk, amely 0,808 értéket adott. A khi-négyzet-próba ( $\chi^2$ ) eredménye 0,001, amely azt mutatja, hogy az eltérés szignifikáns. Az összehasonlítás alapján a quick klaszterezés egyértelműen jobban reprezentálta az országok MI-integráció szerinti besorolását.

Az MDS-modell kimutatta, hogy az országok közötti különbségek jól tükröződnek a technológiai és gazdasági fejlettségük mentén, az  $x$  tengelyen a technológiai fejlettség, az  $y$  tengelyen pedig a gazdasági fejlettség és az MI-integráció aránya alapján.

A kutatás során az alábbi kérdésekre kerestük a választ:

[K1]: Milyen összefüggés figyelhető meg egy ország gazdasági fejlettsége és az MI-technológiák vállalati szintű alkalmazásának aránya között az Európai Unió tagállamaiban?

[H1]: A gazdaságilag fejlettebb országokban magasabb az MI-technológiákat alkalmazó vállalatok aránya.

Az eredmények alátámasztották ezt a feltételezést, mivel a fejlett gazdaságokban, például Dániában (15,2%) és Finnországban (15,1%) az MI-alkalmazások aránya lényegesen magasabb, mint a kevésbé fejlett régiókban, mint például Romániában (1,5%) vagy Bulgáriában (3,6%). A korrelációelemzés kimutatta, hogy az országok GDP-je és az MI-használat között erős pozitív összefüggés áll fenn (3.1. Korrelációelemzés). Ezt a klaszterelemzés tovább erősítette, mivel az MI-használat intenzitása alapján a gazdaságilag fejlettebb országok egy különálló klasztert alkotnak (3.3. Klaszterelemzés). Ezek az eredmények egyértelműen igazolják a hipotézist.

[K2]: Milyen hatással van egy ország digitalizációs és robotizációs fejlettsége az MI-technológiák integrációjára?

[H2]: Az MI-technológiák integrációja pozitív összefüggést mutat az adott ország digitalizációs és robotizációs szintjével.

Az elemzések rámutattak arra, hogy az MI elterjedtsége és az adott ország digitalizáltsága között szoros kapcsolat figyelhető meg, ami alátámasztja a hipotézist. A digitális infrastruktúra fejlettsége, az internetpenetráció és az ipari automatizáltság szintje meghatározó tényezőként jelenik meg az MI-adoptációban. Az 3.1. Korrelációelemzés alapján kimutatható, hogy az MI-alkalmazásokat széles körben használó országok – például Hollandia és Németország – kimagasló digitalizációs indexszel is rendelkeznek. Az 3.4. Többdimenziós skálázás eredményei tovább erősítik ezt a kapcsolatot, hiszen a fejlettebb digitalizációval rendelkező országok egyértelműen az MI-adoptáció magasabb szintjén helyezkednek el a vizuális elrendezésben. Ezen eredmények alapján a hipotézis igazolható.

[K3]: Hogyan befolyásolja az MI-technológiák elterjedtsége az EU tagállamainak regionális különbségeit?

[H3]: Az MI-technológiák elterjedtsége jelentős regionális eltéréseket mutat, és a fejlettebb nyugat-európai országokban lényegesen nagyobb mértékű az alkalmazásuk, mint a közép- és kelet-európai régiókban.

Az eredmények igazolták ezt a hipotézist, mivel az MI-technológiák alkalmazásában éles földrajzi megosztottság figyelhető meg. A klaszterelemzés alapján három fő csoport különült el: a magas MI-adoptációval rendelkező nyugat- és észak-európai országok (pl. Dánia, Finnország, Hollandia), a közepes szintű felhasználók (pl. Franciaország, Magyarország, Olaszország), valamint a jelentős lemaradást mutató országok (pl. Románia, Bulgária). Az 3.3. Klaszterelemzés eredményei alapján a kelet-közép-európai régió országai egyértelműen különálló csoportot alkotnak, ahol az MI-adoptáció szintje alacsonyabb. Az 3.4. Többdimenziós skálázás azt mutatta, hogy ezek az országok nemcsak gazdasági, hanem digitális fejlettségükben is lemaradnak, ami tovább erősíti az MI-elterjedtség regionális eltéréseinek meglétét. Mindezek fényében a hipotézis igazoltnak tekinthető.

Összegzésként a tanulmány fontos betekintést nyújtott az MI-technológiák elterjedésébe és alkalmazásába az EU-ban, és hozzájárul a technológiák közötti összefüggések mélyebb megértéséhez, ami alapvető fontosságú az MI hatékony ipari és szolgáltatási felhasználásában.

## 5. Diskusszió

Eredményeink reményeink szerint jelentősen hozzájárulnak a mesterségesintelligencia-technológiák európai elterjedtségének megértéséhez, valamint a technológia adoptációját befolyásoló gazdasági és ipari tényezők feltárásához. A kapott eredményeket érdemes a releváns kutatások eredményeivel összevetni, hogy megvizsgáljuk, milyen hasonlóságok és eltérések figyelhetők meg.

A tanulmány eredményei megerősítik, hogy az MI-technológiák elterjedtsége és alkalmazása jelentős eltéréseket mutat az Európai Unió egyes tagállamai között. Az olyan fejlett gazdaságok, mint Dánia és Finnország, vezető szerepet töltenek be az MI integrációjában, hasonlóan a *Brodny és Tutak (2022)* által kimutatott eredményekhez, amelyek a digitális transzformáció magas szintjét igazolták ezekben az országokban. Ezzel szemben a kelet-európai tagállamok, különösen Románia és Bulgária, jelentős lemaradást mutatnak az MI alkalmazásában. Eredményeink összhangban állnak *Vasilescu és szerzőtársai (2020)* kutatásaival, akik a digitális készségek alacsony szintjét azonosították ezen régiókban.

Elemzésünk azt is kimutatta, hogy a nagyvállalatok nagyobb valószínűséggel alkalmaznak MI-technológiákat, amely megállapítás alátámasztja *Bach és szerzőtársai (2020)* kutatásait, akik kimutatták, hogy a nagyvállalatok 33,5%-a alkalmaz Big Data alapú megoldásokat, szemben a kis- és középvállalkozások (kkv-k) 10,57%-os arányával. Hasonló eredményekre jutott *Chan és Meunier-Aitsahalia (2020)*, akik azt találták, hogy a digitális technológiák alkalmazásában jelentős a vállalati méret szerinti eltérés.

Főkomponens-elemzési (PCA-) eredményeink alátámasztják a *Malinowski (2021)* által vizsgált életszínvonal és technológiai fejlettség kapcsolatát, kimutatva, hogy az MI-integráció mértéke az adott ország gazdasági fejlettségétől függ. A PCA 66%-ban magyarázza az adatok varianciáját, amely biztosítja a főkomponensek informatív erejét.

A klaszterelemzés során az MI-használat alapján az uniós tagállamokat három csoportba soroltuk, amely eredmények megfelelnek *Brodny és Tutak (2024)* elemzéseinek, akik szintén hasonló klasztereket azonosítottak a digitalizáció és az MI-fejlettség alapján. Tanulmányunkban az optimalizált klaszterszámot a dendrogram elemzésével határoztuk meg, figyelembe véve az egyes csoportok konzisztenciáját.

Az eredmények összhangban állnak *Pripoaie és szerzőtársai (2024)* megállapításával, miszerint a romániai MI-integráció fejlődik, de még mindig elmarad a nyugat-európai szintektől.

Tanulmányunk rávilágít az MI alkalmazásának dinamikáira az EU-ban, és megerősíti a gazdasági fejlettség és a digitalizáció meghatározó szerepét az MI-

adoptációban. Az eredmények támpontot adhatnak a gazdaságpolitikai döntéshozóknak az MI-fejlesztés stratégiáinak finomhangolására, valamint az MI-technológiák hatékonyabb elterjesztésére az EU kevésbé fejlett régióiban.

## 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>
- 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>
- 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>
- Botlíková, M. – Botlík, J. (2020): Local Extremes of Selected Industry 4.0 Indicators in the European Space – Structure for Autonomous Systems. *Journal of Risk and Financial Management*, 13(1), 13.  
<https://doi.org/10.3390/jrfm13010013>
- 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>
- Brodny, J. – Tutak, M. (2022): Analyzing the Level of Digitalization among the Enterprises of the European Union Member States and Their Impact on Economic Growth. *Journal of Open Innovation: Technology, Market, and Complexity*, 8(2), 70. <https://doi.org/10.3390/joitmc8020070>
- Brodny, J. – Tutak, M. (2024): Assessing the Level of Innovativeness and Digitalization of Enterprises in the European Union States. *Journal of Open Innovation: Technology, Market, and Complexity*, 10(1), 100210. <https://doi.org/10.1016/j.joitmc.2024.100210>
- 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>
- 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>
- Duch-Brown, N. – Rossetti, F. – Haarbuerger, R. (2021): *Evolution of the EU Market Share of Robotics: Data and Methodology*. EUR 30896 EN Publications Office of the European Union, Luxembourg. <https://doi.org/10.2760/292931>
- 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)*.  
[https://doi.org/10.2908/isoc\\_eb\\_ain2](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>

- 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>
- Haitovsky, Y. (1969): Multicollinearity in Regression Analysis: Comment. *The Review of Economics and Statistics*, 51(4), 486. <https://doi.org/10.2307/1926450>
- 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>
- 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>
- Kovács E. (2014): *Többváltozós adatelemzés*. Budapesti Corvinus Egyetem. Budapest.
- Kruskal, J. B. (1964): Multidimensional Scaling by Optimizing Goodness of Fit to a Nonmetric Hypothesis. *Psychometrika*, 29(1), 1–27. <https://doi.org/10.1007/bf02289565>
- 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>
- Malinowski, M. (2021): The Standard of Living of Inhabitants and the Scientific and Technological Potential in Selected European Union Regions. *European Research Studies Journal*, 24(2), 714–747. <https://doi.org/10.35808/ersj/2152>
- Miotto, R. – Wang, F. – Wang, S. – Jiang, X. – Dudley, J. T. (2017): Deep Learning for Healthcare: Review, Opportunities and Challenges. *Briefings in Bioinformatics*, 19(6), 1236–1246. <https://doi.org/10.1093/bib/bbx044>
- 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. – Bertonecel, 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>
- Tong, Y. – Lu, W. – Yu, Y. – Shen, Y. (2020): Application of Machine Learning in Ophthalmic Imaging Modalities. *Eye and Vision*, 7(1). <https://doi.org/10.1186/s40662-020-00183-6>
- 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>
- Zoumpiskas, T. – Vavalis, M. – Houstis, E. (2021): Analysis of Innovation with Data Science: The Case of Greece. *International Journal of Data Science and Big Data Analytics*, 1(1), 20–42. <https://doi.org/10.51483/ijdsbda.1.1.2021.20-42>