



Közzététel: 2025. december 12.

A tanulmány címe:

Mesterséges intelligencia alapú technológiák elfogadását befolyásoló tényezők modellezése a kovariancia-alapú strukturális egyenletek módszerével (CB–SEM)

Szerzők:

HORVÁTH KATA

a Miskolci Egyetem doktorandusza

E-mail: kata.horvath@uni-miskolc.hu

MOLNÁR LÁSZLÓ

a Miskolci Egyetem egyetemi docense

E-mail: laszlo.molnar@uni-miskolc.hu

DOI: <https://doi.org/10.20311/stat2025.12.hu1117>

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 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 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 12. számában megjelent, **Horváth Kata – Molnár László** által írt, **Mesterséges intelligencia alapú technológiák elfogadását befolyásoló tényezők modellezése a kovarianciaalapú strukturális egyenletek módszerével (CB–SEM)** című tanulmány (link csatolása)”

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

Horváth Kata – Molnár László

Mesterséges intelligencia alapú technológiák elfogadását befolyásoló tényezők modellezése a kovarianciaalapú strukturális egyenletek módszerével (CB–SEM)

Modelling the factors influencing the acceptance of artificial intelligence-based technologies using covariance-based structural equation modelling (CB–SEM)

Horváth Kata, a Miskolci Egyetem doktorandusza

E-mail: kata.horvath@uni-miskolc.hu

Molnár László, a Miskolci Egyetem egyetemi docense

E-mail: laszlo.molnar@uni-miskolc.hu

A mesterséges intelligencia (MI-) alapú rendszerek társadalmi-gazdasági diffúziója az elmúlt években megkérdőjelezhetetlenül felgyorsult, a folyamatban az egyének technológiával szembeni elfogadó magatartása kulcsszerepet játszik. Jelen kutatás az egyetemi hallgatók körében vizsgálja a mesterséges intelligencia elfogadását befolyásoló tényezőket. Az empirikus kutatás elméleti keretét a technológiaelfogadás és -használat egységesített elmélete (UTAUT-modell) jelenti. A keresztmetszeti vizsgálatra 2024 őszén került sor, hipotéziseinket a kovarianciaalapú strukturális egyenletek módszerével (CB–SEM) teszteltük. Eredményeink alapján a hallgatók MI-elfogadását elsősorban a teljesítményelvárás és a várható erőfeszítés befolyásolja, ugyanakkor a társadalmi befolyás mérsékelt hatást fejt ki a technológiával szembeni nyitottságra. Az elősegítő feltételek nem mutattak szignifikáns kapcsolatot sem a használati szándékkal, sem a tényleges használattal, ami az infrastrukturális tényezők marginális szerepét jelzi a vizsgált populáció elfogadási folyamatában. Mindezek alapján megállapítható, hogy az MI-technológia használatához szükséges erőforrások rendelkezésre állása önmagában nem elegendő az MI-adaptáció elősegítéséhez, a hallgatók mesterséges intelligenciához való viszonyulása elsősorban célzott edukációs programokkal alakítható.

Kulcsszavak: mesterséges intelligencia, technológiaelfogadás, CB–SEM

The socio-economic diffusion of artificial intelligence-based technologies has accelerated in recent years with technology acceptance playing a crucial role in the process. This research examines university students and the factors influencing their acceptance of artificial intelligence. The study employs the Unified Theory of Acceptance and Use of Technology (UTAUT) as a theoretical base. A cross-sectional study was conducted in 2024, the hypotheses were tested using covariance-based structural equation modelling (CB–SEM). Based on our results, performance expectancy and effort expectancy are key determinants of AI-acceptance formation. Furthermore, social influence also showed a positive relationship with behavioral intention to use AI. On the other hand, facilitating conditions (i.e. the availability of infrastructural resources) were proven to have a negligible effect

in promoting the acceptance of technology. The findings provide actionable insights for policy-makers, suggesting that students' expectations towards AI can be most effectively shaped through targeted educational programmes.

Keywords: artificial intelligence, technology acceptance, CB-SEM

A mesterséges intelligencia (MI) alapú rendszerek társadalmi-gazdasági diffúziója az elmúlt években megkérdőjelezhetetlenül felgyorsult. Az MI-technológia mára számos iparágban meghatározó tényezőnek számít, és alapjaiban rendezi át a megszokott piaci viszonyokat, folyamatokat (Grabowski, 2024). Zhang és szerzőtársai (2021) értelmezésében a mesterséges intelligencia a számítógép-tudomány azon alágához tartozik, amelynek célja olyan rendszerek tervezése, amelyek hagyományosan humán kompetenciát vagy beavatkozást igénylő problémák és feladatok megoldására képesek – ilyen például a tanulás, az érvelés és a megértés folyamata is.

A mesterséges intelligencia intenzív terjedésének szerteágazó következményei (Capraro et al., 2024; Lukianenko–Simakhova, 2024) alapvető társadalmi változásokat idéznek elő (Sosaya-Rodríguez et al., 2024), és a megkezdett transzformációs folyamatokban a technológia általános elfogadottságának kiemelt szerep jut. A technológiaelfogadás operacionalizálásakor több magatartástudományi modellre is támaszkodhatunk (Ajzen, 1985; Ajzen–Fishbein, 1980; Bandura, 1986; Davis, 1986; Deci–Ryan, 1985; Triandis, 1979; Venkatesh et al., 2003, 2012, 2016; Venkatesh–Bala, 2008), ezek közül a technológiaelfogadás és -használat egységesített elmélete (*Unified Theory of Technology Acceptance and Use of Technology*, UTAUT) tekinthető a legszofisztikáltabb konstrukciónak. A Venkatesh és szerzőtársai (2003) által kifejlesztett modell több elmélet ötvöztetésével nyújt pontos és részletes képet a fogyasztói elfogadásra ható tényezők komplexitásáról, valamint párhuzamos hatásáról.

Kutatásunk előkészítő szakaszában szisztematikus szakirodalom-elemzést végeztünk, annak érdekében, hogy tudományos szempontból releváns kutatási objektívák mentén biztosítsuk az elvégzett empirikus vizsgálat elméleti kereteit. Olyan, 2018 és 2023 között publikált nemzetközi tanulmányokat vettünk figyelembe, amelyek a fogyasztók MI-elfogadásáról szolgáltatott empirikus adatokat. A végső szakirodalmi adatbázis (n = 44) metaszintézisének konklúziója, hogy ugyan az MI-adaptáció széles körben kutatott terület (Norzelan et al., 2024; Schulz et al., 2023), a felsőoktatási kontextusban értelmezhető használat, valamint elfogadás vizsgálata

nemzetközi és hazai szinten is hiányosnak tekinthető, ami több szempontból is kritikus. Először is a mesterséges intelligencia elfogadásának mérése, valamint az azt befolyásoló tényezők azonosítása az egyetemi hallgatók körében különösen fontos, hiszen ők azok, akik a legközvetlenebbül és legerőteljesebben tapasztalják az MI-technológiák oktatási, szakmai és mindennapi életet formáló hatásait (*Ferk Savec–Jedrinović, 2024*). Másrészt a felsőoktatási környezet nemcsak a technológiahasználat intenzív tanulási és gyakorlati terepe, hanem az MI-adaptációt meghatározó kognitív és információs kompetenciák fejlesztésének elsődleges színtere is (*Alateyyat–Soltan, 2024; Lau et al., 2019; Makarenko et al., 2024*). Kiemelt jelentőségű tehát, hogy a hallgatók – mint a jövő munkaerőpiacának alapvető szereplői – már most olyan tudásra és készségekre tegyenek szert, amelyek meghatározzák az MI-vel való együttműködésük sikerességét. Fontos továbbá leszögezni, hogy az egyetemi hallgatók technológiaelfogadásának elemzése elengedhetetlen a technológia társadalmi beágyazódásának és hosszú távú sikerességének megértéséhez, biztosításához is. Mindezek tükrében az MI széles körű társadalmi adaptációjával kapcsolatban a felsőoktatás nemcsak kritikus belépési küszöbként azonosítható, hanem kulcsfontosságú szerepe is körvonalazódik a technológia elfogadását meghatározó készségek célzott fejlesztésében. Ennek megfelelően jelen kutatás a továbbiakban a felsőoktatás területére fókuszálva elemzi azokat a tényezőket, amelyek elősegítik a mesterséges intelligencia hatékony és széles körű integrációját. A kutatás során egy online kérdőíves felmérés keretein belül vizsgáltuk a magyar egyetemi hallgatók MI-elfogadását. A kutatás elméleti kereteit az UTAUT-modell jelentette. Az adat-elemzés a kovarianciaalapú strukturális egyenletek módszerének (*Covariance-Based Structural Equation Modeling, CB–SEM*) alkalmazásával történt.

A kutatás a következő szerkezetet követi. Az 1. fejezetben szakirodalom-elemzés segítségével törekszünk a tanulmány szempontjából releváns vizsgálati eredmények szintetizálására, valamint kutatásunk elméleti keretrendszerének felállítására. A 2. fejezetben részletezzük a kutatás hipotéziseit, illetve konceptuális modelljét. Az empirikus vizsgálat során alkalmazott módszertan ismertetésére a 3. fejezetben kerítünk sort. Eredményeink, valamint azok értékelése a 4. és az 5. fejezetben olvasható. Végezetül a 6. fejezetben összegezzük tanulmányunk legfontosabb következtetéseit.

1. Szakirodalom-elemzés

1.1. MI-technológiák adaptációs lehetőségei a felsőoktatásban

A mesterséges intelligencia felsőoktatási integrációja forradalmasítja a hagyományos akadémiai gyakorlatokat, jelentős előrelépést kínálva mind az oktatás, mind az intézmények vezetésszervezésének területén. Az elérhető szakirodalmak alapján négy fő adaptációs irányt azonosítottunk: (1) az oktatási tevékenység perszonalizációja (*Jing–Boyi, 2023; Murdan–Halkhoree, 2024; Naseer et al., 2024; Sajja et al., 2024*), (2) az intézményi működés optimalizálása (*Nurhasanah et al., 2024; Téllez et al., 2024*), (3) az adatalapú vezetői döntéshozatal (*Fok et al., 2018; Téllez et al., 2024*), valamint (4) az innovatív oktatási gyakorlatok támogatása (*Alrayes et al., 2024; Saleem et al., 2024*).

Az előnyökön túlmenően ugyanakkor a technológia integrációja kihívásokkal is jár. Mindenekelőtt az etikai problematikákat szükséges kiemelniük (*Alrayes et al., 2024; Murdan–Halkhoree, 2024*), de komoly kihívást jelent az a digitális szakadék is, amely az eltérő szociális háttérrel rendelkező hallgatóknak a technológiához való hozzáféréssel kapcsolatosan jelentkezik. Az alacsony jövedelmű háztartásokból érkező hallgatók esetében a különböző technológiákhoz való hozzáférés (ilyenformán az MI működtetéséhez szükséges eszközök elérhetősége is) korlátozott, ami alapvetően hátráltatja az MI-alapú oktatás előnyeinek teljes kihasználását (*Murdan–Halkhoree, 2024; Téllez et al., 2024*).

Ami a felsőoktatás és a mesterséges intelligencia jövőbeni perspektíváit illeti, az MI szerepe várhatóan tovább bővül majd, és ezt a folyamatot az innováció és az akadémiai környezet változó igényei vezérlik. Az MI-eszközök fejlesztésére fókuszáló aktuális kutatások elsődleges célja olyan MI-alapú chatbotok és prediktív modellek kialakítása, amelyek további segítséget nyújtanak a tanulási élmény perszonalizációjában, valamint az intézményi döntéshozatal támogatásában. Az ez irányú fejlesztések folyamatos monitorizálása kiemelt intézményi feladatként azonosítható (*Alateyyat–Soltan, 2024; Alrayes et al., 2024*). Számottevő jelentőséggel bír továbbá az oktatók specializált képzése is. Az MI sikeres integrációjához elengedhetetlen, hogy az oktatók releváns ismereteket és technológiai készségeket szerezzenek az MI vonatkozásában. A képzési programok és a szakmai fejlődés lehetőségének biztosítása kulcsfontosságú tényező az oktatók adekvát felkészítésében, amely támogatja az MI által vezérelt innovációk sikerességét, az oktatási módszertan, valamint a megszokott gyakorlatok MI-motivált átalakítását (*Murdan–Halkhoree, 2024*).

1.2. Technológiaelfogadás: fókuszban a mesterséges intelligencia

A mesterséges intelligencia elfogadottságának elemzésével, valamint az azt befolyásoló egyéni tényezők vizsgálatával számos tanulmány foglalkozik, amelyek fókuszban a technológia különböző iparági alkalmazásaira is kiterjed az orvostudományoktól kezdve (*Schulz et al., 2023*) a pénzügyeken át (*Norzelan et al., 2024*) az építőiparig (*Na et al., 2022*). A mesterséges intelligencia elfogadása alatt az egyének vagy szervezetek MI-technológiák adaptálására, valamint használatára irányuló hajlandóságát és felkészültségét értjük (*Kelly et al., 2023*). Az egyének MI-alapú technológiákkal szemben tanúsított elfogadó magatartására számos tényező hatással van. Először is az elfogadás kialakulásának támogatásában kiemelt szerepe van a technológia használatából fakadó észlelt hasznosságnak, valamint a használathoz kapcsolódó szükséges erőfeszítés feltételezett mértékének (*Aldraiweesh–Alturki, 2025; Ibrahim et al., 2024*). Ezen változók vizsgálata gyakran olyan elméleti modellek alkalmazása mentén történik, mint a technológiaelfogadási modell (*Technology Acceptance Model, TAM*), valamint a technológiaelfogadás és -használat egységesített elmélete (*Kelly et al., 2023*). *Ismatullaev és Kim (2024)* arra a következtetésre jutott, hogy a mesterséges intelligencia magasabb fokú átláthatósága, illetve megbízhatósága növeli a felhasználók bizalmát, és támogatja az elfogadást is. *Cornelissen és szerzőtársai (2022)* megállapították, hogy az egészségügyi szektorban való MI-használat során a felhasználók elfogadását az MI-rendszerek technikai teljesítménye és funkcionalitása befolyásolja. A technológiai tényezőkön túl az egyéni karakterisztikák is kulcsszerepet játszanak a technológia adaptációjának kialakulásában. *Schiavo és szerzőtársai (2024)* alapján a magasabb szintű MI-műveltség, azaz az MI-rendszerek működésének és működtetésének megértése, elsajátítása csökkenti az egyének szorongását, és pozitív hozzáállást alakít ki a technológiával szemben, ami az elfogadási folyamatra is kedvezően hat. Bizonyos személyiségjegyek, mint a nyitottság és az innovativitás, pozitívan befolyásolhatják az MI használatával kapcsolatos teljesítmény- és erőfeszítés-elvárásokat is, ezáltal elősegítve az elfogadást (*Hao et al., 2021*). A bizalom és a szorongás mértéke szintúgy kardinálisnak tekinthető az elfogadás kialakulásában, bár ellentétes mechanizmusok mentén fejtik ki hatásukat: míg a bizalom elősegíti, addig a szorongás megnehezíti az elfogadó magatartás kialakulását (*Cornelissen et al., 2022; Schiavo et al., 2024*). Ezenkívül a szervezeti tényezők – mint a támogató kultúra, a részvétel (*Bengel, 2020*) és a versenyszellem (*Fousiani et al., 2024*) – szintén létfontosságúak a mesterséges intelligencia intézményi bevezetésében és elfogadásában. Számos tanulmány hangsúlyozza a társadalmi hatások, így a társadalmi normák, a szájhagyomány és a mesterséges intelligenciával kapcsolatos társadalmi attitűdök szerepét is (*Chen et al., 2024; Fares et al., 2024*;

Mutlu, 2024). *Banyté és szerzőtársai (2024)* bebizonyították, hogy az adatvédelemmel és az adatkezeléssel kapcsolatos aggályok szintén akadályozhatják a mesterséges intelligencia elfogadását. Végezetül az érzelmi és a kognitív tényezők is jelentős szerepet játszanak az MI-adaptációs folyamatok során. *Mutlu (2024)* megállapította, hogy az egyének érzelmi és belső motivációi jelentős hatással vannak az MI-vezérelt technológiák használatával szembeni hajlandóságra, és hangsúlyozza, hogy az alapvetően pozitív válaszok segíthetik az elfogadó attitűd megerősödését. *Chen és szerzőtársai (2024)*, valamint *Hao és szerzőtársai (2021)* szerint a mesterséges intelligenciával kapcsolatos észlelt kockázat negatív hatással lehet az elfogadásra. Az MI-vezérelt intézményi innovációk sikerének biztosításához ezen kockázatok célzott kezelése (akár szabályozási irányelvek és edukációs programok révén) elengedhetetlenül fontos. Mindazonáltal az MI-adaptációt befolyásoló tényezők köre és befolyásuk jellege a különböző alkalmazási kontextusokban eltérhet (*Aldraiweesh–Alturki, 2025; Nazri et al., 2023*).

1.3. A technológiaelfogadás és -használat egységesített elmélete (UTAUT)

Kutatásunk kiindulási modelljét a technológiaelfogadás és -használat egységesített elmélete jelenti. A technológiaelfogadás és -használat egységesített elmélete nyolc különböző modell, illetve (elsősorban magatartástudományi) elmélet ötvöztetésével, revideálásával jött létre, többek között magában foglalja a technológiaelfogadási modell bizonyos elemeit, de épít a logikus cselekvések elméletére (*Theory of Reasoned Action, TRA*), illetve a tervezett viselkedés elméletére (*Theory of Planned Behavior, TPB*) is (*Venkatesh et al., 2003*). Az UTAUT-modell a TAM-modellhez hasonlóan a tényleges használatot, illetve a használati szándékot helyezi a középpontba, továbbá vizsgálja az azt befolyásoló független és moderáló változókat is. A *Venkatesh és szerzőtársai (2003)* által kifejlesztett modell négy kulcstényezőt azonosít, a köztük felvázolt primer kapcsolatok az alábbi módon összegezhetők. A modell négy bemeneti és egy mediátorváltozó segítségével magyarázza a fogyasztók technológiaelfogadását, amely a tényleges használatban reflektálódik. A bemeneti változókat a technológiával szemben támasztott individuális elvárások (elvárt teljesítmény, *performance expectancy, PE*), a technológia használatának nehézségével kapcsolatos fogyasztói elképzelések (várható szükséges erőfeszítés, *effort expectancy, EE*), a technológia használatára vonatkozó társadalmi hatás, esetlegesen nyomás (*social influence, SI*), illetőleg bizonyos elősegítő, a technológia használatához szükséges infrastrukturális és egyéb feltételek (*facilitating conditions, FC*) jelentik. Ezek a tényezők közvetlenül befolyásolják a használati szándékot (*behavioural intention, BI*), amely a modellben moderáló szerepet kap.

Ezenkívül a modell az elősegítő feltételek és a kimeneti változó, vagyis a tényleges használat (*use behaviour*, UB) között közvetlen kapcsolatot létesít (*Venkatesh et al., 2003*). A használati szándék előrejelzésének legerősebb tényezőiként az elvárt teljesítményt és a várható erőfeszítést azonosíthatjuk (*Gupta et al., 2019; Simeonova et al., 2013; Sobti, 2019*), bár bizonyos esetekben a várható erőfeszítés hatása nem szignifikáns (*Sánchez-Holgado–Arcila-Calderón, 2024*). Ezzel szemben a társadalmi hatás, illetve az elősegítő feltételek használati szándékra gyakorolt hatása változó, szignifikanciájuk a különböző kutatási kontextusokban eltérő (*Bhati et al., 2023; Jewer, 2018; Soomro, 2019*).

Az általunk elvégzett elemzés elsődlegesen feltáró jelleggel a használati szándékot befolyásoló kulcsdimenziók megértésére tesz kísérletet az egyetemi hallgatók körében. Jelen esetben tehát a kutatási fókusz az MI hallgatói elfogadásának exploratív modellezésén, a báziskapcsolatok és hatások felvázolásán van. A kutatási cél elérését a technológiaelfogadási modellek legdiverzifikáltabb konstrukciójának alapverziója, az UTAUT-modell hatékonyabban támogatja a továbbfejlesztett, kibővített változatainál (*Venkatesh et al., 2016*). Választásunk továbbá az alábbiakkal indokolható. Az UTAUT-modell az UTAUT2-nél egyszerűbb megközelítésnek tekinthető. Ez előnyt jelenthet olyan kontextusokban, ahol a letisztultabb elemzések az alapvető összefüggések feltárását célozzák. Az UTAUT2 alkalmazása bonyolultságából fakadóan akár még hátrányt is jelenthet, amint azt a modell parszimónia szempontjából történő értékelése is mutatja (*Tamilmani et al., 2021*). Ezenkívül az UTAUT2-t elsődlegesen azon szituációk elemzésére fejlesztették ki, ahol a fogyasztói, fogyasztási aspektusok hangsúlyosnak tekinthetők, így a modell olyan tényezőket is magában foglal, mint a hedonista motiváció, illetve az ár-érték, amelyek relevanciája alapvetően nem kereskedelmi kontextusokban megkérdőjelezhető. Ezt bizonyítja *Syamsudin és szerzőtársai (2018)* közszolgáltatások terén végzett kutatása is. Eredményeik azt mutatják, hogy az alapmodell diverzifikációját célzó új modellelemek – mint a hedonista motiváció – kevésbé értelmezhetők a közszolgáltatások igénybevételekor használható technológiák vonatkozásában, ezen változók gyakorta módosításra szorulnak. Tekintettel arra, hogy a felsőoktatási szektor is alapvetően egy nem kereskedelmi kontextusként értelmezhető, kijelenthetjük, hogy a területen végzett technológiaelfogadási vizsgálatok esetében az UTAUT2 bizonyos konstrukciói nem relevánsak. Mindezeket túl *Or (2023)* arra is felhívja a figyelmet, hogy számos esetben az UTAUT2-modell oktatási területen történő alkalmazása nem eredményesebb az UTAUT-modellénél, legalábbis a használati szándék és a tényleges használat közötti variancia magyarázatában. Ez tulajdonképpen azt jelenti, hogy bizonyos oktatási kontextusokat vizsgálva az UTAUT hatékonysága megegyezik az UTAUT2-modell eredményességével, vagy akár meg is haladja azt.

2. A kutatás hipotézisei és konceptuális modellje

A kutatás keretein belül vizsgált hipotéziseink meghatározásakor elsősorban olyan tanulmányok eredményeire építettünk, amelyek különböző oktatási kontextusokban vizsgálták valamely technológia (pl. e-learning-rendszerek, mobilalapú tanulás, interaktív táblák) elfogadottságát.

(H1) Az elvárt teljesítmény (PE) pozitívan befolyásolja az egyetemi hallgatók mesterséges intelligenciával kapcsolatos használati szándékát (BI).

Feltételezzük, hogy a mesterséges intelligencia teljesítményére vonatkozó hallgatói elvárások kedvező hatást fejtenek ki az MI-technológiával kapcsolatos használati szándékra, azaz minél hasznosabbnak tartják a hallgatók az MI-eszközöket, az általuk nyújtott szolgáltatásokat, annál nyitottabbak lesznek azok elfogadására, használatára tanulmányaik során. Az elvárt teljesítmény és a használati szándék közötti erős pozitív kapcsolatot a felsőoktatásban alkalmazható technológiák vonatkozásában már több korábbi tanulmány is megerősítette (Xue et al., 2024). Például az interaktív táblák (Wong et al., 2013) és a mobilalapú tanulás (Khan et al., 2022) esetében egyértelműen kijelenthető, hogy az adott technológia teljesítményével kapcsolatos elvárások szignifikánsan befolyásolják a hallgatói (és az oktatói) szándékot azok adaptálására.

(H2) A technológia használatával járó várható szükséges erőfeszítés (EE) pozitív hatást gyakorol az MI-eszközökkel kapcsolatos használati szándékra (BI) a hallgatók körében.

A várható erőfeszítés és a használati szándék között általánosságban véve pozitív kapcsolatot feltételezhetünk, ugyanakkor a szakirodalmak alapján ezek erőssége meglehetősen kontextusfüggő. Míg bizonyos esetekben közepesen erős szignifikanciát azonosíthatunk (Ali et al., 2024), addig más kutatások elhanyagolható hatást állapítanak meg (Bacuna–Castro, 2023) a várható erőfeszítés és a használati szándék között.

(H3) A társadalmi befolyásolás (SI) pozitív hatással van a mesterséges intelligenciával kapcsolatos hallgatói használati szándékra (BI).

A hallgatók társadalmi környezetének mesterséges intelligenciával kapcsolatos elképzelései, elvárásai feltételezésünk szerint pozitívan befolyásolják a használati szándékot. Ezt több, az oktatás területén végzett technológiaelfogadási vizsgálat is alátámasztja. Ugyanakkor a különböző kutatásokban eltérő hatást tulajdonítanak a társadalmi befolyásolásnak a használati szándék vonatkozásában. Haripin és Warsono (2024) egy e-learning-platform elfogadását vizsgálta, eredményeik szignifikáns kapcsolatot mutattak a társadalmi befolyásolás és a használati szándék között. Ezzel szemben Bacuna és Castro (2023) Google Classroom-használatra vonat-

kozó kutatása szerint a társadalmi befolyásolás használati szándékra gyakorolt hatása elhanyagolható. Mindez arra enged következtetni, hogy a társadalmi háló hatása egyrésztől az adott oktatási kontextustól, másrészt pedig a vizsgált technológiától függ.

(H4) A segítő feltételek (FC) pozitívan hatnak a hallgatók mesterséges intelligenciával kapcsolatos használati szándékára (BI).

A mesterséges intelligencia használatához szükséges erőforrások, a tudás, illetőleg a potenciális segítség elérhetősége közvetlenül támogatja a hallgatók használati szándékát. Feltételezésünket több tanulmány is alátámasztja, hangsúlyozva, hogy a szükséges erőforrások és a támogatás hozzáférhetősége kiemelt jelentőséggel bír bizonyos technológiák elfogadottságának megalapozásában (Bacuna–Castro, 2023). Ugyanakkor vannak olyan helyzetek, amikor ez a pozitív hatás nem tekinthető szignifikánsnak (Ali et al., 2024).

(H5) A segítő feltételek (FC) közvetlen pozitív hatást fejtenek ki a hallgatók tényleges MI-használatára (UB).


A segítő feltételek megléte támogatja a hallgatók tényleges mesterségesintelligencia-használatát. Ez azt jelenti, hogy amennyiben a hallgatók azt érzik, hogy rendelkezésükre állnak a szükséges erőforrások és igényelt támogatások, akkor nagyobb valószínűséggel döntenek majd a mesterséges intelligencia aktív használata mellett. Ez a kapcsolat számos tanulmányban következetesen megfigyelhető (Awwad–Al-Majali, 2015; Khechine–Augier, 2019). Érdekes módon ezzel ellentétes eredmények is napvilágot láttak. Alblooshi és Hamid (2021) negatív kapcsolatot állapított meg a hallgatók e-learning-rendszer-használata és a segítő feltételek között. Eredményeik arra engednek következtetni, hogy pusztán az operatív, illetve a technikai erőforrások biztosítása nem elégséges a tényleges használati magatartás kialakításához abban az esetben, ha az adott feltételek nem reflektálnak a hallgatók tényleges egyedi igényeire, és nem igazodnak a meglévő kompetenciáikhoz, tapasztalataikhoz.

(H6) A hallgatók MI-vel kapcsolatos használati szándéka (BI) pozitívan befolyásolja a tényleges használatot (UB).

Számos tanulmány megerősíti a használati szándék és a tényleges használat közötti erős pozitív kapcsolatot. Például a Covid19-járvány idején alkalmazott tanulásmenedzsment-rendszerek (LMS) kontextusában a használati szándék jelentős hatást gyakorolt a technológia tényleges használatára (Ahmed et al., 2021). Hasonlóképpen, a diákok infokommunikációs, azaz IKT-eszközök használatára irányuló szándéka erősen befolyásolta a tényleges használati viselkedésüket (Attuquayefio, 2022). Ez a kapcsolat nyilvánvaló volt az online oktatással és az e-learninggel foglalkozó tanulmányokban is, ahol szintén a használati szándék tényleges használatra gyakorolt pozitív hatását azonosították (Tahir, 2023; Zulfakar et al., 2023).

A fent részletezett hipotézisek összegzéseként az alábbi elméleti modellt alkottuk meg (1. ábra). A modell a vizsgálatba bevont mérési modelleket (manifeszt és látens változókat) és az egyes konstrukciók közötti kapcsolatokat egyaránt szemlélteti. A látens változókat az ellipszisek, a hozzájuk tartozó manifeszt változókat vagy mérési indikátorokat téglalapok jelölik. A konstrukciók közötti kapcsolatokat, illetőleg a vonatkozó hipotéziseket a változók közötti nyílak szemléltetik.

1. ábra



Forrás: saját szerkesztés.

A felállított modell struktúrájában követi a Venkatesh és szerzőtársai (2003) által megalkotott technológiaelfogadás és -használat egységesített elméletének vázát. A modell függő változója a tényleges használat (UB), amelyet közvetlenül csak a moderáló változó (a használati szándék, BI), illetőleg egy független változó (elősegítő feltételek, FC) befolyásol. A mesterséges intelligencia fogyasztói elfogadására, valamint a használati szándék kialakulására négy független változó van hatással, ezek a funkcionális elemek (elvárt teljesítmény, PE és a várható szükség erőfeszítés, EE), valamint a kontextuális tényezők (társadalmi befolyásolás, SI

és a segítő feltételek, FC). A modellel szemben támasztott elvárás, hogy a felvázolt modellváltozók mentén sematizálja és elemezze a hallgatók MI-használati szándékát, azonosítsa az egyes konstrukciók közötti hatásmechanizmusokat, illetve ezek szignifikanciáját.

3. Módszertan

3.1. Alkalmazott kutatási módszer és minta

A kutatás során keresztmetszeti vizsgálatot végeztünk a jelenleg felsőoktatási tanulmányokat folytató hallgatók körében. A válaszadókat a közösségi média különböző platformjainak segítségével kontaktáltuk és invitáltuk a kérdőíves felmérésben való részvételre. Az adatgyűjtés 2024 szeptembere és novembere között történt, a kéthónapos időintervallum alatt összesen 511 ember töltötte ki a kérdőívet. A reprezentativitás biztosítására elsődlegesen nem és kor szerint törekedtünk. Mintavételi keret nem állt rendelkezésünkre, az alkalmazott mintavételi technika nem véletlen, hanem kvótás. Az adattisztítást egy többlépcsős folyamat mentén valósítottuk meg. Mindenekelőtt a nyers adatokból kiszűrtük azokat a válaszokat, amelyek adott kérdések értelmezési tartományain kívül estek (18 rekord), illetve a kérdőívbe integrált figyelemtesztet sikertelenül teljesítették (2 rekord). Az érdektelen válaszadások (*unengaged responses*, olyan kitöltések, amelyek figyelmetlenségről, az érdeklődés hiányáról tanúskodnak) kiszűrése érdekében megvizsgáltuk a válaszadások szórását is, és azokat a válaszokat töröltük, ahol $s = 0$ (16 rekord), $s < 0,45$ (10 rekord) és $s > 1,55$ (17 rekord). Ezt követően olyan logikai hibákat kerestünk, amelyek szintén érvénytelen kitöltéseket jelenthetnek. Egy olyan rekordot azonosítottunk, ahol a megadott kor (18–19 év) és a képzési típus (PhD) egymást kizáró válaszadásoknak tekinthetők, így ezt a kitöltést is érvénytelennek tekintettük (bár a 0,45 alatti szórás miatt a rekord alapvetően is törlendőnek számított). A duplikátumokat az SPSS segítségével azonosítottuk (3 rekord), a kiugró értékek elemzését *Olkin és Sampson (2001)* alapján a többváltozós elemzések robusztus becslései esetén alkalmazható Mahalanobis-távolságteszt segítségével végeztük el (7 rekord). Az adattisztítást követően az adatbázis 438 elemet tartalmazott, a vonatkozó elemzések ezek figyelembevételével történtek. A statisztikai elemzéseket az SPSS programban végeztük el, míg a kutatás hipotéziseit a kovarianciaalapú strukturális egyenletek módszerével a SmartPLS 4 programban teszteltük. A módszertani választásunk alapvetően a nagy mintával, a többváltozós

normál eloszlással, a faktoralapú modellezéssel és az elmélettesztelési fókusszal magyarázható, tulajdonképpen ezen tényezők mentén döntöttünk a CB–SEM alkalmazása mellett a PLS–útelelemzés (*partial least squares structural equation modeling*, PLS–SEM) módszertanával szemben. A két útelemezési eljárással kapcsolatos szakirodalmi javaslatokat, iránymutatásokat az alábbi táblázatban összegezzük.

1. táblázat

A CB–SEM és a PLS–SEM módszertani összehasonlítása
Methodological comparison of CB–SEM and PLS–SEM

Kritérium	CB–SEM	PLS–SEM	Forrás
Mintanagyság	Nagymintás ($n \geq 100$) vizsgálatok	Kismintás vizsgálatok	<i>Aimran és szerzőtársai (2017), Mohamad és szerzőtársai (2019)</i>
Kutatás típusa	Megerősítő kutatás	Feltáró kutatás	<i>Afthanorhan és szerzőtársai (2020), Dash–Paul (2021), Mohamad és szerzőtársai (2019)</i>
Adatok eloszlása	Többváltozós normál eloszlás feltételeinek megfelelő	Nem felel meg a normál eloszlás feltételeinek	<i>Hair–Alamer (2022), Mohamad és szerzőtársai (2019)</i>
Modelltípus	Faktoralapú	Kompozitalapú	<i>Dash–Paul (2021)</i>
Fókusz	Elmélet tesztelés	Előrejelzés	<i>Dash–Paul (2021), Hair–Alamer (2022)</i>
Komplexitás	Kevésbé alkalmas komplex modellek elemzésére	Alkalmas komplex modellek elemzésére	<i>Hair–Alamer (2022)</i>

Forrás: saját szerkesztés.

A válaszadók demográfiai karakterisztikái az alábbiak szerint összegezhetők. A válaszadók 51,4%-a nő, 48,6%-a férfi. A megkérdezettek 100,0%-a a 18–25 éves korosztályba tartozik (átlagéletkor: 21 év, szórás: 1,68). Ami a lakhely szerinti megoszlást illeti, a válaszadók 21,5%-a faluban, 18,9%-a kisvárosban, 32,6%-a városban, 26,9%-a vármegyeszékhelyen él (fővárosi lakostól nem érkezett kitöltés). A képzési forma tekintetében az alábbi megoszlásokat azonosíthatjuk: a válaszadók 82,6%-a alapképzésben, 11,4%-a osztatlan képzésben, 1,1%-a mesterképzésben, 4,1%-a felsőoktatási szakképzésben, 0,7%-uk szakirányú, posztgraduális továbbképzésben tanul (doktori képzésben részt vevő hallgatóktól nem érkezett kitöltés). A kitöltők 75,6%-a használt már korábban valamilyen mesterséges intelligencia alapú eszközt, csupán 24,4%-uk adott nemleges választ a korábbi tapasztalatok azonosítására irányuló kérdésre. Ennek megfelelően célszerűnek ítéltük a tényleges használat (UB) mint modellkonstrukció megtartását, tekintve, hogy a válaszadások túlnyomó többségében releváns változóként azonosítható.

3.2. Mérési módszertan

A vizsgálatba bevont konstrukciókat (látens változókat) és a vonatkozó mérési indikátorokat (manifeszt változókat), valamint az alkalmazott kódokat a 2. táblázat összegzi. Az egyes mérési indikátorok meghatározásakor a *Venkatesh és szerzőtársai (2003)* által publikált modellelemeket vettük figyelembe, törekedve az egyes indikátorok felsőoktatási kontextusának megteremtésére. Az adatgyűjtés során a válaszadóknak többek között az alábbi táblázatban található 19 állítást kellett értékelniük egy ötfokú Likert-skálán egyetértésük függvényében. A skála két szélsőértékét az „1 = egyáltalán nem értek egyet” és az „5 = teljes mértékben egyetértek” válaszalternatívák jelentették.

2. táblázat

Konstrukciók és mérési indikátorok
Constructs and measurement items

Konstrukció	Mérési indikátor	Kód
Teljesítmény-elvárás (PE)	A mesterséges intelligencia hatékony segítség számomra tanulmányaim során.	PE1
	Az MI segítségével gyorsabban végzem el a feladatokat.	PE2
	A mesterséges intelligencia használata növelheti a teljesítményemet.	PE3
	Az MI használatával nőnek az esélyeim a jobb tanulmányi eredmények elérésére.	PE4
Várható erőfeszítés (EE)	A mesterséges intelligenciával lefolytatott interakció számomra egyszerű és egyértelmű.	EE1
	Könnyű megtanulnom az MI használatát és gyakorlottá válnom az alkalmazásában.	EE2
	Az MI használatát egyszerűnek tartom.	EE3
	Az MI kezelésének elsajátítása nem jelent számomra problémát.	EE4
Társadalmi befolyásolás (SI)	Azon személyek, akik befolyással vannak rám és a viselkedésemre, úgy gondolják, hogy használnom kellene a mesterséges intelligenciát.	SI1
	A számomra fontos emberek úgy gondolják, hogy használnom kellene a mesterséges intelligenciát.	SI2
Elősegítő feltételek (FC)	Rendelkezem a mesterséges intelligencia használatához szükséges erőforrásokkal.	FC1
	Rendelkezem a mesterséges intelligencia használatához szükséges tudással.	FC2
	A mesterséges intelligencia nem kompatibilis az általam használt egyéb eszközökkel.	FC3
	Vannak olyan ismerőseim, akik tudnának segíteni, ha nehézségekbe ütköznék az MI használatával kapcsolatban.	FC4
Használati szándék (BI)	Ha elérhető lenne számomra az MI, akkor mindenképp használnám.	BI1
	Ha elérhető lenne számomra az MI, úgy gondolom, hogy használnám.	BI2
	A jövőben tervezem használni a mesterséges intelligenciát.	BI3
Tényleges használat (UB)	Gyakran használok mesterséges intelligenciát tanulmányaimhoz, iskolai feladataim teljesítéséhez.	UB1
	Úgy érzem, a tanulmányaim során muszáj használnom az MI-t.	UB2

Forrás: saját szerkesztés.

A CB–SEM-vizsgálatot megelőzően feltáró faktorelemzés (*exploratory factor analysis*) segítségével validáltuk az egyes konstrukciók szerkezetét. Az ellenőrzés eredményeképp két indikátor (az EE1 és az FC4) törlésre került. Az EE1 esetében úgynevezett keresztterhelés (*cross-loading*) volt azonosítható, vagyis a változó nemcsak egy faktorhoz kapcsolódott egyértelműen, hanem két faktorról is összefüggést mutatott, ami jelentős mértékben rontja a faktorszerkezet tisztaságát. Az FC4-indikátor esetében az alacsony (0,327-es) faktorsúly volt a törlés oka. Mindezek alapján a végső elemzésbe, valamint értékelésbe 17 indikátort vontunk be.

4. Eredmények

4.1. Konvergencia- és diszkriminanciavalidálás

Mindenekelőtt modellünk validálását a konvergencia és a diszkriminancia szempontjainak értékelésével kezdtük. Az értékelés során a Fornell–Larcker-kritériumot (*Fornell–Larcker, 1981*) vettük figyelembe, amely szerint a konvergencia feltétele, hogy az átlagos magyarázott variancia (*average variance extracted, AVE*) meghaladja a 0,5-es értéket. Mindezeket túl *Hair (2006)* javaslatai alapján a konvergencia érvényességének megállapításához az is szükséges, hogy az AVE mellett a standardizált faktorsúlyok is 0,5-nél nagyobb értéket vegyenek fel, illetőleg a tényezőmegbízhatóság (*composite reliability, CR*) meghaladja a 0,7-es küszöbértéket. Ahogy az a 3. táblázatból is visszatükröződik, a megalkotott elméleti modellünk mindezen kritériumoknak rendre megfelel.

A felállított modell diszkriminanciaérvényessége kielégítő, tekintettel arra, hogy a korrelációs értékek egyike se haladta meg a 0,85-os küszöbértéket, ami *Henseler és szerzőtársai (2015)* alapján gyenge diszkriminanciavaliditásra engedne következtetni. A konstrukciók között azonosítható korrelációkat a 4. táblázat szemlélteti.

3. táblázat

Átlagok, szórások, konvergencia- és diszkriminanciamutatók összefoglaló táblázata
Summary table of averages, standard deviations, convergence and discriminant validity indicators

Konstrukció	Indikátor	Átlag	Szórás	Faktorsúly	Cronbach- α	AVE	CR
Teljesítményelvárás (PE)	PE1	3,68	1,142	0,784	0,899	0,689	0,896
	PE2	3,71	1,241	0,891			
	PE3	3,37	1,247	0,825			
	PE4	3,19	1,293	0,681			
Várható erőfeszítés (EE)	EE2	3,73	1,101	0,823	0,892	0,737	0,892
	EE3	3,76	1,042	0,921			
	EE4	3,68	1,088	0,728			
Társadalmi befolyásolás (SI)	SI1	2,22	1,127	0,821	0,844	0,733	0,847
	SI2	2,28	1,162	0,899			
Elősegítő feltételek (FC)	FC1	3,87	1,133	0,830	0,742	0,521	0,742
	FC2	3,39	1,139	0,715			
	FC3	3,38	1,304	0,586			
Használati szándék (BI)	BI1	3,50	1,271	1,038	0,917	0,883	0,715
	BI2	3,63	1,268	0,842			
	BI3	3,76	1,267	0,592			
Tényleges használat (UB)	UB1	2,89	1,327	0,837	0,785	0,686	0,804
	UB2	2,31	1,267	0,688			

Forrás: saját szerkesztés.

4. táblázat

Heterotrait-monotrait (HTMT) -aránymátrix
Heterotrait-monotrait (HTMT) ratio matrix

	BI	EE	FC	PE	SI	UB
BI						
EE	0,677					
FC	0,559	0,767				
PE	0,778	0,607	0,469			
SI	0,439	0,272	0,244	0,336		
UB	0,654	0,473	0,394	0,758	0,463	

Forrás: saját szerkesztés.

4.2. Megbízhatóság

A modell pontossága három megbízhatósági teszt segítségével értékelhető: Cronbach alpha (α), átlagos magyarázott variancia (AVE) és tényezőmegbízhatóság (CR). Megbízhatóságát tekintve egy mérési modell abban az esetben tekinthető elfogadhatónak, amennyiben a fentiekben nevesített három tényező szignifikáns, azaz $\alpha > 0,5$ (vagy ideális esetben 0,7), $AVE > 0,5$ (Fornell–Larcker, 1981), és $CR > 0,7$ (Malkanthie, 2015). Ahogy a 3. táblázatból leolvasható, minden konstrukció esetében 0,742-es vagy annál nagyobb Cronbach- α -értéket állapíthattunk meg, az AVE rendre meghaladja a 0,521-et, a tényezőmegbízhatóság (CR) pedig minden esetben nagyobb, mint 0,715. Az eredmények a mérési modell optimális megbízhatósági szintjére engednek következtetni.

4.3. Modellilleszkedés

Mindezekon túl a felállított modell abszolút és relatív illeszkedését is megvizsgáltuk. Az abszolút illeszkedés esetében a χ^2 -négyzet-próba 771,941-es értéket ($DF = 113$) adott $p < 0,001$ megfigyelt szignifikanciaszint mellett. Ezen felül a χ^2/df arány 6,831 volt. A további abszolút illeszkedési mutatók az alábbi értékeket vették fel: GFI: 0,825; AGFI: 0,763; RMSEA: 0,115; SRMR: 0,256.

A relatív illeszkedés vizsgálatakor az NFI-, a TLI- és a CFI-mutatót vettük figyelembe. Az NFI 0,85-os értéket vett fel, a TLI esetében 0,841-es értéket kaptunk, a CFI 0,868-es értéket adott.

Összességében a szakirodalmi ajánlások alapján (Byrne–St, 2010; Doğan, 2022; Heene et al., 2011; Lide et al., 2013; Mohammad–Yusoff, 2018) az illeszkedési mutatókat elfogadhatónak tartjuk. Mindezekon túl kijelenthető, hogy a modell megfelel a paraméterbecslések elemzésére és értelmezésére.

4.4. Hipotézisvizsgálat és becslések

A kovarianciaalapú strukturális modellt a korábban felvázolt hipotéziseink vizsgálatának, az egyetemi hallgatók mesterséges intelligenciával kapcsolatos használati szándéka mélyebb megértésének céljával alkalmaztuk. A hipotézisvizsgálat eredményeit a modellben mért nem standardizált és standardizált regressziós súlyokkal együtt az 5. táblázatban összegezzük. Abban az esetben, amikor a statisztikailag szignifikáns kapcsolat ($p < 0,05$) a predikált irányban megerősítést nyert, a vonatkozó hipotézist elfogadtuk.

5. táblázat

Nem standardizált és standardizált regressziós súlyok és hipotézisvizsgálat
Unstandardized and standardized regression weights and hypothesis testing


Hipotézis	Kapcsolat	Standardizálatlan				Standardizált regressziós súlyok	Eredmény
		regressziós súly	standard hiba	t	p		
H1	PE→BI	0,640	0,047	13,504	< 0,001	0,679	elfogadva
H2	EE→BI	0,308	0,056	5,501	< 0,001	0,306	elfogadva
H3	SI→BI	0,238	0,045	5,260	< 0,001	0,229	elfogadva
H4	FC→BI	0,113	0,057	1,972	0,051	0,110	elutasítva
H5	FC→UB	0,132	0,077	1,725	0,085	0,101	elutasítva
H6	BI→UB	0,724	0,058	12,419	< 0,001	0,570	elfogadva

Forrás: saját szerkesztés.

A kapott paraméterek stabilitásának biztosítása érdekében a bootstrapping-eljárást alkalmaztuk, ami az eredeti adatbázisból véletlenszerű mintákat generálva lehetővé teszi annak ellenőrzését, hogy a kapott paraméterbecslések mennyire érzékenyek az adatkészlet kismértékű változásaira, vagy stabilak. A H5-ös hipotézis esetében mind a primer, mind pedig a szekunder értékelés (bootstrapping-eljárás) alkalmazásával szignifikánsan magas p-értéket azonosítottunk, így a H5-ös hipotézis egyértelmű elutasítása mellett döntöttünk. A primer elemzés során a H4-es hipotézis esetében a 0,05-os határtértékhez rendkívül közeli p-értéket kaptunk, ami alapján a H4-es hipotézis elutasítandó. A bootstrapping-eljárást követően megerősítést nyert, hogy a H4-es hipotézisben megfogalmazott kapcsolat nem szignifikáns, hiszen a szekunder vizsgálat során $p = 0,123$ -es értéket vett fel (H5: $p = 0,206$, míg H1; H2; H3; H6: $p < 0,001$).

A 2. ábra a standardizált becsléseket és a faktorsúlyokat tartalmazza, továbbá szemlélteti az egyes modellkonstrukciók és a megfigyelt indikátorok közötti kapcsolatokat, illetve a modell korrekciós tényezőit is.

2. ábra



5. Diszkusszió

Az alábbiakban összegezzük és értékeljük a hipotézisvizsgálat eredményeit.

Mindenekelőtt azt feltételeztük, hogy a hallgatók mesterséges intelligenciával kapcsolatos teljesítményelvárásai pozitív hatást gyakorolnak a technológiára vonatkozó használati szándékukra (H1). Ezt a hipotézist elfogadtuk ($\beta = 0,679$, $p < 0,001$), ami egyben megerősíti, hogy az egyetemi hallgatók esetében az MI-technológia használatától remélt teljesítménynövekedés szignifikáns szerepet játszik a használati szándék kialakulásában. Más szóval, minél hasznosabbnak tartanak egy adott MI-eszközt a hallgatók, annál valószínűbb, hogy alkalmazni is fogják azt a tanulmányaik során. Ez hangsúlyozza az MI előnyeire fókuszáló explicit kommunikáció fontosságát a technológia elfogadásának növelése érdekében. Az eredmények alapvetően párhuzamba állíthatók a korábban publikált tudományos eredményekkel. A különböző oktatási kontextusokban elvégzett vizsgálatok

során az elvárt teljesítmény következetesen jelentős prediktornak bizonyult egy adott technológiához (akár interaktív táblákhoz vagy online tanulási platformokhoz) kapcsolódó használati szándék kialakulásában (*Wong et al., 2013; Yudiant-maja et al., 2022*). A tanulmányok továbbá az elvárt teljesítmény és a használati szándék közötti pozitív korrelációt is több ízben megerősítik (*Basak et al., 2018; Xue et al., 2024*).

Második hipotézisünk szerint (H2) a várt erőfeszítés és a használati szándék között pozitív kapcsolat van. A kapott eredményekre tekintettel ez a hipotézis is elfogadható ($\beta = 0,306$, $p < 0,001$). Mindezek alapján kijelenthető, hogy minél gördülékenyebbnek érzik a hallgatók a mesterséges intelligenciával lefolytatott interakciót, minél könnyebbnek vélik az MI-technológiák működtetéséhez szükséges tudás elsajátítását vagy épp a konkrét használatot, annál nagyobb valószínűséggel fogják használni az adott eszközt. Ez tulajdonképpen a felhasználóbarát kezelőfelületek és az egyszerűbb hozzáférés fontosságát domborítja ki. A várt erőfeszítés és a használati szándék közötti pozitív kapcsolat több kutatásban is megerősítést nyert az oktatás területén alkalmazható technológiákkal kapcsolatban. *Chao (2019)*, illetve *Shaya és szerzőtársai (2023)* kutatásukban a mobilalapú tanulás elfogadottságát vizsgálták, eredményeik alapján pedig szignifikáns pozitív kapcsolatot azonosítottak a várt erőfeszítés és a használati szándék között. Hasonló eredményeket mutatnak az IKT-eszközökre (*Rosaline–Wesley, 2017*), valamint a VR-szemüvegekre (*Shen et al., 2017*) fókuszáló adaptációs vizsgálatok is.

Harmadik hipotézisünkben (H3) a társadalmi befolyásolás és a használati szándék között vázoltunk fel pozitív kapcsolatot. Az elemzést követően ezt a hipotézist is elfogadhatónak tartjuk ($\beta = 0,229$, $p < 0,001$). Ez arra enged következtetni, hogy a hallgatók számára fontos referenciacsoportok – a család, a barátok vagy egyéb ismerősök – visszajelzései pozitívan befolyásolják a hallgatók azon szándékát, hogy mesterséges intelligenciát alkalmazzanak a különböző, tanulmányukhoz köthető feladatok elvégzésekor. Ez azt is sugallja, hogy a társadalmi támogatás, illetőleg a megerősítő kortársi hatás segíthetnek az MI-adaptáció előmozdításában. A témában íródott tanulmányok többsége azonos következtetésre jut a társadalmi befolyásolás és a használati szándék közötti kapcsolat vonatkozásában, valamely technológia oktatási környezetben vagy tanulmányok során történő alkalmazását illetően. Egy tajvani kutatás például a hallgatók körében vizsgálta az e-learning-rendszerrel kapcsolatos magatartásokat, szokásokat, az eredmények alapján a társadalmi hatás és a használati szándék között pozitív kapcsolatot állapítottak meg (*Liao et al., 2011*). Az összefüggést *Haripin és Warsono (2024)* is megerősíti, akik szintén az e-learning-rendszerek elfogadottságát vizsgálták az UTAUT-modell segítségével.

Negyedik hipotézisünkben (H4) pozitív kapcsolatot feltételeztünk a segítő feltevések és a használati szándék között. A kapott eredmények alapján ezt a hipotézist

el kellett vetnünk ($\beta = 0,110$, $p = 0,051$). A gyenge kapcsolat és a magas szignifikanciaszint azt jelzi, hogy nincs szignifikáns kapcsolat az elősegítő feltételek (pl. infrastruktúra, támogatás) és a használati szándék között. Bár a segítő feltételek szerepe alapvetően nem elhanyagolható, úgy tűnik, nem játszanak kulcsszerepet a hallgatók MI-re irányuló használati szándékának kialakításában. Eredményeinkkel ellentétben azon kutatások túlnyomó többsége, amelyek az oktatás területén elemzik egy adott technológia elfogadottságát, általánosságban a támogató feltételek és a használati szándék közötti erőteljes pozitív kapcsolatot erősítik meg. Példaként szolgálhatnak a felsőoktatási intézményekben egyre inkább elterjedő e-learning-rendszerek vizsgálatára fókuszáló kutatások megállapításai, amelyek az elősegítő feltételek (vagyis a személyi és eszközjellegű infrastrukturális ellátottság) és a használati szándék között szignifikáns pozitív kapcsolatot azonosítottak (*Alblooshi–Abdul Hamid, 2021; Nain, 2021*). Elszórtan bár, de vannak olyan kutatási eredmények is, amelyek a jelen tanulmányhoz hasonlóan pozitív kapcsolatot tulajdonítanak az elősegítő feltételek és a használati szándék relációjának, ugyanakkor a hatást elhanyagolhatónak tekintik. Ennek megfelelő eredményeket közöltek például *Maita és szerzőtársai (2018)* is: az akadémiai információs rendszerek elfogadottságát vizsgálták, és az elősegítő feltételek és a használati szándék kapcsolatát illetően *Shah és szerzőtársai (2024)* is azonos eredményekre jutottak. Az elősegítő feltételek és a használati szándék közötti elhanyagolható kapcsolat magyarázatának alapvetően három potenciális irányát látjuk. Egyrészt az azonosított kapcsolat utalhat arra, hogy a technológiahasználathoz szükséges alapfeltételek alapvetően már a hallgatók rendelkezésére állnak, vagyis az egyetemen elérhetőek az MI-eszközök működtetéséhez szükséges technikai feltételek (wifi, számítógép, szoftverek), így ezek nem számítanak kiemelkedő motivációs tényezőknél a hallgatók számára. Tulajdonképpen ez azt is jelenti, hogy a különböző infrastrukturális feltételek meglétét a hallgatók magától értetődőnek tekintik, és azokat nem kapcsolják közvetlenül össze a technológiára vonatkozó használati szándékukkal. Másrészt a gyenge kapcsolatot magyarázhatja a rendelkezésre álló erőforrásokra vonatkozó alacsony tudatosság is. Előfordulhat az is, hogy a hallgatók nincsenek tisztában azzal, hogy milyen erőforrások érhetők el számukra az egyetemen belül (pl. AI-laborok vagy szoftverlicencek). Ennek elsődleges oka feltételezhetően az, hogy az MI-hez kapcsolódó erőforrások, illetőleg azok szerepe nem kap elég hangsúlyt az egyetem kommunikációjában. Harmadrészt a használati szándék és az elősegítő feltételek közötti gyenge kapcsolat magyarázata lehet az is, hogy a hallgatók nem érzik magukat elég felkészültnek az MI-eszközök használatára, ilyenformán a segítő feltételek megléte önmagában nem jelent elég ösztönző erőt. Más szóval, az MI-hez kapcsolódó előzetes technikai készségek hiánya önmagában akadályozhatja a használati szándék kialakulását.

Ötödik hipotézisünkben (H5) az elősegítő feltételek és a tényleges használat között feltételeztünk közvetlen pozitív kapcsolatot, amelyet a kapott eredményeink nem támasztottak alá ($\beta = 0,101$, $p = 0,085$). Mindezek alapján arra következtethetünk, hogy felsőoktatási kontextusban a mesterséges intelligencia működtetéséhez szükséges infrastrukturális ellátottság, illetve egyéb fontos, szellemi és technikai erőforrások megléte nem szignifikáns tényező a technológiára vonatkozó használati szándék, illetőleg tényleges használati magatartás kialakításában. Ez alapvetően eltér a területen végzett kutatások általános eredményeitől. A legtöbb tanulmány szerint ugyanis a támogató feltételek szignifikáns, pozitív kapcsolatban állnak a tényleges használattal. Például a támogató feltételek kedvezően befolyásolják az online oktatási gyakorlatok elsajátítását (Tahir, 2023). Ugyanakkor Handoko (2019) azt találta, hogy az online tanulási programokban részt vevő hallgatók esetében a támogató feltételek nem gyakorolnak hatást a tényleges használatra. Egy másik kutatás szerint a támogató feltételek kizárólag közvetett módon, a használati szándékon keresztül befolyásolják a tényleges használatot, nem pedig közvetlen kapcsolat révén (Kuciapski, 2016). Az elősegítő feltételek és a tényleges használat között azonosított gyenge kapcsolat meglátásunk szerint az alábbiakkal magyarázható. Egyrészt az eredményekből levonhatjuk azt a konzekvenciát, hogy a tényleges használat kialakításában elsődlegesen a motivációs tényezők (pszichológiai és társadalmi befolyások) dominálnak az infrastrukturális feltételekkel szemben, vagyis a hallgatók döntéseit leginkább az eszköz hasznosságáról alkotott véleményük (elvárt teljesítmény, H1) és a használat egyszerűsége (H2) irányítja. A gyenge kapcsolatot magyarázhatja továbbá a rendelkezésre álló erőforrások alacsony kihasználtsága is. Elképzelhető, hogy bár a szükséges erőforrások elérhetőek a hallgatók számára, nem használják ki őket optimálisan, nem élnek az általuk nyújtott lehetőségekkel – kiváltképp, ha nem látják az eszközhasználatból származó közvetlen előnyöket. Ez például akkor fordulhat elő, ha a hallgatók nem kapják meg azt az elegendő iránymutatást vagy kellő gyakorlatias támogatást, amely a technológiahasználat explicit előnyeit hangsúlyozná. Mindezekon túl a hallgatók önállósága, az intézménytől való függetlensége is magyarázatul szolgálhat az elősegítő feltételek és a tényleges használat közötti gyenge kapcsolatra. Ez az önállóság elsősorban abban jelenik meg, hogy a hallgatók saját tanulási stratégiákat alkalmaz(hat)nak, és nem érzik annak szükségét, hogy az egyetemi infrastruktúrára támaszkodjanak. Ezt támogatja többek között az is, hogy az MI használatához szükséges eszközök egy része a hallgatók személyes eszközein (pl. laptop, okostelefon) is elérhető, és ez tovább csökkenti az egyetemi infrastruktúrától való függőség mértékét.

Végezetül hatodik hipotézisünkben (H6) a hallgatók mesterséges intelligenciára irányuló használati szándéka, valamint a tényleges MI-használat közötti pozitív kapcsolatot fogalmaztuk meg. A hipotézist elfogadtuk ($\beta = 0,570$, $p < 0,001$),

ami egyben megerősíti azon állítást, hogy azok az egyetemi hallgatók, akik alapvetően nyitottak a mesterséges intelligencia használatára, nagyobb valószínűséggel fogják ténylegesen is alkalmazni azt tanulmányaik során. Egy adott technológia oktatási kontextusban történő alkalmazására vonatkozó használati szándék és a tényleges használat közötti pozitív kapcsolatot több tanulmány is alátámasztja. Az online oktatás terén végzett technológiaelfogadási tanulmányok arra utalnak, hogy a használati szándék és a tényleges használat között erőteljes pozitív kapcsolat azonosítható (*Tahir, 2023*). Ezenkívül *Awwad és Al-Majali (2015)* a jordániai egyetemek elektronikus könyvtári szolgáltatásai kapcsán is megállapították, hogy a tényleges használatot (a támogató feltételek mellett) a használati szándék határozza meg.

Összefoglalva megállapítható, hogy az egyetemi hallgatók (elsődlegesen tanulmányi célú) mesterségesintelligencia-használatának legfontosabb előrejelzői a személyes percepciók, nevezetesen a hasznosság (elvárt teljesítmény) és a könnyű használat (várt erőfeszítés). Mindezekén túl a társadalmi befolyásolás is szerepet játszik a tényleges használati magatartás kialakításában, bár hatása az előbb ismertetett tényezőkhez képest mérsékelt. Ezzel szemben a technológia használatát elősegítő (személyi és eszközjellegű) infrastrukturális feltételek nem bizonyultak kulcsfontosságú tényezőknek a hallgatói használati szándék és a tényleges használat kialakulásában. A fent részletezett eredmények mélyebb megértése, valamint az esetleges intervenciók validálása érdekében további (elsődlegesen kvalitatív) vizsgálatok elvégzését látjuk szükségesnek.

6. Összegzés

A magyar egyetemi hallgatók körében végzett empirikus kutatás sikeresen azonosította azokat a tényezőket, amelyek a mesterséges intelligencia elfogadását és alkalmazását közvetlenül befolyásolják. Megállapítottuk, hogy a mesterséges intelligencia használatának legjelentősebb előrejelzői a személyes észlelések, különösen a teljesítményelvárás és a várható erőfeszítés. Emellett a társadalmi befolyás is hozzájárul a tényleges használati szándék alakításához, bár hatása viszonylag alacsony. Ezzel szemben az elősegítő feltételek – beleértve az emberi és az anyagi infrastruktúrát is – nem bizonyultak számottevőnek sem a használati szándék, sem a tényleges használat kialakulásában. Ez azt is jelenti, hogy bár az infrastrukturális rendelkezésre állás fontos, szerepük marginálisnak tekinthető az MI felsőoktatási alkalmazásának ösztönzésében.

A tanulmány tudományos hozzájárulásai ellenére bizonyos korlátokkal rendelkezik. Elsődleges korlátjaként azonosítható, hogy kizárólag a magyar egyetemi hallgatókra összpontosít, ami alapvetően szűkíti a más társadalmi csoportokra való általánosíthatóság lehetőségét. A jövőbeli kutatásoknak érdemes a különböző oktatási és kulturális kontextusokra is reflektálniuk. Bár a kvantitatív megközelítés megbízhatónak és megfelelőnek bizonyult a kutatás céljainak elérésében, a technológia elfogadását befolyásoló hatásmechanizmusok differenciáltabb megértését a kvalitatív módszerek alkalmazása tovább erősíthetné. A jövőbeli kutatások során az egyéni tényezőkön túlmenően érdemes olyan intézményi elemeket is figyelembe venni, mint az oktatók támogatása, a tantervtervezés és a digitális írástudással kapcsolatos kezdeményezések.

Az eredmények gyakorlati útmutatást kínálnak az egyetemek, a döntéshozók és a fejlesztők számára egyaránt. Meglátásunk szerint a felsőoktatási intézmények kiemelt feladata a mesterséges intelligencia előnyeivel kapcsolatos tudatosság erősítése, valamint olyan képzési programok kidolgozása, amelyek a hallgatók technológiahasználati nyitottságát és agilitását támogatják. A kortárs együttműködés ösztönzése és a mesterséges intelligencia tanulási feladatokba történő integrálása felerősítheti a társadalmi befolyás kedvező hatását, ami végső soron tovább fokozhatja az elfogadó magatartás kialakulását. Zárásként megállapítható, hogy a döntéshozók az MI-műveltség célzott fejlesztésének támogatásán, a fejlesztők pedig az intuitív, oktatási célú eszközök tervezésén keresztül teremthetnek kedvező feltételeket a technológia szélesebb körű adaptációjához.

Köszönetnyilvánítás

Jelen tanulmány a Kulturális és Innovációs Minisztérium Egyetemi Kutatói Ösztöndíj Programjának a Nemzeti Kutatási, Fejlesztési és Innovációs Alapból finanszírozott szakmai támogatásával készült.

Irodalom

- Afthanorhan, A. – Awang, Z. – Aimran, N. (2020): Five Common Mistakes for Using Partial Least Squares Path Modeling (PLS-PM) in Management Research. *Contemporary Management Research*, 16(4), 255–278. <https://doi.org/10.7903/cmr.20247>
- Ahmed, R. R. – Štreimikienė, D. – Štreimikis, J. (2021): The extended UTAUT model and learning management system during Covid-19: evidence from PLS-SEM and conditional process modeling. *Journal of Business Economics and Management*, 23(1), 82–104. <https://doi.org/10.3846/jbem.2021.15664>
- Aimran, A. N. – Ahmad, S. – Afthanorhan, A. – Awang, Z. (2017): *The assessment of the performance of covariance-based structural equation modeling and partial least square path modeling*. AIP Conference Proceedings, 1842(1). <https://doi.org/10.1063/1.4982839>

- Ajzen, I. (1985): From Intentions to Actions: A Theory of Planned Behaviour. In: Kuhl, J. – Beckmann, J. (eds.): *Action Control*, 11–39. Springer-Verlag Berlin, Heidelberg, New York, Tokyo. https://doi.org/10.1007/978-3-642-69746-3_2
- Ajzen, I. – Fishbein, M. (1980): *Understanding Attitudes and Predicting Social Behavior* (1st ed.). NJ: Pearson.
- Alateyyat, S. – Soltan, M. (2024): *Utilizing Artificial Intelligence in Higher Education: A Systematic Review*. 2024 ASU International Conference in Emerging Technologies for Sustainability and Intelligent Systems (ICETSYS), 371–374. <https://doi.org/10.1109/ICETSYS61505.2024.10459629>
- Alblooshi, S. – Abdul Hamid, N. A. B. (2021): The Role of Unified Theory of Acceptance and Use of Technology in E-Learning Adoption in Higher Education Institutions in the UAE. *IBIMA Business Review*, 1–16. <https://doi.org/10.5171/2021.730690>
- Aldraiweesh, A. A. – Alturki, U. (2025): The Influence of Social Support Theory on AI Acceptance: Examining Educational Support and Perceived Usefulness Using SEM Analysis. *IEEE Access*, 13, 18366–18385. <https://doi.org/10.1109/ACCESS.2025.3534099>
- Ali, I. – Warraich, N. F. – Butt, K. (2024): Acceptance and use of artificial intelligence and AI-based applications in education: A meta-analysis and future direction. *Information Development*, 02666669241257206. <https://doi.org/10.1177/02666669241257206>
- Alrayes, A. – Henari, T. F. – Ahmed, D. A. (2024): ChatGPT in Education – Understanding the Bahraini Academics Perspective. *Electronic Journal of E-Learning*, 22(2), 112–134. <https://doi.org/10.34190/ejel.22.2.3250>
- Attuquayefio, S. N. (2022): Information and Communication Technology (ICT) Adoption in Higher Education. *International Journal of Virtual and Personal Learning Environments*, 12(1), 1–21. <https://doi.org/10.4018/IJVPLE.295309>
- Awwad, M. S. – Al-Majali, S. M. (2015): Electronic library services acceptance and use: An empirical validation of unified theory of acceptance and use of technology. *The Electronic Library*, 33(6), 1100–1120. <https://doi.org/10.1108/EL-03-2014-0057>
- Bacuna, R. D. – Castro, E. T. (2023): *Acceptance of Google Classroom Technology among Students at Romblon State University-Cajidiocan Campus Using the Modified UTAUT Model*. 2023 3rd Asian Conference on Innovation in Technology (ASIANCON), 1–8. <https://doi.org/10.1109/ASIANCON58793.2023.10270575>
- Bandura, A. (1986): *Social Foundations of Thought and Action: A Social Cognitive Theory* (1). Prentice-Hall.
- Banytė, J. – Lindžiuvienė, J. – Dargytė, G. (2024): *What Factors Determine the Consumer Acceptance of AI-Based Services? The Case of Lithuanian Consumers*. 386, 137–154. https://doi.org/10.1007/978-981-97-1552-7_10
- Basak, S. K. – Wotto, M. – Belanger, P. (2018): *University Students' M-learning Adaption Behavioral Factors: A Pilot Study*. 2018 IEEE 9th Annual Information Technology, Electronics and Mobile Communication Conference (IEMCON), 68–73. <https://doi.org/10.1109/IEMCON.2018.8615084>
- Bengel, D. (2020): *Organizational Acceptance of Artificial Intelligence: Identification of AI Acceptance Factors Tailored to the German Financial Services Sector* (50). <https://doi.org/10.1007/978-3-658-30794-3>
- Bhati, J. – Sharma, S. – Gola, K. R. (2023): *Exploring Factors Behind E-Banking Adoption in India: A UTAUT Model Study*. 2023 9th International Conference on Advanced Computing and Communication Systems (ICACCS), 2450–2454. <https://doi.org/10.1109/ICACCS57279.2023.10113040>

- Byrne, B. M. – St, C. (2010): *Structural Equation Modeling With AMOS*. Routledge, New York.
- Capraro, V. – Lentsch, A. – Acemoglu, D. – Akgun, S. – Akhmedova, A. – Bilancini, E. – Bonnefon, J.-F. – Brañas-Garza, P. – Butera, L. – Douglas, K. M. – Everett, J. A. C. – Gigerenzer, G. – Greenhow, C. – Hashimoto, D. A. – Holt-Lunstad, J. – Jetten, J. – Johnson, S. – Kunz, W. H. – Longoni, C. – Viale, R. (2024): The impact of generative artificial intelligence on socioeconomic inequalities and policy making. *PNAS Nexus*, 3(6), 191. <https://doi.org/10.1093/pnasnexus/pgae191>
- Chao, C.-M. (2019): Factors Determining the Behavioral Intention to Use Mobile Learning: An Application and Extension of the UTAUT Model. *Frontiers in Psychology*, 10, 1652. <https://doi.org/10.3389/fpsyg.2019.01652>
- Chen, G. – Fan, J. – Azam, M. (2024): Exploring artificial intelligence (AI) chatbots adoption among research scholars using unified theory of acceptance and use of technology (UTAUT). *Journal of Librarianship and Information Science*. <https://doi.org/10.1177/09610006241269189>
- Cornelissen, L. – Egger, C. – van Beek, V. – Williamson, L. – Hommes, D. (2022): The Drivers of Acceptance of Artificial Intelligence–Powered Care Pathways among Medical Professionals: Web-Based Survey Study. *JMIR Formative Research*, 6(6). <https://doi.org/10.2196/33368>
- Dash, G. – Paul, J. (2021): CB–SEM vs PLS–SEM methods for research in social sciences and technology forecasting. *Technological Forecasting and Social Change*, 173, 121092. <https://doi.org/10.1016/j.techfore.2021.121092>
- Davis, F. D. (1986): *A Technology Acceptance Model for Empirical Testing New End-User Information System: Theory and Results* (Massachusetts Institute of Technology).
- Deci, E. L. – Ryan, R. M. (1985): *Intrinsic Motivation and Self-Determination in Human Behavior*. Springer US. <https://doi.org/10.1007/978-1-4899-2271-7>
- Doğan, İ. (2022): A simulation study comparing model fit measures of structural equation modeling with multivariate contaminated normal distribution. *Communications in Statistics – Simulation and Computation*, 51(5), 2526–2536. <https://doi.org/10.1080/03610918.2019.1698745>
- Fares, O. H. – Zhu, Q. – Lee, S. H. – Aversa, J. (2024): Consumers’ drivers of generative pre-trained transformer (GPT) conversational bot adoption. In: *Revolutionizing the Service Industry With OpenAI Models*, 114–145. <https://doi.org/10.4018/979-8-3693-1239-1.ch005>
- Ferk Savec, V. – Jedrinović, S. (2024): The Role of AI Implementation in Higher Education in Achieving the Sustainable Development Goals: A Case Study from Slovenia. *Sustainability*, 17(1), 183. <https://doi.org/10.3390/su17010183>
- Fok, W. W. T. – He, Y. S. – Yeung, H. H. A. – Law, K. Y. – Cheung, K. – Ai, Yy. – Ho, P. (2018): *Prediction model for students’ future development by deep learning and tensorflow artificial intelligence engine*. 2018 4th International Conference on Information Management (ICIM), 103–106. <https://doi.org/10.1109/INFOMAN.2018.8392818>
- Fornell, C. – Larcker, D. F. (1981): Evaluating Structural Equation Models with Unobservable Variables and Measurement Error. *Journal of Marketing Research*, 18(1), 39. <https://doi.org/10.2307/3151312>
- Fousiani, K. – Michelakis, G. – Minnigh, P. A. – De Jonge, K. M. M. (2024): Competitive organizational climate and artificial intelligence (AI) acceptance: The moderating role of leaders’ power construal. *Frontiers in Psychology*, 15. <https://doi.org/10.3389/fpsyg.2024.1359164>
- Grabowski, R. (2024): The Future of AI Ain’t What It Used To Be. *Design Engineering* (Canada), 69(1), 1.
- Gupta, K. P. – Manrai, R. – Goel, U. (2019): Factors influencing adoption of payments banks by Indian customers: Extending UTAUT with perceived credibility. *Journal of Asia Business Studies*, 13(2), 173–195. <https://doi.org/10.1108/JABS-07-2017-0111>

- Hair, J. – Alamer, A. (2022): Partial Least Squares Structural Equation Modeling (PLS-SEM) in second language and education research: Guidelines using an applied example. *Research Methods in Applied Linguistics*, 1(3), 100027. <https://doi.org/10.1016/j.rmal.2022.100027>
- Hair, J. F. (ed.). (2006): *Multivariate data analysis* (6th ed). Pearson Prentice Hall.
- Handoko, B. L. (2019): *Application of UTAUT Theory in Higher Education Online Learning*. Proceedings of the 2019 10th International Conference on E-Business, Management and Economics, 259–264. <https://doi.org/10.1145/3345035.3345047>
- Hao, Z. – Miao, E. – Yan, M. (2021): *Research on School Principals' Willingness to Adopt Artificial Intelligence Education and Related Influencing Factors*. Tenth International Conference of Educational Innovation through Technology (EITT), pp. 356–361. <https://doi.org/10.1109/EITT53287.2021.00076>
- Haripin, – Warsono, S. (2024): Analysis of the acceptance of E-learning platform (SIDEK-Edu) among high school students with UTAUT2-TOE approach: Implications for digital learning. *The International Journal of Information and Learning Technology*, 41(5), 585–600. <https://doi.org/10.1108/IJILT-03-2024-0051>
- Heene, M. – Hilbert, S. – Draxler, C. – Ziegler, M. – Bühner, M. (2011): Masking misfit in confirmatory factor analysis by increasing unique variances: A cautionary note on the usefulness of cutoff values of fit indices. *Psychological Methods*, 16(3), 319–336. <https://doi.org/10.1037/a0024917>
- Henseler, J. – Ringle, C. – Sarstedt, M. (2015): A New Criterion for Assessing Discriminant Validity in Variance-based Structural Equation Modeling. *Journal of the Academy of Marketing Science*, 43, 115–135. <https://doi.org/10.1007/s11747-014-0403-8>
- Ibrahim, F. – Münscher, J.-C. – Daseking, M. – Telle, N.-T. (2024): The technology acceptance model and adopter type analysis in the context of artificial intelligence. *Frontiers in Artificial Intelligence*, 7. <https://doi.org/10.3389/frai.2024.1496518>
- Ismatullaev, U. V. U. – Kim, S.-H. (2024): Review of the Factors Affecting Acceptance of AI-Infused Systems. *Human Factors*, 66(1), 126–144. <https://doi.org/10.1177/00187208211064707>
- Jewer, J. (2018): Patients' intention to use online postings of ED wait times: A modified UTAUT model. *International Journal of Medical Informatics*, 112, 34–39. <https://doi.org/10.1016/j.ijmedinf.2018.01.008>
- Jing, R. – Boyi, H. (2023): *Research on Adaptive Learning Model of Higher Vocational Education Under the Background of Artificial Intelligence*. 2023 3rd International Conference on Smart Generation Computing, Communication and Networking (SMART GENCON), 1–4. <https://doi.org/10.1109/SMARTGENCON60755.2023.10442081>
- Kelly, S. – Kaye, S.-A. – Oviedo-Trespalacios, O. (2023): What factors contribute to the acceptance of artificial intelligence? A systematic review. *Telematics and Informatics*, 77, 101925. <https://doi.org/10.1016/j.tele.2022.101925>
- Khan, F. M. – Singh, N. – Gupta, Y. – Kaur, J. – Banik, S. – Gupta, S. (2022): A Meta-analysis of Mobile Learning Adoption in Higher Education Based on Unified Theory of Acceptance and Use of Technology 3 (UTAUT3). *Vision: The Journal of Business Perspective*, 09722629221101159. <https://doi.org/10.1177/09722629221101159>
- Khechine, H. – Augier, M. (2019): *Adoption of a social learning platform in higher education: An extended UTAUT model implementation*. 53–62. <https://doi.org/10.24251/HICSS.2019.008>
- Kuciapski, M. (2016): Students Acceptance of m-Learning for Higher Education – UTAUT Model Validation. In: Wrycza, S. (ed.): *Information Systems: Development, Research, Applications, Education*, 155–166. Springer International Publishing. https://doi.org/10.1007/978-3-319-46642-2_11

- Lau, J. – Bonilla, J. L. – Gárate, A. (2019): Artificial Intelligence and Labor: Media and Information Competencies Opportunities for Higher Education. In: Kurbanoglu, S. – Špiranec, S. – Ünal, Y. – Boustany, J. – Huotari, M. L. – Grassian, E. – Mizrachi, D. – Roy, L. (eds.): *Information Literacy in Everyday Life*, 619–628. Springer International Publishing
https://doi.org/10.1007/978-3-030-13472-3_58
- Liao, P. W. – Yu, C. – Yi, C. C. (2011): Exploring Effect Factors of E-Learning Behavioral Intention on Cross-Level Analysis. *Advanced Materials Research*, 204–210, 174–177.
<https://doi.org/10.4028/www.scientific.net/AMR.204-210.174>
- Lide, N. – Mat Daud, N. – Shidrah, N. (2013): Interaction Between Writing Apprehension, Motivation, Attitude and Writing Performance: A Structural Equation Modeling Approach. *World Applied Sciences Journal*, 21 (Special Issue of Studies in Language Teaching and Learning): 102–108.
<https://doi.org/10.5829/idosi.wasj.2013.21.s1t1.2143>
- Lukianenko, D. – Simakhova, A. (2024): Artificial Intelligence in the Scientific and Technological Paradigm of Global Economy. *Problemy Ekorozwoju*, 19(2), 55–65.
<https://doi.org/10.35784/preko.6256>
- Maita, I. – Saide, Indrajit, R. E. – Irmayani, A. (2018): *User Behavior Analysis in Academic Information System Using Unified Theory of Acceptance and Use of Technology (UTAUT)*. Proceedings of the 2018 1st International Conference on Internet and E-Business, 223–228.
<https://doi.org/10.1145/3230348.3230351>
- Makarenko, O. – Borysenko, O. – Horokhivska, T. – Kozub, V. – Yaremenko, D. (2024): Embracing Artificial Intelligence in Education: Shaping the Learning Path for Future Professionals. *Multi-disciplinary Science Journal*, 6, 2024ss0720. <https://doi.org/10.31893/multiscience.2024ss0720>
- Malkanthe, A. (2015): *Structural Equation Modeling with AMOS*.
<https://doi.org/10.13140/RG.2.1.1960.4647>
- Mohamad, M. – Afthanorhan, A. – Awang, Z. – Mohammad, M. (2019). Comparison Between CB-SEM and PLS-SEM: Testing and Confirming the Maqasid Syariah Quality of Life Measurement Model. *The Journal of Social Sciences Research*, 53, 608–614.
<https://doi.org/10.32861/jssr.53.608.614>
- Mohammad, J. A. M. – Yusoff, M. S. B. (2018): Psychometric properties of the mentor behaviour scale in a sample of Malaysian medical students. *Journal of Taibah University Medical Sciences*, 13(1), 58–63. <https://doi.org/10.1016/j.jtumed.2017.04.005>
- Murdan, A. P. – Halkhoree, R. (2024): *Integration of Artificial Intelligence for educational excellence and innovation in higher education institutions*. 2024 1st International Conference on Smart Energy Systems and Artificial Intelligence (SESAT), 1–6.
<https://doi.org/10.1109/SESAT61023.2024.10599402>
- Mutlu, A. Y. (2024): *Users Acceptance of Generative Artificial Intelligence Based on ChatBot Use*. 9th International Conference on Computer Science and Engineering (UBMK), Antalya, Türkiye.
<https://doi.org/10.1109/UBMK63289.2024.10773553>
- Na, S. – Heo, S. – Han, S. – Shin, Y. – Roh, Y. (2022): Acceptance Model of Artificial Intelligence (AI)-Based Technologies in Construction Firms: Applying the Technology Acceptance Model (TAM) in Combination with the Technology–Organisation–Environment (TOE) Framework. *Buildings*, 12(2). <https://doi.org/10.3390/buildings12020090>
- Nain, H. (2021): *Understanding Students' Behavioural Intentions To Use Social Media Learning In Education: A Utaut Model Approach*. 2021 International Conference on Computational Performance Evaluation (ComPE), 256–261. <https://doi.org/10.1109/ComPE53109.2021.9752450>

- Naseer, F. – Khan, M. N. – Tahir, M. – Addas, A. – Aejaaz, S. M. H. (2024): Integrating deep learning techniques for personalized learning pathways in higher education. *Heliyon*, 10(11), e32628. <https://doi.org/10.1016/j.heliyon.2024.e32628>
- Nazri, I. S. B. M. – Rodzi, Z. M. – Razali, I. N. B. – Rahman, H. A. – Rahman, A. B. A. – Al-Sharqi, F. (2023): *Unraveling the Factors Influencing the Adoption of Artificial Intelligence (AI) in Education*. 186–193. <https://doi.org/10.1109/AiDAS60501.2023.10284698>
- Norzelan, N. A. – Mohamed, I. S. – Mohamad, M. (2024): Technology acceptance of artificial intelligence (AI) among heads of finance and accounting units in the shared service industry. *Technological Forecasting and Social Change*, 198. <https://doi.org/10.1016/j.techfore.2023.123022>
- Nurhasanah, F. – Nugraheni, A. S. C. – Kusharjanta, B. – Ardiansyah, R. – Widono, S. – Saddhono, K. (2024): *A Design of Virtual Classrooms Through AI, ML and DL to Improve the Level of Learning*. 4th International Conference on Advance Computing and Innovative Technologies in Engineering (ICACITE), 940–945. <https://doi.org/10.1109/ICACITE60783.2024.10616641>
- Olkin, I. – Sampson, A. R. (2001): Multivariate Analysis: Overview. In: Smelser, N. J. – Baltes, P. B. (eds.): *International Encyclopedia of the Social & Behavioral Sciences*, 10240–10247. Pergamon. <https://doi.org/10.1016/B0-08-043076-7/00472-1>
- Or, C. (2023). Examining Unified Theory of Acceptance and Use of Technology 2 through Meta-analytic Structural Equation Modelling. *Journal of Applied Learning & Teaching*, 6(2), 2. <https://doi.org/10.37074/jalt.2023.6.2.7>
- Rosaline, S. – Wesley, J. R. (2017): Factors Affecting Students' Adoption of ICT Tools in Higher Education Institutions: An Indian Context. *International Journal of Information and Communication Technology Education*, 13(2), 82–94. <https://doi.org/10.4018/IJICTE.2017040107>
- Sajja, R. – Sermet, Y. – Cikmaz, M. – Cwiertny, D. – Demir, I. (2024): Artificial Intelligence-Enabled Intelligent Assistant for Personalized and Adaptive Learning in Higher Education. *Information*, 15(10), 596. <https://doi.org/10.3390/info15100596>
- Saleem, N. – Mufti, T. – Sohail, S. S. – Madsen, D. Ø. (2024): ChatGPT as an innovative heutagogical tool in medical education. *Cogent Education*, 11(1), 2332850. <https://doi.org/10.1080/2331186X.2024.2332850>
- Sánchez-Holgado, P. – Arcila-Calderón, C. (2024): Adoption and use factors of artificial intelligence and big data by citizens. *Communication & Society*, 37(2), 227–246. <https://doi.org/10.15581/003.37.2.227-246>
- Schiavo, G. – Businaro, S. – Zancanaro, M. (2024): Comprehension, apprehension, and acceptance: Understanding the influence of literacy and anxiety on acceptance of artificial Intelligence. *Technology in Society*, 77. <https://doi.org/10.1016/j.techsoc.2024.102537>
- Schulz, P. J. – Lwin, M. O. – Kee, K. M. – Goh, W. W. B. – Lam, T. Y. T. – Sung, J. J. Y. (2023): Modeling the influence of attitudes, trust, and beliefs on endoscopists' acceptance of artificial intelligence applications in medical practice. *Frontiers in Public Health*, 11. <https://doi.org/10.3389/fpubh.2023.1301563>
- Shah, S. – Mehta, N. – Sunil, A. (2024): Investigation of e-learning adoption in higher education based on the unified theory of acceptance and use of technology model. *E-Learning and Digital Media*, 20427530241232493. <https://doi.org/10.1177/20427530241232493>
- Shaya, N. M. – Madani, R. A. – Mohebi, L. M. B. (2023): An Application and Extension of the UTAUT Model Factors Influencing Behavioral Intention to Utilize Mobile Learning in UAE Higher Education. *Journal of Interactive Learning Research*, 34(1), 153–180.
- Shen, C. – Ho, J. – Kuo, T-C. – Luong, T. H. (2017): *Behavioral Intention of Using Virtual Reality in Learning*. Proceedings of the 26th International Conference on World Wide Web Companion – WWW '17 Companion, 129–137. <https://doi.org/10.1145/3041021.3054152>

- Simeonova, B. – Bogolyubov, P. – Blagov, E. (2013): *Use and acceptance of learning platforms within universities*. Proceedings of the European Conference on Knowledge Management, ECKM, 2, 642–651.
- Sobti, N. (2019): Impact of demonetization on diffusion of mobile payment service in India: Antecedents of behavioral intention and adoption using extended UTAUT model. *Journal of Advances in Management Research*, 16(4), 472–497. <https://doi.org/10.1108/JAMR-09-2018-0086>
- Soomro, Y. A. (2019): Understanding the Adoption of SADAD E-Payments: UTAUT Combined with Religiosity as Moderator. *International Journal of E-Business Research*, 15(1), 55–74. <https://doi.org/10.4018/IJEER.2019010104>
- Sosaya-Rodríguez, L. R. – Zegarra-Arevalo, R. M. – Angeles-Quinones, N. A. – Jiménez-Vera, J. D. (2024): *El rol de la universidad en el desarrollo social de la ciencia y la tecnología en el siglo XXI*. <https://doi.org/10.5281/ZENODO.11114480>
- Syamsudin, Meiyanti, R. – Satria, D. – Wahyuni, R. – Sensuse, D. I. (2018). *Exploring Factors Influence Behavioral Intention to Use E-Government Services Using Unified Theory of Acceptance and Use of Technology 2 (UTAUT2)*. 2018 International Seminar on Research of Information Technology and Intelligent Systems (ISRITI), 237–242. <https://doi.org/10.1109/ISRITI.2018.8864474>
- Tahir, M. M. (2023): Students' Behavioural Intention towards Adoption of Online Education: A Study of the Extended UTAUT Model. *Journal of Learning for Development*, 10(3), 392–410. <https://doi.org/10.56059/jl4d.v10i3.949>
- Tamilmani, K. – Rana, N. P. – Wamba, S. F. – Dwivedi, R. (2021). The extended Unified Theory of Acceptance and Use of Technology (UTAUT2): A systematic literature review and theory evaluation. *International Journal of Information Management*, 57, 102269. <https://doi.org/10.1016/j.ijinfomgt.2020.102269>
- Téllez, R. A. – Ortiz, F. L. M. – Domínguez, F. C. T. (2024): Artificial Intelligence in University Administration: An Overview of its Uses and Applications. *Revista Interamericana de Bibliotecología*, 47(2). <https://doi.org/10.17533/udea.rib.v47n2e353620>
- Triandis, H. C. (1979): Values, attitudes, and interpersonal behavior. *Nebraska Symposium on Motivation*, 27, 195–259.
- Venkatesh, V. – Morris, G. M. – Davis, B. G. – Davis, D. F. (2003): User Acceptance of Information Technology: Toward a Unified View. *MIS Quarterly*, 27(3), 425. <https://doi.org/10.2307/30036540>
- Venkatesh, V. – Thong, L. Y. J. – Xu, X. (2012): Consumer Acceptance and Use of Information Technology: Extending the Unified Theory of Acceptance and Use of Technology. *MIS Quarterly*, 36(1), 1. <https://doi.org/10.2307/41410412>
- Venkatesh, V. – Bala, H. (2008): Technology Acceptance Model 3 and a Research Agenda on Interventions. *Decision Sciences*, 39(2), 2. <https://doi.org/10.1111/j.1540-5915.2008.00192.x>
- Venkatesh, V. – Thong, J. – Xu, X. (2016): Unified Theory of Acceptance and Use of Technology: A Synthesis and the Road Ahead. *Journal of the Association for Information Systems*, 17, 328–376. <https://doi.org/10.17705/1jais.00428>
- Wong, K-T. – Teo, T. – Russo, S. (2013): Interactive Whiteboard Acceptance: Applicability of the UTAUT Model to Student Teachers. *The Asia-Pacific Education Researcher*, 22(1), 1–10. <https://doi.org/10.1007/s40299-012-0001-9>
- Xue, L. – Rashid, A. M. – Ouyang, S. (2024): The Unified Theory of Acceptance and Use of Technology (UTAUT) in Higher Education: A Systematic Review. *Sage Open*, 14(1), 21582440241229570. <https://doi.org/10.1177/21582440241229570>

- Yudiatmaja, W. E. – Yoserizal, Y. – Edison, E. – Kristanti, D. – Tovalini, K. – Samnuzulsari, T. – Malek, J. A. (2022): Adoption of Online Learning in Indonesian Higher Education during the Covid-19 Pandemic. *Journal of Behavioral Science*, 17(2), 73–89.
- Zhang, L. – Pan, Y. – Wu, X. – Skibniewski, M. J. (2021): Introduction to Artificial Intelligence. In: Zhang, L. – Pan, Y. – Wu, X., – Skibniewski, M. J. (eds.): *Artificial Intelligence in Construction Engineering and Management*, 1–15. Springer Singapore.
https://doi.org/10.1007/978-981-16-2842-9_1
- Zulfakar, Z. A. – Rahim, F. A. – Hussain, N. H. C. – Ahmad, A. – Tat-Huei, C. – Aw, E. C-X. (2023): ZOOM-ing into a New Pedagogy: Permanent Adoption of Online Teaching and Learning in Private Higher Education Institution in Malaysia. In: Al-Sharafi, M. – Al-Emran, M. – Al-Kabi, N. – Shaalan, K. (eds.): *Proceedings of the 2nd International Conference on Emerging Technologies and Intelligent Systems. Lecture Notes in Networks and Systems*, 573.
https://doi.org/10.1007/978-3-031-20429-6_39