

<https://doi.org/10.17048/AM.2025.161>

**Dr. Pajtókné Csathó Erika**

## **A mesterséges intelligenciával támogatott tanulási analitika alkalmazása a kompetenciaalapú felsőoktatási gazdasági képzési gyakorlatban**

**Dr. Pajtókné Csathó Erika**

Eszterházy Károly Katolikus Egyetem

[erikacsatho@hotmail.com](mailto:erikacsatho@hotmail.com)

**Absztrakt:** A gazdasági felsőoktatás kompetenciaalapú megközelítését a tömegessé válás és a hallgatók heterogenitása új típusú kihívások elé állították. Az egyéni fejlődés nyomon követése és a lemorzsolódás megelőzése a korábbi gyakorlathoz képest jóval nagyobb hangsúlyt kapott. A tanulmány során az alkalmazott módszertanba a Learning Analytics és a mesterséges intelligencia integrálási lehetőségeit vizsgáljuk. A kutatás arra keresi a választ, hogy miként fordíthatóak le a digitális tanulási környezetekben keletkező aktivitási adatok pedagógiaiailag is értelmezhető információkká és specifikus kompetenciaelemekké.

A vizsgálat mixed-method megközelítést követ, azon belül is szekvenciális explanatory design-t alkalmaz. A kvantitatív, első szakaszban gépi tanulási algoritmusok segítségével a hallgatói sikertelenséget legpontosabban jelző prediktív indikátorok azonosítása történik. A vizsgálat kvalitatív részében félig strukturált interjúkkal tárjuk fel azt, hogy az oktatók miként értelmezik a vizuális dashboard-jelzéseket. A kutatás kiterjed arra is, hogy az érintettek milyen döntési mechanizmusok alapján választanak az automatizált visszacsatolás vagy a személyes mentorálás eszközei közül.

A remélt eredményeként létrejövő konceptuális modell összekapcsolja a nyers logadatokat a transzverzális kompetenciákkal, mint a precizitás vagy a stratégiai gondolkodás. A kutatás kitér arra is, hogy az adatvezérelt megoldások alkalmazása során az etikai megfontolások és az emberi kontroll megkerülhetetlenek. Az alkalmazott megközelítésben a mesterséges intelligencia nem önálló döntéshozóként kap szerepet, hanem egyfajta kontrollált döntéstámogató eszközként működik. A technológia feladata az oktatói munka segítése azáltal, hogy a hallgatói kompetenciák személyre szabott fejlesztéséhez nyújt háttérinformációkat, miközben az intézményi hatékonyság növeléséhez is hozzájárul. A rendszer alapelve, hogy a hallgatókat érintő érdemi kérdésekben a végső felelősség minden esetben az emberi döntéshozó kezében marad.

**Kulcsszavak:** tanulási analitika, mesterséges intelligencia, kompetenciaalapú oktatás, felsőoktatás, gazdasági képzés

## **The Application of AI-Supported Learning Analytics in Competency-Based Higher Education Business Training Practice**

**Abstract:** The competence-based approach in higher business education has been faced with new types of challenges due to massification and student heterogeneity. Tracking individual progress and preventing dropout have received significantly more emphasis than in previous practices. This study explores the possibilities of integrating Learning Analytics and Artificial Intelligence into the applied methodology. The research seeks to answer how activity data generated in digital learning environments can be translated into pedagogically interpretable information and specific competence elements.

The study follows a mixed-methods approach, specifically employing a sequential explanatory design. In the first, quantitative phase, machine learning algorithms are used to identify the predictive indicators that most accurately

signal student failure. The qualitative part of the study employs semi-structured interviews to explore how instructors interpret visual dashboard signals. The research also covers the decision-making mechanisms through which stakeholders choose between automated feedback or personal mentoring tools.

The resulting conceptual model aims to link raw log data with transversal competences, such as precision or strategic thinking. The research also addresses the fact that ethical considerations and human control are indispensable when applying data-driven solutions. In the applied approach, artificial intelligence does not function as an autonomous decision-maker but as a controlled decision-support tool. The role of technology is to assist faculty work by providing background information for the personalized development of student competences, while also contributing to institutional efficiency. The fundamental principle of the system is that final responsibility for substantive questions affecting students remains in the hands of the human decision-maker in all cases.

**Keywords:** learning analytics, artificial intelligence, competence-based education, higher education, business education

## **1 Bevezetés**

A felsőoktatásban az utóbbi időben kulcskérdéssé vált, hogyan tudjuk a kompetenciákat és a tanulási célokat valóban összehangolni. A kompetenciaalapú oktatás módszertani kihívása az, hogy nehéz objektív és megbízható módon mérni. A kompetenciák komplex, kontextusfüggő és többdimenziós fogalmak, ezért nem tudjuk standardizált mérőeszközökké alakítani anélkül, hogy sérülne validitásuk (Hermann, Kiss és Varga, 2022). Ezekre a kihívásokra nyújt egy megoldási eszközrendszert a Learning Analytics, melynek célja a tanulással kapcsolatos adatok gyűjtése, elemzése és értelmezése a tanulási eredmények optimalizálása érdekében (Siemens, 2013). A kompetenciaalapú oktatás, olyan pedagógiai célkitűzés, amelynek empirikus támogatását a tanulási analitika biztosíthatja az adatalapú döntéshozatal révén (Ferguson, 2012; Lang et al., 2017). A kutatás aktualitását a gazdasági képzések tömegessé válása adja. Az eltérő előképzettségű, motivációjú és szociális háttérű hallgatók támogatása összetett pedagógiai és szervezeti megoldásokat igényel, amelyekben a technológia fontos kiegészítő szerepet játszhat (Fehér, 2021; Papp-Danka, 2021). A Learning Analytics eszközei lehetővé teszik, hogy a lemorzsolódást ne utólagos statisztikai tényként kezeljük, hanem korán azonosítható, mérhető és befolyásolható folyamatként. A tanulmány abból a felismerésből indul ki, hogy a lemorzsolódás leggyakrabban nem egyetlen hirtelen döntés eredménye. A valóságban egy jól követhető folyamatról van szó, amely világos nyomot hagy a rendszerben: a csökkenő aktivitás, a gyengülő teljesítmény vagy a motivációvesztés mind olyan mérhető mintázatok, amelyek időben jelezhetik a bajt a digitális tanulási környezetben. Ebben a folyamatban a mesterséges intelligencia jelent előrelépést: míg a Learning Analytics leírja és értelmezi a tanulási folyamatokban megjelenő mintázatokat, az MI képes előre jelezni a várható kimeneteket és támogatni a beavatkozási döntéseket. Összefoglalva: a felsőoktatásban a mesterséges intelligencia a Learning Analytics prediktív és preskriptív kiterjesztéseként jelenik meg. A tanulmány azt vizsgálja, hogyan építhető be a mesterséges intelligencia és a tanulási analitika a kompetenciaalapú gazdasági képzésekbe. Arra keresem a választ, hogy az adatokra alapozott beavatkozások miként javíthatják a hallgatók bentmaradási esélyeit és tanulmányi sikerességét a pedagógiai szempontok és az etikai elvárások mellett.

## **2 A tanulási analitika, a kompetenciamérés és a gazdasági képzések sajátosságai**

### **2.1 A tanulási analitika és az MI pedagógiai szerepe**

A tanulási analitika fejlődése a technikai adatfeldolgozástól a pedagógiai is értelmezhető, majd az előrejelző (prediktív) és javaslattevő (preskriptív) alkalmazások felé haladt. A rendszerek leírják a tanulási folyamatokat és alkalmasak a hallgatói kockázatok korai felismerésére, valamint a célzott pedagógiai beavatkozások megalapozására is. Az alkalmazott megközelítésben a tanulási analitika technológiai eszköz és a tanulási folyamat

**ESZTERHÁZY KÁROLY KATOLIKUS EGYETEM**  
**INFORMATIKA KAR • DIGITÁLIS TECHNOLÓGIA INTÉZET**  
**AGRIA MÉDIA KONFERENCIA 2025**

pedagógiai értelmezésének és segítésének egyik meghatározó kerete. A felsőoktatásban mindez egyre inkább az adatvezérelt egyetem modellje felé mutat, amelyben az intézményi és tanulási adatok nemcsak adminisztratív nyilvántartásként és pedagógiai erőforrásként is hasznosíthatók. Ebben a környezetben a mesterséges intelligencia a tömegoktatás személyre szabásának egyik kulcsfontosságú eszköze. Az önszabályozó tanulás (SRL) a modern pedagógia és tanuláselmélet egyik fontos eleme. Az SRL egyszerű tanulási technika helyett több tényezőt összekapcsoló komplex folyamat, amely során a tanuló aktívan irányítja saját fejlődését kognitív, metakognitív, motivációs és viselkedési tényezők segítségével (Zimmerman, 2002; Pintrich, 2004). A folyamat lényege, hogy a tanuló tudatosan tervezi, figyelemmel kíséri és értékeli saját tevékenységét a hatékonyabb célérés érdekében. Itt kapcsolódik be a tanulási analitika, amely konkrét adatokkal és visszajelzésekkel segíti a tanulók önszabályozását. Másképpen fogalmazva: az SRL jelöli ki a pedagógiai célt, a tanulási analitika pedig az eszköz a cél eléréséhez. Fontos kiemelni, hogy az analitika nem hoz döntést a hallgató helyett, de segíti őt a tudatos választásokban azáltal, hogy egyfajta metakognitív tükörként szolgál. A mesterséges intelligencia ebben a rendszerben a tanulási analitika prediktív és preskriptív funkcióit teljesíti ki: feltárja a kockázati mintázatokat és előkészíti a konkrét segítségnyújtást is.

A Purdue University Course Signals rendszere vagy éppen a Georgia State University GPS Advising modellje is jól mutatja, hogy az adatvezérelt előrejelzésre épülő EWS-ek valóban javítják a hallgatói sikerességet. A nemzetközi gyakorlatok arra is rámutatnak, hogy az adatok érthető visszacsatolás és az emberi döntéshozatal nélkül nem elegendők. Ha a tanulási analitika és az MI az önszabályozó tanulószolgálat, szükségszerűen felmerül a kérdés: a tanulási folyamat során formálódó kompetenciák miként tehetők megbízhatóan mérhetővé?

## **2.2 Kompetenciamérés mint módszertani kihívás**

A kompetenciák mérése a modern pedagógia egyik módszertani kihívása, mivel ezek a konstrukciók a tudáselemeken túl készségekből és attitűdökből is állnak. A kompetencia mindig kontextusfüggő, vagyis a hallgató teljesítményét alapvetően meghatározza az adott szituáció és környezet. Emiatt a mérésük nem redukálható egyszerű, statikus mérőeszközökre validitásvesztés nélkül. Ez különösen igaz azoknál a kompetenciáknál, amelyek nem közvetlenül teljesítménypontszámokban, hanem érvelési, értékelési és döntési folyamatokban jelennek meg. Az MI-vel támogatott tanulási környezetek ugyanakkor lehetőséget teremthetnek arra, hogy a hallgatók ne pusztán válaszokat fogadjanak el, hanem azokat kritikailag értelmezzék, összevessék más forrásokkal és reflektált döntéseket hozzanak. A konklúzió nem a mérés egyszerűsítése, sokkal inkább a mérési módszerek hozzáigazítása a kompetenciákhoz.

A tanulási folyamat digitális környezetben történő követése azért jelent előrelépést, mert nem csupán a teljesítmény végpontját, hanem a tanulási tevékenység szerkezetét, ritmusát és mintázatait is láthatóvá teszi. Ez különösen fontos akkor, amikor a cél a tanulási stratégiák, az önmonitorozás vagy a problémamegoldás minőségének vizsgálata. Ebben a kontextusban a tanulási analitika, a kompetenciamérés empirikus támogatása, mivel a folyamat közben keletkező adatok alapján árnyaltabb képet adhat a hallgatói tanulásról. Az LA ezért különösen alkalmas lehet arra, hogy a hagyományos értékelési formákat kiegészítve hozzájáruljon a kompetenciák kontextusérzékenyebb és pedagógiai relevánsabb értelmezéséhez. Ehhez olyan mérési megoldásokra van szükség, mint a portfólióértékelés, a folyamatkövetés vagy az MI-alapú szövegelemzés, amelyek a gondolkodási folyamat összetettségét is képesek megragadni.

## **2.3 A gazdasági képzések sajátosságai és a releváns adatmintázatok**

A közgazdászképzésben a hallgatóknak egyszerre kell magas szintű kvantitatív analitikai készségekkel és komplex kvalitatív döntéshozatali képességekkel rendelkezniük. A digitális tanulási környezetben a hallgatók olyan adatokat generálnak, amelyek a kompetenciák értelmezéséhez is felhasználhatók. Ezek az adatok több szempontból eltérnek más tudományterületek tanulási logjaitól. Míg más képzési területeken a tanulási aktivitás elsősorban a tartalomfogyasztás vagy az egyéni teljesítmény lineáris előrehaladásában ragadható meg, a gazdasági

képzésekben a problémamegoldási útvonalak, a döntési elágazások és az elemzési stratégiák is kiemelt jelentőségűek. Az egyik legfontosabb adatforrást a kvantitatív feladatmegoldások időbélyegei és a megoldási folyamat szakaszai jelentik. Ebben a kontextusban nem kizárólag a végeredmény pontossága mérvadó, hanem a hibázási mintázatok. Ilyen hibázási mintázat lehet például, hogy a hallgató egy ökonometria modell építése során hányszor korrigálja alapfeltevéseit, vagy éppen milyen logikai sorrendben építi fel a megoldást. Az ilyen típusú adatok a tudás megléte mellett arról is árulkodnak, hogy a hallgató milyen stratégiával közelít a problémához, mennyire következetesen dolgozik, és hogyan reagál a hibákra.

Az esettanulmány-alapú feladatok során keletkező logadatok jól tükrözik a hallgatók stratégiai gondolkodásának folyamatát. Egy üzleti szimuláció során az MI képes rögzíteni a hallgató információkeresési stratégiáját, például azt, hogy megvizsgálja-e a piaci környezetet, mielőtt beruházási döntést hoz. A szekvenciális adatokból jól látszik, milyen lépésekben dolgozza fel a hallgató az információkat. Így követhető, hogyan jut el az adatok értelmezésétől az üzleti következtetésekig. Ez segít megérteni a döntési folyamat felépítését. A releváns adatmintázatok ezért nem pusztán a helyes vagy helytelen válaszokban, hanem a megoldási útvonalakban, a javítási lépésekben, az információkeresés sorrendjében és a döntési logika szerkezetében ragadhatók meg. Ha a rendszer azt érzékeli, hogy a hallgató nem veszi figyelembe a kockázati tényezőket, célzott kérdéssel ráirányíthatja a figyelmet ezekre. Ez segítheti a kritikusabb elemzést. Ebből a szempontból a digitális tanulási környezet egyszerű adatforrás helyett, olyan pedagógiai tér is, amelyben a hallgatói gondolkodási folyamatok részben rekonstruálhatók és értelmezhetők. A gazdasági kompetenciák értelmezésének egyik kihívása, hogy megértsük a hallgatók mennyire képesek különböző információkat összekapcsolni és abból következtetéseket levonni. A tanulási folyamat során sok olyan adat keletkezik, amely nem illeszkedik a hagyományos táblázatos formákba. Ezeket ma már mesterséges intelligencián alapuló szövegelemzési (NLP) módszerekkel lehet vizsgálni. Ez különösen fontos azokban a feladathelyzetekben, ahol a hallgatói teljesítmény szöveges indoklásokban, érvelésekben vagy döntési reflexiókban jelenik meg. Hosszú távon a cél, hogy az értékelési rendszerek a digitális tanulási adatok alapján átfogóbb képet adjanak a hallgatók tudásáról. Így nemcsak az ismeretek szintje válik láthatóvá, hanem a komplex üzleti készségek is. Mindez azért bír különös jelentőséggel, mert a gazdasági felsőoktatásban a hallgatói sikeresség nem csupán a tananyag reprodukcióján, hanem az elemző, mérlegelő és adaptív döntéshozatali képességeken is múlik. Mindez indokolja egy olyan kutatási modell kialakítását, amely a digitális aktivitási adatokból nemcsak kockázati mintázatokat, hanem pedagógiaiailag értelmezhető kompetenciajelzéseket is igyekszik azonosítani (Gašević, Dawson és Siemens, 2015). A kutatás ebből kiindulva azt vizsgálja, hogy a Moodle-alapú aktivitási adatok milyen mértékben kapcsolhatók össze a gazdasági képzésekben releváns kompetenciaelemekkel és oktatói beavatkozási lehetőségekkel.

### **3 Jogi és etikai keretrendszer**

#### **3.1 Átláthatóság, adatvédelem és hallgatói bizalom**

Az adatvezérelt oktatás egyik problémája annak meghatározása, hogy hol húzódik a határ a hallgatói támogatás és a folyamatos megfigyelés között. A Learning Analytics célja nem a kontroll, sokkal inkább a segítségnyújtás, de ahhoz, hogy a hallgatók is így tekintsenek rá, elengedhetetlen az őszinteség és az átláthatóság. Az adatkezelés akkor tekinthető etikusan megalapozottnak, ha mindenki számára egyértelmű a rendszer haszna, továbbá világos, hogy milyen adatokat, milyen célból és milyen keretek között használnak fel. A GDPR alapján az adatgyűjtésnek célhoz kötöttnnek, arányosnak és jogszerűnek kell lennie. Ez az oktatási gyakorlatban azt is jelenti, hogy az intézményeknek pontosan meg kell határozniuk, meddig terjed a hallgatói támogatás legitim köre, és honnan kezdődik az indokolatlan megfigyelés. A pedagógiai szempontból legitim alkalmazás feltétele ezért nem pusztán a technológiai pontosság, hanem az értelmezhetőség, az arányosság és a hallgatói bizalom fenntartása.

### **3.2 Algoritmikus torzítás, címkézés és emberi felügyelet**

A mesterséges intelligenciára épülő oktatási rendszerek egyik kockázata, hogy az algoritmusok leképezik és erősíthetik is társadalmi és oktatási egyenlőtlenségeket. A modell múltbeli adatok alapján újratermelheti a korábbi torzulásokat és a hallgatókat statisztikai kategóriák mentén azonosíthatja be. Erre címkézésként vagy stigmatizációként is hivatkozhatunk, hiszen, ha a rendszer valamely hallgatót „kockázatosnak” minősít, ez könnyen befolyásolhatja az oktatói által támasztott elvárásokat és a hallgató önképét is. Ezért fontos, hogy az algoritmikus jelzések ne írják felül a pedagógiai megítélést.

Az Európai Unió MI-rendelete az oktatási célú MI-alkalmazásokat magas kockázatú kategóriába sorolja, ezért különös hangsúlyt helyez az átláthatóságra, az elszámoltathatóságra és az emberi felügyeletre. Ez egyúttal azt is megköveteli, hogy az intézmények felelősséget vállaljanak az alkalmazott modellek működéséért, valamint az ezekből fakadó döntési következményekért. A szabályozás alapelve, hogy a hallgatókat érintő érdemi döntések esetében a végső felelősség nem kerülhet ki az emberi döntéshozatal köréből. Ez a kutatás szempontjából is meghatározó, mivel az analitikai eredmények csak akkor válhatnak pedagógiai hasznossá, ha azokat az oktató a tanulási kontextus ismeretében értelmezi. A technológia ebben a keretben nem autonóm döntéshozó, sokkal inkább egy kontrollált döntéstámogató eszközként értelmezhető (Molloy et al., 2020; Baker, 2021; Bokor, 2023).

## **4 A kutatás módszertana**

A szakirodalmi áttekintésben bemutattam, hogy a tanulási analitika és a kompetenciafejlesztés kapcsolata nem vizsgálható pusztán számokkal. Egy hallgató digitális lábnyoma nem fedi le a teljes tanulási folyamatot, ezért az adatok értelmezéséhez elengedhetetlen a keletkezési kontextus ismerete. Ez különösen igaz akkor, amikor az adatokat mesterséges intelligenciával támogatott prediktív és pedagógiai elemzésben kívánjuk felhasználni.

### **4.1 Kutatási design és kutatási kérdések**

A kutatás felépítése abból indul ki, hogy a digitális aktivitási mintázatok önmagukban nem adnak teljes képet a tanulási folyamatról. A jelenség összetettségéből fakad, hogy a vizsgálat során mindenképpen mixed-method módszertanú megközelítést kell alkalmazni úgy, hogy az egyes mérőeszközöknek rögzített a sorrendje (Creswell és Plano Clark, 2018). Ez a szekvenciális explanatory design, amelynek logikája, hogy az első (kvantitatív) szakasz a korai kockázati mintázatok feltárására, a kvalitatív szakasz pedig ezek pedagógiai értelmezésére szolgál. A tanulási analitika kvantitatív mutatói elsősorban a „mit” kérdésekre adnak választ, viszont a mögöttük meghúzódó oktatói döntési mechanizmusok és pedagógiai reflexiók feltárásához már kvalitatív mérőeszközök kellenek. A két szemléletmód együttese biztosítja a triangulációt, ezáltal az eredményeket több irányból tudjuk hitelesíteni.

A céloom annak vizsgálata, hogy a digitális tanulási környezetekben keletkező aktivitási adatok hogyan használhatók fel a hallgatói sikertelenség korai előrejelzésére, valamint hogyan alakíthatók át pedagógiai szempontból értelmezhető információvá az oktatói döntéshozatal támogatására. A vizsgálat három, egymáshoz kapcsolódó kutatási kérdésre épül: a digitális aktivitási adatok prediktív elemzésére, az analitikai információk pedagógiai értelmezésére, valamint a tanulási aktivitások kompetenciaalapú értelmezésére. A kutatás logikáját követve a kvantitatív szakaszban azonosítjuk a mintázásokat, amelyek a hallgatói sikertelenség korai előjelei lehetnek, a kvalitatív szakaszban feltárjuk, hogy ezek a jelzések miként jelennek meg az oktatói értelmezésben és a pedagógiai beavatkozásban.

K1: Melyek azok a digitális aktivitási indikátorok, amelyek egy mesterséges intelligencia-alapú prediktív modellben a legnagyobb pontossággal jelzik előre a hallgatói sikertelenséget a gazdasági alapozó tárgyaknál?

K2: Miként alakul át az MI-alapú analitikai adat konkrét pedagógiai intervencióvá az oktatói döntéshozatali folyamatban?

K3: Hogyan fordíthatók le a Moodle-logadatok a gazdasági képzések specifikus kompetenciaelemeire egy adatvezérelt konceptuális modell segítségével?

#### **4.2 Adatforrások és indikátorképzés**

A kutatási design gyakorlati megvalósításának kulcskérdése, hogy a digitális tanulási környezetből milyen típusú adatok nyerhetők ki, és ezek miként alakíthatók pedagógiaiilag értelmezhető indikátorokká. A gyakorlatban ez azt jelenti, hogy az alkalmazott oktatási keretrendszerben, például a Moodle-ban keletkező adatokat nemcsak utólagos ellenőrzésre, hanem prediktív célokra is használjuk. A folyamat első lépése a Moodle-logadatok exportálása, majd ezek tisztítása. Az adatforrások kiválasztásánál ezért nem minden rendszeresemény tekinthető egyformán relevánsnak, mivel a kutatás azokra az aktivitásokra koncentrál, amelyek a tanulási folyamat szervezettségéről, intenzitásáról és stratégiai jellegéről hordoznak információt. A data cleaning kulcsfontosságú, mert a Moodle adatbázisa hatalmas mennyiségű „zajt” termel. Nem minden log tükrözi a hallgató tanulási erőfeszítéseit, ezért ezek torzíthatják a későbbi elemzést. Zajként jelenhetnek meg a rendszergenerált események, az adminisztratív műveletek vagy az oktatói jelenlét által generált logok is. A fókusz az esetünkben a mélytanuláson van, ezért kizárólag a tartalmi interakciókat tartjuk meg az elemzésben.

A szűrés után megmaradt aktivitási elemeket súlyozni kell, mert a passzív és az aktív események nem tekinthetők egyenértékűnek. Figyelembe kell venni a súlyozásnál az időtartamot is, mert a túl rövid ideig tartó munkamenetek nem valós tanulási időt jelölnek. A szűrt és súlyozott adatok halmaza már alkalmas lehet arra, hogy valós tanulási mintázatokat azonosítsunk és pedagógiai jelentéstartalmat hordozzon. A tisztítás után az adatok transzformációja következik, ahol származtatott indikátorokat és kompozit mérőszámokat hozunk létre. Az indikátorképzés célja, hogy a nyers, önmagukban nehezen értelmezhető rendszereseményeket olyan mérhető változókká alakítsa, amelyek pedagógiai jelentéssel is bírnak. Ilyen lehet például a feladatmegoldási hajlandóság, a

tananyaggal való interakció konzisztenciája vagy a tanulási látencia. A gazdasági képzések gyakorlatorientált tárgyainál különösen érdemes figyelni az ismétlési intenzitásra és a tananyagban bejárt útvonalakra. Ezek a mutatók jelzik a jelenlétet és számszerűsítik a hallgatói stratégia tudatosságát és a mélytanulásra való törekvést is. Ez megteremti az összeköttetést a nyers digitális adatok, a későbbi prediktív elemzés és a pedagógiai értelmezés között.

#### **4.3 Prediktív modellezés**

Az elméleti keretek és a kutatási kérdések rögzítése után a vizsgálat első lépése a prediktív mutatók technikai és statisztikai meghatározása, koncentrálna arra, hogy megtaláljuk a hallgatói sikertelenség legkorábbi digitális jeleit. A korai jelzőrendszerek (Early Warning Systems – EWS) lényege, hogy még időben felismerjék a hallgatói lemorzsolódásra utaló jeleket. Lényegük, hogy ne utólag, hanem már a folyamat közben észrevegyük, ha egy hallgató elakad. Az EWS-rendszerek olyan hétköznapi adatokat fésülnek össze, mint az LMS-felület használatának gyakorisága, a tananyagok megnyitása, a részfeladatok jegyei vagy a határidők pontos betartása. Ebben a folyamatban a mesterséges intelligencia jelent előrelépést, mert nemcsak az összefüggések azonosítására, hanem a várható kimenetek előrejelzésére is képes.

A modell célváltozója a hallgatói sikertelenség, illetve annak korai kockázata, amelyet a tanulmányi eredmények, a kurzusteljesítés és a kritikus aktivitási mintázatok együttesen jelezhetnek (Jovanović et al., 2020; Budai, 2022). A modell érvényességének igazolásához ezeket a származtatott mutatókat a Neptun rendszerből kinyert tanulmányi eredményekkel vetem össze. A validációt követően a mesterséges intelligencia alapú mintázatfelismerő algoritmusok képesek azonosítani a nem lineáris összefüggéseket a hallgatói aktivitás mintázatai és a tanulmányi sikertelenség között. A mutatók és az MI-támogatott prediktív modellezés kettőse együtt segíti a kockázati profilok pontosabb beazonosítását. A prediktív modellezés célja ugyanakkor nem pusztán a statisztikai pontosság növelése, hanem olyan korai jelzések azonosítása, amelyek pedagógiai beavatkozást tehetnek lehetővé. A modellből nyert

kockázati jelzések értelme ezért nem önmagukban, hanem az oktatói értelmezés és a későbbi beavatkozás összefüggésében ragadható meg.

#### **4.4 Oktatói dashboard és kvalitatív interpretáció**

Pedagógiai dimenzióban az oktatói döntéshozatal folyamatát vizsgáljuk meg. Nem maguk az adatok a végcélok, hanem az a mód, ahogyan az oktatók ezeket felhasználják a napi gyakorlatban. A prediktív modellekből származó jelzések ugyanis csak akkor válnak pedagógiailag hasznossá, ha azokat az oktató értelmezi és alkalmazni is tudja. Az oktatói dashboard erre nyújt komplex eszközrendszert. A dashboard működése mögött meghúzódó eljárások a hallgatói aktivitást vetik össze a sikeres tanulási mintázatokkal, amivel jelentősen csökken az oktatókra nehezedő elemzési teher. A rendszer több száz hallgató aktivitását képes egyidejűleg monitorozni, valamint jelezni a rejtett összefüggéseket. Az így kapott eredményeket közérthető, színekódolt vizuális jelzések formájában visszaadja, lehetővé téve az oktató számára az azonnali döntéshozatalt. A dashboard önálló döntéshozó felület helyett az analitikai eredmények pedagógiai fordításának eszközeként működik.

A jelzések alapján a beavatkozás az elakadás súlyosságától és jellegétől függően három, egymástól jól elkülöníthető szinten valósulhat meg. Az első a mikroszintű vagy automatizált intervenció. Ennek során a rendszer közvetlen visszacsatolást küld a hallgatónak, amely a ritmizált tanulás fenntartását szolgálja anélkül, hogy oktatói erőforrásokat igénybe venne. Ott, ahol az adatok már tartós elakadást vagy a mélytanulás hiányát mutatják, már személyes és támogató beavatkozásra van szükség. Az oktatói mentorálás a konzultáció felajánlásától egészen egyéni nehézségek diagnosztizálásáig is terjedhet. Amennyiben indokolt, az oktató beavatkozhat a tanulási folyamatba úgy, hogy módosítja kurzus struktúráját, extra segédanyagok épít be vagy felülbírálja nehézségi szintet. A beavatkozási formák kiválasztása technikai és értelmezési kérdés is, amelyben az oktatói tapasztalat és a tanulási kontextus ismerete egyaránt meghatározó szerepet játszanak.

Az K2 megválaszolásához elengedhetetlen az említett oktatói döntési mechanizmusok alapos kvalitatív feltárása. A QUAN szakaszban azonosított mintázatokra az oktatókkal készített félig strukturált interjúk segítségével reflektálunk. Az interjúk segítségével pontosabb képet kaphatunk arról, hogyan is értelmezik az oktatók a dashboard jelzéseit, és mikor érzik szükségét a rendszer felülbírálatának. Az analitikai adatokból ugyanis csak akkor lesz valódi segítség, ha a statisztikai valószínűséget kiegészíti az oktatói tapasztalat és pedagógiai tudatosság. A dashboard és az oktatói interpretáció kapcsolata így nemcsak a beavatkozás, hanem a tanulási mintázatok pedagógiai jelentésének feltárása szempontjából is alapvető.

#### **4.5 Kompetencia-leképezés**

A dashboard jelzései az oktatói döntéshozatal során a hallgató gazdasági szakmai attitűdjére vonatkozó, közvetlenül nem látható információkat is felszínre hozhatnak. Lehetőség nyílik arra, hogy az elemzés ne pusztán teljesítménymérésre korlátozódjon, hanem a kompetenciaalapú fejlesztés irányába is elmozduljon. A gazdasági képzés egyik sajátossága, hogy a hallgatóktól már az egyetemi évek alatt elvárja azokat a transzverzális kompetenciákat, amelyeket később a piaci környezetben kell alkalmazniuk. Ilyen képességek például a módszertani fegyelem és a strukturált gondolkodás.

A releváns adatmintázatok nem pusztán a helyes vagy helytelen válaszokban, hanem a megoldási útvonalakban, a javítási lépésekben, az információkeresés sorrendjében és a döntési logika szerkezetében ragadhatók meg. Az ilyen típusú adatok nemcsak a tudás meglétéről vagy hiányáról árulkodnak, hanem arról is, hogy a hallgató milyen stratégiával közelít a problémához. Az aktivitási adatok ugyanakkor nem közvetlenül mérik a kompetenciákat, hanem azok közvetett viselkedési jelzéseként értelmezhetők. A kompetencia ezért nem egyetlen mutatóban jelenik meg, hanem több aktivitási mintázat együttes értelmezéséből rajzolódik ki.

A modellben kiemelt szerepet kap a precizitás, az önszabályozás és a stratégiai gondolkodás, amelyek különböző aktivitási mintázatokon keresztül válnak értelmezhetővé. A kutatás célja egy olyan konceptuális modell kialakítása,

amely az aktivitási adatokat, az ezekből azonosított mintázatokat és a hozzájuk kapcsolt kompetenciaelemeket közös értelmezési keretben kapcsolja össze. Ez a megközelítés közvetlenül a K3 kutatási kérdésre ad választ, amely a Moodle-alapú aktivitási adatok és a gazdasági kompetenciaelemek közötti kapcsolat feltárására irányul.

## **5 Várható eredmények és gyakorlati hasznosíthatóság**

A kutatás várhatóan három, szorosan összefüggő eredménnyel zárul. Elsőként azonosítjuk azokat a mutatókat, amelyek időben jelzik a hallgatói lemaradást. Majd feltárjuk, hogyan értelmezik az oktatók az analitikai visszajelzéseket, végül pedig kidolgozunk egy kompetenciamérési keretrendszert. Ez az MI-támogatott modell a gazdasági felsőoktatás modernizációjának egyik hatékony eszköze lehet, amely az intézményi, az oktatói és a hallgatói szint igényeit is egyszerre kiszolgálja. A kutatás során felvázolt konceptuális modell

gyakorlati haszna, hogy lehetővé teszi a személyre szabott kompetenciafejlesztést már az egyetemi évek alatt. Az adatokból kirajzolódó képességprofilok alapján azonosíthatóvá válik, ki rendelkezik a kiváló elemzőkhöz szükséges precizitással, és ki mutat hajlamot az önszabályozó menedzseri szemléletre. Ebből a prediktív jellegből adódik, hogy a pedagógiai beavatkozás a tudatos karrierépítést is szolgálhatja. Oktatói szinten ez azt jelenti, hogy a dashboardból és a kvalitatív értelmezésből származó információk célzott támogatást és korábbi beavatkozást tehetnek lehetővé. Intézményi szinten a kar vezetése végre tényleges hallgatói viselkedésmintákra alapozhatja az oktatásfejlesztési döntéseit. Ez az adatvezérelt szemlélet hosszú távon a képzés színvonalán túl az intézmény hitelességét és stabilitását is erősítheti. A várható eredmény egy olyan döntéstámogató keret, amely a hallgatói sikeresség, a kompetenciafejlesztés és az intézményi alkalmazhatóság szempontjait mind összekapcsolja. Ezt az emberi döntéshozatal elsődlegessége is indokolja, amelyet a módszertani és etikai keretek egyaránt megerősítenek.

## **6 Összegzés**

A gazdasági képzések jelenlegi hallgatói létszáma mellett a hagyományos módszertani keretek fenntarthatósága megkérdőjelezhető. Az egyéni figyelem biztosítása technológiai támogatás nélkül korlátozott (Kárpáti, 2020; Marciniak, 2024). Ebben a környezetben a Learning Analytics (LA) és az MI alkalmazása a kompetenciaalapú oktatás megvalósíthatóságának jelentős technikai feltétele.

A tanulmány azt vizsgálta, hogyan tehetők a digitális tanulási környezetekben keletkező adatok pedagógiaiailag értelmezhetővé, és miként támogathatják az oktatói döntéshozatalt. A kutatás több egymáshoz kapcsolódó dimenzióra épül. Az első a hallgatói sikertelenséget korán jelző prediktív indikátorok azonosítása, majd az analitikai jelzések oktatói értelmezésének feltárása, valamint egy kompetencia-leképezési keret kialakítása.

A bemutatott megközelítés megmutatja, hogy a digitális aktivitási adatok nem közvetlenül mérik a kompetenciákat, sokkal inkább olyan mintázatokat rajzolnak ki, amelyek pedagógiai értelmezésen keresztül köthetők össze egyes kompetenciaelemekkel. A modellben a tanulási analitika és a mesterséges intelligencia nem önálló döntéshozók. A kutatás eredményeként kirajzolódik egy olyan döntéstámogató keret, amely összekapcsolja a hallgatói sikeresség, a kompetenciafejlesztés és az intézményi alkalmazhatóság szempontjait.

## **Irodalomjegyzék**

- Baker, R. S. (2021). Artificial Intelligence in Education: Bringing it All Together. OECD Education Working Papers, No. 248. Paris: OECD Publishing.
- Bokor T. (2023). A mesterséges intelligencia alkalmazása az oktatásban – kihívások és következmények technológiaiinvariáns szempontból. In: Kovács Z. (szerk.) A mesterséges intelligencia hatásainak vizsgálata. Budapest: KNBSZ, pp. 114–129.

**ESZTERHÁZY KÁROLY KATOLIKUS EGYETEM**  
**INFORMATIKA KAR • DIGITÁLIS TECHNOLÓGIA INTÉZET**  
**AGRIA MÉDIA KONFERENCIA 2025**

- Budai G. (2022). A mesterséges intelligencia lehetőségei a felsőoktatási lemorzsolódás csökkentésében. *Információs Társadalom*, 22(2), pp. 45–62.
- Creswell, J. W. és Plano Clark, V. L. (2018). *Designing and Conducting Mixed Methods Research*. 3rd ed. Thousand Oaks: SAGE Publications.
- Fehér P. (2021). *Digitális transzformáció az oktatásban*. Budapest: Wolters Kluwer.
- Ferguson, R. (2012). Learning analytics: drivers, developments and challenges. *Int. J. of Tech. Enhanced Learning*, 4(5/6), pp. 304–317.
- Gašević, D., Dawson, S. és Siemens, G. (2015). Let's not forget learning analytics are about learning: Context is everything. *Software Quality Journal*, 23(1), pp. 9–35.
- Hermann, Z., Kiss, H. J. és Varga, J. (2022). *A hallgatói lemorzsolódást befolyásoló tényezők a magyar felsőoktatásban*. Budapest: KRTK.
- Jovanović, J. et al. (2020). Learning analytics to unveil self-regulatory processes in learning processes. *The Internet and Higher Education*, 44, 100707.
- Kárpáti A. (2020). *Digitális tanulási környezetek és módszerek a felsőoktatásban*. Budapest: Akadémiai Kiadó.
- Lang, C. et al. (szerk.) (2017). *Handbook of Learning Analytics*. Beaumont: SoLAR.
- Marciniak R. (2024). Szövegalkotó mesterséges intelligencia a társadalomtudományi felsőoktatásban. *Educatio*, 32(4), pp. 599–612.
- Molloy, I. et al. (2020). *Trustworthy AI in Education: Ethical Considerations and Guidelines*. Paris: UNESCO.
- Papp-Danka A. (2021). A tanulási analitika alkalmazási lehetőségei a hazai felsőoktatásban. *Pedagógiai Szemle*, 71(5-6), pp. 112–130.
- Pintrich, P. R. (2004). A conceptual framework for assessing motivation and self-regulated learning in college students. *Educational Psychology Review*, 16(4), pp. 385–407.
- Siemens, G. (2013). Learning Analytics: Envisioning a Data-Driven Educational System. *Education*, 18(3), pp. 4–20.
- Zimmerman, B. J. (2002). Becoming a self-regulated learner: An overview. *Theory Into Practice*, 41(2), pp. 64–70.