

A mesterséges intelligencia legújabb alkalmazási trendjei a bankszektorban*

Lülök Gergely  – Sebestyén Zoltán 

A tanulmány a mesterséges intelligencia (MI) bankszektorban történő alkalmazásának legújabb trendjeit vizsgálja, kiemelve a bankcsődök előrejelzését, a kockázatkezelést és az ügyfélkapcsolatok optimalizálását. A kutatás szisztematikus irodalomkutatáson alapul, amely a Scopus és Web of Science adatbázisok releváns publikációira épül, és a PRISMA-módszertant alkalmazza a források kiválasztására és elemzésére. Az eredmények szerint a felügyelet nélküli tanulási modellek dominálnak a csődelőrejelzésben és a kockázatelemzésben, míg a természetes nyelvfeldolgozás és mélytanulás technikák elsősorban az ügyfélkapcsolatok fejlesztésére és a banki hatékonyság növelésére irányulnak. A kutatás igazolja, hogy az MI egyre meghatározóbb szerepet tölt be a banki döntéshozatalban, azonban a különböző alkalmazási területek eltérő szabályozási és etikai kihívásokkal szembesülnek. Az eredmények rámutatnak arra, hogy a pénzügyi intézmények számára kulcsfontosságú az MI átláthatóságának és interpretálhatóságának javítása, valamint az adaptív szabályozási keretek kialakítása az innováció és a biztonság egyensúlyának fenntartása érdekében.

Journal of Economic Literature (JEL) kódok: C10, G21, O33

Kulcsszavak: mesterséges intelligencia, bankszektor, pénzügyi szolgáltatások, trendanalízis

1. Bevezetés

A mesterséges intelligencia egyre meghatározóbb szerepet tölt be a bankszektor működésében, forradalmasítva a hitelminősítést, a kockázatelemzést és a tranzakciófeldolgozás területeit. Az MI-alapú rendszerek alkalmazása lehetővé teszi az automatizált döntéshozatalt, a pénzügyi kockázatok pontosabb előrejelzését, valamint a csalásészlelési mechanizmusok fejlesztését. A pénzügyi intézmények egyre inkább kihasználják a gépi tanulás (Machine Learning) és az adattudomány által kínált lehetőségeket, amelyek elősegítik a szektor hatékonyságának növelését.

* A jelen kiadványban megjelenő írások a szerzők nézeteit tartalmazzák, ami nem feltétlenül egyezik a Magyar Nemzeti Bank hivatalos álláspontjával.

Lülök Gergely: Budapesti Műszaki és Gazdaságtudományi Egyetem, PhD-hallgató.

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

Sebestyén Zoltán: Budapesti Műszaki és Gazdaságtudományi Egyetem, egyetemi docens.

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

A magyar nyelvű kézirat első változata 2025. március 17-én érkezett szerkesztőségünkbe.


DOI: <https://doi.org/10.25201/HSZ.24.2.47>

Jelen tanulmány szisztematikus szakirodalmi áttekintés (systematic literature review, SLR), amely a mesterséges intelligencia banki szektorban történő alkalmazásainak tudományos feldolgozottságát vizsgálja. A kutatás célja nem új empirikus adatok gyűjtése, hanem a nemzetközi szakirodalom PRISMA-módszertan szerinti feltérképezése és tartalmi, technológiai, valamint idézettségi szempontú elemzése. A vizsgálat során rendszerezük, hogy az MI mely technológiáit, milyen célterületeken és milyen módszertani keretek között alkalmazzák a pénzügyi szektorban, különös tekintettel a bankcsődök előrejelzésére, a kockázatkezelésre és az ügyfélkapcsolatok fejlesztésére. A tanulmány célja a tudományos eredmények strukturált összegzése, valamint a legmeghatározóbb kutatási trendek azonosítása, hozzájárulva ezzel a pénzügyi MI-alkalmazások rendszerezéséhez és összehasonlíthatóságához.

A mesterséges intelligenciával kapcsolatos tudományos érdeklődés és kutatási aktivitás jelentős növekedést mutat az elmúlt évtizedben. Az 1. ábra azt mutatja, hogy többek között az “Artificial intelligence” + “finance industry”, “Artificial intelligence” + “bank sector”, “Artificial intelligence” + “credit scoring”, “Machine learning” + “finance”, és “Machine learning” + “transaction” kulcsszavakra vonatkozó keresési találatok száma folyamatosan emelkedik. Az ábra a Google Scholar, a Web of Science (WoS), és a Scopus keresési eredményein alapul, amelyek az MI és bankszektorbeli alkalmazásainak tudományos feldolgozását tükrözik 2014 és 2024 között.

1. ábra

A mesterséges intelligencia pénzügyi és bankszektorbeli keresési trendjei (2014–2024)



Az ábra alapján a 2014 és 2019 közötti időszakban az MI és pénzügyi alkalmazásai iránti érdeklődés mérsékelt növekedést mutatott, évi néhány ezer találattal. Az első jelentős ugrás 2020-ban figyelhető meg, amikor a találatok száma meghaladja a 23 ezret. Ezt követően további növekedés tapasztalható, amely valószínűleg az MI-alapú pénzügyi modellek szélesebb körű alkalmazásához és a banki digitalizáció fokozódásához kapcsolható. A keresési eredmények 2021 és 2023 között folyamatosan növekedtek, majd 2024-ben drámai megugrás figyelhető meg. A találatok száma közel megduplázódik az előző évhez képest, meghaladva a 96 ezret. Ez arra utal, hogy az MI alkalmazásai a banki szektorban 2023–2024-ben váltak igazán kiemelt témává. Fontos megjegyezni, hogy a mesterséges intelligencia gyakorlati alkalmazásainak terjedése és a témában megjelenő tudományos publikációk száma között jellemzően 1–2 éves eltolódás (publikációs késleltetés) figyelhető meg, így a keresési adatok a korábbi innovációs hullámok tudományos feldolgozását tükrözik.

A keresési adatok alapján az MI és a pénzügyi szektor kapcsolatának vizsgálata napjainkban folyamatosan nő. A bankok és a pénzügyi intézmények egyre nagyobb mértékben alkalmazzák az MI-alapú modelleket hitelbírálatokhoz, pénzmosás elleni védelemhez és személyre szabott pénzügyi tanácsadás nyújtására. A trendek azt mutatják, hogy a mesterséges intelligencia nem csupán kiegészítő technológiaként jelenik meg a bankrendszerekben, hanem alapvető stratégiai eszközzé válik, jelentősen átalakítva az ágazat működését és versenyképességét.

Számos nemzetközi tanulmány vizsgálta már a mesterséges intelligencia banki alkalmazásait, különös tekintettel az ügyfélkapcsolatok, a kockázatkezelés és az előrejelzési modellek fejlesztésére. A 3. fejezetben részletesen bemutatott szakirodalom alapján elmondható, hogy ezek a kutatások jellemzően egy-egy részterületre fókuszáltak, és eltérő módszertani megközelítést alkalmaztak. Tanulmányunk célja ezzel szemben olyan átfogó, szisztematikus elemzés elkészítése, amely tematikusan kategorizálja az MI banki alkalmazásait, és kvantitatív mutatók (idézettség, technológiai megoszlás) alapján is értékeli tudományos súlyukat. A PRISMA-módszertan használatával biztosítjuk a feldolgozás átláthatóságát és megbízhatóságát. A tanulmány újdonságtartalmát a magas tudományometriai jellemzőkkel rendelkező cikkek ilyen széles körére alkalmazott módszertan és a többdimenziós elemzési keret együttes alkalmazása adja.

Kutatásunk során többek között az alábbi kutatási kérdésekre és hipotézisekre keressük a választ:

[K1]: *Milyen mesterségesintelligencia-modellek dominálnak a bankcsődök előrejelzésében és a kockázatkezelésben, és miért ezek a leghatékonyabbak?*

[H1]: A felügyelet nélküli tanulás (Unsupervised Learning)-alapú megoldások dominálnak a bankcsődök előrejelzésében és a kockázatkezelésben, mivel ezek a modellek képesek hatékonyan azonosítani a nem egyértelmű pénzügyi mintázatokat és anomáliákat.

[K2]: *Hogyan járul hozzá az MI az ügyfélkapcsolatok fejlesztéséhez?*

[H2]: Az ügyfélkapcsolatok optimalizálása elsősorban a természetes nyelvfeldolgozás (Natural Language Processing) és a mélytanulás (Deep Learning) technikákra épül, mivel ezek a módszerek hatékonyan képesek elemezni az ügyfelek preferenciáit és automatizálni az interakciókat.

[K3]: *Milyen mesterségesintelligencia-modellek segítik leginkább a banki teljesítmény és működési hatékonyság növelését?*

[H3]: A félig felügyelt tanulás (Semi Supervised Learning) és a mélytanulás technikák kiemelt szerepet töltenek be a banki teljesítmény és hatékonyság növelésében, mivel ezek a módszerek segítik az operatív folyamatok automatizálását és optimalizálását.

2. A mesterséges intelligencia kutatási trendjei és alkalmazásai a bank-szektorban – szakirodalmi áttekintés

A mesterséges intelligencia térnyerése a banki szolgáltatásokban számos lehetőséget és kihívást rejt magában. Az ügyfelek és a pénzügyi intézmények szempontjából egyaránt kulcsfontosságú az elfogadás vizsgálata, hiszen az MI-alapú rendszerek hatékony integrációja növelheti a működési hatékonyságot és a felhasználói elégedettséget.

Az alábbi tanulmányok különböző megközelítésekből vizsgálják az *MI elfogadását*, kiemelve a technológiai, pszichológiai és szervezeti tényezők szerepét.

A *természetes nyelvfeldolgozás* területén végzett kutatások rámutattak, hogy a kognitív és érzelmi tényezők jelentősen befolyásolják az MI-elfogadást. *Cintamür (2024)* az ügyfélélmény és a kockázati attitűdök összefüggését vizsgálva megállapította, hogy a társadalmi befolyás és az érzelmi motivációk ösztönzik, míg a technológiai szorongás és kockázatkerülés akadályozza az elfogadást. *Lee és Chen (2022)* a mobilbanki MI-megoldások kapcsán kimutatta, hogy az intelligencia és az emberi jellemzők erősítik a bizalmat, de növelhetik az észlelt költségeket is.

A gépi tanulás alkalmazása a banki folyamatokban több tanulmány középpontjában áll. *Ikhsan et al. (2025)* az indonéz bankszektorban igazolta, hogy az MI elfogadását az észlelt könnyű használat és hasznosság ösztönzi, míg a kockázatzet akadályozza. *Mogaji és Nguyen (2021)* a banki menedzserek MI-vel kapcsolatos ismereteit vizsgálva kiemelte, hogy a szabályozási környezet és a szervezeti koordináció kulcsszerepet játszik az MI integrációjában. *Mostafa (2009)* az arab bankok esetében rámutatott arra, hogy a mesterséges intelligencián alapuló rendszerek elfogadottsága összefügg a teljesítményértékelés pontosságával. Minél megbízhatóbb értékelést nyújt egy MI-rendszer, annál nagyobb a belső szervezeti bizalom iránta. *Khaled Alarfaj és Shahzadi (2025)* tanulmánya a mélytanulási módszerek alkalmazásával azt bizonyította, hogy a technológiai hatékonyság – jelen esetben a banki csalások azonosítása – szintén hozzájárul az MI elfogadásához, mivel növeli a pénzügyi intézmények biztonságérzetét és rendszerszintű bizalmát az új technológiák iránt.

A kognitív számítástechnika (*Cognitive Computing*) területén *Norzelan et al. (2024)* az MI elfogadását elemezte a pénzügyi és számviteli osztályok vezetői körében, különös tekintettel a megosztott szolgáltatások szektorára. Eredményeik szerint az elfogadást leginkább az észlelt hasznosság és a technikai készségek befolyásolják, míg a társadalmi nyomás és a támogatói környezet kevésbé meghatározó.

Összességében ezek a tanulmányok rávilágítanak arra, hogy az MI elfogadása a bankszektorban összetett folyamat, amelyet a technológiai jellemzők, az ügyfélélmény és a szervezeti struktúra egyaránt alakít. A fogyasztói oldalon a bizalom, a könnyű használhatóság és a társadalmi normák kulcsszerepet játszanak, míg a pénzügyi intézmények számára az integrációs kihívások és a szabályozási követelmények jelentik a fő akadályokat.

A banki teljesítmény és működési hatékonyság növelése kulcsfontosságú cél a pénzügyi szektorban, amelyet az MI egyre hatékonyabb alkalmazása támogat. A gépi tanulás különböző módszerei lehetőséget biztosítanak az üzleti modellek optimalizálására, a működési költségek csökkentésére és a profitabilitás növelésére, ahogy ezt a következő tanulmányok is igazolják. *Bolívar et al. (2023)*, *González-González et al. (2022)*, illetve *Bonaparte (2024)* kimutatták, hogy az MI-alapú elemzések javítják a banki üzleti modellek hatékonyságát és növelik a nyereségeséget. Hasonlóan, *Chishti és szerzőtársai (2024)* arra jutottak, hogy az MI és a zöld pénzügyek kombinációja hosszú távon stabilizálhatja a gazdasági ciklusokat, csökkentve a pénzügyi ingadozásokat. Ezzel összhangban, *Fraisse és Laporte (2022)* a mélytanulási modellek alkalmazásával pontosabb tőke megfelelési előrejelzéseket ért el, ami hozzájárulhat a bankok szabályozói tőkekövetelményeinek csökkentéséhez. Ehhez hasonló eredményeket mutattak ki *González-Carrasco és szerzőtársai (2019)*, akik

banki tranzakciók közötti összefüggések automatizált azonosításával javították az adatintegrációt és az üzleti döntéshozatal pontosságát. *López Lázaro et al. (2018)* szintén az MI hatékonyságnövelő szerepét igazolta, amikor a készpénzlogisztika optimalizálására alkalmazva 14 százalékos költségcsökkenést ért el. Ezzel egy irányba mutatnak *Met és szerzőtársai (2023)* eredményei, akik az automatikus gépi tanulás (Auto Machine Learning)-alapú előrejelzéseket vizsgálva megállapították, hogy azok javítják a bankfiókok teljesítményértékelését és célkitűzéseinek meghatározását. Végül, *Moffo (2024)* a banki stressztesztek területén alkalmazott gépi tanulási modellekkel pontosabb előrejelzéseket ért el, amelyek elősegíthetik a hatékonyabb tőke megfelelési stratégiák kialakítását. Ezek a kutatások egyértelműen igazolják, hogy a gépi tanulás széles körű alkalmazása jelentős hatékonyságnövekedést eredményez a banki működés minden területén, támogatva a hosszú távú versenyképességet.

A stratégiai döntéshozatal fejlesztése is egyre inkább támaszkodik a mesterséges intelligenciára, amely támogatja a pénzügyi elemzéseket, előrejelzéseket és üzleti stratégiák kialakítását. A következő kutatások mind *gépi tanulásra* építenek a döntéshozatal javítása érdekében.

Lu et al. (2024) rámutat, hogy az MI-alapú modellek pontosabb előrejelzéseket nyújtanak a pénzügyi struktúrávaltozások hatásainak elemzésére, mint a hagyományos gazdasági modellek. Hasonlóan, *Ma et al. (2025)* kimutatta, hogy a fenn tartható pénzügyek jelentősebb befolyást gyakorolnak a fintech-piacra, mint az MI-részvényekre, amely kulcsfontosságú tényező a pénzügyi stratégiai döntéshozatalban. *Qian et al. (2024)* pedig azt vizsgálta, hogyan hat a politikai bizonytalanság a banki hitelezésre és a vállalatok beruházási döntéseire, és gépi tanulási modellek segítségével azonosította a legfontosabb befolyásoló tényezőket. Ezekkel összhangban, *Tang és Li (2023)* a mélytanulási modellek pontosságát igazolta a predikciós feladatokban, amelyek segíthetik az üzleti döntéshozók munkáját. *Xie et al. (2023)* továbbá a gépi tanulási modellek interpretálhatóságát vizsgálta a banki telemarketingben, megmutatva, hogy ezek az eszközök segíthetik a célcsoportok pontosabb elérését és növelhetik a kampányok hatékonyságát. *Klein és Walther (2024)* olyan pénzügyi alkalmazásokat vizsgáltak, amelyek az MI-modellek átláthatóságát javítják a kockázatkezelésben, hiteldöntésekben és szabályozási megfelelésben.

A természetes nyelvfeldolgozás is kulcsfontosságú szerepet játszik a stratégiai pénzügyi döntések támogatásában, különösen a szöveges adatok elemzésével. *Katsafados és szerzőtársai (2024)* gépi tanulás alapú szövegelemzést alkalmaztak bankfúziók előrejelzésére, kimutatva, hogy a vállalatvezetők által használt nyelvezet megbízható indikátora lehet a fúziós szándékoknak. *Sun et al. (2024)* a kínai árnyékbankrendszer szabályozási változásainak hatását vizsgálta természetes

nyelvfeldolgozás és szöveganalízis segítségével, ami eredményeik szerint jelentősen befolyásolja a banki hitelezési stratégiákat. Ezek a kutatások rámutattak arra, hogy a természetes nyelvfeldolgozás hatékony eszköz a banki szabályozás és piaci döntéshozatal támogatásában.

A mesterséges intelligencia egyre fontosabb szerepet tölt be a *bankcsődök előrejelzésében* is, ami alapvető jelentőségű a pénzügyi stabilitás szempontjából. A következő kutatások mind *gépi tanulási* módszereket alkalmaztak a csődvalószínűség pontosabb becslésére. *Gogas et al. (2018)* támogatott vektorgépek segítségével alakított ki egy modellt, amely 99,22 százalékos pontossággal különítette el a fizetőképes és csődbe jutott bankokat, felülmúlva a hagyományos statisztikai módszereket. Hasonlóan, *Hu et al. (2025)* a Random Forest algoritmust az amerikai bankok csődjének előrejelzésére alkalmazta, kiemelve a tőke megfelelési arányok jelentőségét a predikciós pontosság szempontjából.

Lagasio és szerzőtársai (2022) az elsőként alkalmazott gráf neurális hálózatokkal vizsgálták az euroövezeti bankok csődkockázatát, kimutatva, hogy a piaci verseny befolyásolja a csődvalószínűséget. Ezzel összhangban *Le és Viviani (2018)* igazolta, hogy a mesterséges neurális hálózatok pontosabb csődelőrejelzést nyújtanak, mint a logisztikus regresszió, így segítve a szabályozói döntéshozatalt. *Petropoulos et al. (2020)* alátámasztotta a Random Forest hatékonyságát, amely megbízható teljesítményt mutatott mind az amerikai, mind az európai bankok csődvalószínűségének becslésében. *Asmar és Tuqan (2024)*, valamint *Durongkadej et al. (2024)* kutatásai azt igazolták, hogy a gépi tanulási modellek hatékonyan azonosítják a digitális bankokat érő fenyegetéseket, és jelentősen csökkentik a csődkockázatokat. Ezek az eredmények egyértelműen bizonyítják, hogy a gépi tanulás alkalmazása jelentősen növeli a bankcsődök előrejelzésének pontosságát, hozzájárulva a pénzügyi rendszer stabilitásához.

Az MI egyre nagyobb szerepet kap a banki *kockázatok kezelésében*, pontosabb előrejelzéseket és hatékonyabb döntéshozatalt téve lehetővé. A következő kutatások mind *gépi tanulási* modellekre épültek. *Alonso-Robisco és Carbó (2022)*, valamint *Hussein Sayed et al. (2024)* kutatásai igazolják, hogy a gépi tanulási modellek pontosabb előrejelzéseket biztosítanak, ezáltal csökkentve a szabályozási tőkekövetelményeket. *Kruppa et al. (2013)* és *Lin et al. (2025)* a Random Forest és XGBoost alkalmazásával mutatták ki a gépi tanulási modellek előnyeit a fogyasztói és autóhitel-kockázatok előrejelzésében. *Mercadier et al. (2025)*, illetve *Heß és Damásio (2025)* egy új MI-alapú megközelítést dolgoztak ki a globális bankrendszeri kockázatok azonosítására, míg *Wang et al. (2024)* és *Uddin et al. (2023)* a banki digitalizáció hatásának szemszögéből tették ugyanezt. *Shahbazi és Byun (2022)* szintén

egy hasonló megoldást fejlesztett ki, ám ők a kriptovaluta-piacok kockázatainak csökkentésére. *Sugozu et al. (2025) kutatása* a török bankrendszer hitelkockázatát elemezte, és kimutatta, hogy az iszlám bankok magasabb kockázati kitettséggel rendelkeznek, különösen versenyhelyzetben, *Zhou et al. (2019)* pedig egy IoT (Internet of things)-alapú pénzügyi kockázatkezelési rendszert mutatott be, amely párhuzamos számítások révén gyorsabb és pontosabb előrejelzéseket tesz lehetővé.

Az egyetlen *természetes nyelvfeldolgozást* alkalmazó tanulmány *Thi Nguyen et al. (2024)* munkája, amely a banki tőkemegfelelési mutatók és stressztesztek kockázatelemzését vizsgálta.

A banki *ügyfélkapcsolatok fejlesztésében* egyre nagyobb szerepet kap a mesterséges intelligencia, amely támogatja az ajánlatok személyre szabását, az ügyfél-elégedettség növelését és a pénzügyi tanácsadás hatékonyságát. A *gépi tanulás* alkalmazása lehetővé teszi az ügyfél-preferenciák pontosabb modellezését és előrejelzését. *Bockel-Rickermann et al. (2025)* a kauzális gépi tanulás alkalmazását vizsgálta a jelzáloghitel-ajánlatok optimalizálásában, míg *Singh et al. (2024)* az ügyfélvesztés előrejelzésére fejlesztett predikciós modelleket tanulmányozta, kiemelve az XGBoost és a döntési erdő hatékonyságát. Hasonlóan, *Omoge et al. (2022)* bizonyította, hogy az MI-alapú ügyfélkapcsolat-kezelési (Customer Relationship Management, röviden CRM) rendszerek növelik az elégedettséget és a vásárlói lojalitást, bár a technológiai kimaradások korlátozhatják hatékonyságukat. *Northey és szerzőtársai (2022)* kutatásukban kimutatták, hogy a fogyasztók jobban bíznak az emberi tanácsadóknak, mint az MI-alapú robot tanácsadóknak, különösen nagyobb befektetési döntések esetén. A mélytanulási modellek az ügyfél-elégedettség előrejelzésében is kiemelkedőek, *Zeinalizadeh et al. (2015)* neurális hálózatokkal vizsgálta az ügyfél-elégedettség fő befolyásoló tényezőit.

A *természetes nyelvfeldolgozás* szintén kulcsszerepet játszik az ügyfélvélemények elemzésében és az automatizált ügyfélszolgálat fejlesztésében. *Hentzen et al. (2021)* a természetes nyelvfeldolgozás alapú tartalomkinyerés (Content Extraction) ügyfélbefogadásra gyakorolt hatását vizsgálta, míg *Königstorfer és Thalmann (2020)* szentiment-analízissel (Sentiment Analysis) elemezte az MI-alapú szolgáltatások ügyféltapasztalatait. Az eredmények szerint a természetes nyelvfeldolgozás hatékonyan segíti a banki interakciók megértését, ezáltal javítva az ügyfélélményt és optimalizálva a marketingstratégiákat.

Elemzésünk kizárólag Q1-es nemzetközi tudományos publikációkra épült, célunk az volt, hogy ezek alapján adjunk átfogó képet a mesterséges intelligencia legújabb pénzügyi alkalmazási trendjeiről. A hazai tanulmányokat az elemzésbe nem vontuk

be, mivel nemzetközi szemléletű, tudományos szempontból meghatározó szakirodalmi áttekintést kívántunk nyújtani.


Ugyanakkor fontos hangsúlyozni, hogy a magyar kutatók részéről is egyre fokozódó érdeklődés mutatkozik az MI pénzügyi szektorban történő alkalmazása iránt. *Domokos és Sajtos (2024)* a mesterséges intelligencia banki használatának kulcsterületeit – például kockázatkezelést és ügyfélkapcsolat-automatizációt – vizsgálta, kiemelve a szabályozási kérdéseket is. *Rajka és Pollák (2024)* az XGBoost algoritmus hitelkockázati modellezésben való alkalmazását elemezte, kimutatva annak prediktív előnyeit. *Bagó (2023)* a gépi tanulás és a big data szerepét vizsgálta a banki digitalizációban. *Prisznayák (2022)* részletesen bemutatta az MI-vel támogatott ügyfélszolgálati megoldásokat és banki robotizációt. *Harkácsi és Szegfű (2021)* a megfelelőségbiztosítás és MI kapcsolatát írta le. *Boncz és Szabó (2022)* és *Zsinkó (2025)* a mesterséges intelligencia munkaerőpiacra gyakorolt hatását elemezték. *Benedek és Nagy (2023)* pedig kimutatta, hogy a gépjármű-biztosítási csalások azonosítására szolgáló MI-alapú módszerek jelenleg kevésbé költséghatékonyak, mint a hagyományos statisztikai-ökonometriai eszközök. Ezek a tanulmányok jól mutatják, hogy a hazai tudományos diskurzus is aktívan foglalkozik az MI pénzügyi vetületeivel, ami kutatásunk aktualitását és hiánypótló jellegét tovább erősíti, hiszen mi a fókuszált esettanulmányokon túlmutatva rendszerezett módon tekintjük át a nemzetközi MI-alkalmazások egészét a banki szférában.

3. A kutatás módszertana

A kutatás során a mesterséges intelligencia bankszektorban betöltött szerepét vizsgáltuk, különös tekintettel arra, hogy milyen típusú megoldásokat alkalmaznak leggyakrabban. Ennek érdekében szisztematikus irodalomkutatást végeztünk, amelynek során a Scopus és a Web of Science (WoS) adatbázisokból gyűjtöttünk releváns tudományos publikációkat.

Az elemzés során a *Preferred Reporting Items for Systematic Reviews and Meta-Analyses (PRISMA)*-módszertant alkalmaztuk, ami biztosítja a szakirodalmi áttekintések átláthatóságát és megismételhetőségét. Az elemzési folyamat négy fő lépésből állt: azonosítás, szűrés, megfelelőség és bevonás. A folyamatot a 2. ábra szemlélteti.

2. ábra
A releváns publikációk feltérképezése a PRISMA-módszerrel




Az azonosítási szakaszban egy előre meghatározott keresési stratégiát alkalmaztunk, amelyben az *“Artificial Intelligence”*, *“Machine Learning”*, *“Finance”*, *“Banking”*, *“Credit Scoring”* és hasonló kulcsszavakat használtuk. Ennek eredményeként 279 releváns publikációt azonosítottunk a Scopus, valamint 217 publikációt a Web of Science adatbázisban, így összesen 496 tanulmányt vontunk be a kezdeti vizsgálatba.

A *szűrési szakaszban* az első lépés a duplikált tanulmányok eltávolítása volt, ami után 352 egyedi publikáció maradt. Ezt követően a címek és absztraktok áttekintésével kizártuk azokat a tanulmányokat, amelyek nem kapcsolódtak szorosan a mesterséges intelligencia pénzügyi alkalmazásainak vizsgálatához. E lépés eredményeként 214 publikáció maradt az elemzésben, míg 138 publikációt kizártunk, mert nem feleltek meg a vizsgálati kritériumoknak.

A *megfelelőségi szakaszban* további szűrést végeztünk, amelynek során teljes szöveges elemzést hajtottunk végre. E folyamat során értékeltük a publikációk kutatási kérdéseit, módszertanát, adatbázisait és relevanciáját. Az elemzés eredményeként 107 publikációt tartottunk meg, míg 31 tanulmányt kizártunk, mert azok nem tartalmaztak elégséges empirikus adatot, vagy nem foglalkoztak közvetlenül az MI alkalmazásának konkrét eseteivel.

A *bevonási szakaszban* a végső szűrés célja az volt, hogy a legrelevánsabb és legmagasabb színvonalú tanulmányokat azonosítsuk. Ehhez figyelembe vettük az impakt-faktort, az idézettségi mutatókat, valamint a publikációk tudományos jelentőségét. Végül 50 tanulmányt választottunk ki, amelyek részletes elemzésre kerültek, és tematikusan kategorizáltuk őket az MI különböző pénzügyi alkalmazásai szerint.

A 3. ábra a WoS indexáltság szerinti megoszlását mutatja a kiválasztott publikációknak. A vizsgált 50 tanulmányból 46 szerepel a WoS adatbázisban, míg 4 nem WoS-indexált. Ez azt jelenti, hogy a mintában szereplő tanulmányok 92 százaléka WoS-indexált forrásból származik, míg a nem WoS-indexált publikációk aránya mindössze 8 százalék.



A magas WoS-indexáltság arra utal, hogy az elemzésbe bevont tanulmányok többsége elismert, lektorált folyóiratokban jelent meg, ami biztosítja a szakirodalmi áttekinthetőség megbízhatóságát és tudományos hitelességét. A nem WoS-indexált publikációk alacsony aránya azt jelzi, hogy a kutatás elsősorban a nemzetközi szinten is elismert forrásokra támaszkodik, minimalizálva az esetlegesen kevésbé megalapozott vagy gyengébb minőségű tanulmányok befolyását az eredményekre.

Az 1. táblázat a kutatásban alkalmazott mesterségesintelligencia-módszerek definícióját, magyar, illetve angol megfelelőit tartalmazza, elősegítve az egyes technikák egyértelmű értelmezését és egységes használatát a tanulmányban.

1. táblázat Mesterségesintelligencia-módszerek és definícióik		
MI-módszer angol megfelelője	MI-módszer magyar megfelelője	A módszer rövid kifejtése
Cognitive Computing	Kognitív számítástechnika	Olyan mesterségesintelligencia-rendszerek, amelyek emberi gondolkodást utánozó adatfeldolgozási képességekkel rendelkeznek, például természetes nyelvfeldolgozás, döntéstámogatás és mintázatfelismerés révén segítik az összetett problémák megoldását.
Content Extraction	Tartalomkinyerés	Olyan természetes nyelvfeldolgozási technika, amely strukturálatlan szöveges adatokból nyer ki releváns információkat, például pénzügyi jelentésekből kulcsfontosságú mutatókat vagy szerződésekben lényeges jogi kifejezéseket.
Deep Learning	Mélytanulás	A gépi tanulás egy speciális ága, amely mély neurális hálózatokat használ nagy mennyiségű adat elemzésére és összetett mintázatok felismerésére, például képfelismerésben, beszédfelismerésben és pénzügyi előrejelzésekben.
Dimensionality Reduction	Dimenziócsökkentés	Olyan gépi tanulási technika, amely az adatok lényeges jellemzőinek megtartása mellett csökkenti változók számát, például pénzügyi modellekben vagy ügyfél-csoportosításban az adatelemzés hatékonyságának növelése érdekében.
Information Retrieval	Információkeresés	Olyan természetes nyelvfeldolgozási technika, amely nagy adathalmazokból képes releváns dokumentumokat, adatokat vagy kulcsfontosságú információkat kinyerni, például pénzügyi jelentésekben, jogi szövegekben vagy ügyfélarchívumokban történő kereséshez.
Machine Learning	Gépi tanulás	Olyan mesterségesintelligencia-módszer, amely adatminták alapján képes tanulni és előrejelzéseket készíteni anélkül, hogy explicit programozásra lenne szükség, például hitelkockázat-elemzésben vagy ügyfélviselkedés előrejelzésében.
Natural Language Processing	Természetes nyelvfeldolgozás	Olyan mesterségesintelligencia-technológia, amely lehetővé teszi a számítógépek számára az emberi nyelv értelmezését, feldolgozását és generálását, például chatbotokban, pénzügyi jelentések elemzésében vagy ügyfélvélemények szentimentelemzésében.

MI-módszer angol megfelelője	MI-módszer magyar megfelelője	A módszer rövid kifejtése
Question Answering	Kérdés-megválaszolás	Olyan természetes nyelvfeldolgozási technika, amely lehetővé teszi a mesterséges intelligencia számára, hogy struktúrált vagy struktúrátlan adatok alapján pontos és releváns válaszokat adjon emberi kérdésekre, például ügyfélszolgálati chatbotokban vagy pénzügyi jelentések elemzésében.
Reinforcement Learning	Megerősítéssel tanulás	Olyan gépi tanulási módszer, amelyben az algoritmus kísérletezés és visszacsatolás alapján optimalizálja döntéseit jutalmazási rendszer segítségével, például algoritmikus kereskedésben vagy robotikai alkalmazásokban.
Semi Supervised Learning	Félig felügyelt tanulás	Olyan gépi tanulási módszer, amely kis mennyiségű címkézett és nagy mennyiségű címkézetlen adat kombinálásával tanul, például családetektálásban vagy hitelkockázat-elemzésben, ahol teljeskörűen címkézett adathalmazok nem mindig állnak rendelkezésre.
Sentiment Analysis	Széntimentelemzés	Olyan természetes nyelvfeldolgozási technika, amely szöveges adatok érzelmi tartalmát elemzi és osztályozza pozitív, negatív vagy semleges kategóriákba, például ügyfélvélemények, piaci hírek vagy pénzügyi jelentések érzelmi hangulatának értékelésére.
Text Generation	Szöveggenerálás	Olyan természetes nyelvfeldolgozási technika, amely képes emberi nyelvű szövegek automatikus létrehozására, például pénzügyi jelentések összegzésére, chatbotok válaszainak generálására vagy marketingtartalmak előállítására.
Topic Modeling	Témamodellezés	Olyan természetes nyelvfeldolgozási technika, amely nagy szöveges adathalmazokban rejlő főbb témák és mintázatok automatikus felismerésére szolgál, például pénzügyi jelentések, ügyfélvélemények vagy piaci elemzések kategorizálására.
Unsupervised Learning	Felügyelet nélküli tanulás	Olyan gépi tanulási módszer, amely címkézetlen adatokból keres mintázatokat és struktúrákat, például ügyfélszegmentációban vagy anomáliadetektálásban a pénzügyi szektorban.
Forrás: Khosravi et al. (2023) alapján szerkesztve		

4. A mesterséges intelligencia technikák alkalmazásának kvantitatív elemzése

A 2. táblázat a vizsgált szakirodalom forrásainak minőségét, eloszlását és relevanciáját mutatja be, amely alapján megállapítható, hogy a kutatás szilárd tudományos alapokon nyugszik. Minden forrás Q1 minősítésű folyóiratból származik, ami biztosítja a magas szintű szakmai ellenőrzést és az elismert kutatási eredményeket.

2. táblázat A vizsgált szakirodalom forrásainak minősítése és idézettsége			
Folyóirat	Minősítés	H-index	Hivatkozások mennyisége
Borsa Istanbul Review	Q1	42	1
Computers and Industrial Engineering	Q1	161	1
Data Science and Management	Q1	13	1
Decision Support Systems	Q1	180	1
Digital Business	Q1	13	1
Ecological Informatics	Q1	77	1
Engineering Applications of Artificial Intelligence	Q1	137	1
European Journal of Operational Research	Q1	305	2
Expert Systems with Applications	Q1	271	3
Finance Research Letters	Q1	101	4
Heliyon	Q1	88	1
IEEE Access	Q1	242	6
Information Sciences	Q1	227	2
International Journal of Bank Marketing	Q1	104	7
International Journal of Cognitive Computing in Engineering	Q1	16	1
International Journal of Forecasting	Q1	119	2
International Journal of Information Management Data Insights	Q1	34	1
International Review of Economics & Finance	Q1	78	1
International Review of Financial Analysis	Q1	91	3
Journal of Banking & Finance	Q1	197	1
Journal of Behavioral and Experimental Finance	Q1	39	1
Journal of Financial Stability	Q1	73	1
Pacific-Basin Finance Journal	Q1	75	3
Research in International Business and Finance	Q1	73	2
Technological Forecasting and Social Change	Q1	179	2

A vizsgált folyóiratok között számos kiemelkedő H-index értékű lap szerepel, mint például az European Journal of Operational Research (H-index: 305), az Expert Systems with Applications (H-index: 271) és az IEEE Access (H-index: 242). Ezek

a folyóiratok a mesterséges intelligencia, adatfeldolgozás és döntéstámogatás területén vezető szerepet töltenek be. A pénzügyi és banki szektorra összpontosító lapok, mint a Journal of Banking & Finance (H-index: 197) és a Finance Research Letters (H-index: 101) ugyancsak jelentős hatású publikációs platformok.

A források tematikus megoszlása alapján az MI pénzügyi alkalmazásainak elemzése multidiszciplináris megközelítést tükröz. Az olyan folyóiratok, mint az International Journal of Bank Marketing (7 cikk), az IEEE Access (6 cikk) és a Finance Research Letters (4 cikk) különösen gyakran foglalkoznak az MI és a bankszektor kapcsolatával. Az adatelemzés és gépi tanulás alkalmazását az Expert Systems with Applications és az Engineering Applications of Artificial Intelligence publikációi támasztják alá. A pénzügyi stabilitás és előrejelzések kapcsán az International Journal of Forecasting és a Journal of Financial Stability kiemelkedő szerepet játszik.

Összességében a vizsgált szakirodalom széles tudományterületeket ölel fel, beleértve az MI-alapú döntéshozatalt, banki kockázatelemzést, ügyfélkapcsolatok kezelését és gazdasági előrejelzéseket. Ez biztosítja, hogy a tanulmány a pénzügyi és banki szektor mesterségesintelligencia-trendjeinek átfogó értékelését nyújtsa.

Az MI pénzügyi és banki alkalmazásainak kutatása az elmúlt években jelentősen felgyorsult, amit a hivatkozások év szerinti eloszlása is alátámaszt (3. táblázat).

3. táblázat	
A hivatkozott tanulmányok év szerinti eloszlása	
Évszám	Hivatkozott tanulmányok mennyisége
2009	1
2013	1
2015	1
2018	3
2019	2
2020	2
2021	2
2022	8
2023	5
2024	16
2025 márciusig	9

Az MI pénzügyi és banki alkalmazásainak kutatása az elmúlt években gyors ütemben fejlődött, amit a hivatkozások év szerinti eloszlása is alátámaszt. 2009 és 2021 között a terület iránti érdeklődés fokozatos, de mérsékelt növekedést mutatott, amely az első jelentős ugrást 2018-ban érte el. A publikációs aktivitás 2022-től fokozódott, 2024-ben pedig kiugró értéket ért el (16 hivatkozás), ami jól illeszkedik a keresési

találatok drámai megugrásához ebben az időszakban. Ez a tendencia arra utal, hogy az MI a banki szektorban 2023–2024-ben vált igazán központi kutatási témává, és a legfrissebb tanulmányok egyre inkább meghatározzák az ágazat technológiai fejlődését. A bankok és pénzügyi intézmények egyre nagyobb mértékben alkalmazzák az MI-alapú modelleket hitelbírálatra, pénzmosás elleni védelemre és ügyfélkapcsolatok fejlesztésére, ami azt jelzi, hogy az MI nem csupán támogató eszköz, hanem alapvető stratégiai tényezővé válik a pénzügyi szektorban.

A 4. táblázat bemutatja a mesterséges intelligencia különböző alkalmazási területeit a banki szektorban, az MI kategóriák és alkategóriák szerinti eloszlási, valamint az idézettségi adatok alapján. A mesterséges intelligencia banki szektorban való alkalmazásának kvantitatív elemzése során a szakirodalmi keresések angol nyelvű kulcsszavak alapján történtek, így az eredmények következetes és pontos bemutatása érdekében az MI-kategóriák és -módszerek megnevezése is angol nyelven kerül feltüntetésre. Ez biztosítja az egyértelmű terminológiai megfelelést, és lehetővé teszi az eredmények összehasonlítását a nemzetközi kutatásokkal.

Az MI elfogadása területén a gépi tanulás és természetes nyelvfeldolgozás technikák dominálnak, ahol a félig felügyelt tanulás (372 idézet) és a felügyelet nélküli tanulás (191 idézet) kiemelt szerepet játszik. A mélytanulás és kérdés-megválaszolás rendszerek kevésbé idézett területek, de továbbra is fontosak az MI elfogadásának vizsgálatában.

A banki teljesítmény és működési hatékonyság növelése főként a felügyelet nélküli tanulásmodellekre épül (85 idézet, 5 hivatkozás), míg a mélytanulás (37 idézet) és dimenziócsökkentés (5 idézet) szintén jelentős. A szöveggenerálás-modellek kisebb, de releváns szerepet kapnak (11 idézet, 2 hivatkozás).

A bankcsődök előrejelzése terén a felügyelet nélküli tanulási modellek dominálnak (502 idézet, 4 hivatkozás), jelezve azok jelentőségét a pénzügyi stabilitás előrejelzésében. A felügyelt tanulás és mélytanulás kevesebb idézettséget kapott (20–0 idézet), de továbbra is releváns területek maradnak.

A kockázatkezelésben a felügyelet nélküli tanulás (317 idézet) és a mélytanulás (126 idézet) kiemelkedő fontosságú, mivel ezek pontos előrejelzéseket biztosítanak. A megerősítéssel tanulás (51 idézet) szerepet játszik a kockázati modellezésben, míg az információkinyerés-megoldások kisebb hangsúlyt kapnak (3 idézet, 1 hivatkozás).

A stratégiai döntéshozatal fejlesztését főként a felügyelet nélküli tanulás támogatja (11 és 3 idézet, több hivatkozásban), míg a mélytanulás (6 idézet) és a dimenziócsökkentés (2 idézet) is megjelenik. A témamodellkezés-technikák alacsony idézettséget mutatnak (0 idézet).

4. táblázat


A mesterséges intelligencia alkalmazási területeinek megoszlása a banki szektorban

Terület	MI-kategória	MI-alkategória	Idézettség	Hivatkozott tanulmányok mennyisége
MI elfogadása	Kognitív számítástechnika	–	45	1
	Gépi tanulás	Mélytanulás	0	1
		Félig felügyelt tanulás	372	2
		Felügyelet nélküli tanulás	191	1
	Természetes nyelvfeldolgozás	Kérdés-megválaszolás	7	1
		Témamodellezés	168	1
Banki teljesítmény és működési hatékonyság növelése	Gépi tanulás	Mélytanulás	37	1
		Dimenziócsökkentés	5	1
		Félig felügyelt tanulás	63	1
		Felügyelet nélküli tanulás	85	5
	Természetes nyelvfeldolgozás	Szöveggenerálás	11	2
Bankszódók előrejelzése	Gépi tanulás	Mélytanulás	20	2
		Félig felügyelt tanulás	0	1
		Felügyelet nélküli tanulás	502	4
Kockázat-kezelés	Gépi tanulás	Mélytanulás	126	3
		Megerősítéses tanulás	51	1
		Félig felügyelt tanulás	71	2
		Felügyelet nélküli tanulás	317	4
	Természetes nyelvfeldolgozás	Információkeresés	3	1
Stratégiai döntéshozatal fejlesztése	Gépi tanulás	Felügyelet nélküli tanulás	11	1
		Mélytanulás	6	1
		Dimenziócsökkentés	2	1
		Felügyelet nélküli tanulás	3	3
	Természetes nyelvfeldolgozás	Információkeresés	20	1
		Témamodellezés	0	1
Ügyfélkapcsolatok fejlesztése	Gépi tanulás	Mélytanulás	151	2
		Megerősítéses tanulás	74	1
		Félig felügyelt tanulás	40	1
		Felügyelet nélküli tanulás	0	1
	Természetes nyelvfeldolgozás	Tartalomkinyerés	193	1
		Szövegértékelés	314	1

Az ügyfélkapcsolatok fejlesztésében a természetes nyelvfeldolgozás és a gépi tanulás egyaránt meghatározó. A szentimentelemzés kiemelkedő idézettséggel bír (314 idézet), míg a mélytanulás-modellek (151 idézet) szintén jelentős szerepet játszanak. A tartalomkinyerés (193 idézet) és a megerősítéses tanulás (74 idézet) segítenek az ügyfélkapcsolatok automatizálásában és személyre szabásában.

Az eredmények összhangban állnak az MI alkalmazásainak növekvő szerepével a pénzügyi és banki szektorban, ahol a felügyelet nélküli tanulás, mélytanulás és szentimentelemzés kiemelkedő fontosságú az üzleti alkalmazásokban.

A 4. ábra a mesterséges intelligencia különböző kategóriáinak és alkategóriáinak megoszlását mutatja a vizsgált cikkek alapján.



A legdominánsabb módszer a felügyelet nélküli tanulás (38%), amely különösen a bankcsődök előrejelzésében és a kockázatkezelésben kap szerepet, mivel ezen a területen a nagyméretű, strukturálatlan adatok elemzésére és mintázatok felismerésére van szükség. A felügyelet nélküli tanulás széles körű alkalmazása azt mutatja, hogy a pénzügyi instabilitás előrejelzésében és a hitelkockázatok kezelésében ez a megközelítés a leggyakoribb.

Ezt követi a mélytanulás (20%), amelyet elsősorban az ügyfélkapcsolatok fejlesztésére és a banki hatékonyság növelésére alkalmaznak, különösen az automatizált ügyfélszolgálati rendszerek és személyre szabott pénzügyi ajánlatok optimalizálásában. A félig felügyelt tanulás (14%) szintén jelentős részt képvisel, főként az MI elfogadásának vizsgálatában és a banki teljesítmény növelésében, mivel ötvözi a felügyelt és felügyelet nélküli tanulás előnyeit, így hatékonyabb döntéstámogatási rendszereket eredményezhet.

A természetes nyelvfeldolgozás technikák közül az információkeresés (4%) alkalmazása emelkedik ki, amely jelentős szerepet játszik az ügyfélkapcsolatok és a kockázatkezelés támogatásában. A témamodellzés (4%) és a szöveggenerálás (4%) szintén fontos területek, különösen a banki szöveges adatok elemzése és automatizált jelentéskészítési felhasználása során. Bár kisebb arányban jelenik meg, a szentimentelemzés (2%) és a tartalomkinyerés (2%) is hozzájárul az ügyfélélmény elemzéséhez.

A megerősítési tanulás (4%) főként pénzügyi tanácsadási és ügyfél-interakciós rendszerek fejlesztésére szolgál, lehetővé téve az optimalizált döntéshozatalt dinamikus pénzügyi környezetben.

Ez az elemzés alátámasztja, hogy a banki szektorban az MI különböző formái eltérő célokra kerülnek alkalmazásra. Míg a felügyelet nélküli tanulás dominál a csőd- és kockázatelőrejelzésben, addig a természetes nyelvfeldolgozás módszereket leginkább az ügyfélkapcsolatok és a marketing optimalizálására alkalmazzák. A mélytanulás elsősorban a hatékonyságnövelő alkalmazásokban kap szerepet, például az automatizált ügyfélszolgálatban és a pénzügyi tanácsadásban, míg a megerősítési tanulás és a félig felügyelt tanulás a dinamikus pénzügyi modellek fejlesztéséhez járul hozzá.

5. Diszkusszió

Kutatásunk egyediségét három szempont alapján jellemezhetjük:

1. a PRISMA-módszer szigorú alkalmazásával strukturált irodalmi áttekintést nyújtunk a bankszektorban alkalmazott MI-technológiákról, amelyre korábbi tanulmányok ilyen részletességgel nem tértek ki;
2. a vizsgált szakirodalmat kvantitatív módon rendszerezzük a mesterséges intelligencia fő kategóriái és alkategóriái szerint, így a tanulmány újdonsága a bibliometriai elemzés és a trendalapú MI-besorolás kombinációja;
3. táblázatok és ábrák segítségével bemutatjuk az idézettségi adatokon alapuló hatástényezőket, melyek alapján konkrét következtetéseket vonunk le a jövőbeli kutatási és alkalmazási lehetőségekről. Mindezek együttesen eredményezik a kutatás gyakorlati hasznosságát és tudományos relevanciáját.

Az alábbiakban releváns tanulmányok eredményeit vetjük össze saját kutatásunkkal, kiemelve a mesterséges intelligencia pénzügyi szektorban történő alkalmazásának legfontosabb párhuzamait és eltéréseit. Ezt követően részletesen elemezzük saját eredményeinket, és visszautalunk a kutatásunk során megfogalmazott hipotézisekre, értékelve azok megerősítését vagy esetleges módosulását az empirikus adatok fényében.

Mishra et al. (2023) tanulmányában az MI és a gépi tanulás banki szektorban betöltött szerepét vizsgálta, különös figyelmet fordítva a kockázatkezelésre, csalás-detektálásra és az ügyfélkapcsolatok optimalizálására. Hasonlóan kutatásunkhoz, eredményeik szerint a felügyelet nélküli tanulás dominál a csődelőrejelzés és kockázatelemzés területén, míg a természetes nyelvfeldolgozás és a mélytanulás az ügyfélkapcsolatok és hatékonyságjavítás eszközei. Emellett a tanulmány kiemelte a nagy nyelvi modellek és a blokklánc-technológia pénzügyi integrációját, amely kutatásunk eredményeivel összhangban azt mutatja, hogy az MI különböző technológiai megoldásai eltérő célokat szolgálnak a pénzügyi szektoron belül.

Almubaydeen és szerzőtársai (2025) az MI szerepét vizsgálták a banki számviteli információk minőségének javításában, különösen a szakértői rendszerek és az automatikus tanulás alkalmazásával. Eredményeik megerősítik kutatásunkat, amely szerint a felügyelet nélküli tanulás (38%) és a mélytanulás (20%) kulcsszerepet játszik a bankcsődök előrejelzésében, a kockázatkezelésben és az ügyfélkapcsolatok fejlesztésében. Kutatásunk továbbá szintén kimutatta, hogy a természetes nyelvfeldolgozási technikák (szentimentelemzés, információkeresés) támogatják az adatfeldolgozás hatékonyságát és a pénzügyi döntéshozatal gyorsaságát, ami egybevág a szerzők megállapításaival.

Al-Hawamdeh és AlShaer (2022) tanulmányukban a mesterséges intelligencia banki innovációra gyakorolt hatását vizsgálták, kiemelve a fuzzy logikán alapuló rendszerek (fuzzy logic systems) alkalmazását. Kutatásunk megerősíti, hogy az MI különböző területeken más-más célt szolgál.

A felügyelet nélküli tanulás a pénzügyi kockázatelemzés és csődelőrejelzés terén dominál, míg a természetes nyelvfeldolgozás és a mélytanulás az ügyfélkapcsolatok és operatív hatékonyság növelésére alkalmas.

Ezenkívül mindkét tanulmány hangsúlyozza az MI gyors fejlődését és az intézmények számára szükséges folyamatos technológiai alkalmazkodást, amelyet kutatásunk az MI különböző szabályozási és innovációs kihívásainak vizsgálatával támaszt alá.

Összességében e négy tanulmány eredményei és saját kutatásunk egyaránt azt mutatják, hogy az MI banki alkalmazásai jelentős változásokat hoznak a kockázatelemzésben, az ügyfélkapcsolatokban és a döntéshozatalban. A felügyelet nélküli tanulás a csődmodellek és kockázatelemzés területén dominál, míg a természetes

nyelvfeldolgozás és a mélytanulás az ügyfélszolgáltatás és banki hatékonyság fejlesztésére összpontosít. A szabályozási és etikai kérdések minden vizsgált kutatásban központi szerepet kapnak, alátámasztva, hogy a pénzügyi MI-megoldások transzparenciája és megfelelősége kulcsfontosságú a szektor további fejlődése szempontjából.

Kutatásunk eredményei rámutattak arra, hogy a mesterséges intelligencia egyre meghatározóbb szerepet tölt be a bankszektorban, különösen az olyan kulcsfontosságú területeken, mint a bankcsődök előrejelzése, a kockázatkezelés, az ügyfélkapcsolatok fejlesztése és a stratégiai döntéshozatal támogatása. A vizsgálat során a legdominánsabb MI-technológiák a gép tanulás és a természetes nyelvfeldolgozás kategóriájába tartoztak, különösen a felügyelet nélküli tanulás, mélytanulás és szentimentelemzés módszerek révén.

Az eredmények egyértelműen alátámasztják a [H1] hipotézist, miszerint a felügyelet nélküli tanulás alapú megoldások dominálnak a bankcsődök előrejelzésében és a kockázatkezelésben. Az idézettségi adatok szerint ez a módszer a legmagasabb szakirodalmi támogatottsággal bír (502 idézet a bankcsődök előrejelzésében és 317 idézet a kockázatkezelésben), ami arra utal, hogy az ilyen modellek hatékonyan azonosítják a nem egyértelmű pénzügyi mintázatokat és anomáliákat. Ezzel szemben a mélytanulás és a félig felügyelt tanulás kevésbé domináns ezen a területen, ami arra utal, hogy bár ezek a technológiák pontos előrejelzéseket biztosíthatnak, az önálló mintázatfelismerésben a felügyelet nélküli tanulási módszerek hatékonyabbak.

A [H2] hipotézissel összhangban az eredmények azt mutatják, hogy az ügyfélkapcsolatok optimalizálása a természetes nyelvfeldolgozás és a mélytanulás technikákra épül. A természetes nyelvfeldolgozás és a szentimentelemzési megoldások rendkívül magas idézettséget mutattak (314 idézet), jelezve, hogy az ügyfélkommunikáció és a piaci preferenciák elemzése kulcsfontosságú tényező a banki marketing- és ügyfélszolgálati stratégiákban. A mélytanulás alkalmazásának magas idézettsége (151 idézet) szintén azt igazolja, hogy az automatizált ügyfélszolgálati rendszerek és személyre szabott ajánlatok egyre nagyobb szerepet kapnak a pénzügyi szektorban.

A kutatás alátámasztja a [H3] hipotézist is, miszerint a félig felügyelt tanulás és mélytanulás technikák fontos szerepet játszanak a banki teljesítmény és működési hatékonyság növelésében. Az idézettségi adatok szerint a félig felügyelt tanulás (63 idézet) és a felügyelet nélküli tanulás (85 idézet) módszerek jelentős mértékben hozzájárulnak az operatív folyamatok optimalizálásához és az automatizált döntéshozatalhoz. Ezek az eredmények is megerősítik, hogy a banki szektorban a hibrid tanulási modellek – amelyek a felügyelt és felügyelet nélküli tanulás előnyeit ötvözik – különösen hatékonyak lehetnek az üzleti folyamatok automatizálásában.

A kutatás egyik fontos megállapítása, hogy az MI alkalmazása a bankszektorban jelentősen felgyorsult az elmúlt években, ahogy azt a hivatkozott tanulmányok év szerinti eloszlása is mutatja.

Az MI-vel kapcsolatos publikációk száma 2019-től kezdődően meredeken emelkedett, és 2024-ben érte el csúcát, ami azt jelzi, hogy az MI a banki szektorban stratégiai fontosságú technológiává vált. A trendek azt mutatják, hogy a pénzügyi intézmények egyre inkább a gépi tanulás és a természetes nyelvfeldolgozás alkalmazására támaszkodnak az üzleti döntéshozatal, a kockázatkezelés és az ügyfélkapcsolatok optimalizálása terén.

A kutatás eredményei rávilágítanak arra, hogy a mesterséges intelligencia egyre mélyebb integrációja a bankszektor működésébe nemcsak a hatékonyság növelését és a kockázatkezelés optimalizálását segíti elő, hanem hosszú távon stratégiai előnyt is jelent a pénzügyi intézmények számára.

A felügyelet nélküli tanulás dominanciája a csődelőrejelzésben és a kockázatelemzésben, valamint a természetes nyelvfeldolgozás és a mélytanulás kulcsszerepe az ügyfélkapcsolatok fejlesztésében arra utal, hogy az MI alkalmazásai célzottabbá és egyre kifinomultabbá válnak.

A jövőbeli kutatások szempontjából kiemelt jelentőségű lehet az MI interpretálhatóságának és átláthatóságának javítása, különösen a felügyelet nélküli tanulási modellek esetében, ahol a döntéshozatali folyamatok nehezen visszafejthetők. Emellett a szabályozási környezet dinamikus fejlődése további kutatásokat indokol az MI etikai és jogi kérdéseiről, különösen az automatizált döntéshozatal és a pénzügyi szolgáltatások személyre szabása terén.

A technológiai fejlődés várható irányai között szerepel a nagy nyelvi modellek és a generatív MI-rendszerek fokozott integrációja a pénzügyi szektorba, ami új lehetőségeket nyithat az ügyfélszolgáltatások automatizálásában és az adatvezérelt döntéshozatalban. Az MI és a blokklánc-technológia együttes alkalmazása szintén ígéretes terület, amely hozzájárulhat a pénzügyi tranzakciók biztonságának és átláthatóságának növeléséhez.

Végül soron a mesterséges intelligencia fejlődése nemcsak a jelenlegi pénzügyi folyamatokat alakítja át, hanem a bankszektor jövőbeli versenyképességének egyik meghatározó tényezőjévé is válik. Ennek megfelelően a jövőbeli kutatásoknak nemcsak a technológiai innovációkra, hanem a velük járó kockázatok kezelésére és a szabályozási kihívásokra is nagyobb figyelmet kell fordítaniuk.

Felhasznált irodalom

- Al-Hawamdeh, M.M. – AlShaer, S.A. (2022): *Artificial intelligence applications as a modern trend to achieve organizational innovation in Jordanian commercial banks*. Journal of Asian Finance, Economics and Business, 9(3): 257–263. <https://doi.org/10.13106/jafeb.2022.vol9.no3.0257>
- Almubaydeen, T. – Alkabbji, R. – Fleifil, M.K.A. (2025): *Effect of applying artificial intelligence on the quality of accounting information in commercial banks (a field study)*. In: Musleh Al-Sartawi, A.M.A. – Al-Okaily, M. – Al-Qudah, A.A. – Shihadeh, F. (eds): Studies in Systems, Decision and Control. Vol. 572, Springer, Cham., pp. 787–803. https://doi.org/10.1007/978-3-031-76011-2_56
- Alonso-Robisco, A. – Carbo, J.M. (2022): *Can machine learning models save capital for banks? Evidence from a Spanish credit portfolio*. International Review of Financial Analysis, 84, 102372. <https://doi.org/10.1016/j.irfa.2022.102372>
- Asmar, M. – Tuqan, A. (2024): *Integrating machine learning for sustaining cybersecurity in digital banks*. Heliyon, 10(17), e37571. <https://doi.org/10.1016/j.heliyon.2024.e37571>
- Bagó Péter (2023): *A mesterséges intelligencia lehetőségei a pénzügyekben*. Gazdaság és Pénzügy, 10(1): 21–38. <https://doi.org/10.33926/gp.2023.1.2>
- Benedek Botond – Nagy Bálint Zsolt (2023): *Hagyományos versus MI-alapú csalásfelderítés: Költséghatékonyság a gépjármű-biztosítások területén*. Hitelintézeti Szemle, 22(2): 77–100. <https://doi.org/10.25201/hsz.22.2.77>
- Bockel-Rickermann, C. – Verboven, S. – Verdonck, T. – Verbeke, W. (2025): *Can causal machine learning reveal individual bid responses of bank customers? — A study on mortgage loan applications in Belgium*. Decision Support Systems, 190, 114378. <https://doi.org/10.1016/j.dss.2024.114378>
- Bolívar, F. – Duran, M.A. – Lozano-Vivas, A. (2023): *Business model contributions to bank profit performance: A machine learning approach*. Research in International Business and Finance, 64, 101870. <https://doi.org/10.1016/j.ribaf.2022.101870>
- Bonaparte, Y. (2024): *Artificial Intelligence in Finance: Valuations and Opportunities*. Finance Research Letters, 60, 104851. <https://doi.org/10.1016/j.frl.2023.104851>
- Boncz Bettina – Szabó Zs. Roland (2022): *A mesterséges intelligencia munkaerő-piaci hatásai – Hogyan készüljünk fel?*. Vezetéstudomány / Budapest Management Review, 53(2): 68–80. <https://doi.org/10.14267/veztud.2022.02.06>

- Chishti, M.Z. – Dogan, E. – Binsaeed, R.H. (2024): *Can artificial intelligence and green finance affect economic cycles?* Technological Forecasting and Social Change, 209, 123740. <https://doi.org/10.1016/j.techfore.2024.123740>
- Cintamür, İ.G. (2024): *Acceptance of artificial intelligence devices in banking services: Moderation role of technology anxiety and risk aversion.* International Journal of Bank Marketing, 42(7): 2143–2176. <https://doi.org/10.1108/ijbm-10-2023-0563>
- Domokos Anna – Sajtos Péter (2024): *Mesterséges intelligencia a pénzügyi szektorban – Innováció és kockázatok.* Hitelintézeti Szemle, 23(1): 155–166. <https://hitelintezetiszemle.mnb.hu/hsz-23-1-szc1-domokos-sajtos>
- Durongkadej, I. – Hu, W. – Wang, H.E. (2024): *How artificial intelligence incidents affect banks and financial services firms? A study of five firms.* Finance Research Letters, 70, 106279. <https://doi.org/10.1016/j.frl.2024.106279>
- Fraisse, H. – Laporte, M. (2022): *Return on investment on artificial intelligence: The case of bank capital requirement.* Journal of Banking & Finance, 138, 106401. <https://doi.org/10.1016/j.jbankfin.2022.106401>
- Gogas, P. – Papadimitriou, T. – Agrapetidou, A. (2018): *Forecasting bank failures and stress testing: A machine learning approach.* International Journal of Forecasting, 34(3): 440–455. <https://doi.org/10.1016/j.ijforecast.2018.01.009>
- González-Carrasco, I. – Jiménez-Márquez, J.L. – López-Cuadrado, J.L. – Ruiz-Mezcua, B. (2019): *Automatic detection of relationships between banking operations using machine learning.* Information Sciences, 485: 319–346. <https://doi.org/10.1016/j.ins.2019.02.030>
- González-González, J. – García-Méndez, S. – De Arriba-Pérez, F. – González-Castaño, F.J. – Barba-Seara, Ó. (2022): *Explainable automatic industrial carbon footprint estimation from bank transaction classification using natural language processing.* IEEE Access, 10: 126326–126338. <https://doi.org/10.1109/access.2022.3226324>
- Harkácsi Gábor József – Szegfű László Péter (2021): *A megfelelősbiztosítási funkció szerepe a digitalizáció, mesterséges intelligencia és robotizáció idején a pénzügyi szektorban.* Hitelintézeti Szemle, 20(1): 152–170. <https://doi.org/10.25201/hsz.20.1.152170>
- Hentzen, J.K. – Hoffmann, A. – Dolan, R. – Pala, E. (2021): *Artificial intelligence in customer-facing financial services: A systematic literature review and agenda for future research.* International Journal of Bank Marketing, 40(6): 1299–1336. <https://doi.org/10.1108/ijbm-09-2021-0417>
- Heß, V.L. – Damásio, B. (2025): *Machine learning in banking risk management: Mapping a decade of evolution.* International Journal of Information Management Data Insights, 5(1), 100324. <https://doi.org/10.1016/j.jjimei.2025.100324>

- Hu, W. – Shao, C. – Zhang, W. (2025): *Predicting U.S. bank failures and stress testing with machine learning algorithms*. Finance Research Letters, 75, 106802. <https://doi.org/10.1016/j.frl.2025.106802>
- Hussein Sayed, E. – Alabrah, A. – Hussein Rahouma, K. – Zohaib, M. – Badry, R.M. (2024): *Machine learning and deep learning for loan prediction in banking: Exploring ensemble methods and data balancing*. IEEE Access, 12: 193997–194019. <https://doi.org/10.1109/access.2024.3509774>
- Ikhsan, R.B. – Fernando, Y. – Prabowo, H. – Yuniarty, Y. – Gui, A. – Kuncoro, E.A. (2025): *An empirical study on the use of artificial intelligence in the banking sector of Indonesia by extending the TAM model and the moderating effect of perceived trust*. Digital Business, 5(1), 100103. <https://doi.org/10.1016/j.digbus.2024.100103>
- Katsafados, A.G. – Leledakis, G.N. – Pyrgiotakis, E.G. – Androutsopoulos, I. – Fergadiotis, M. (2024): *Machine learning in bank merger prediction: A text-based approach*. European Journal of Operational Research, 312(2): 783–797. <https://doi.org/10.1016/j.ejor.2023.07.039>
- Khaled Alarfaj, F. – Shahzadi, S. (2025): *Enhancing fraud detection in banking with deep learning: Graph neural networks and autoencoders for real-time credit card fraud prevention*. IEEE Access, 13: 20633–20646. <https://doi.org/10.1109/access.2024.3466288>
- Khosravi, T. – Al Sudani, Z.M. – Oladnabi, M. (2023): *To what extent does ChatGPT understand genetics?* Innovations in Education and Teaching International, 61(6): 1320–1329. <https://doi.org/10.1080/14703297.2023.2258842>
- Klein, T. – Walther, T. (2024): *Advances in explainable artificial intelligence (xAI) in finance*. Finance Research Letters, 70, 106358. <https://doi.org/10.1016/j.frl.2024.106358>
- Königstorfer, F. – Thalmann, S. (2020): *Applications of artificial intelligence in commercial banks – A research agenda for behavioral finance*. Journal of Behavioral and Experimental Finance, 27, 100352. <https://doi.org/10.1016/j.jbef.2020.100352>
- Kruppa, J. – Schwarz, A. – Armingier, G. – Ziegler, A. (2013): *Consumer credit risk: Individual probability estimates using machine learning*. Expert Systems with Applications, 40(13): 5125–5131. <https://doi.org/10.1016/j.eswa.2013.03.019>
- Lagasio, V. – Pampurini, F. – Pezzola, A. – Quaranta, A.G. (2022): *Assessing bank default determinants via machine learning*. Information Sciences, 618: 87–97. <https://doi.org/10.1016/j.ins.2022.10.128>
- Le, H.H. – Viviani, J.-L. (2018): *Predicting bank failure: An improvement by implementing a machine-learning approach to classical financial ratios*. Research in International Business and Finance, 44: 16–25. <https://doi.org/10.1016/j.ribaf.2017.07.104>

- Lee, J.-C. – Chen, X. (2022): *Exploring users' adoption intentions in the evolution of artificial intelligence mobile banking applications: The intelligent and anthropomorphic perspectives*. International Journal of Bank Marketing, 40(4): 631–658. <https://doi.org/10.1108/ijbm-08-2021-0394>
- Lin, S. – Song, D. – Cao, B. – Gu, X. – Li, J. (2025): *Credit risk assessment of automobile loans using machine learning-based SHapley Additive exPlanations approach*. Engineering Applications of Artificial Intelligence, 147, 110236. <https://doi.org/10.1016/j.engappai.2025.110236>
- López Lázaro, J. – Barbero Jiménez, Á. – Takeda, A. (2018): *Improving cash logistics in bank branches by coupling machine learning and robust optimization*. Expert Systems with Applications, 92: 236–255. <https://doi.org/10.1016/j.eswa.2017.09.043>
- Lu, Y. – Zhao, Z. – Tian, Y. – Zhan, M. (2024): *How does the economic structure break change the forecast effect of money and credit on output? Evidence based on machine learning algorithms*. Pacific-Basin Finance Journal, 84, 102325. <https://doi.org/10.1016/j.pacfin.2024.102325>
- Ma, C.-Q. – Liu, X. – Klein, T. – Ren, Y.-S. (2025): *Decoding the nexus: How fintech and AI stocks drive the future of sustainable finance*. International Review of Economics & Finance, 98, 103877. <https://doi.org/10.1016/j.iref.2025.103877>
- Mercadier, M. – Tarazi, A. – Armand, P. – Lardy, J.-P. (2025): *Monitoring bank risk around the world using unsupervised learning*. European Journal of Operational Research, 324(2): 590–615. <https://doi.org/10.1016/j.ejor.2025.01.036>
- Met, I. – Erkoc, A. – Seker, S.E. (2023): *Performance, efficiency, and target setting for bank branches: Time series with automated machine learning*. IEEE Access, 11: 1000–1010. <https://doi.org/10.1109/access.2022.3233529>
- Mishra, M.K. – Pattanayak, M. – Shankar, A.U. – Murthy, G.V.K. – Singh, S. (2023): *Impact of artificial intelligence on human behaviour & well-being – An empirical analysis*. Tuijin Jishu/Journal of Propulsion Technology, 44(3): 1393–1401. <https://doi.org/10.52783/tjjpt.v44.i3.492>
- Moffo, A.M.F. (2024): *A machine learning approach in stress testing US bank holding companies*. International Review of Financial Analysis, 95(Part C), 103476. <https://doi.org/10.1016/j.irfa.2024.103476>
- Mogaji, E. – Nguyen, N.P. (2021): *Managers' understanding of artificial intelligence in relation to marketing financial services: Insights from a cross-country study*. International Journal of Bank Marketing, 40(6): 1272–1298. <https://doi.org/10.1108/ijbm-09-2021-0440>

- Mostafa, M. (2009): *Modeling the efficiency of top Arab banks: A DEA–neural network approach*. Expert Systems with Applications, 36(1): 309–320. <https://doi.org/10.1016/j.eswa.2007.09.001>
- Northey, G. – Hunter, V. – Mulcahy, R. – Choong, K. – Mehmet, M. (2022): *Man vs machine: How artificial intelligence in banking influences consumer belief in financial advice*. International Journal of Bank Marketing, 40(6): 1182–1199. <https://doi.org/10.1108/ijbm-09-2021-0439>
- 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, 123022. <https://doi.org/10.1016/j.techfore.2023.123022>
- Omoge, A.P. – Gala, P. – Horky, A. (2022): *Disruptive technology and AI in the banking industry of an emerging market*. International Journal of Bank Marketing, 40(6): 1217–1247. <https://doi.org/10.1108/ijbm-09-2021-0403>
- Petropoulos, A. – Siakoulis, V. – Stavroulakis, E. – Vlachogiannakis, N.E. (2020): *Predicting bank insolvencies using machine learning techniques*. International Journal of Forecasting, 36(3): 1092–1113. <https://doi.org/10.1016/j.ijforecast.2019.11.005>
- Prisznyák Alexandra (2022): *Mesterséges intelligencia a bankszektorban*. Gazdaság és Pénzügy, 9(4): 395–402. <https://doi.org/10.33926/gp.2022.4.6>
- Qian, Y. – Wang, F. – Zhang, M. – Zhong, N. (2024): *Political uncertainty, bank loans, and corporate behavior: New investigation with machine learning*. Pacific-Basin Finance Journal, 87, 102480. <https://doi.org/10.1016/j.pacfin.2024.102480>
- Rajka, L. – Pollák, Z. (2024): *Mesterséges intelligencia a hitelkockázati modelleknél*. Gazdaság és Pénzügy, 11(3): 246–273. <https://doi.org/10.33926/gp.2024.3.1>
- Shahbazi, Z. – Byun, Y.-C. (2022): *Machine learning-based analysis of cryptocurrency market financial risk management*. IEEE Access, 10: 37848–37856. <https://doi.org/10.1109/access.2022.3162858>
- Singh, P.P. – Anik, F.I. – Senapati, R. – Sinha, A. – Sakib, N. – Hossain, E. (2024): *Investigating customer churn in banking: A machine learning approach and visualization app for data science and management*. Data Science and Management, 7(1): 7–16. <https://doi.org/10.1016/j.dsm.2023.09.002>
- Sugozu, I.H. – Verberi, C. – Yasar, S. (2025): *Machine learning approaches to credit risk: Evaluating Turkish participation and conventional banks*. Borsa Istanbul Review, 25(3): 497–512. <https://doi.org/10.1016/j.bir.2025.02.001>

- Sun, S. – Qian, G. – Yu, J. (2024): *The impacts of China's shadow banking regulation on bank lending—An empirical analysis based on textual analysis and machine learning*. Pacific-Basin Finance Journal, 88, 102565. <https://doi.org/10.1016/j.pacfin.2024.102565>
- Tang, Y. – Li, H. (2023): *Comparing the performance of machine learning methods in predicting soil seed bank persistence*. Ecological Informatics, 77, 102188. <https://doi.org/10.1016/j.ecoinf.2023.102188>
- Thi Nguyen, L.Q. – Matousek, R. – Muradoglu, G. (2024): *Bank capital, liquidity creation and the moderating role of bank culture: An investigation using a machine learning approach*. Journal of Financial Stability, 72, 101265. <https://doi.org/10.1016/j.jfs.2024.101265>
- Uddin, N. – Uddin Ahamed, Md.K. – Uddin, Md.A. – Islam, Md.M. – Talukder, Md.A. – Aryal, S. (2023): *An ensemble machine learning-based bank loan approval predictions system with a smart application*. International Journal of Cognitive Computing in Engineering, 4: 327–339. <https://doi.org/10.1016/j.ijcce.2023.09.001>
- Wang, L. – Huang, Y. – Hong, Z. (2024): *Digitalization as a double-edged sword: A deep learning analysis of risk management in Chinese banks*. International Review of Financial Analysis, 94, 103249. <https://doi.org/10.1016/j.irfa.2024.103249>
- Xie, C. – Zhang, J.-L. – Zhu, Y. – Xiong, B. – Wang, G.-J. (2023): *How to improve the success of bank telemarketing? Prediction and interpretability analysis based on machine learning*. Computers & Industrial Engineering, 175, 108874. <https://doi.org/10.1016/j.cie.2022.108874>
- Zeinalizadeh, N. – Shojaie, A.A. – Shariatmadari, M. (2015): *Modeling and analysis of bank customer satisfaction using neural networks approach*. International Journal of Bank Marketing, 33(6): 717–732. <https://doi.org/10.1108/ijbm-06-2014-0070>
- Zhou, H. – Sun, G. – Fu, S. – Liu, J. – Zhou, X. – Zhou, J. (2019): *A big data mining approach of PSO-based BP neural network for financial risk management with IoT*. IEEE Access, 7: 154035–154043. <https://doi.org/10.1109/access.2019.2948949>
- Zsinkó Máté (2025): *A mesterséges intelligencia munkaerőpiacra gyakorolt hatása*. Hitelintézeti Szemle, 24(1): 160–175. <https://hitelintezetiszemle.mnb.hu/hsz-24-1-szc1-zsinko>