

DOKTORI ÉRTEKEZÉS

Prisznyák Alexandra

Pécs, 2024

PÉCSI TUDOMÁNYEGYETEM
KÖZGAZDASÁGTUDOMÁNYI KAR

GAZDÁLKODÁSTANI DOKTORI ISKOLA

Prisznyák Alexandra

Bankrobotika és az AI-címkézés

DOKTORI ÉRTEKEZÉS

Témavezető: Dr. Kuti Mónika
egyetemi docens

Pécs, 2024

TARTALOMJEGYZÉK

ÁBRAJEGYZÉK	
TÁBLÁZATOK JEGYZÉKE	
ABSZTRAKT	10
1. BEVEZETŐ.....	1
1.1. A kutatás előzményei.....	1
1.2. Kutatási célok, újdonságtartalom.....	4
1.3. A disszertáció logikai struktúrája és kapcsolódó hipotézisek.....	8
1.4. A szakirodalom áttekintés módszertana.....	12
1.5. Az elemzés megközelítésének újdonságtartalma.....	13
1.6. A disszertáció korlátai.....	14
1.7. A szakirodalom áttekintés korlátja.....	14
1.8. Köszönetnyilvánítás.....	15
2. Bankrobotika.....	16
2.1. Robot-és AI-címkézés jelensége.....	16
2.1.2. Robot-és AI-címkézés: eredet és mögöttes technológiák.....	19
2.1.2. A robot- és az AI-címke közötti különbsége meghatározása.....	25
2.1.3. AI-címkézés és az AI-washing jelenség.....	26
2.2. Bankrobotika koncepció és kutatási terület.....	27
2.2.1. A bankrobotika koncepció eredeti értelmezése.....	27
2.2.2. Bankrobotika technológiák.....	28
2.2.3. A bankrobotika vertikális és horizontális értékteremtésének keretrendszere.....	37
2.2.4. A bankrobotika terület lehatárolásának szükségessége.....	41
2.2.5. A bankrobotika fogalom iterációja és a bankszektor DNS modellje.....	43
3. A bankrobotika jogszabályi keretrendszere.....	50
3.1. A bankrobotika komplex jogszabályi keretrendszere.....	51
3.1.1. A bankrobotika jogszabályi keretrendszerének főbb komponensei.....	53
3.2. AI rendszerek kockázati osztályozása.....	59
3.2.1. Tiltott AI rendszerek.....	61
3.2.2. Alacsony kockázatú AI rendszerek.....	61
3.2.3. Magas kockázatú AI rendszerek.....	62
3.2.4. Generatív AI rendszer szabályozása.....	63
3.3. Magas kockázatú banki AI rendszerek.....	64
3.3.1. Hitelminősítő rendszerek, HR profilozó rendszerek.....	64
3.3.2. Magas kockázatú banki generatív AI modellek.....	67

3.3.3.	MNB Sandbox, InnovationHuB	67
3.4.	<i>Az autonóm AI rendszerek emberi felügyelete</i>	69
4.	Bankrobotika a banki front/middle/back office-ban	73
4.1.	<i>Front office területek és a bankrobotika</i>	74
4.1.1.	Sales, Marketing	75
4.1.2.	Portfólió- és vagyongazdálkodás	80
4.1.3.	Intelligens robotok az ügyféltérben	87
4.2.	<i>Middle office és a bankrobotika technológiák</i>	89
4.2.1.	Az adósminősítés ML-alapú támogatása	90
4.3.	<i>Banki back office és a bankrobotika technológiák</i>	93
4.3.1.	Compliance	93
4.3.2.	Pénzmosás-és terrorizmusfinanszírozás megakadályozása, csalásmegelőzés	94
4.3.3.	Ismerd meg az ügyfeled! - ML modellek a KYC területén	97
4.3.4.	AI lehetőségei az emberi erőforrásmenedzsment területén	99
4.3.5.	Az NLP felhasználási lehetőségei a banki front/middle/back office területeken	102
4.3.6.	A gépi látás lehetőségei a banki front/middle/back office területeken	103
5.	Empirikus elemzés: bankrobotika és AI-címkézés	104
5.1.	<i>Az empirikus elemzés során alkalmazott módszertanok</i>	104
5.2.	<i>Primer kutatási eredmények - mélyinterjúk</i>	107
5.2.1.	Mélyinterjú I. - A bankrobotika terület lehatárolásának szükségessége	110
5.2.2.	Mélyinterjú II.	115
5.3.	<i>Bankrobotika jogszabályi keretrendszerének elemzése</i>	117
5.3.1.	Eredmények szintetizálása: Hipotézis vizsgálat	121
5.3.2.	Mélyinterjúk III.	123
5.4.	<i>Bankrobotika területen alkalmazott robot/AI-címkézés vizsgálata</i>	130
5.4.1.	Az AI szabadalmak világszintű növekedése	132
5.4.2.	Modell választás a szabadalmi adatok elemzéséhez	134
5.4.3.	Az adatbázis: Google Patent Public Database	134
5.4.4.	A szűrt adatállomány bemutatása: Top50Bank_Patents.xlsx	135
5.4.5.	Limitáció és az elemzéshez rendelkezésre álló adatmennyiség	136
5.4.6.	A bankrobotika szabadalmak manuális címkézése	139
5.4.7.	Az elemzési környezet bemutatása: Google Colaboratory	140
5.4.8.	Bankrobotika szabadalmi adatok elemzése	141

5.4.9.	A bankrobotika szabadalmi portfóliók alakulásának elemzése	145
5.5.	<i>A bankrobotika technológiák közötti fedés</i>	152
5.6.	<i>Vektorizáció alapú címkézés: NLP és ML modell alkalmazása</i>	156
5.6.1.	Az 1. modell kiértékelése, eredmények	157
5.7.	<i>A gépi címkézés kiértékelése –Üzleti területi csoportosítás</i>	158
5.7.1.	Bankrobotika technológiák fedése	165
5.7.2.	A 2. modell kiértékelése	166
5.8.	<i>Az AI-címkézés jelensége</i>	167
6.	Összefoglalás: Kutatási eredmények	173
6.1.	<i>A kutatás kiindulópontja: szakirodalmi hiányosságok és kutatási célkitűzések</i>	173
6.2.	<i>Alkalmazott kutatási módszerek és eredmények</i>	176
6.2.1.	A bankrobotika lehatárolásának szükségessége (K1, H1)	176
6.2.2.	A robot/AI-címkézés jelensége (K2, H2)	178
6.2.3.	AI és kapcsolódó technológiák a banki területeken (K3, H3)	179
6.2.4.	Bankrobotika technológiák együttes felhasználása/fedés (K4, H4)	180
6.2.5.	AI-címkézés érvényesülése (K5, H5)	180
7.	Továbbmutató kutatási irány	183
8.	MELLÉKLETEK	185
	IRODALOMJEGYZÉK	248

ÁBRAJEGYZÉK

1. ÁBRA: KUTATÓMUNKÁM SORÁN MEGJELENT PUBLIKÁCIÓIM KUTATÁSI ÚJDONSÁG TARTALMA ÉS KAPCSOLÓDÁSA A DISSZERTÁCIÓHOZ – 1. RÉSZ	7
2. ÁBRA: KUTATÓMUNKÁM SORÁN MEGJELENT PUBLIKÁCIÓIM KUTATÁSI ÚJDONSÁG TARTALMA ÉS KAPCSOLÓDÁSA A DISSZERTÁCIÓHOZ – 2. RÉSZ	8
3. ÁBRA: AZ ELSŐ HÁROM FEJEZET LOGIKAI STRUKTÚRAJA ÉS A VIZSGÁLÓDÁS OK-OKOZATI ÖSSZEFÜGGÉSEI	11
4. ÁBRA: A PRISMA KERETRENDSZER FOLYAMATÁBRÁJA	13
5. ÁBRA: DIGITÁLIS/FIZIKAI ROBOTOK– SAJÁT INTERPRETÁCIÓ	21
6. ÁBRA: TECHNOLÓGIAI KONVERGENCIA ÉS A ROBOT-CMKÉZÉS JELENSÉG KIALAKULÁSA.....	25
7. ÁBRA: ROBOT-ÉS AI-CÍMKE SZŰKÍTÉSI LEHETŐSÉGE A BANKROBOTIKA TECHNOLÓGIÁK ESETÉBEN	27
8. ÁBRA: A BANKROBOTIK EREDETI KONCEPCIÓJÁHOZ TARTOZÓ BANKROBOTIKA TECHNOLÓGIÁK	29
9. ÁBRA: AZ AI-RENDSZEREK GONDOLATI FOLYAMATOKON ÉS VISELKEDÉSEN ALAPULÓ MEGKÖZELÍTÉSE – SAJÁT INTERPRETÁCIÓ	33
10. ÁBRA: AZ AI ERNYŐFOGALMA ALÁ TARTOZÓ ML ALGORITMUSOK	35
11. ÁBRA: A BANKROBOTIKA HORIZONTÁLIS ÉS VERTIKÁLIS ÉRTÉKTEREMTÉSÉNEK MODELLJE.....	38
12. ÁBRA: A BANKSZEKTOR DNS MODELLJE – SZERVEZETI ASPEKTUS NANO, MIKRO ÉS MEZZO SZINTJEL ..	46
13. ÁBRA: A BANKROBOTIKA HORIZONTÁLIS ÉS VERTIKÁLIS ÉRTÉKTEREMTÉSI MODELLJÉBE ILLESZKEDŐ DNS SZINTŰ ALKALMAZKODÁS	49
14. ÁBRA: A BANKROBOTIKA KOMPLEX JOGSZABÁLYI KERETRENDSZERE – FŐBB KOMPONENSEK	53
15. ÁBRA: A BANKSZABÁLYOZÁS SZINTJEI	54
16. ÁBRA: AZ AI-RENDSZEREK KOCKÁZATI OSZTÁLYOZÁSA	60
17. ÁBRA: AZ MNB INNOVATION HUB BANKROBOTIKÁVAL KAPCSOLATOS ELKÉPZELÉSE.....	68
18. ÁBRA: AZ AUTONÓMIA ÉS FELÜGYELETI MECHANIZMUSOKKAL KAPCSOLATOS OPERATÍV KOCKÁZATI SZEMLELÉTVÁLTÁS	72
19. ÁBRA: A BANKI FRONT, MIDDLE, BACK OFFICE SZAKTERÜLETEK - SAJÁT FELOSZTÁS	73
20. ÁBRA: A BANKROBOTIKA TECHNOLÓGIÁK FRONT/MIDDLE/BACK OFFICE TERÜLETI ILLESZKEDÉSE A SZERVEZET NANO SZINTJÉN.....	74
21. ÁBRA: INTELLIGENS ROBOTOK A BANKI ÜGYFÉLTEREKBEK	88
22. ÁBRA: A BANKROBOTIKA TECHNOLÓGIÁK BEÁGYAZÓDÁSA A BANKI FOLYAMATOKBA.....	91
23. ÁBRA: EMPIRIKUS VIZSGÁLÓDÁS MENETE ÉS AZ ALKALMAZOTT MÓDSZERTANOK	105
24. ÁBRA: SZABADALMI MINTA A GOOGLE PATENT ADATBÁZISÁBÓL	133
25. ÁBRA: BANKROBOTIKA SZABADALMAK MEGOSZLÁSA ORSZÁGONKÉNT	141
26. ÁBRA: A SZABADALMAK SZÁMÁNAK ALAKULÁSA A VIZSGÁLT IDŐSZAK ALATT	142
27. ÁBRA: SZABADALMAK SZÁMA BANKONKÉNT 1999-2010 KÖZÖTT.....	143
28. ÁBRA: SZABADALMAK SZÁMÁNAK ALAKULÁSA BANKONKÉNT 2010-2018 KÖZÖTT.....	144
29. ÁBRA: SZABADALMAK SZÁMÁNAK ALAKULÁSA BANKONKÉNT 2018-2023 KÖZÖTT.....	145
30. ÁBRA: A BANKROBOTIKA SZABADALMAK SZÁMÁNAK ALAKULÁSA A VIZSGÁLT IDŐSZAK ALATT	146
31. ÁBRA: BANKROBOTIKA SZABADALMAK IDŐBELI ALAKULÁSA BANKROBOTIKA TECHNOLÓGIÁNKÉNT..	147
32. ÁBRA: BANKROBOTIKA TECHNOLÓGIÁK MEGOSZLÁSA 1999-2010 KÖZÖTT	148
33. ÁBRA: BANKROBOTIKA SZABADALMI PORTFÓLIÓ ALAKULÁSA 1999-2010.....	148
34. ÁBRA: BANKROBOTIKA TECHNOLÓGIÁK MEGOSZLÁSA 2010 – 2018 KÖZÖTT	149
35. ÁBRA: BANKROBOTIKA SZABADALMI PORTFÓLIÓ ALAKULÁSA 2010-2018.....	150
36. ÁBRA: BANKROBOTIKA TECHNOLÓGIÁK MEGOSZLÁSA 2018 – 2023 KÖZÖTT	151
37. ÁBRA: BANKROBOTIKA SZABADALMI PORTFÓLIÓ ALAKULÁSA 2018-2023.....	152
38. ÁBRA: A BANKROBOTIKA TECHNOLÓGIÁK FEDÉSI TÁBLÁZATA A MINTA ALAPJÁN (N=1023; 36 BANKROBOTIKA CÍMKE).....	154
39. ÁBRA: A BANKROBOTIKA TECHNOLÓGIÁK FEDÉSI TÁBLÁZATA A MINTA ALAPJÁN (N=1023; 19 BANKROBOTIKA CÍMKE).....	155
40. ÁBRA: A BANKROBOTIKA TECHNOLÓGIÁK KÖRÉNEK KIBŐVÍTÉSE	156
41. ÁBRA: AZ 1. MODELL FUTTATÁSÁNAK EREDMÉNYE – RÉSZLET A GOOGLE COLAB KÖRNYEZETBŐL.....	158

42. ÁBRA: A FŐKATEGÓRIÁNKÉNT JELZETT KLASZTER HOVATARTOZÁS (N=964 ELEM SZÁM ALAPJÁN)	159
43. ÁBRA: BANKROBOTIKA TECHNOLÓGIÁK ÜZLETI CÉLÚ FELHASZNÁLÁSÁNAK ALAKULÁSA BANKONKÉNT	164
44. ÁBRA: BANKOK BANKROBOTIKA SZABADALMI PORTFÓIÓJÁNAK ALAKULÁSA AZ ÜZLETI CÉLOK TEKINTETÉBEN	165
45. ÁBRA: A 2. MODELL FUTTATÁSÁNAK EREDMÉNYE – RÉSZLET A GOOGLE COLAB KÖRNYEZETBŐL	167
46. ÁBRA: AZ ELMEZÉSBE BEVONT ROBOTOK	184
47. ÁBRA: ÉTIKA SZERVEZETI INTERPRETÁCIÓJÁNAK MEGVALÓSULÁSA – A SZERZŐ ÉRTELMEZÉSÉBEN ..	195

TÁBLÁZATOK JEGYZÉKE

1. TÁBLÁZAT: AI ÉS ROBOT ÁLTAL OKOZTA INCIDENSEK	18
2. TÁBLÁZAT: A ROBOT-CÍMKÉZÉS JELENSÉGE – A ROBOT SZINONIM FOGALMAI A SZAKIRODALOMBAN	24
3. TÁBLÁZAT: A MESTERSÉGES INTELLIGENCIA FOGALOM FEJLŐDÉSE- SAJÁT KATEGORIZÁLÁS	31
4. TÁBLÁZAT: AZ NLP BANKI FELHASZNÁLÁSÁNAK LEHETŐSÉGEI	36
5. TÁBLÁZAT: A BANKROBOTIKA HORIZONTÁLIS ÉS VERTIKÁLIS ÉRTÉKTEREMTÉSÉNEK DIMENZIÓI	39
6. TÁBLÁZAT: PÉLDA A BANKROBOTIKA LEHATÁROLÁSÁT TÁMOGATÓ TÉNYEZŐRE	42
7. TÁBLÁZAT: AZ EMBERI FELÜGYELET AZ AI TÖRVÉNYBEN ÉS AZ ETIKAI IRÁNYMUTATÁS A MEGBÍZHATÓ MESTERSÉGES INTELLIGENCIÁRA VONATKOZÓAN: ÖSSZEHASONLÍTÁS	70
8. TÁBLÁZAT: SALES ÉS MARKETING TERÜLETEN ALKALMAZOTT ML ALGORITMUSOK.....	79
9. TÁBLÁZAT: PORTFÓLIÓ-ÉS VAGYONGAZDÁLKODÁS TERÜLETEN ALKALMAZOTT ML ALGORITMUSOK ..	86
10. TÁBLÁZAT: AML, CFT ÉS CSALÁSMEGELŐZÉS TERÜLETEN ALKALMAZOTT ML ALGORITMUSOK	96
11. TÁBLÁZAT: AML ML MODELL TIPIKUS VÁLTOZÓI A FELDOLGOZOTT SZAKIRODALMAK ALAPJÁN	97
12. TÁBLÁZAT: AZ NLP ALKALMAZÁSI LEHETŐSÉGEI	102
13. TÁBLÁZAT: AZ ELŐZETES MÉLYINTERJÚ RÉSZTVEVŐI.....	108
14. TÁBLÁZAT: A MÉLYINTERJÚK SORÁN VIZSGÁLT KUTATÁSI KÉRDÉSEK ÉS KAPCSOLÓDÁSUK A DISSZERTÁCIÓ KUTATÁSI KÉRDÉSEIHEZ/HIPOTÉZISEIHEZ	109
15. TÁBLÁZAT: BANKROBOTIKA TECHNOLÓGIÁK BEVEZETÉSÉT AKADÁLYOZÓ TÉNYEZŐK (K4).....	113
16. TÁBLÁZAT: BANKROBOTIKA KOMPLEX JOGSZABÁLYI KÖRNYEZET – KÖVETELMÉNY KAPCSOLÓDÁSI PÉLDÁK AZ AI RENDELET, CRR, GDPR KÖZÖTT	118
17. TÁBLÁZAT: ROBOT/AI-CÍMKÉK ÉS MÖGÖTTES TECHNOLÓGIÁK – A MÉLYINTERJÚK TAPASZTALATA ALAPJÁN.....	124
18. TÁBLÁZATA MÉLYINTERJÚK EREDMÉNYEK ÖSSZEFOGLALÓ TÁBLÁZATA	125
19. TÁBLÁZAT: ROBOT OPRISK ESEMÉNYEK A HUNOR ADATBÁZIS ALAPJÁN KIVONATOLVA 2024.08.02-ÁN	127
20. TÁBLÁZAT: A HUNOR ADATBÁZISBAN FELLELT ROBOT-INCIDENSEK POTENCIÁLIS RÉSZLETEZÉSI LEHETŐSÉGE	128
21. TÁBLÁZAT: TOP50BANK_PATENTS.XLSX ADATBÁZIS ADATSÉMÁJA.....	135
22. TÁBLÁZAT: A TOP50 BANK SZABADALMI ADATAINAK RENDELKEZÉSRE ÁLLÁSA	137
23. TÁBLÁZAT: BANKROBOTIKA SZABADALMI PORTFÓLIÓK MÉRETE	140
24. TÁBLÁZAT: A VIZSGÁLT MINTA BANKROBOTIKA SZABADALMI PORTFÓLIÓJA	153
25. TÁBLÁZAT: KLASZTERENKÉNT LEGGYAKRABBAN ELŐFORDULÓ TECHNOLÓGIA	160
26. TÁBLÁZAT: TECHNOLÓGIÁK EGYÜTTES ALKALMAZÁSA	166
27. TÁBLÁZAT: AZ AI TECHNOLÓGIA FEDÉSI MÁTRIXA A VIZSGÁLT MINTÁBAN	168
28. TÁBLÁZAT: A BANKROBOTIKA TECHNOLÓGIÁK ÉS AZ AI FEDÉSE – EREDETI KULCSSZAVAK (36).....	169
29. TÁBLÁZAT: POTENCIÁLIS AI-CÍMKÉK MANUÁLIS ÁTTEKINTÉSE	171
30. TÁBLÁZAT: A GÉPI VALAMINT A MANUÁLIS CÍMKÉZÉS ÖSSZEVETÉSE.....	172
31. TÁBLÁZAT: KUTATÁSI KÉRDÉSEK ÉS HIPOTÉZISEK ÖSSZEFOGLALÓ TÁBLÁZATA	175
32. TÁBLÁZAT: BANKROBOTIKA TECHNOLÓGIÁK FEDÉSI ÉRTÉKEI	HIBA! A KÖNYVJELZŐ NEM LÉTEZIK.
33. TÁBLÁZAT: AI ÉS EGYÉB BANKROBOTIKA TECHNOLÓGIÁK KÖZÖTTI FEDÉSI ÉRTÉKEK	HIBA! A KÖNYVJELZŐ NEM LÉTEZIK.
34. TÁBLÁZAT: A DISSZERTÁCIÓ HIÁNYPÓTLÓ JELLEGE, KUTATÁSI ÚJDONSÁGOK	181
35. TÁBLÁZAT: SAJÁT KUTATÁSI EREDMÉNYEK ÖSSZEFOGLALÁSA A KUTATÁSI KÉRDÉSEK MENTÉN	182

RÖVIDÍTÉSEK JEGYZÉKE

Algoritmus	Rövidítés
Artificial Intelligence	AI
Machine Learning	ML
Natural Language Processing/Természetes nyelvek feldolgozása	NLP
Application Programming Interface/Alkalmazásprogramozási felület	API
Distributed Ledger Technology/Elosztott főkönyvi technológia	DLT
Privacy Enhancing Technology/ Személyes adatvédelmet támogató technológia	PET
Decision Tree/Döntési fa	DF
Random Forest/ Véletlen erdő	RF
Regression tree/Regressziós fa	RT
Boosted Regression Tree/Fejlődő/sokasított regressziós fák	BRT
Naive Bayes	NB
K-Nearest Neighbors/Legközelebbi szomszéd osztályozó	kNN
Support Vector Machine/ tartóvektor-gép	SVM
Neural Network/Neurális hálózatok	NN
Deep Neural Network/ Mély neurális hálózatok	DNN
Deep Learning/Mélytanulás	DL
Hidden Markov Model/Rejtett Markov Modell	HMM
Logistic Regression/ Logisztikus regresszió	LR
Linear Regression/ Lineáris regresszió (PLS, LASSO)	PLS, LASSO
Non-linear Regression/ Nem lineáris regresszió (LARS)	LARS
K-Means Clustering/ K-közép klaszterezés	K-közép
Bayesian Networks/ Bayes-hálók	BN
Q-learning/Q-tanulás	Q-learning
Density-Based Spatial Clustering of Applications with Noise	DBSCAN
Principal Component Analysis/Főkomponens analízis	PCA
Genetic algorithms/Genetikus algoritmusok	GA
eXtensible Business Reporting Language	XBRL
Gradient boosting algorithm/ Gradient boosting algoritmus	GBRT
(Optimal) Long-Short Term Memory/Optimális hosszú rövidtávú memória (NN)	(O-)LSTM
Exponential Long-Short Term Memory/Exponenciális hosszú rövidtávú memória (NN)	ELSTM
Bidirectional LSTM /Kétirányú hosszú rövidtávú memóriát	BiLSTM
Stochastic Gradient Boosting	SGD
Recursive Autoencoders for Feature Extraction/ Rekurzív Autoenkóderek Jellemző Kinyeréshez	RAF

ABSZTRAKT

A mesterséges intelligencia és kapcsolódó innovatív technológiákkal járó kockázatok sebezhetőbbé tették a pénzügyi rendszert. A szakirodalom jelenleg nem jelöl ki egy olyan kutatási területet, amely a bankszektort a maga szigorúan szabályozott jogszabályi/működési környezetében elemezné az AI és kapcsolódó innovatív technológiák banki front, middle, back office területi alkalmazási lehetőségeit, illetve jellemzően benchmarkok felállítására törekszik. Következésképpen, hiányzik az a holisztikus szemléletmód, illetve kapcsolódó vizsgálódási keretrendszer, amely egy elszeparált kutatási területként vizsgálja a szigorú szabályozói környezettel rendelkező bankszektorban alkalmazott AI és kapcsolódó innovatív technológiák felhasználási lehetőségeit. Ezen hiányosság áthalására, kutatómunkám során javaslatot tettem a bankrobotika koncepció kialakítására és kutatási területként történő meghonosítására. A lehatárolt terület hiányából eredően a vizsgálati keretrendszer is hiányzott. Ennek pótlására létrehoztam a bankrobotika vertikális és horizontális értékteremtési modelljét, amely horizontális (nano, mikro, mezzo, makro, globális), valamint vertikális dimenziók mentén (szervezet/bank, befektetők, munkavállalók, regulator) biztosítja a strukturált vizsgálódást. A terület lehatárolás megalapozottsága érdekében a bankrobotika komplex jogszabályi környezetét elemeztem. A megbízható banki AI rendszerek kialakítása érdekében az AI rendeleten és a szektor-specifikus prudenciális szabályozáson (CRR, CRD) túlmenően további Európai Uniói jogforrások figyelembevétele szükséges (Alapjogi Charta, GDPR, DORA, Felhő ajánlás). A disszertáció másik vizsgálódási területeként a robot/AI- címkézés jelensége jelentkezik. A javasolt jelenség a robot/AI szavak univerzális használatával járó kockázatra hívja fel az erőteljesen kockázatkező banki intézmények figyelmét. A technológiák konvergenciájából eredően, a fogalmak szinonim módon történő alkalmazásával a mögöttes technológiák nem kerülnek hangsúlyozásra. Ugyanakkor ezen technológiák eltérő felhasználási lehetőségeik, autonómia szintjük, emberi felügyeleti mechanizmusaik révén eltérő kockázatokat hordozhatnak. A jelenség létezését a mélyinterjúk, illetve a HunOR adatbázis is megerősítette. A vizsgálat eredményeképpen, mind a terület lehatárolási szükségességet, mind a robot/AI-címkézés jelenséget igazoltam. A két témát együttesen a bankrobotika területen megvalósuló robot/AI-címkézés jelenségeként vizsgálom a bankrobotika kulcsszólista által a Google Patent szabadalmi adatbázis alapjára összeállított szűrt adatállományon az összes eszközérték alapján a világ top 50 nagybankjára vonatkozóan.

A technológiák használatának elemzése megerősíti a széleskörű felhasználást, gyakori együttes alkalmazást, és az AI-címkézés jelenség létezését a bankrobotika területen.

Tárgyszavak: *bankrobotika, bankszektor, megbízható mesterséges intelligencia, gépi tanulás, robot, robot-címkézés, AI-címkézés, AI rendelet*

Készítette: Prisznyák Alexandra

Témavezető: Dr. Kuti Mónika

1. BEVEZETŐ

1.1. A kutatás előzményei

A „tradicionális” banki infrastruktúra maradványait lebontó mesterséges intelligencia (Artificial Intelligence, AI), gépi tanulás (Machine Learning, ML), robotok és kapcsolódó innovatív technológiák az erős ügyfélbizalmon alapuló bankszektor területén is széles skálán mozognak (Payne – Peltier – Barger, 2021; Agarwal, 2017). Alkalmazott technológia szempontjából a „bankrobotika” a FinTech területen is megjelenő AI és kapcsolódó innovatív technológiák, mint a ML, (testet öltött) intelligens robotok, a gépi látás (Computer Vision), a természetes nyelvfeldolgozás (Natural Language Processing, NLP), a felhő (Cloud), az alkalmazás-programozási felületek (Application Programming Interface, API), az elosztott főkönyvi technológia (Distributed Ledger Technology, DLT), a blokklánc (blockchain), a kiterjesztett és virtuális valóság (Augmented/Virtual Reality, AR/VR), a kvantum-számítástechnika (quantum computing), az IoT (Internet of Things), illetve a személyes adatvédelmet támogató technológiák (Privacy Enhancing Technology, PET) – továbbiakban bankrobotika technológiák – bankszektori alkalmazását jelenti a banküzemi folyamatok és szolgáltatások racionalizálása és javítása céljából (Prisznyák, 2023c).

Az innovatív technológiák lehetővé tették a pénzügyi intézmények számára a nagyméretű adatbázisokban rejlő potenciál kiaknázását. A Bank of America Global Research, a digitális transzformáció elterjedését (1.) az adatok demokratizálására, (2.) a technológia-és adathasználat tömeges elfogadására, (3.) a technológiai fejlődés dinamizmusára, valamint (4.) a felhasználási megoldások spektrumának szélesedése vezeti vissza (Bank of America Global Research, 2023), amit a Covid19-pandémiás időszak tovább fokozott (Harkácsi – Szegfű, 2021).

Az AI és kapcsolódó innovatív megoldások dinamikus fejlődése a nyílt bankoláson (PSD2) (Torrent – Visani – Bagli, 2020) keresztül lehetővé tette a FinTech és BigTech vállalatok számára a beágyazott szolgáltatások (embedded finance) ügyfelek számára történő nyújtását és a kapcsolódó ügyfélszerzést (Stulz, 2019; Valverde – Fernández, 2020; Resano – Ramon, 2021; Pintér – Herczeg, 2023), ezzel fokozva a versenyt a hagyományos pénzügyi termékek és szolgáltatás nyújtó bankok számára (Diener – Špaček, 2021).

A FinTech - az MNB megfogalmazásában - a pénzügyi szektor technológia vezérelt átalakulásaképp értendő, valamint olyan nem vagy részlegesen szabályozott vállalkozásokra is utal, amelyek célja az innovatív technológiákon alapuló pénzügyi szolgáltatások nyújtása (MNB, 2017; Varga, 2017). A digitális fogyasztói társadalom fizetési szolgáltatási szokásaiban bekövetkező változás (Kreger, 2022) és megnövekedett ügyfélelvárás, valamint a granuláris szolgáltatásnyújtással magas fogyasztói élményt nyújtó FinTech/BigTech megoldásokkal szemben védekező tradicionális bankok versenyképességük fenntartása érdekében a digitális pénzügyi szolgáltatások megváltozott értékeajánlatának irányába fordultak (Kerényi – Molnár, 2107; Horváth, 2019).

A FinTech térnyeréssel járó digitalis transzformáció új üzleti modellek iránti igényt, új termék- és szolgáltatási portfóliót eredményezett a bankok számára (Diener – Dvouletý – Špaček, 2023). Az innovatív FinTech-technológiák kiaknázása a páratlan personalizáció éráját és az azonnali kiszolgálás több csatornán keresztül (omnichannel) történő megvalósulását, valamint a szolgáltatási portfólió megújulását is indukálta, teret engedve az innovatív megoldásoknak, mint a 'Vásárolj Most Fizess Később' (Buy Now Pay Later, BNPL), drive-through bankolás, beyond banking, conversation banking, platformizáció és ökoszisztéma modell (Brewis, 2004; McKinsey, 2019; El-Gohary et al., 2021; KPMG, 2023; FCA, 2023), miközben az AI- és robot-megnevezési jelenség hype-jával is jár (Prisznyák 2023c). Például az ökoszisztémák terén a DBS Singapore létrehozta a DBS Marketplace-t, hogy külső vállalatokkal együttműködve API-kon keresztül együttműködve beépítse szolgáltatásait az ügyfélútba, és új, magasabb ügyfélértékajánlatokat kínáljon (Kien – Weill – Xu, 2019). Túllépve a platform ökoszisztémák világán, 2018-ban a China Construction Bank megnyitotta a világ első teljesen robotok által működtetett bankfiókját, így az ügyfelek már a valóságban is megtapasztalhatják a robotok közelségét (Guardian, 2018). A digitális éra technológiáinak dinamikus elterjedése kihívás elé állítja a bankokat a működési hatékonyság, a kockázatkezelés és a fogyasztói igények háromszögében (Prisznyák, 2023c), amelyhez növekvő szabályozói elvárások és a modern technológián alapuló támogató mechanizmusok (Regulatory Technologies, RegTech) társulnak (Fáykiss et al., 2018; European Banking Federation, 2019; Guerra – Castelli, 2021).

A bankok bevétel maximalizálási törekvéseinek egyik alapvető gátját a prudens működés biztosítását és a kockázati éhség korlátozásául szolgáló bankszabályozás

(Kovács – Marsi, 2018), amely a FinTech technológiák adaptációs korlátjaként is jelentkezik (Kumar et al., 2021; Singhal – Dube – Jain, 2022; Fang et al., 2023; Grünbichler, 2023; Prisznyák, 2023c). Következésképpen kutatásom során a bankrobotikát a FinTech fontos részeként definiáltam. Ugyanakkor leszögeztem, hogy a két fogalom az eltérő fókuszterület és szabályozói kihívások keretrendszere miatt nem tekinthető szinonimának, hiszen a FinTech a pénzügyi szektor szélesebb spektrumán értelmezendő, és a bankszektoron kívül a pénzügyi szektor egyéb területeire is kiterjed. Vagyis, a bankrobotika területén túlmenően a FinTech értelmezési területe szélesebb, így a szabályozói szempontból kevésbé szabályozott piacokat és piaci szereplőkre is kiterjed (Prisznyák, 2023c).

A digitális technológia banki folyamatokra gyakorolt transzformatív hatását számos szerző benchmarkok felállításán, összehasonlításán keresztül elemzi (Sabbeh, 2018; Alt – Beck – Smith, 2018; Loukili – Messaoudi – El Ghazi, 2022; Mandurkar et al., 2022), illetve új magyarázható modelleket (Samek – Müller, 2019; Arrieta et al., 2020) Bussmann et al., 2020; Torrent– Visani – Bagli, 2020; Cao, 2021; Guliyev – Tatoğlu, 2021), mintavételezési technikákat és modellezési megközelítéseket (Leung – Chung, 2020), valamint optimalizáló megoldásokat javasolnak (Zhang et al., 2021; Loukili – Messaoudi – El Ghazi, 2022, Mushava – Murray, 2022).

A globális pénzügyi rendszer stabilitásáért felelős Pénzügyi Stabilitási Tanács (Financial Stability Board, FSB) a banki területeken megjelenő AI és kapcsolódó innovatív technológiák tekintetében az alábbi alkalmazási területeket emeli ki:

- *front office*: az intelligens, biometrikus ügyfélazonosítást, a chatbotok és az okos szerződések elterjedését, a piaci kereskedést, a trend előrejelzést, valamint a modellezést és a hatáselemzéseket támogató szerepét,
- *middle office*: a gépi tanulási modellekkel támogatott hitelelemzési, scoring, ügyfélminősítési, valamint ügyfél szegmentációs megoldások térnyerését,
- *back office*: banki folyamatok esetében a Compliance, a pénzmosás és terrorizmusfinanszírozás megakadályozásában, csalásfelderítésben, a modellezésben (stressz tesztek, anomáliák azonosítása és modellek validációja) betöltött kockázatkezelési és a jogszabályi megfeleléshez nyújtott támogatást (FSB, 2017).

Az AI-hoz és kapcsolódó technológiákhoz kötődő működési kockázatok lényegében informatikai kockázatok (Giudici, 2018; BIS, 2021), amelyek változatosak, (Cheng – Qu,

2023a) és a bankok kockázatkezelési rendszerének megújítását igénylik (EBA, 2024; ISO, 2023; Schuett, 2023; Schnitzer et al., 2024). Az AI rendszerekkel kapcsolatos kockázatok a nem megfelelő kockázatkezelés esetén az egész nemzetközi bankszektort érintően veszélyeztethetik a pénzügyi rendszer működését és stabilitását (Uddin et al., 2023; Diener – Dvouletý – Špaček, 2023). Ugyanakkor a robotok mögött meghúzódó mögöttes technológiák ismerete (robot-és és AI-címkézés jelenséget azonosítottam és tárgyalom) az eltérő kockázati profiljuk felismerése révén hozzájárulhat a felhasználásuktól függő kockázatok megfelelő kezeléséhez és elfogadható szintre csökkentéséhez (Prisznyák, 2024a). Ez a gondolatmenet elvezet a disszertáció kiindulópontjához: *Mit jelent a robot a bankszektorban?*

1.2. *Kutatási célok, újdonságtartalom*

Az AI, robotok, ML és kapcsolódó innovatív technológiák egyes banki területeken történő alkalmazásának vizsgálata bár növekvő szakirodalommal bír, a banki működésre gyakorolt hatásuknak vizsgálata több szempontból is hiányosan valósult meg.

A szakirodalom jelenleg nem jelöl ki egy olyan kutatási területet, amely a bankszektor maga szigorú jogszabályi/működési környezetében elemezné az alkalmazott AI és kapcsolódó innovatív technológiákat.

- ***Ezen hiányosságot kiküszöbölendő, javaslatot tettem a bankrobotika koncepció és kutatási terület meghonosítására, amelynek keretében a bankrobotikát a FinTech alszögmenseként definiáltam*** (Prisznyák, 2023c).

A terület lehatárolásának hiányában a kapcsolódó strukturált elemzési keretrendszer is hiányzik.

- ***Ezen hiányosság áthidalására kialakítottam a bankrobotika vizsgálódási keretrendszerét, a vertikális és horizontális modellt (VHM)***, amely a horizontális: 1.) nano (operatív szint); 2.) mikro (intézmény szint), 3.) mezzo (bankszektor szint), 4.) makro (nemzetgazdasági szint), 5.) globális, teszi lehetővé a vizsgálódást, illetve vertikális értékteremtési dimenzióik mentén: 1.) befektető, 2.) a fogyasztó, 3.) a szervezet (bank), 4.) a munkavállalók, 5) regulátor aspektusából nyújt keretet a célzott vizsgálódáshoz (Prisznyák, 2023c).

A publikációk többsége elfelejtkezik a bank, mint szervezet, működésének egészben történő vizsgálatáról, és jellemzően benchmarkok felállítására törekszik. Így kizárólag

bizonyos dedikált szakterület szempontjából folytatnak vizsgálódást (Patil – Dharwadkar, 2017; Dawood – Elfakhrany – Maghraby, 2019; Zhang – Trubey, 2019; Jullum – Løland – Huseby, 2020; Elrefai – Elgazzar – Khodeir, 2021; Mirete-Ferrer et al., 2022; Zheng. – Zhang – Zhang, 2023), és viszonylag kevés publikáció szorítkozik arra, hogy a bank szélesebb területén folytasson kutatást (Jewandah, 2018; Fisch – Laboure – Turner, 2018; Kaur – Kaur, 2020; Wang, 2023). Továbbá, bár léteznek olyan tanulmányok, amelyek az érintett jogszabályi környezetet (AI rendelet, GDPR, CRR), illetve az azok között fennálló kapcsolódási pontokat vizsgálják, a vizsgálódásuk jellemzően egyoldalú. Fókuszuk kizárólag a jogszabályi oldal felől közelíti a témát. Így a modellek elemzése és a jogszabályi környezet vizsgálata jellemzően nem kapcsolódik össze. Következésképpen, hiányzik az a holisztikus szemléletmód, amely elszeparált kutatási területként kezelve vizsgálja a szigorú szabályozói környezettel rendelkező bankszektorban alkalmazott AI és kapcsolódó innovatív technológiák felhasználási lehetőségeit.

- A bankrobotika terület FinTech-től való elkülönítésének szükségességét *a bankrobotika komplex jogszabályi keretrendszerének 'kialakításán', vizsgálatán keresztül* végeztem el. Összhangban az AI rendelet azon meglátásával, hogy a megbízható banki AI rendszerek kialakítása érdekében nem elégséges az AI rendelet által támasztott és a szektor-specifikus prudenciális követelményeknek való megfelelés biztosítása, hanem további Európai Unió jogforrásokat is figyelembe kell venni (Alapjogi Charta, GDPR, Data Act, DORA, Felhő-ajánlás, ISO sztenderdek).

A robot és AI univerzális szóhasználata nehezíti annak pontos megértését, hogy milyen konkrét technológia áll ezen címkék mögött. Ez a hiányosság veszélyeztetheti a bankok kockázatkezelési gyakorlatát, mivel a különböző technológiák eltérő kockázatokot hordoznak, és a pontos azonosítás hiányában elmaradhatnak a szükséges megelőző intézkedések. Ezt a problémát a bankrobotika kutatási terület alapjaként definiálom, így vizsgálódásomat is ezzel indítom a második fejezetben.

- A szakirodalomban, szürkeirodalomban, illetve a piaci gyakorlatban megjelenő **jelenséget robot/AI-címkézésnek neveztem el.** *A robot/AI- címkézés jelensége ráirányítja a figyelmet arra, hogy a robot/AI szavak univerzális használata valójában olyan mögöttes technológiákra utal, amelyek eltérő felhasználási lehetőségekkel, robot autonómia szinttel, illetve emberi felügyeleti mechanizmussal rendelkeznek.*

Így a kapcsolódó kockázatok sem feltétlenül azonosak. A mögöttes technológia pontos definiálása hiányában elmaradhatnak azon megelőző kockázatkezelési intézkedések, amelyek az új technológiákhoz kapcsolódnak (Prisznyák, 2024a).

További hiányosságként került azonosításra, hogy az etikus AI-al kapcsolatos szakirodalmi cikkek jellemzően az etikus elvek proliferációjával foglalkoznak, és nem fókuszálnak a gyakorlati implementációra.

- Kutatásom során megállapítottam, hogy az AI rendszerek, robotok és kapcsolódó technológiák tervezése és bevezetése során az etikus AI elvek nem érvényesülnek a gyakorlatban és javaslatokat tettem ennek kiküszöbölése érdekében (Prisznyák 2023b).

Végezetül, a szoftver robotok alkalmazása mellett, a hardver robotok bankfióki alkalmazását vizsgáló szakcikkek száma is meglehetősen alacsony (egyetlen forrást találtam).

- Ezen hiányosság pótlására külön cikk keretében foglalkozok a banki humanoid robotok társadalmi elfogadására ható tényezőkkel, amelyek képesek a humán-robot interakciót kedvező irányba befolyásolni. Javaslatot teszek a szakirodalmi elemzés alapján a RoboSapiens Bankercus, mint ideális antropomorph robot koncepció bevezetésére, és megállapítom, hogy a banki robotok tervezése során a dehumanizáció érvényesül (Prisznyák, 2024a).

Az 1., 2. ábra a kutatómunkám során megjelent/publikálás alatt lévő munkáimat ismerteti.

1. ábra: Kutatómunkám során megjelent publikációim kutatási újdonság tartalma és kapcsolódása a disszertációhoz – 1. rész

<p>A bankrobotika horizontális és vertikális értékteremtése és az AI-washing jelenség</p>	<p>The robot-labelling phenomenon. Robot-Ready Modern Operational Risk Management</p>	<p>Bankrobotika: mesterséges intelligencia és gépi tanulás alapú banki kockázatkezelés: Pénzmosás és terrorizmusfinanszírozás megakadályozása</p>
<p>2023c Hitelintézeti Szemle</p>	<p>2024a Journal of Operational Risk (publikálás alatt)</p>	<p>2022b Pénzügyi Szemle</p>
<p>Empíria • Mélyinterjúk</p>	<p>Empíria • HunOR adatbázis (oprisk események)</p>	<p>Empíria • Szakirodalom áttekintő</p>
<p>Saját kutatási eredmény</p> <ul style="list-style-type: none"> Bankrobotika terület vizsgálódási keretrendszerének kialakítása (VHM) Az AI tárgyi eszközként értelmezendő A bankrobotika beruházások megvalósulása során az in-house fejlesztés, a partnering, a felvásárlás, illetve ezek együttese, míg a megközelítés tekintetében a top-down megközelítés, továbbá a menedzsment oldali hiányos AI-ismeretek jellemzőek. Befektetői és fogyasztói nyomás-alapú AI-címkézés alakult ki. 	<p>Saját kutatási eredmény</p> <ul style="list-style-type: none"> Bevezetem a robot-címkézés jelenségét és hangsúlyozom a széles körű, helytelen használatát az irodalomban és a banki gyakorlatban. A robotok, AI és kapcsolódó technológiák banki alkalmazását vizsgálom, és ezekhez társítom a robotok autonómia- és felügyeleti szintjeit, a szakirodalom nem banki területein alapulva. Oprisk területen (HunOR adatbázis alapján) a jelenlegi működés nem rögzíti a robotok autonómiáját vagy az emberi felügyeletet, és az emberközpontú kockázat-kategorizálás dominál. 	<p>Saját kutatási eredmény</p> <ul style="list-style-type: none"> Nincs egyetlen ideális algoritmus. A választást a mögöttes működési logika mellett számos összehasonlítható tényező támogatja. A modellépítés az üzleti IT- és vízionárius menedzsment hibrid szempontjainak kialakítását igényli. A bankrobotika beruházások bevezetését és értékteremtésük megvalósulását akadályozó tényezők fő-és alkategóriákba történő rendszerezése
<p>Javaslat Felügyeleti követelmények és felülvizsgálat az alábbiakra:</p> <ul style="list-style-type: none"> Publikusan elérhető AI-incidens adatbázis vezetése AI-címkék szabályozása a mögöttes technológiák ismeretében és az AI-washing visszaszorítása érdekében. Bankrobotika investíciók nyilvánosságra hozatali követelményeinek meghatározása. A menedzsment, az üzleti és az IT-terület kooperációja az AI-hype generálta túlzott elvárások horgonyzása érdekében. 	<p>Javaslat Oprisk szemléletváltozása az alábbiak figyelembevételével:</p> <ol style="list-style-type: none"> AI-címke mögött lévő technológiák kockázati profilozása a felhasználást figyelembe véve, ember-robot feladatmegosztási (trade-off) katalógusok, és robot/AI incidenskatalógusok vezetése, az operatív kockázati adatbázis modernizálása, képzés, és (robot) Fórum létrehozása a bank szakterületeinek bevonásával. 	<p>Javaslat</p> <ul style="list-style-type: none"> Az AI-kockázati osztályozásához társterületi láncok definiálását javaslom, annak érdekében, hogy a front, middle, back office területeken áthidalóan alkalmazott AI rendszerek potenciális kockázatait hatékonyan kezeljék. Hangsúlyozom az alkalmazott ML modellek validációjában a humán felügyelet fontosságát. A ML algoritmusok közötti körültekintő választást a cél, adatbázis és egyéb tényezők (futási idő) befolyásolják

Forrás: Saját táblázat

2. ábra: Kutatómunkám során megjelent publikációim kutatási újdonság tartalma és kapcsolódása a disszertációhoz – 2. rész

Etikus AI: Javaslat az EU megbízható AI szabályozás hiányosságainak áthidalására és a gyakorlati implementáció támogatására	Robo Sapiens Bankercus: an ideally designed anthropomorph banking service robot?
2023b Gazdaság és Pénzügy	2023c Publikálás alatt
Empíria <ul style="list-style-type: none"> • Mélyinterjúk, • jogszabályi gap elemzés 	Empíria <ul style="list-style-type: none"> • Kérdőív: 26 robot (ebből 7 banki SR) vizsgálata (ember-szerűség, benyomás) 181 válaszadó alapján
Saját kutatási eredmény <ul style="list-style-type: none"> • A gap elemzés az etikus AI iránymutatás és az AI rendelet alapján Eredménye (1): hibás visszacsatolási hurkok meglétéről és kezelésük módjáról, illetve a felügyeletet ellátó személy szükséges képességeiről (rendszerműködés, kapacitás, korlátok megértésének a képessége) az etikus iránymutatás nem részletezi. <ul style="list-style-type: none"> • Az etikus AI elvek jellemzően hiányoznak az üzleti tervezés során → „AI ethics-washing” jelenség	Saját kutatási eredmény Bevezettem az ideális banki robot, a RoboSapiens Bankercus koncepcióját, A résztvevők jelentős eltéréseket mutattak a robotok iránti preferenciáikban: a mérsékelt humanoid robot (Pari) tette a legerősebb benyomást, míg az ember-szerűbb Robot Anna-t tekintették a legemberibb banki képviselőnek. Továbbá, a résztvevők több emberi tulajdonságot tulajdonítottak az értékelt robotoknak, mint amit az ABOT human-likeness prediktora mutatott. <ul style="list-style-type: none"> • a jelenlegi robotok tervezésénél a dehumanizációt érvényesül
Javaslat Etikus AI fejlesztés támogatására a két gap érdekében 20 javaslatot állapítottam meg. <ul style="list-style-type: none"> • Például az etikai kódexek revízióját, a szervezeti stratégiába illesztést, a kockázatkezelési folyamatok kidolgozását, valamint az algoritmusok és a rendszer átláthatóságának biztosítását. 	Javaslat A RoboSapiens Bankercus koncepció további kutatása és alkalmazása a banki robotok tervezése során. Cél: antropomorfiizáció vs. dehumanizáció kényes egyensúlyának megtalálása az 'ideális' banki robotok tervezése érdekében

Forrás: Saját táblázat

1.3. A disszertáció logikai struktúrája és kapcsolódó hipotézisek

A disszertációt az alábbi három fő téma köré szerveztem: (1.) bankrobotika kutatási terület lehatárolása, (2.) a robot-címkézés jelenség létezésének igazolása, (3.) a bankrobotika területen alkalmazott robot/AI-címkézés vizsgálata. Ezen témák mentén összesen öt kutatási kérdés és hozzá tartozó hipotézist vizsgálók.

Az alábbiakban a disszertációban megfogalmazott kutatási kérdések vizsgálatához illeszkedő logikai struktúrát ismertetem, összhangban a 3. ábrával.

A bevezetőt (1. fejezet) követően, a 2. fejezetet tárgyalását a robot/AI-címkézés jelenség tárgyalásaával kezdem, amely a bankrobotika kutatási terület alapjait képezi (a 3. ábrán az első pont). A robot-címkézés jelensége felhívja a figyelmet arra, hogy a robot/AI szavak univerzális használata olyan mögöttes technológiákra utal, amelyek eltérő felhasználási lehetőségekkel és ebből eredően eltérő kockázatokkal rendelkeznek (a 3. ábrán a második pont) (Prisznyák, 2024a). Kapcsolódóan megfogalmazom a H1, H2 hipotézisemet:

H1: A bankszektor szigorú prudenciális szabályozása természetes akadályul szolgál az AI és kapcsolódó technológiák implementációjának, fejlesztésének. A szektor-specifikus sajátosságok figyelembevétele miatt célszerű a területet lehatárolt, önálló területként kezelni.

H2: A szakirodalom alapján a robot/AI univerzális szóhasználat mögött jellemzően az alábbi technológiák húzódnak meg: technológiákra: AI, ML, NLP, gépi látás, kvantum számítás, blokklánc, API, PET technológia, felhő, DLT, AR/VR, IoT. Ezen mögöttes technológiák felhasználási lehetősége a banki front/middle/back office területen különbözik, vagyis eltérő kockázatokat indukálnak – amely összefüggésben áll a kockázatkezelést kiemelten kezelő bankrobotika területtel.

A 2. fejezetben továbbá, bemutatom a bankrobotika koncepciót és (a FinTechtől lehatárolt) kutatási területet (a 3. ábrán a harmadik pont), valamint ismertetem a bankrobotika technológiákat (a 3. ábrán a negyedik pont) és kialakítom a vizsgálódás keretrendszerét biztosító horizontális és vertikális értékteremtési modellt (továbbiakban VHM) (a 3. ábrán az ötödik pont). A bankrobotika fogalom iterációjához felhasználom a digitális transzformáció szakirodalmát, hogy a korábbi kizárólag technológiai aspektust kiegészítsem a szervezetcentrikus látásmóddal is. A technológiai implementáció által előidézett szervezeti, digitális átalakulását a bankoknak, illetve a bankszektornak a DNS metaforával élve szemléltetem a fejezet végén.

A 3. fejezetben a bankrobotika szabályozói környezetének elemzésével folytatom a téma kifejtését (a 3. ábrán a hatodik pont), amely egyrészt az első fejezetben ismertetett FinTechtől való lehatárolás jogosultságát erősíti meg, másrészt hozzájárulhat a robot/AI-címke mögöttes technológiák felhasználási lehetőségeinek azonosítása. Vizsgálatom azt mutatja be, hogy miért nem elegendő csupán az AI rendeletnek való megfelelés a bankszektorban alkalmazott technológiák esetében. A banki és egyéb jogszabályi keretrendszerek (például GDPR) tovább korlátozhatják ezen technológiák bankszektori implementálását, ezáltal megteremtve a bankrobotika kutatási terület létjogosultságát. Mindezzel pótolom a szakirodalom azon hiányosságát, hogy az AI és kapcsolódó innovatív technológiák banki területi vizsgálata, illetve ML modellek alkotása során figyelmen kívül hagyják ezen kritériumok érvényesülését. Ugyanakkor a bankrobotika jogszabályi keretrendszerével kapcsolatos tisztánlátás és az AI-címkezés jelenség együttes megértése (vagyis a mögöttes technológia jogszabályilag elfogadott felhasználási lehetőségei és kockázati besorolása) hozzájárulhat a sikeres AI kockázatkezeléshez.

A 4. fejezetben a HVM segítségével leszűkítem a vizsgálódás fókuszát a banki nano szint szervezeti aspektusból történő elemzésre, amelynek keretein belül az AI, ML, intelligens robotok és kapcsolódó innovatív technológiák banki front/middle/back office területeken megvalósuló alkalmazási lehetőségeit vizsgálom (a 3. ábrán a hetedik pont). Kapcsolódóan megfogalmazom a H1, H2 hipotézisemet:

***H3:** A feldolgozott szakirodalmak alapján a főbb alkalmazási területek a Sales, marketing, portfóió-és vagyongazdálkodás, hitelezési tevékenység, AML, CFT, csalásmegelőzés terület igényei által meghatározottak, amelyeket az irodalmi összefoglaló táblázatokban is szerepeltettek.*

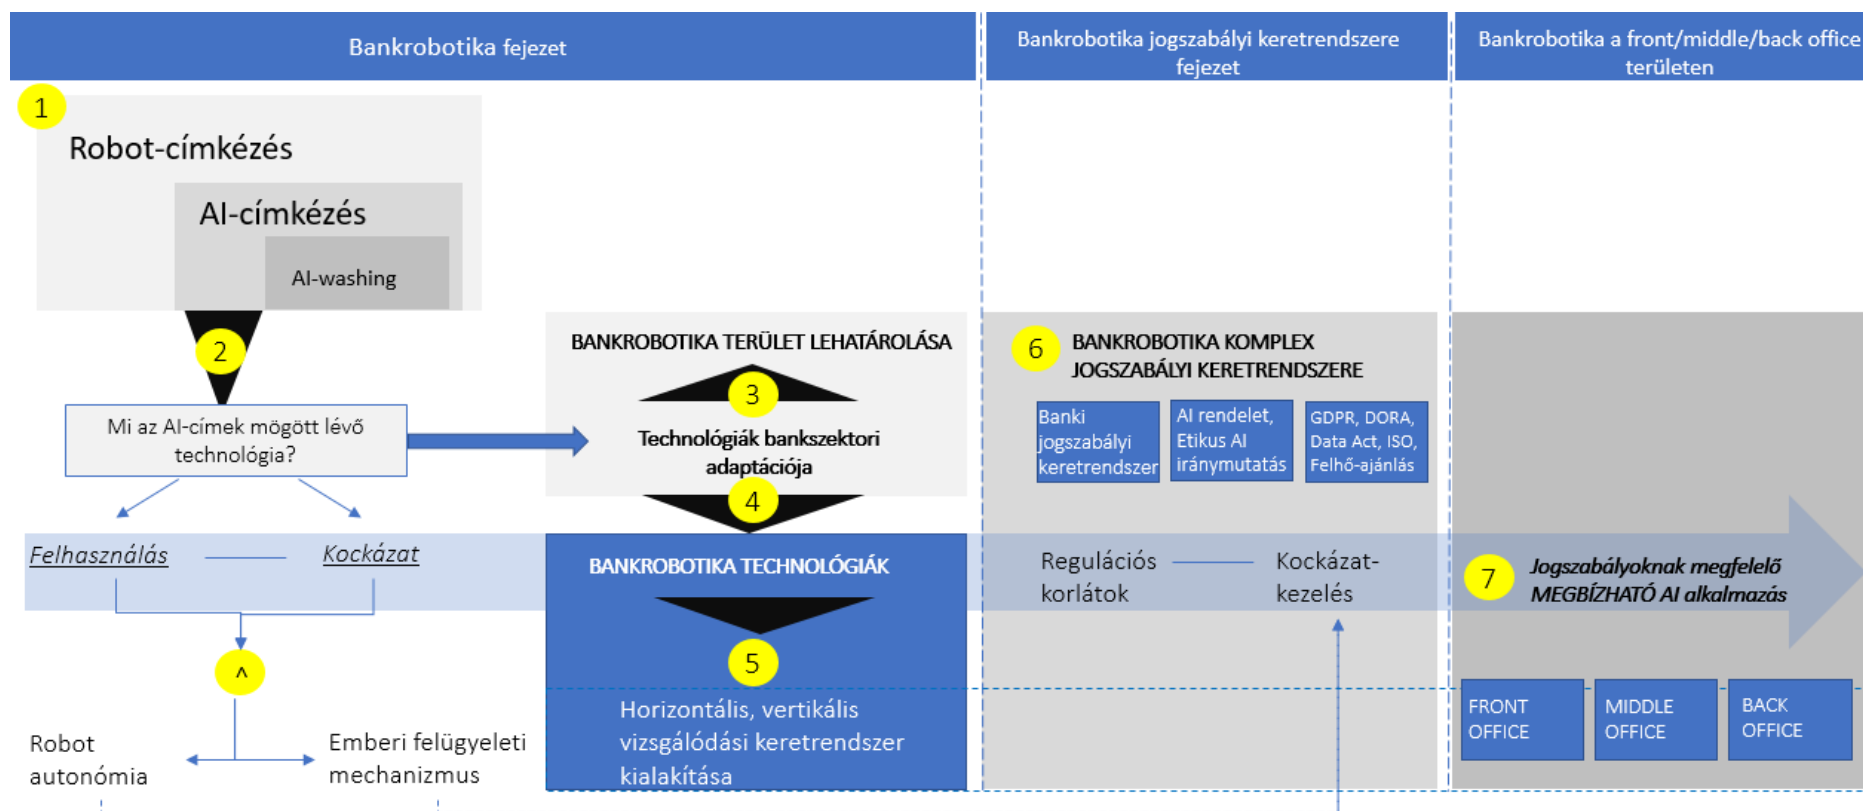
***H4:** Az alkalmazott bankrobotika technológiák önállóan, de más technológiákkal együttesen is jelentős mértékben kerülnek alkalmazásra, igazodva a terület specifikusan megfogalmazott üzleti célokhoz*

***H5:** A szakirodalom alapján megállapított AI-címkézés keretében az AI-címkézés jellemzően az alábbi technológiák esetében kerül alkalmazásra: ML, NLP, gépi látás, intelligens chatbotok, intelligens robotok.*

Az 5. fejezetben az empirikus elemzést végzem el. (1.) lépésként a lefolytatott mélyinterjúk kiértékelését végzem el. Az eredményeket a (2.) lépésként kivitelezett jogszabáyelemzés révén támogatom a bankrobotika terület lehatárolásának alátámasztása céljából. A robot-címkék gyakorlati érvényesülésnek vizsgálatát a (3.) lépésben a HunOR (működési kockázati események) adatbázis elemzésén keresztül végzem el – kiegészítve az e téren szerzett mélyinterjú kutatási eredményeket. Az eredmények alapján megtörténik a döntés a H1-H2 hipotézisekről. Végül (4.) lépésként a két terület együttes vizsgálata valósul meg a bankrobotika területen alkalmazott bankrobotika technológiák szabadalmainak vizsgálatán keresztül, hogy igazolni tudjam a H3-H5 hipotéziseimet. Ezt a Google Patent adatbázis (szekunder adatok) felhasználásával összeállítom a bankrobotika technológiák kulcsós listája alapján adatbázisomat (Top50Bank_Patents.xlsx), amelyet a Google Colaboratory elemzési környezetben Python kódok futtatása révén elemzek a szavak vektorizációja révén. Ezzel a bankrobotika területen érvényesülő robot/AI-címkézés jelenség vizsgálatának tesztek eleget, amire a disszertáció címe is utal egyben.

A disszertáció 6. fejezetében összegzem a kutatási eredményeket és szintetizálom az újdonságtartalmat. A disszertáció utolsó, 7. fejezetében a továbbmutató kutatási irányom kerül bemutatásra.

3. ábra: Az első három fejezet logikai struktúrája és a vizsgálódás ok-okozati összefüggései



Forrás: Saját ábra

1.4. A szakirodalom áttekintés módszertana

A szisztematikus szakirodalom áttekintéshez a felmérő áttekintést (scoping review) egyik módszerét, a PRISMA keretrendszert választottam. A keresés több szakaszból tevődött össze. A szakirodalom feltérképezése érdekében többlépcsős szűrési stratégiát alkalmaztam a PRISMA módszer lépéseit követve, amely keresőmotorok használatával mind induktív és deduktív szűrést tartalmazott. A releváns publikációkat három keresési stratégia révén azonosítottam:

1. Szakirodalom kutatás

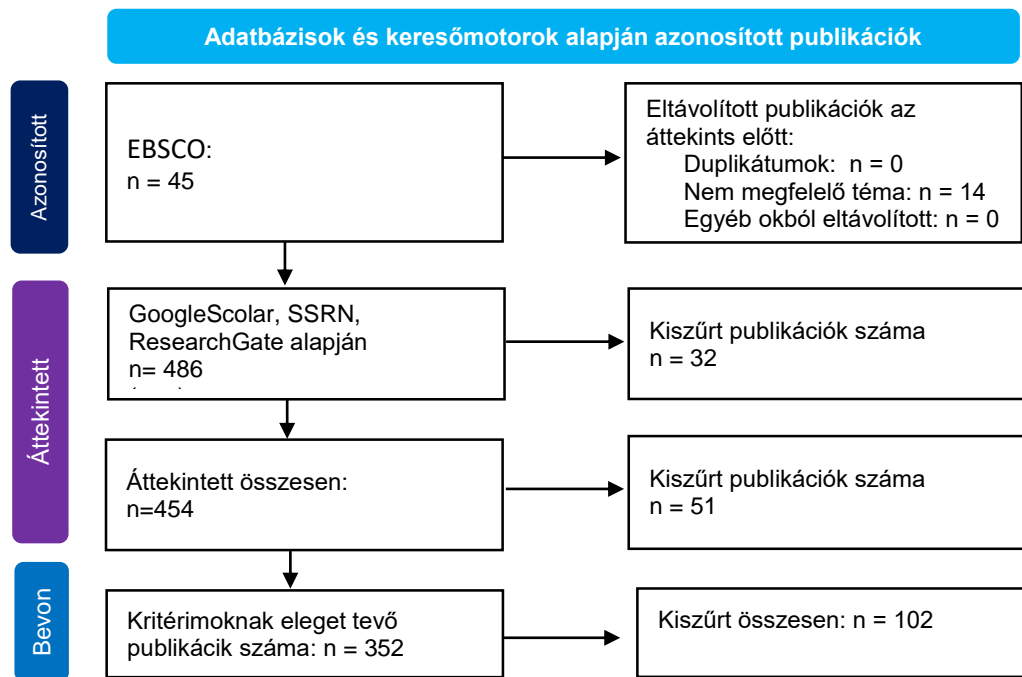
A keresés módja: kulcsszavakra alapozott keresés.

Adatbázisok, források: a tudományos (ellenőrzött) publikációk kiválasztására az EBSCO Discovery Service által elérhető releváns adatbázisokat használtam 2023-ban, amelyek az alábbiak: EBSCO Academic Search Complete (multidiszciplináris), Business Source Premier, EconLit (gazdaságtudomány). A bankszektorra vonatkozóan kevés publikációt azonosítottam, amelyek megfeleltek a céljaimnak (45), így a keresést más keresőmotorokkal egészítettem ki. A tudományos publikációk keresését a GoogleScholar, SSRN, ResearchGate, keresőmotor segítségével tovább bővítettem. A találatokat az első 200 találati listáig ellenőriztem minden keresés esetén, kiszűrve a már áttekintett publikációkat (duplikáció elkerülése) (3. ábra). Kapcsolódóan áttekintettem a szürkeirodalmat is. A körülíró áttekintés módszerének keretében olyan prominens szervezetek által közreadott publikációkat is elemeztem, amelyek az alábbi intézmény kategóriákba tartoznak:

- a) Törvényhozás, jogalkotás, ellenőrzés, végrehajtás (European Parliament/Commission),
- b) Felügyeleti hatóság, jegybank (MNB, EBA),
- c) Független szakértői csoport (HLEG),
- d) Nemzetközi szinten egyéb jelentős nemzetközi szervezetek (ISO, WTO, OECD),
- e) a szakterülethez kapcsolódó szövetség (EBF, IRPA), illetve
- f) Banki tanácsadást végző vállalatok (McKinsey, EY, Deloitte, KPMG, Accenture).

A keresés eredménye a 4. ábrán látható PRISMA keretrendszer alapján közel 500 találatot eredményezett

4. ábra: A PRISMA keretrendszer folyamatábrája



Forrás: Saját szerkesztés PRISMA folyamatábrája alapján

A kulcsszavas keresés és elemzés eredményeképpen összesen 352 forrás került első körben azonosításra a kulcsszavas keresések révén (4. ábra). Az áttekintést és szűrést követően 454 publikáció maradt áttekintési céllal, eleget téve a téma elvárásainak. A publikációk feldolgozása során további 51 munkaanyag került scope területen kívülre a tartalma miatt. A végső feldolgozott publikáció összesen 402. tanulmányt tartalmaz.

1.5. Az elemzés megközelítésének újdonságtartalma

Az adatbázis és az alkalmazott módszertan egyediségét az adja, hogy a szakirodalom alapos áttekintése során nem találtam a banki területen alkalmazott AI és kapcsolódó innovatív technológiák szabadalmi elemzését szolgáló publikációt és ehhez tartozó módszertani leírást, valamint statisztikai modellt, így két feladat állt előttem, egyrészt egy, a kutatási célkitűzéseimet kiszolgáló egyedi adatbázis létrehozása, illetve az ezt támogató statisztikai módszertan implementálása a banki területet érintő AI és kapcsolódó technológiai szabadalmak vizsgálatához. Az elemzést a Google Colaboratory elemzési környezetben Python programozási nyelv révén végeztem el, támaszkodva az NLP és a ML modellezés kombinációjára. A szavak vektorizációja révén a szavak hasonlóságának elemzése alapján történő klaszterező eljárást a K-közép algoritmus biztosította, amely banki szabadalmi adatokra (saját összeállítású adatbázis) történő alkalmazása szintén újdonság a szakterületen.

1.6. A disszertáció korlátai

Limitációként jelentkezik egyrészt, hogy a disszertáció keretei között nem térek ki a fizetési folyamatokra, amely az egyik legkevésbé szabályozott pénzügyi szolgáltatás, ahol a FinTech és BigTech vállalatok jelentős részesedést hasítottak ki maguknak az elmúlt évek során (Stulz, 2019; Valverde – Fernández, 2020). A FinTech, BigTech tárgyalása szétfeszítené a disszertáció kereteit. (Csakúgy, mint a felhő alkalmazások, a blockchain.)

A bankok front/middle/back office területek közül értekezésemben az alábbi területekre koncentrálok: értékesítés (Sales), marketing, portfólió-és vagyongazdálkodás, hitelezés, kockázatkezelés, Compliance (KYI, KYC), pénzmosás-és terrorizmusfinanszírozás megakadályozása, csalásmegelőzés, HR.

A technológiák tekintetében kiemelten jelentkezik a ML, NLP, gépi látás. Mivel az NLP területén jelentkező generatív AI növekvő népszerűségnek örvend, mióta a disszertáció eredeti verziója elkészült, így az értekezés ezt érintőlegesen tárgyalja. További szűkítést jelentkezik az empirikus vizsgálat során a vizsgált bankok köre az elérhető szabadalmi adatok nyelvi korlátai miatt.

1.7. A szakirodalom áttekintés korlátja

A kutatásom ezen szakaszában érvényesülő szakirodalmi kutatás számos limitációt tartalmaz. Előfordulnak olyan publikációk az elemzett dokumentumok között, amelyek a formális jogalkotási hatáskör és/vagy a végrehajtási eszközök hiánya miatt „soft law” és magatartási kódex, irányelv, ajánlott gyakorlatot javasoló jellegűek. Ezen tanulmányok önmagukban nem rendelkeznek kötelező jogi erővel, ugyanakkor bírhatnak bizonyos – jellemzően közvetett módon megvalósuló- jogi következménnyel, célozva a gyakorlati hatás megvalósulását, vagyis a piaci szereplők által megvalósuló implementációt. Ennek köszönhetően a szürkeirodalom területéhez tartoznak. Ezen dokumentumok visszakereshetősége a hagyományos tudományos adatbázisokban kevésbé ismételtető, a tudományos (ellenőrzött) adatbáziskereséshez képest. Ezt a fajta limitációt igyekszem áthidalni azáltal, hogy kizárólag olyan nemzetközileg megalapozott jelenléttel bíró, prominens, esetenként jogszabályalkotó intézmények publikációit alkalmazom, amelyeket a szakirodalom is rendszeresen hivatkozik.

1.8. Köszönetnyilvánítás

Szokás mondani, hogy a doktori kutatómunka alapvetően minden kutató egyéni, rögzös útja, amely úton számomra a bankrobotika lehatárolása és rendszerben történő gondolkodásmódjának kialakítása jelentette a legnagyobb kihívását. Ugyanakkor ez nem csak a kutatásról, de mindenekelőtt a személy fejlődéséről szóló utazás, amely nem sikerülhetett volna azok nélkül, akiknek ezúton szeretném köszönetemet kifejezni.

Elsősorban szeretném megköszönni, a témavezetőmnek, dr. Kuti Mónikának, hogy elvállalta a témavezetésemet és értékelte a téma iránti elszántságomat. Köszönet illeti továbbá, dr. Ozsvald Évát, aki a kutatásom mélypontján karolt fel szellemileg és mind a mesterséges intelligenciával, mind a robotokkal kapcsolatos kimerítő eszmefuttatásaimat türelemmel és érdeklődéssel hallgatta, feltéve a megfelelő kérdéseket, amelyek mentén újult erővel vettem magam bele a kutatás más aspektusból történő közelítésébe.

Hálámat szeretném kifejezni továbbá, a Nemzetköz Bankárképző Központ Zrt. vezetőinek, akik érdeklődést és támogatást tanúsítottak a PhD képzésem iránt. Kiemelt köszönet illeti Öcsi Bélát (Bankárképző CEO-ja) és Marsi Erikát (alelnök), hogy megbíztak 2021-2022 között a tizenkét alkalomból álló Bankrobotika program vezetésével, amelynek keretében egy olyan szellemi közegbe kerültem (Dobák László, Kiss László-ezúton nekik is köszönöm), ahol felfedeztem a témám iránti szenvedélyemet és nagy erővel kezdtem el feltérképezni a banki területeken alkalmazott mesterséges intelligencia, gépi tanulás, intelligens robotok és kapcsolódó technológiák alkalmazási lehetőségeit. Köszönöm Somogyi Virágnak és Mészáros Mártának a szakmai mentorálást, amely a disszertáció elkészítését a szakmai fejlődésem szempontjából támogatta, valamint valamennyi kollégámnak (köztük kifejezetten Barnucz Szilviának), akik folyamatosan érdeklődtek a haladásom iránt.

Hálás vagyok dr. Schmuck Viktornak, akivel kontinenseken átívelő beszélgetéseket folytathattam az AI és robotika témakörében, gondolataim megértő fülekre találtak nála, és számos érdekes tapasztalatot osztott meg velem a robotok világával kapcsolatban.

Köszönöm Édesanyám, Nagymamám, családom biztatását. Végül hálásan köszönöm Ildikónak, aki annak ellenére, hogy nem szakterülete, már kívülről ismeri valamennyi fejezetem tartalmát. Nélkületek nem sikerülhetett volna.

2. Bankrobotika

A mesterséges intelligencia és kapcsolódó innovatív technológiák a tradicionális bankszektor maradványainak újraprogramozó hajtóerejeként átalakítják a pénzügyi rendszert és a bankszektort (Kerényi – Molnár, 2017; Horváth, 2019; Szikora – Nagy, 2020; Bagó, 2023). Az AI és a robotok alkalmazása azonban új működési kockázati típusok felmerüléséhez vezet (Romão – Costa – Costa, 2019; Pintér – Herczeg, 2023; EBA, 2024). A robot/AI- címkével ellátott innovatív technológiák új típusú incidensek megjelenését indukálják, amelyek a címke mögött lévő mögöttes technológia felhasználási területe függvényében eltérő kockázatokat eredményeznek (Prisznyák, 2024a). Ugyanakkor a bankszektor speciális jogszabályi környezete ezen technológiák alkalmazása számára természetes korlátot is állít a prudens és transzparens működés jegyében (Ulrich-Diener – Spacek, 2021; Kumar et al., 2021; Singhal – Dube – Jain, 2022; Grünbichler, 2023; Prisznyák, 2023c). A bankszektor specifikus jogszabályi környezet előírásainak eleget tevő AI rendszerek fejlesztése a terület elszeparált vizsgálatának szükségességét indukálja a megfelelő kockázatkezelés érdekében (Prisznyák, 2023c).

E fejezetben a szakirodalomból hiányzó holisztikus látásmód hiányát pótlom a bankrobotika koncepció és kutatási terület meghonosítására tett javaslatomon keresztül. A terület lehatárolás szükségességének alapvető indokaként felvetem és vizsgálom a robot/AI-címkézés jelenség létezését, továbbá vizsgálom a bankrobotika technológiákat. A bankrobotika fogalmának iterációját a digitális transzformáció vizsgálatán keresztül végzem el. A bankrobotika koncepció két aspektusát (technológiai, szervezeti) a digitális átalakulással járó adaptációs folyamatok kulcsaként határozom meg, amelyek a bankok és az egész bankszektor DNS láncának módosulásához vezetnek.

2.1. Robot-és AI-címkézés jelensége

A mesterséges intelligencia és a robotok lehetővé tették a bankok számára a digitális átalakulást (Fehér – Varga, 2017; Cheng – Qu, 2023). A humán ügyintéző nélküli bankfiókok, amelyeket a szoftver/testet öltött robotok teljes autonómiával működtetnek, már a képzeletet meghaladó valósággá váltak (Prisznyák, 2023c; 2024b). A Bank of America 2017 óta teszteli a teljesen automatizált robot fiókokat, amelyek célja a humán munkavállalók kiváltása a bankfiókokban (Financial Times, 2017). A Nepál SBI Bank, mindössze két munkavállalót alkalmaz a bankfiókban, ahol a működést autonóm gépek és Pari, a humanoid robot, támogatják (Nepal SBI Bank, 2017). 2018-ban a China Construction Bank megnyitotta a világ első, teljesen

robotok működtette bankfiókját, amelyet a Xiao Long nevű robot irányít, aki képes bankkártyát elfogadni, biometrikus azonosítást végezni, számlákat ellenőrizni, és kommunikál az ügyfelekkel (Guardian, 2018). Még az euróövezeten belül is megfigyelhető az AI és kapcsolódó technológiáknak a banki működésre gyakorolt átalakító hatása (Kou et al., 2021; Chen, 2018; Discanno, 2023). Azonban összefüggés van a digitalizáltság foka és a kapcsolódó kockázatok növekedése között (He – Ho – Xu, 2020).

A szoftver/hardver robotok különböző jellemzőkkel, felhasználási területtel rendelkeznek, ugyanakkor számos AI-al kapcsolatos innovatív technológián osztoznak (Gratch et al., 2015). A szoftver és szolgáltató robotok (Service Robots, SR) a javuló képességeiknek és a csökkenő fejlesztési költségeiknek köszönhetően egyre gyakrabban jelennek meg 'munkavállalókként' a banki front, middle és back office területeken (EY, 2016; Boute – Gijsbrechts – Van Mieghem, 2020).

Az AI és a robotok alkalmazása új működési kockázati típusok felmerüléséhez vezet (Romão – Costa – Costa, 2019; Pintér – Herczeg, 2023). A robotokkal kapcsolatos incidensek összefüggésbe hozható rendszerhibákkal, külső és belső biztonsági fenyegetésekkel, modellezési (visszacsatolási hurkok, átláthatóság, magyarázhatóság) (Samek – Müller, 2019; Arrieta et al., 2020), valamint döntéshozatalai hibákkal (diszkriminatív döntéshozatal, torzítás, reprezentativitás hiánya), illetve adatkezelési hibákkal (Giudici, 2018; Schnitzer et al., 2024, Langenbucher, 2022). Az AI-hoz és kapcsolódó technológiákhoz kötődő működési kockázatok informatikai kockázatok (Giudici 2018; BIS, 2021, Cheng – Qu, 2023), amelyek az egész nemzetközi bankszektort érintően egy sebezhetőbb pénzügyi rendszerhez vezethetnek a megfelelő kockázatkezelés hiányában (Ulrich-Diener– Spacek, 2021; Uddin et al. 2023; Diener – Dvouletý – Špaček, 2023). Az alábbi, 1. táblázat, a pénzügyi intézményeket is érintő, robot/AI incidenseket ismerteti. (A robotok és AI okozta működési kockázati eseményeknek illeszkedniük szükséges a Bázeli Bankfelügyeleti Bizottság (BCBS) meglévő működési kockázati taxonómiájába (BCBS, 2021). A BCBS működési kockázati események kategorizálásánál a határeseteket csillaggal jelöltem.) Ahogy a 1. táblázatból látható, a robotok, AI okozta incidensek különböző mögöttes technológiákhoz, felhasználási területhez kapcsolódnak. Ugyanakkor gyakran szinonimaként alkalmazzák őket a technológiák konvergenciája következtében. Ezt a jelenséget robot/AI-címkezésnek neveztem el. (Prisznyák, 2024a).

1. táblázat: AI és robot által okozta incidensek

Érintett intézmény	Potenciális működési kockázati esemény kategória a BCBS alapján	Incidens leírása	Incidens dátuma
Digital wealth management company	Külső csalás (Rendszerbiztonság)	Jogosulatlan hozzáférés az ügyfél információihoz (számlák, portfólió jelentések, tranzakciók) és adózási adatokhoz (biztosítási szám).	2020/10/16
Unnamed big bank	Ügyfelek, termékek és üzleti gyakorlatok (Helytelen üzleti vagy piaci gyakorlatok)	A bank algoritmikus programjai előnyben részesítik azokat az alapokat, amelyek harmadik felektől származnak, akik milliókat fizetnek a bankoknak a vagyonos ügyfelekhez való hozzáférésért.	2017/07/27
FTX	Külső csalás	Egy deepfake készült az FTX korábbi vezérigazgatójáról, amely a közösségi médiában arra szólította fel az embereket, hogy utaljanak pénzt egy névtelen kriptovaluta pénztárcába.	2022/01/22
Unnamed bank	Külső csalás (Rendszerbiztonság)	Csalók deepfake technológiát használva utánozták az igazgató hangját, és arra kérték a menedzsert, hogy hagyjon jóvá egy 35 millió dolláros pénzáttalást.	2020/01/01
Not a bank – relevant due to Pepper	Rendszerek hibájából adódó, üzletmenet megszakadást kiváltó esemény (hardver/szoftver meghibásodás)	A beépített robot meghibásodott, mechanikai hibákat okozott, nem tervezett szüneteket tartott, és nem ismerte fel a korábban találkozott embereket.	2021/07/13
West Bank	Ügyfelek, termékek és üzleti gyakorlatok (Helytelen üzleti vagy piaci gyakorlatok)	Az arcfelismerés alapú rendszer az ügyfeleket nemzetiség alapján figyelte meg és különböztette meg.	2016/01/06
HSBC	Külső csalás (Rendszerbiztonság)	Az ügyfélhang-felismerő azonosítási rendszert egy külső személy által utánozott hanggal törték fel, hogy hozzáférjenek a bankszámlához.	2017/05/19
Unnamed bank	Külső csalás	Rablók egy eszméletlen ügyfél fiókjához fértek hozzá, hogy pénzt utaljanak át arcfelismeréssel.	2022/04/20
Lloyds Bank	Külső csalás (Rendszerbiztonság)	A hangalapú ügyfélazonosítást mesterséges intelligenciával generált hanggal kerülték meg, hogy hozzáférjenek a bankszámlához.	2023/02/22
Reserve Bank of Australia	Reputációs kockázati esemény	A ChatGPT tévesen kapcsolatba hozott egy bankot és egy polgármestert egy vesztegetési ügyben.	2023/03/15
Bank of America	Külső csalás (Rendszerbiztonság)	Egy befektető hangját deepfake technológiával utánozták, hogy megtévesszék a bankot, és pénzt utaltassanak át egy másik számlára.	2023/08/30

Forrás: Saját táblázat az AI Incident Database (2024) alapján (Prisznyák, 2024a)

A robot/AI- címkézés jelensége ráirányítja a figyelmet arra, hogy a robot/AI szavak univerzális használata valójában olyan mögöttes technológiákra utal, amelyek eltérő felhasználási lehetőségekkel (autonómiával/felügyelette) és kapcsolódó kockázatokkal rendelkezhetnek. Ezen kockázatokkal kapcsolatos tisztánlátás igényli, hogy a robot/AI-címke mögött lévő technológiák vizsgáljuk. Így az AI kockázatok sikeres menedzselése igényli az AI

kockázatkezelési keretrendszerek (AI Risk Management Framework, AI RMF) integrálását a már meglévő bank kockázatkezelési rendszerekbe (EBA, 2024; ISO, 2023a; Schuett, 2023; Schnitzer et al., 2024). Annak megválaszolása, hogy pontosan mit jelent a robot, nem könnyű feladat (Robertson, 2017). Ezért a következő alfejezet a robot/AI-címkézés okainak feltárásával és a mögöttes technológiák azonosításával foglalkozik. Mindez egy látszólag „egyszerű” kérdésből ered: mit értünk „robot” alatt a bankszektorban?

2.1.2. Robot-és AI-címkézés: eredet és mögöttes technológiák

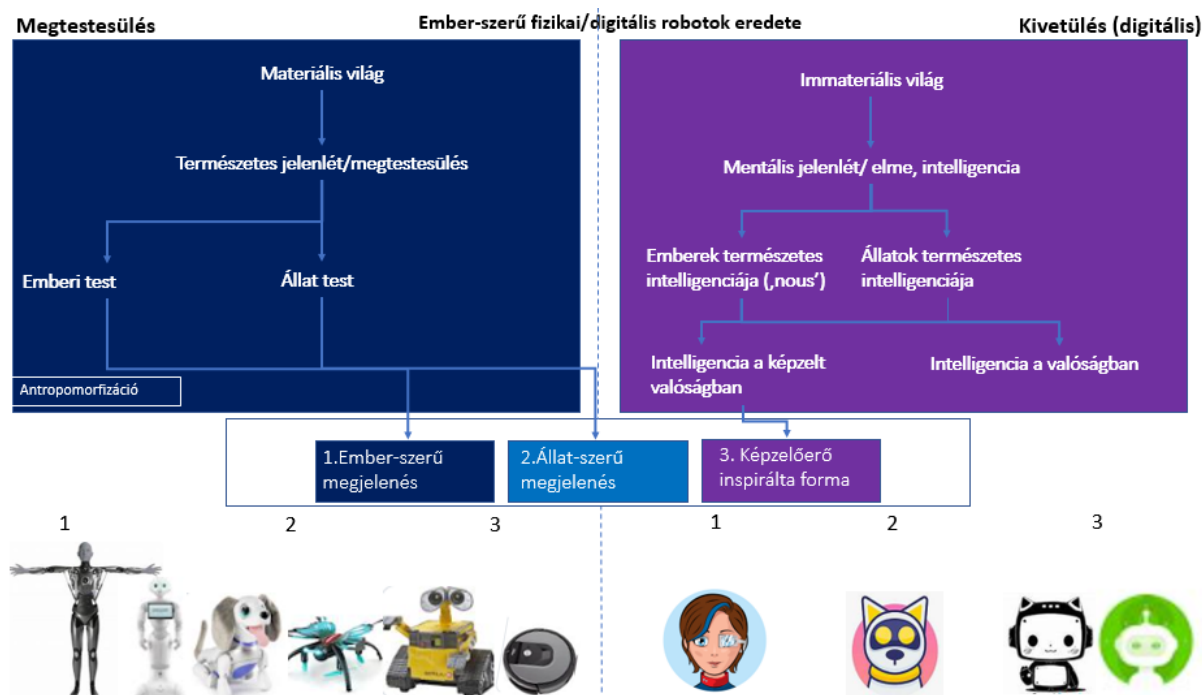
Az AI és a kapcsolódó innovatív technológiák közötti határvonal a technológiák konvergenciájának következtében az idők folyamán összemosódott (Török – Zódi, 2021). Így a szóhasználat tévesen szinonimaként azonosítja az egyébként különálló technológiákat (Prisznyák, 2023b). A bankszektorban a folyamatok „okos” automatizálására (smart automation) és az AI-alapú intelligens megoldásokra gyakran használt kifejezés a „banking robotics”, banki robotika, banki robotizáció (Agarwal, 2017; Sibalija – Jovanović – Đurić, 2019; Vijai – Suriyalakshmi – Elayaraja, 2020; Prateek, 2020; Kedziora – Penttinen, 2021; Prisznyák, 2023b). *Jogosan merülhet fel a kérdés, hogy miért használják a "robotika" és a "banki robot" kifejezéseket a szoftver alapú rendszerekre?*

A robot-címkézés számos tényezőre vezethető vissza (Prisznyák, 2024a). Technológiai szempontból a robot kifejezés a robotikában gyökerezik, ami a robotok tervezésének, gyártásának, működésének tanulmányozását folytató tudományaként egy programozott gép (fizikai ügynök) létrehozására törekszik (ISO, 2012, 2015, 2021). Az ISO 8373:2021 megfogalmazásában a feladatok végrehajtására programozott robot ügynök egy vezérlőrendszer által működtetett, bizonyos fokú autonómiával rendelkező gép (fizikai ágens), amely érzékelés (szenzorok, kamerák, egyebek) révén képes a feladatok célorientált végrehajtására, a fizikai környezetben lévő objektumok megváltoztatásának lehetőségével, elősegítve a humán munkavégzést (ISO, 2021; Russell – Norvig, 2010). Az intelligens robot esetében a szoftver-alapú AI hardveres megjelenési formával társul. Ezen robotok AI rendszert használnak az autonóm működéshez, érzékeléshez és döntéshozatalhoz, ami tovább erősíti a robotika és az AI technológiák, mint elszeparált területek összekapcsolódását. A technológiák (robotika, AI) együttes alkalmazása révén létrejövő intelligens (digitális/hardver) robotot a köznyelv redukálta a robotra (Prisznyák, 2023c, 2024a). Megnyitva a kapukat az ember-szerű (antropomorf) külsővel rendelkező robotok, így ASIMO, AIBO, Kismet, Sophia, AMECA, Optimus, illetve a bankfiókokban is alkalmazott társaik előtt (Pari, OPBA, Robo Anna)

(Prisznyák, 2023c, 2024b). Az ember-szerű robot lények már jóval az előtt történelmünk részét képezték, hogy a technológia lehetővé tette volna létrehozásukat. A robotika tudomány fejlődéstörténetének hajnala egészen az ókori vallási, mitológiai (Talos) történetekig nyúlik vissza (Yates – Vaessen – Roupret, 2011). Nyelvészeti gyökerek tekintetében a robot szó a szláv nyelvekből ered, ahol a monoton, rabszolgamunka-szerű tevékenységre irányul. A szóhasználat popkultúrába integrálása a cseh író, Karel Čapek, *Rossum's Universal Robots (R.U.R.)* című darabjával indult útjának (1920). Az irodalom és filmek fikció-alapú világában a mesterségesen intelligens robotokat, lásd például Asimov híres regényeiben (1942, 1950), olyan ágensként ábrázolják, amelyek célja az ember-centrikus világban az emberi munkaerő helyettesítése a robot autonómia és intelligencia révén (Robertson, 2017; Baraka – Alves-Oliveira – Ribeiro, 2020). Fizikai megjelenésük mellett a filmek gyakran szuper intelligenciával és szabad akarattal rendelkező robotokat jelenítenek meg (*Mátrix* (1999), *Én, a robot* (2004), *Terminátor* (1984), *Transformers* (2007), *Ex Machina* (2015), *Westworld* (2016), *A teremtő* (2023)).

Az intelligens technológiákon osztozó fizikai és virtuális robotok megjelenési formája bár alapvetően különbözik egymástól a létezésük formájából adódóan, ugyanakkor egyaránt rendelkezhetnek ember-szerű jellemzőkkel (gesztusokkal, arckifejezésekkel, megjelenéssel, mozgással, nemmel) (Epley – Waytz – Cacioppo, 2007; Castro-González – Admoni – Scassellati, 2016; Abel – Buccino – Binkofski, 2024). Az antropomorfizmus egy önműködő kognitív mechanizmus, torzítás, egyszerűsítési folyamat, amely a környezetben található jelenségeket, tárgyakat és élőlényeket emberi tulajdonságokkal ruházza fel annak érdekében, hogy az ismeretlen objektumokat, élőlényeket értelmezni tudja a kapcsolódó viselkedési feltételezések révén (Epley – Waytz – Cacioppo, 2007) (5. ábra). Miért fontos ez a robot-címke tárgyalásakor? A filozófiai és pszichológiai gyökerek tekintetében a szoftver-alapú és fizikai robotok megjelenése (képernyőn/testet öltve, illetve ember-szerű megjelenés) meghatározza a robotok felhasználási körét, valamint a fogyasztók humán-robot interakciójához fűződő attitűdjét és elfogadását (Nass – Moon, 2000). Az ember-szerű antropomorf kivetülés ösztönzően hat a humán-robot közötti kapcsolat létesítésére (de Graaf, 2016) – erről bővebben a külön publikációban értekezek (Prisznyák, 2024b). Ez a folyamat elősegítheti a "robot" kifejezés általános használatát, akár különböző technológiai eszközökre (fizikai robotok) és rendszerekre (szoftverrobotok) is.

5. ábra: Digitális/fizikai robotok– saját interpretáció



Forrás: Saját ábra

Amint láhattuk a robot szóhasználat univerzális elterjedése számos okra visszavezethető, amely okok jellemzően összefüggésben állnak a felhasználási területekkel és célokkal.

2.1.2.1. Szoftverrobotok

A bankszektorban alkalmazott szoftverrobotok egyre szélesebb körben jelentkeznek és számos front/middle/back office munkafolyamatban fejtik ki költségcsökkentő, hatékonyságnövelő, felhasználói élményt fokozó tevékenységüket (El-Gohary et al., 2021; Prisznyak 2022a, 2022b, 2023c, 2024a; Uddin et al. 2023). A digitális robotok, mint a virtuális asszisztensek és robot tanácsadók, olyan ügyfél által irányított automatizált online platformok/eszközök, amelyek algoritmus-vezérelt működés alapján különféle folyamatokat képesek támogatni (Jung et al. 2018; Fisch – Laboure – Turner, 2018; Phoon – Koh, 2018). Tripathi (2018) a robotokat olyan szoftver programokként írja le, amelyek az emberi cselekvéseket utánozzák. A különböző szintű autonómiával rendelkező robotokkal támogatott emberi döntéshozatali folyamatok (humán-robot munkaerő kombinálása) egy magasabb szolgáltatásminőséghez vezethetnek (Etzioni – Etzioni, 2016; Lacity – Willcocks, 2016; Novait 2017; Nordea Bank, 2020; Prisznyák, 2022c). A robot képes különböző belső/külső rendszerekkel kapcsolatba lépni a humán feladatok végrehajtása és a döntéshozatal támogatása

érdekében, amelyhez szükséges információt a rendszerbe integrálódva gyűjti össze (Sibaliya – Jovanović – Đurić, 2019). A robotok, mint számítógépes szoftverek, lehetővé teszik az adatok digitalizálását, rögzítését, feldolgozását, az adatok manipulálását (IRPA, 2014). A folyamatok végrehajtását jellemzően ML, gépi látás, NLP és kapcsolódó technológiákkal kiegészülve végzik (Phoon – Koh, 2018; Zheng – Zhang – Zhang, 2023; Wang, 2023).

A gépi látással rendelkező AI rendszer, mint például a KYC folyamatokat támogató hardver/szoftverrobotok, a valós idejű adatok/ képek gyűjtésén, feldolgozásán keresztül könnyítik meg az arc- és biometrikus adatok kezelését (biztonsági rendszerekben, ATM-ben) (Oko – Oruh, 2012; Hannan, et al., 2023; Diksha – Poonam –Awadhesh, 2022). Képesek Továbbá, a bankfiókokban tapasztalt rendellenes tevékenységeket és mintázatok (például támadások, tűz) felismerésére (Nar – Singal – Kumar, 2016; Chai et al., 2021). Az NLP technológiával ellátott robotok felismerik és megértik a beszélt nyelvet (Spiliotopoulos – Androutsopoulos – Spyropoulos, 2001; Suhel et al., 2020), információt nyernek ki hírekből és chatbeszélgetésekből (Gu – Kelly – Xiu, 2020), valamint éves jelentésekből (Azimi – Agrawal, 2021). Mindez olyan hibrid munkafolyamatokat létrejöttét eredményezte, amelyek az AI fejlődésével egyre inkább megkérdőjelezik a természetes intelligencia dominanciáját bizonyos területeken (Song – Kim, 2022). Például, a Capital Bank virtuális asszisztense, Eno, valós időben képes automatikusan figyelmeztetni az ügyfeleket a lehetséges csalásokra, jelenteni a csalárd tevékenységet, zárni az ügyfelek kártyáját, és ideiglenes megoldást nyújtani nekik (Capital Bank, 2024).

Kapcsolódóan, Vijai, Suriyalakshmi és Elayaraja a robotokat olyan adatfeldolgozó, támogató eszközöknek tekintik, amelyek az előre programozott válaszok alapján képesek meghatározott szituációkban (társalgás, chat) az embert megtévesztő módon kommunikációt folytatni és non-stop ügyféltámogatást biztosítani (Vijai – Suriyalakshmi – Elayaraja, 2020). Ezek a robotok dinamikusan is képesek kommunikálni és személyre szabott szolgáltatásokat nyújtani az ügyfeleknek (Phoon – Koh, 2018). A felhasználók kérdéseinek megválaszolását támogatóan, az ügyfélszolgálati AI-alapú chatbotok, rövid időn belül képesek a kért tájékoztatás szolgáltatására a különböző forrásokból származó adatok összegyűjtése révén 7/24 működés során (Jewandah, 2018). Például az OTP Bank Lesya nevű intelligens hangfelismerő robotja tanácsadóként működik (Novait, 2017), míg a Bank of America virtuális asszisztense, Erica, fejlett analitikát és kognitív üzenetküldést használ (Suhel et al., 2020). Ennek eredményeként a robot tanácsadók (megtakarítási robot) és a virtuális asszisztensek (szoftverrobotok) gyakran

AI-alapú banki alkalmazottként működnek, különböző autonómiai szinteken utánozva az emberi tanulási és döntéshozatali folyamatokat (Etzioni – Etzioni, 2016; Nordea Bank, 2020). A robotok a termelékenység növelése és a költségek csökkentése mellett a szervezeti kultúrára is hatással vannak (Fernandez – Aman, 2018). Az EY „Get ready for robots” éves jelentésében a robotokról, mint virtuális munkavállalókról értekezik (EY, 2016), amelyek banki folyamatokban történő alkalmazása hozzájárul a munkaerő magasabb-hozzáadott értékű feladatra allokálásához (Jewandah, 2018; Prisznyák, 2023a). A robotok integrálása révén a bankok újratervezik folyamataikat és stratégiájukat.

A robot tanácsadók olyan (ügyfél irányítású) automatizált online platformok (szoftverek), amelyek algoritmusokat alapul véve nyújtanak széleskörű szolgáltatást (Jung et al., 2018). Phoon és Koh megfogalmazásában a robot-tanácsadás, a robot tanácsadók, illetve digitális tanácsadók elnevezés egyaránt a zéró vagy minimális humán felügyelet mellett operáló automatizált, algoritmus vezérelt digitális platformokra utal, amelyek pénzügyi szolgáltatások nyújtását támogatják (Phoon – Koh, 2018). Ennek eredményeként a robot tanácsadók (megtakarítási robotok a vagyionkezelés-és portfóliógazdálkodás területen) és a virtuális asszisztensek (szoftverrobotok) gyakran virtuális banki alkalmazottak képében kerülnek népszerűsítésre (Nordea Bank, 2020; EY, 2016). A robot jellemzően valamilyen alkalmazott ML modellen alapulva hozza meg a befektetési döntését (Phoon – Koh, 2018; Zheng – Zhang – Zhang, 2023; Wang, 2023). A robottanácsadók személyre szabott szolgáltatást biztosítanak az ügyfelek számára (Phoon – Koh, 2018; Wang – Li – Li, 2020), elősegítik a pénzügyi inklúzió növelését, a megbízási díjak és tranzakciós költségek csökkentését (Wang – Li – Li, 2020), valamint a megbízó és a kereskedő közötti bizalmi válság áthidalását is támogatják (Brenner – Meyll, 2020). A feldolgozott szakirodalom alapján azonosított tipikus robot szókapcsolatokat témánként az 1. számú melléklet szemlélteti.

2.1.1.2. Fizikai robotot

A testet öltött intelligens robotok esetében a szoftver alapú AI hardveres megjelenési formával társul. A szolgáltató robotok (Service Robot, SR) olyan mechanikus eszközök, amelyek az emberi viselkedést utánozhatják, hogy autonóm vagy félig autonóm módon szolgáltatásokat nyújtsanak az embereknek (ISO, 2012). A bankfiókokban alkalmazott intelligens SR-ok célja a kiszolgálás támogatása az ügyfélélmény javítása, a várakozási idők csökkentése és a banki alkalmazottak tehermentesítése révén (Beer – Fisk – Rogers, 2014; Appel et al., 2020). 2010 óta a Santander Group „El Faro” központjában SiGA robotok üdvözlik az oda érkezőket, 2014-

től Pepper robot szórakoztatja az ügyfeleket (HSBC, Mizuho Bank, Rabobank, Capital Bank of Jordan, Emirates NBD, Leumi Group, DSK Bank). A bankszektorban a humanoid robotok, mint NAO, Lakshmi, Sberbasha, valamint Pari, Robot Anna, OPBA és Promobot mellett, a fantázia inspirálta robotok (Link 237) is megjelentek (Prisznyák, 2023b). Ugyanakkor a banki szolgáltató robotok elfogadásával csak néhány publikáció foglalkozik (Amelia – Mathies – Patterson, 2022; Prisznyák, 2023b). Az ismertetett szakirodalom alapján megállapíthatjuk, hogy a robot-címke mögött számos technológia húzódik meg: RPA, AI, ML, DL, robot/virtuális asszisztensek, (intelligens) chatbotok és fizikai robotok, NLP (2. táblázat). Amint láthatjuk, a koncepciók keveredése indukálja, hogy a robot-címkével szinonim módon kerül értelmezése az AI-címke is.

2. táblázat: A robot-címkézés jelensége – a robot szinonim fogalmai a szakirodalomban

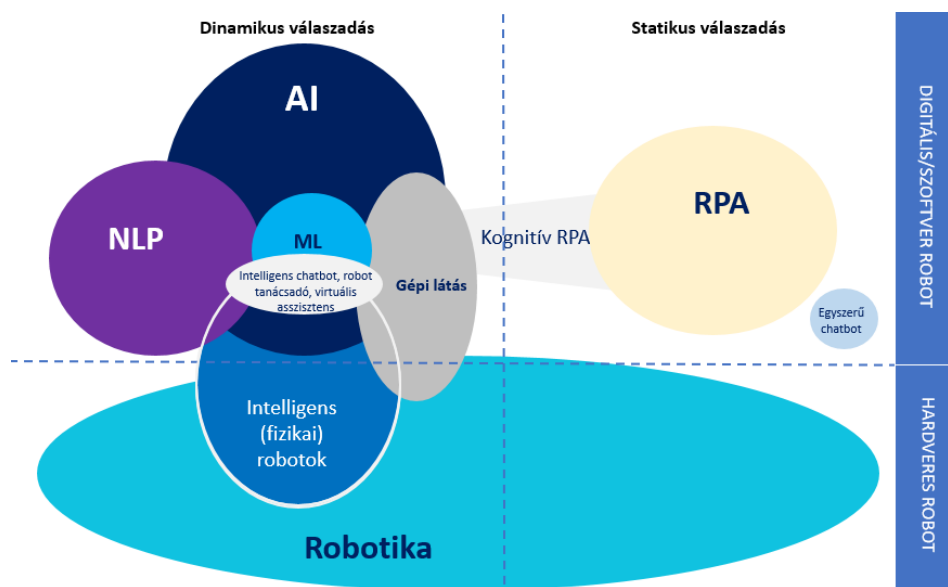
Szerző (év)	Robot-címkézés (mögöttes terminológusok és technológiák)
Jewandah (2018)	Intelligens robot asszisztens (személyi robotok); folyamatautomatizálás (RPA)
Agarwal (2017)	Mechanikus robot, mint bankfióki asszisztens, szoftver robot, mint Siri; robot tanácsadó; RPA (robotikus szoftverügynökök); felhő-alapú robotika
Vijai – Suriyalakshmi – Elayaraja (2020)	Szoftver, amely automatizálja a feladatokat a számítógépen. Szoftverprogram, amely utánozza és integrálja az emberi cselekvéseket, különböző rendszerekkel kommunikálva; RPA robot
Kedziora – Penttinen (2021)	Szoftveres eszköz (RPA), amely széleskörű üzleti folyamatokat kezel, beleértve a tranzakciós feldolgozást, belső és külső jelentéstételt, valamint a végfelhasználókkal való interakciót
Fernandez –Aman (2018)	Robotikus folyamatautomatizálás (RPA), amely automatizálja a folyamatokat és interakcióba lép más számítógépekkel
Lacity –Willcocks (2016)	Elektromechanikai gépek, amelyek emberi feladatokat végeznek; folyamatautomatizálás (szoftver, amely végrehajtja az ismétlődő és unalmas szolgáltatási feladatokat, amelyeket korábban emberek végeztek). RPA automatizál strukturált feladatokat
Prateek (2020)	Hardveres és szoftverrobotok. Folyamatautomatizálás (RPA), a robot adatokat gyűjt és irányít úgy, mint ahogy azt az emberi munkaeő tenné.
Sibalija – Jovanović – Đurić (2019)	Mechanikus robot; RPA - a „robot” egy szoftver alapú megoldást jelent, amelyet arra terveztek, hogy ismétlődő eljárásokat, folyamatokat vagy feladatokat hajtsen végre, általában emberi munkavállalók által végzett munkák helyett
Phoon – Koh (2018)	Robot tanácsadó
Wang – Li – Li (2020)	Intelligens befektetési robotok gépi tanulás alapú algoritmusokon alapulva; robot tanácsadó
Lokman – Ameen (2019)	kognitív/intelligens chatbot (NLP-t használnak a felhasználó kommunikációjának megértésére és reprodukálására (hang, szöveg)
Spiliotopoulos – Androutsopoulos –Spyropoulos (2001)	Beszédalapú párbeszéd rendszer (SDS)/gépi látással és NLP-vel felszerelt robotik asszisztens, hogy kommunikáljon a felhasználókkal és interakcióba lépjen más gépekkel
Suhel et al. (2020)	Robot AI asszisztens (chatbot, beszélgetési ügynök)
Jung et al. (2018)	Robo-tanácsadó (digitális platformok, amelyek intelligens asszisztensként segítséget nyújtanak)

Forrás: saját táblázat

2.1.2. A robot- és az AI-címke közötti különbsége meghatározása

Az AI-alapú rendszereknek megfigyelik a környezetet és önállóan elemzik az információt, következtetéseket vonnak le és intézkedéseket hajtanak végre a környezet változását alapul véve (COM/2018/237 final) (European Commission, 2018). Az RPA estében ugyanakkor az automatizálás az előre programozott statikus válaszadás képességére korlátozódik (Kaya, 2019), amely jellemzően alacsony kognitív képességeket igényelnek (Sibalijsa – Jovanović – Đurić, 2019), így nem foglalja magába a működés során szerzett adatok és tapasztalat révén történő tanulás. Másképp, az RPA egyfajta statikus, önmagától cselekedni és megérteni nem képes technológiát takar (Sibalijsa – Jovanović – Đurić, 2019). Következésképpen, értelmezésben az RPA nem tartozik az AI ernaőfogalma alá, mivel előre meghatározott feladatokat automatizál, míg az AI tanul és alkalmazkodik (IBM, 2024). Ezen megállapításból kiindulva korábbi kutatásom során kizártam az RPA-t a bankrobotikai technológiák közül (Prisznyák, 2023b).

6. ábra: Technológiai konvergencia és a robot-cmkzés jelenség kialakulása



Forrás: saját ábra Prisznyák (2024a) alapján

Vagyis a robot-címkezés szűkítése az AI-címkezés jelenségére egyúttal a bankrobotika mögöttes technológiáinak szűkítését is jelenti az intelligens technológiákra. Így a továbbiakban a statikus válaszadási képességgel bíró RPA-t, illetve egyszerű chatbotot a robot-címkezés alatt,

de az AI-címkézéstől elkülönülten kezeltem (6. ábra). Ezek alapján a határvonalat a robot- és AI-címke között a gépi 'gondolkodási', tanulási képesség és a végrehajtás között húzom meg.

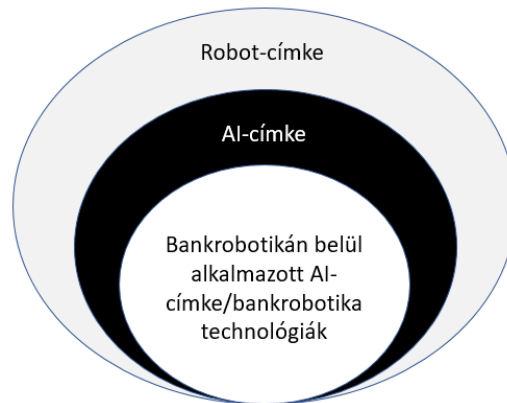
Az RPA intelligens megoldásokkal (genAI) való kiegészítése révén ezek a rendszerek bizonyos fokú tanulásra képesek, és a kognitív RPA területét képviselik, közelítve a dinamikus válaszadási lehetőséget biztosító technológiák felé (Guhathakurta, 2018).

2.1.3. AI-címkézés és az AI-washing jelenség

Amint a robot-címkézésnél láthattuk a robot és az AI szó univerzális használata megnehezíti annak megítélését, hogy valójában AI technológiával van-e dolgunk. State és szerzőtársai alapján az AI-címkét gyakran az alapvető ML-algoritmusokra használják (State, et al., 2023). Seele és Schultz a „machinewashing” kifejezéssel él, hangsúlyozza a szervezetek szándékos megtévesztő, félrevezető magatartását (kommunikáció) (Seele – Schultz, 2022). Kapcsolódóan, a (fogyasztó megtévesztésének tilalmán keresztül) a szabályozó hatóságok felhívják a figyelmet az alkalmazott technológia képességeinek túlzásával összefüggő jelenség létezésére és térnyerésére (Federal Trade Commission, 2021, 2023). Korábbi kutatásom során az AI-washing jelenséget az alábbiaképp fogalmaztam meg „[...] arra a vállalati gyakorlatra/magatartásra utal, amely során a szervezet úgy próbálja magát (reputáció) kedvező pozícióba hozni, hogy a működés szempontjából kiemelt stakeholder csoportok irányába (befektetők, ügyfelek, média, egyébek) hangsúlyozza az AI-alapú működést és megoldásokat, illetve előnyeiket, ugyanakkor érdemleges tevékenységet e területen valójában nem folytat” (Prisznyák, 2023c, p. 103.). Mind a robot, mind az AI-címkézés, illetve az AI-washing jelenség tárgyalása hiánypótló volt szakirodalomban. Hasonlóképpen fogalmazznak az újonnan megjelent publikált munkaanyagok. Az AI-washing célja a különböző érintett csoportok (különösen az ügyfelek, befektetők, média) és a piac (részvényárfolyam) manipulálása azzal, hogy az AI alkalmazását ígérik, miközben a valóságban ezek a vállalatok csak egyszerű, statikus technológiákat és statisztikai módszereket használnak, amelyek nem rendelkeznek a valódi AI jellemzőivel, vagyis a tanulási és alkalmazkodási képességekkel (SEC, 2024; Leffrang – Mueller, 2023). Az AI-címke alkalmazása magasabb szakértelmet sugall, aminek hatására a tanácsok elfogadási hajlandósága nő, annak ellenére, hogy a mögöttes technológia valójában változatlan (egyszerű automatizálási vagy szabályalapú rendszer) (Leffrang – Mueller, 2023). Az AI-washing jelenség kezelése, vagyis a valódi AI-innováció elkülönítése a pusztán AI-marketingtől, kihívásként jelentkezik a szabályozók számára (SEC, 2024).

Az AI-washing jelenség vizsgálata a robot-és AI-címke között egy újabb különbséget eredményez. Vagyis, míg a robot-címke univerzális szóhasználata a technológiák kifejezésének egyszerűsítésére irányul, addig az AI-címke használata mögött nem csak a technológiák konvergenciája miatti téves szóhasználat, hanem a szándékos manipuláció is meghúzódhat (7. ábra).

7. ábra: Robot-és AI-címke szűkítési lehetősége a bankrobotika technológiák esetében



Forrás: Saját ábra

A következő alfejezetekben a bankrobotika koncepció kialakítására és lehatárolására törekszem.

2.2. Bankrobotika koncepció és kutatási terület

2.2.1. A bankrobotika koncepció eredeti értelmezése

Tekintettel a mesterséges intelligencia, gépi tanulás, intelligens robotok és kapcsolódó innovatív technológiák növekvő bankszektori alkalmazására, továbbá, a szigorú, bankszektor-specifikus szabályozói környezetre (szemben a FinTech vállalatok szabályozói környezetével) (MNB, 2017; Fáykiss et al., 2018), *korábbi kutatásom során javaslatot tettem a „bankrobotika” koncepció meghonosítására és szektor specifikus kutatási irányként történő kialakítására* (Prisznyák, 2023c). Az eredeti bankrobotika definíció a bankrobotika technológiai fókuszával és a bankszektor szigorú jogszabályi keretrendszerével közelítette a területet, amikor a FinTech területen is megjelenő innovatív technológiák bankszektori alkalmazásaként határozza meg a bankrobotikát. Ezen bankrobotika technológiák célja a banküzemi folyamatok és szolgáltatások racionalizálása és javítása. Ezzel szemben a FinTech (tágabb kategóriaként) a pénzügyi szektorban megvalósuló szélesebb spektrumán értelmezendő, hiszen a bankszektoron kívül a pénzügy egyéb területeire (szereplőire) is kiterjed. A bankrobotika tehát a FinTech fontos

részeként definiálható, Ugyanakkor a két fogalom az eltérő célok és szabályozói kihívások keretrendszere miatt nem tekinthető szinonimának (Prisznyák, 2023c). A digitális transzformáció és bankrobotika technológiák banki felhasználási lehetőségeinek vizsgálata során szükségesnek véltem a fogalom iterációját (lásd későbbi alfejezet) és a kutatási terület lehatárolását a FinTechtől. (Utóbbit a következő fejezet, A bankrobotika jogszabályi környezete is megerősíti.)

2.2.2. Bankrobotika technológiák

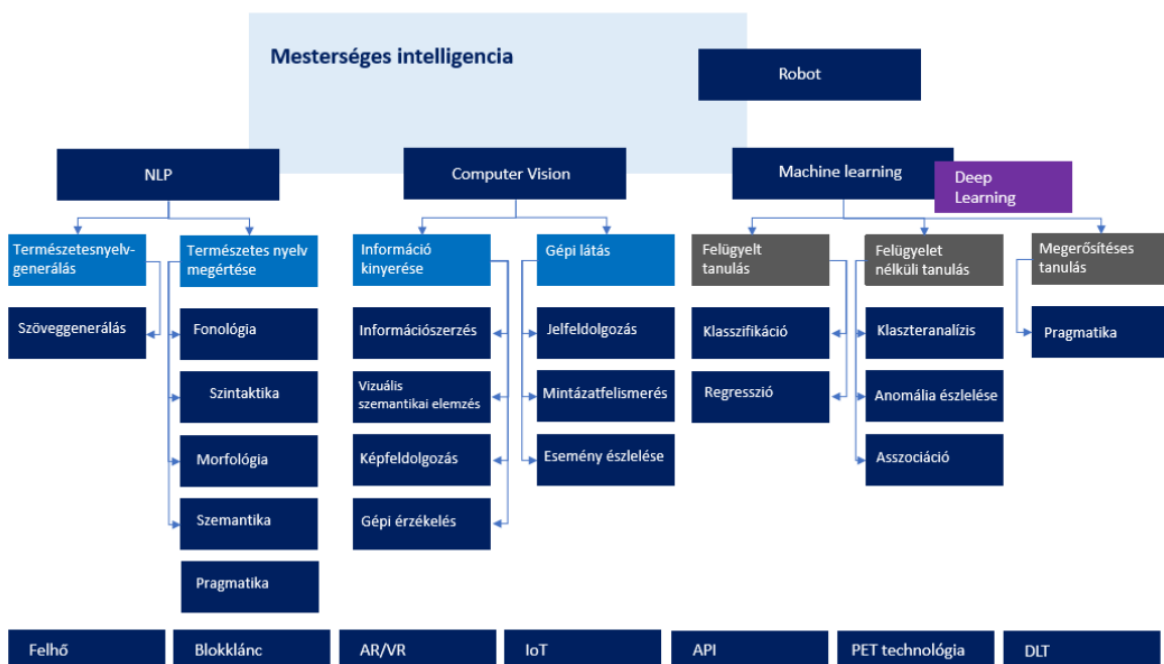
A kutatás kezdetén kérdésként adódott, hogy mely innovatív technológiákat szükséges a bankszektort érintően a bankrobotika alatt vizsgálni? Az első fejezet robot-és AI-címkézése részben választ adott erre, hiszen a technológiák dinamikus/statikus válaszadási képessége, valamint tanulási és adaptációs jellege alapján az RPA-t, illetve az egyszerű chatbotokat a bankrobotika területen kívül eső technológiákként azonosította.

A vállalatoknál alkalmazott mesterséges intelligencia tekintetében Grünbichler (2023) az alábbiakat emeli ki: ML (tanulás, neurális hálózatok, döntési fa, regresszió; klasszifikáció, klaszterezés, k-legközelebbi szomszéd, K-közép, Naïve Bayes, felügyelt tanulás, felügyelet nélküli tanulás, megerősítéses tanulás), nyelvfeldolgozás, beszédfelismerés, RPA, intelligens folyamat-automatizálás, mély. Hasonlóképpen, a Stanford Egyetem AI index tanulmánya az alábbi kulcsszavakat nevesíti az AI terjedésével kapcsolatosan végzett keresések alapján: RPA, mélytanulás, digitális ikrek, arcfelismerés, GAN, tudásgráfok, természetes nyelvgenerálás, beszédértés, szövegértés, fizikai robotok, ajánlórendszerek, megerősítéses tanulás, nyelvi modellek, virtuális asszisztensek (VA) (Shoham, 2018). A Statistics Austria (2023) az adatbányászatot, a ML algoritmusokat, az RPA-t, a beszédfelismerést, a természetes nyelvgenerálást, a képfelismerést és -feldolgozást, valamint az önállóan mozgó robotokat említi a mesterséges intelligencia ernyőfogalom alá tartozó technológiák közül. A McKinsey (2020) tanulmánya alapján a bankszektor átalakításában az alábbi technológiák játszanak kiemelt szerepet: RPA, a számítógépes látás, a természetes nyelvi szövegértés és -generálás, a virtuális ügynökök vagy beszélgető interfészek, a generatív mesterséges intelligencia, a mélytanulás, a tudásgráfok, az ajánlórendszerek, a digitális ikrek, a természetes nyelvi beszédértés, a fizikai robotika, a megerősítéses tanulás, valamint az arcfelismerés és a természetes nyelvi technológiák. A Deloitte (2020) az RPA, a mesterséges intelligencia, a gépi tanulás, a felhőalapú számítástechnika, az IoT, a blokklánc, a DLT és a Big Data dominanciáját emeli ki, míg a KPMG (2019) az AI, a gépi tanulás, a biometrikus adatok és azonosítás, a DLT, a

blokklánc, a felhőalapú számítástechnika, az IoT, a kiterjesztett virtuális valóság, a virtuális asszisztensek és az API technológiák szerepét említi. (Ezek alapján az is látható, hogy az AI, mint címke kerül számos esetben alkalmazásra.)

Kutatásom során az alábbi kulcsszólistát határoztam meg, amelyet az empirikus elemzés fejezetben is alkalmazok: artificial intelligence, AI, machine learning, ML, chatbot, smart bot, robo-advisor, robo-consultant, virtual-advisor, virtual agent, chatbot, softbot, robot, computer vision, natural language processing, NLP, deep learning, neural network, blockchain, cloud, Application programming interface, API, virtual reality, sensor, optical character recognition, OCR, privacy enhancing technology, PET, distributed ledger technology, DLT. (A technológiák az empirikus elemzésnél használt szabadalmi adatok miatt kerülnek angol nyelven említésre a kulcsszólistánál.) Ezek alapján, eredeti megfogalmazásomban a bankrobotika a FinTech területen is megjelenő AI és kapcsolódó innovatív technológiák (a gépi tanulás, testet öltött intelligens robotok, a gépi látás, a természetes nyelvfeldolgozás, a felhő, az alkalmazás-programozási felületek, az elosztott főkönyvi technológia, a blokklánc technológia, a kiterjesztett és virtuális valóság, a kvantum-számítástechnika, az IoT, a személyes adatvédelmet támogató technológiák) (továbbiakban bankrobotika technológiák) bankszektori alkalmazását jelenti a banküzemi folyamatok és szolgáltatások racionalizálása és javítása céljából” (Prisznyák, 2023c,) (8. ábra).

8. ábra: A bankrobotik eredeti koncepciójához tartozó bankrobotika technológiák



Forrás: Saját ábra (Prisznyák, 2023c)

Az alábbiakban a mesterséges intelligencia, ML, robotok, NLP és gépi látás technológiákat ismertetem röviden, előkészítve ezek banki front, middle, back office területi felhasználásával kapcsolatos szakirodalom elemzés (4. fejezet) megértését.

2.2.2.1. *Mesterséges intelligencia: a természetes intelligencia mesterséges manifesztációja*

A mesterséges intelligencia történetét a gépek egyre intelligensebb viselkedést tükröző magatartásával azonosítják. Hátterében ugyanakkor az emberi faktor áll, az emberi elme szárnyalása. Az ókori görög filozófiában megjelenő 'nous' kifejezésként az emberi elme intellektuális gondolkodás, racionális érvelés képességeire és tapasztalás útján felhalmozott tudásra vonatkozóan az értelem vagy az intelligencia kifejezésére használatos (Nikolarea, 2021). Az emberi értelem és gondolkodás terén hasonló kifejezésként a latin nyelvű „intelligentia” vagy „intellectus” is megjelenik (főképp a filozófiában, mint a magasabb rendű gondolkodásra és az intellektuális képességekre utaló cselekvés) (Prisznyák, 2023b). Az intelligencia az egyik legvitatottabb fogalomként számos tudományterületen különféle módon kerül tárgyalásra. A Pedagógiai Lexikon megfogalmazását tekintve az intelligencia, vagy értelmesség, egy olyan összetett probléma megoldási képesség (tanult ismeretek hatékony alkalmazása), illetve annak egyenénenként eltérő foka, amely logikus, elvont gondolkodásra, új információk befogadására, megértésére (tanulás), illetve ezek célirányos alkalmazására teszi képessé az egyént- elvont problémahelyzetekben is (Pedagógiai Lexikon, 1977). Az intelligencia filozófiai aspektusból történő vizsgálata fedésben van az AI-ról alkotott definíciókkal, vagyis jellemzően az egyén/társadalom „megfelelő” gondolkodási módját, viselkedésének megértését taglalja, korszakonként eltérő társadalmi normák konvencionális keretei között. Utóbbi az etikus-AI kialakításában játszhat kiemelkedő szerepet (Prisznyák, 2023b).

Prognózisunk a mesterséges intelligencia fejlődésére vonatkozóan, csak ennek tükrében bontakozik ki igazán, s számos alkalmazással kapcsolatos kérdést -korlátokat és lehetőségeket egyaránt- felvet. Amennyiben egy olyan komplex fogalmat vizsgálunk, mint az AI, nem jelenthet problémát egy egyszerű kérdés megválaszolása: *Mi a természetes intelligencia?*

Az intelligenciát leggyakrabban embereken tanulmányozzák. Ugyanakkor, – ahogy arra korábban számos filozófus utalt- egyéb élőlények intelligenciájának megfigyelése sem eseti megoldás. Mindez napjainkban a gépek által tanúsított intelligencia megfigyelésével és mérésével is kiegészül. Az AI rendszer kontextusba helyezése révén az AI-alapú rendszerek az emberi intelligenciát utánozzák (Kurzweil, 1999), képessé téve a rendszert, hogy egy adott

környezetben, a környezetet érzékelve (Russell – Norvig, 2010), az emberi gondolkodásmód logikai formalizmusa alapján (Weizenbaum, 1976) előre programozott módon (Minsky – Seymour, 1969) bizonyos mértékű autonómiával, önállóan (European Commission, 2018) hozzanak döntéseket bizonyos problémákra és azoknak megfelelően előrelátó működést hajtsanak végre (Nilsson, 2010; HLEG, 2019).

Bár egyelőre hiányzik a mesterséges intelligencia univerzálisan elfogadott definíciója, számos felfogás született az intelligens, gondolkodó gépek meghatározására vonatkozóan (Wang, 2019) (3. táblázat). Ezen fogalmakat tartalmi irányultságukat tekintve a fogalmakat két fő kategóriába sorolom: (1.) az emberi gondolkodásra, illetve (2.) az emberi viselkedésre hasonlító működést leíró fogalmakra. Az ötletet Russell és Norvig szerzőpáros szolgáltatta, akik az AI-t két dimenzió (gondolkodást/cselekvés, illetve racionális viselkedés) mentén négy kategóriában értelmezik: emberi módon gondolkodó/ cselekvő, illetve racionálisan gondolkodó/ cselekvő rendszerek (Russell – Norvig, 2010).

3. táblázat: A mesterséges intelligencia fogalom fejlődése- saját kategorizálás

Mesterséges intelligencia felfogás (kategória)	Szerző	Év
A kognitív architektúrák az emberi agy működéséhez hasonló automatikus, logikus folyamatokból álló rendszerek indirekt módon kapcsolódnak a gondolkodó gépek létezésének felvetéséhez. (1)	Neumann	1948, 1951
Ha egy gép úgy viselkedik, mintha gondolkozna, beszélne, érezne, akkor egy bizonyos ponton már nem különböztethetjük meg (2)	Turing	1950
„Mesterséges intelligenciát hozunk létre, [...] gépeket, amelyek olyan feladatokat tudnak megoldani, amelyek az emberi intelligenciához kötődnek.” (1,2)	McCarthy– Minsky– Rochester– Shannon	1955:2
„Egy számítógépet úgy lehet programozni, hogy megtanuljon jobban sakkozni, mint az, aki írta a programot.” (1,2)	Samuel	1959:11.
„A kérdés az, hogy vajon az emberi gondolkodás minden aspektusa redukálható-e egy logikai formalizmusra, vagy másképpen fogalmazva, hogy az emberi gondolkodás teljes mértékben kiszámítható-e.” (1)	Weizenbaum	1976:7; 12
„Míg a természetes intelligenciával rendelkező emberek a feladatok elvégzését önállóan megtanulják, a számítógépeket programozni szükséges erre”. (1)	Minsky– Seymour	1969: 3
„A fenomenológiai szint alatt a megvalósítási részletek olyan kognitív kerekéből állnak, amelyek eltérnek az emberi agy működésétől.” (1)	Dennett	1984: 14
„Az a kutatási terület, amely az emberi intelligenciát próbálja utánozni.” (1)	Kurzweil	1999:223
A mesterséges intelligencia, mint tevékenység intelligensé teszi a gépeket, lehetővé téve számukra, hogy adott környezetben megfelelően és előrelátóan működjenek. (1,2)	Nilsson	2010
Az AI-t úgy definiálhatjuk, mint ügynököket, amelyek érzékelik a környezetüket és cselekvéseket eszközölnek. (1,2)	Russell Norvig	– 2010

„Az emberi analitikai és/vagy döntéshozatali képességek replikációja.” (1)	Finlay	2018: 11
„A mesterséges intelligencia intelligens viselkedésre utaló rendszereket takar, amelyek konkrét célok eléréséhez elemzik a környezetüket és – bizonyos mértékű autonómiával – intézkedéseket hajtanak végre.” (COM(2018) 237 final) (1,2)	COM/2018/237 final	2018:1
A mesterséges intelligencia olyan rendszerekre utal, amelyek intelligens viselkedést mutatnak környezetük elemzésével és autonóm cselekvésekkel konkrét célok elérése érdekében. Lehet tisztán szoftver-alapú, vagy hardver-be integrált (1,2)	HLEG	2019
Olyan gép-alapú rendszer, amely különböző autonómia szinten képes működni és képes a környezetéhez alkalmazkodni adott célok elérése érdekében az inputok alapján levont következtetések révén, továbbá képes különböző outputok (előrejelzések, tartalom, ajánlások vagy döntések) generálásra képes, befolyásolva ezáltal a fizikai vagy virtuális környezetet (1,2)	AI rendelet (EU) 2024/1689	2024

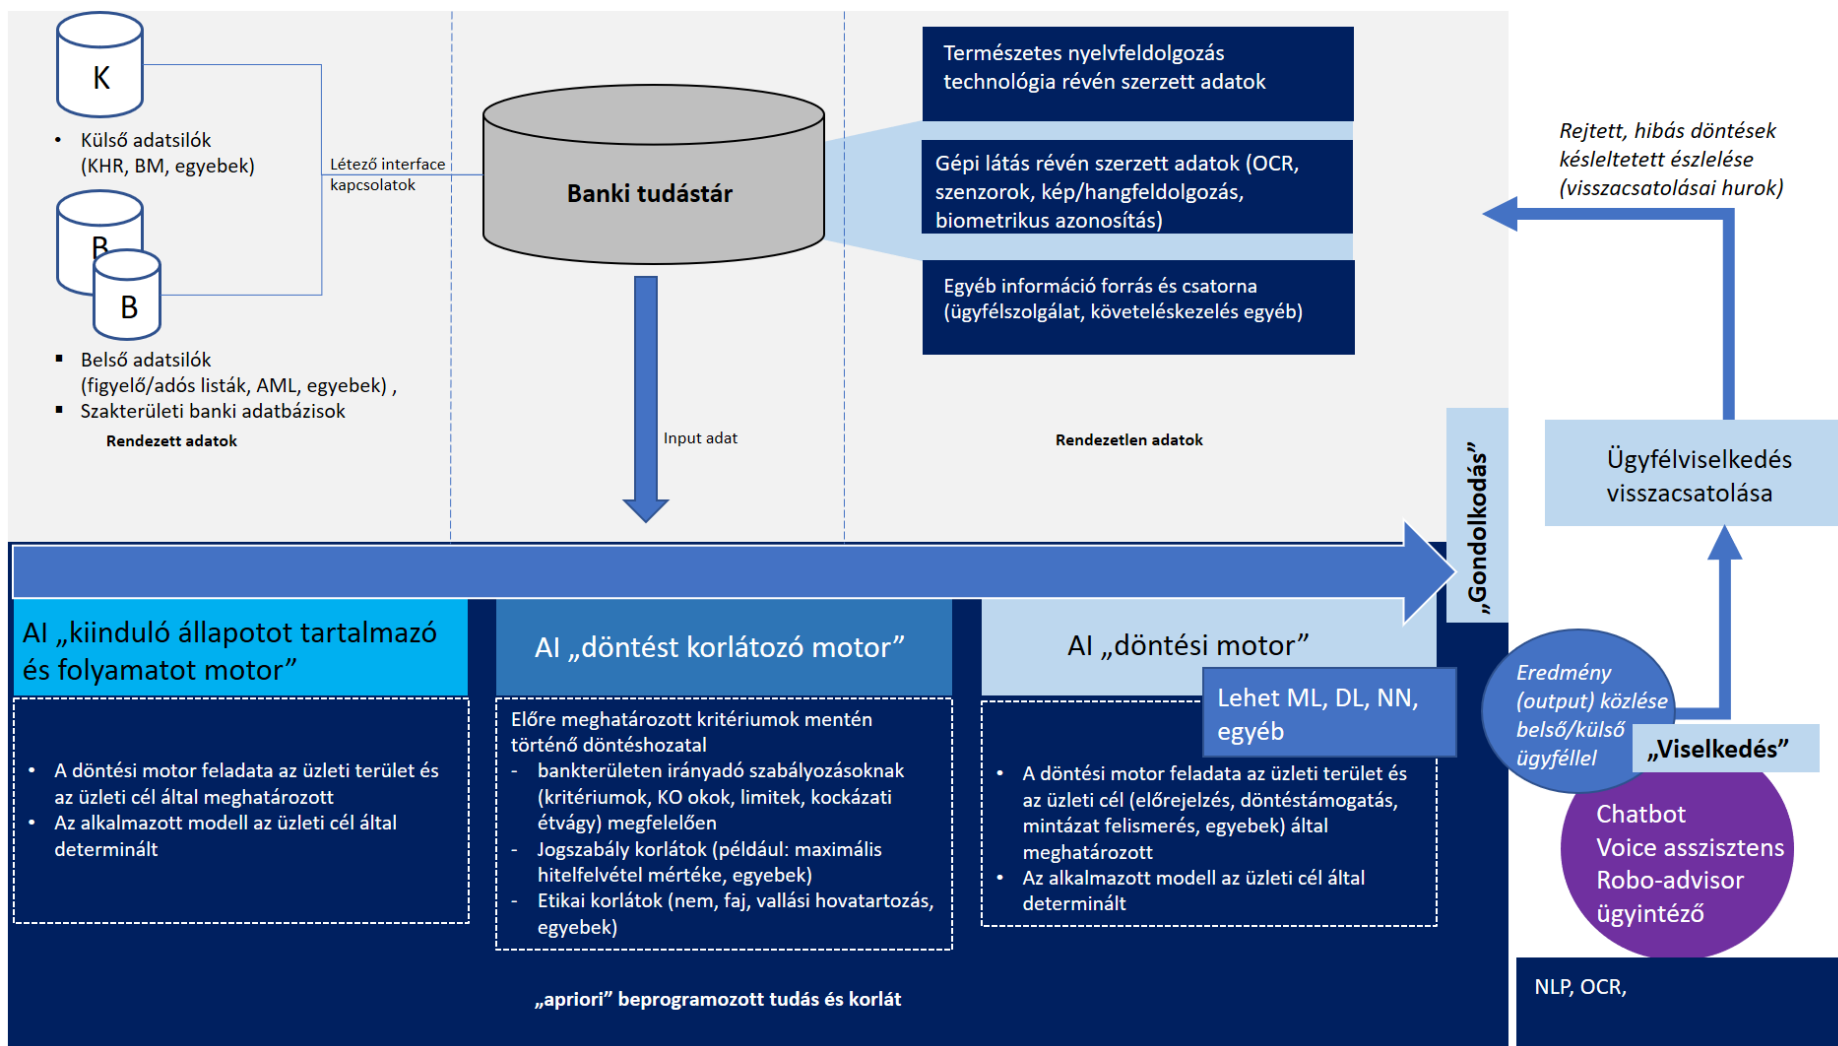
Forrás: Saját táblázat

Mit jelent tehát a mesterséges intelligencia? Amint láthattuk, egységesen elfogadott definíció hiányában, a történelmünk és tudományterületeink menetén körvonalazódva, jelenthet: absztrakciót, logikát, mérést, önismeretet, tanulási folyamatot, érzelmi tudást, tervelés és érvelés képességét, kreativitást, gondolkodást és problémamegoldást is. Ami egyértelműen látszik a felsoroltak tükrében, hogy (1) képességre irányul a fogalom, illetve magában hordozza a (2) nem materiális (mentális) természeti jelleget, Továbbá, (3) tudással összefüggő tevékenységre (észlelés, gondolkodás, problémamegoldás) utal, illetve látens tényezőként feltételezi (4) a (korábban) észlelt/szerzett információ alapján történő aktív reagálás (következtetés) a környezet változására (adaptív viselkedési formában). (A mesterséges intelligencia fejlettségi szintjeinek összehasonlítását az 2. számú melléklet tartalmazza.)

2.2.2.2. *Az AI-rendszerek komplexitása és az alkotó komponensek*

Az AI-rendszerek olyan AI-alapú szoftvert és/vagy hardvert komponenseket tartalmaznak, amelyek jellemzően más rendszerekbe beágyazottan működnek (HLEG, 2019). Az AI rendszer minden egyes komponense kiemelt feladatokat lát el, és a rendszer egészének működését szinergiahatások révén támogatja. Az AI rendszer a környezet elemzése céljából a gépi látást biztosító szenzorokat (érzékelők, kamerák), természetes nyelvfeldolgozási elemeket, valamint döntés-támogató gépi tanulási algoritmusokat is tartalmaz (HLEG, 2019, pp: 2; Chai et al., 2021). A feladat (döntéstámogatás, előrejelzés) végrehajtásáért felelős AI-motor integráltan működik együtt a többi alkotókomponenssel (ML, NLP, gépi látás) (9. ábra).

9. ábra Az AI-rendszerek gondolati folyamatokon és viselkedésen alapuló megközelítése – saját interpretáció



Forrás: Saját ábra

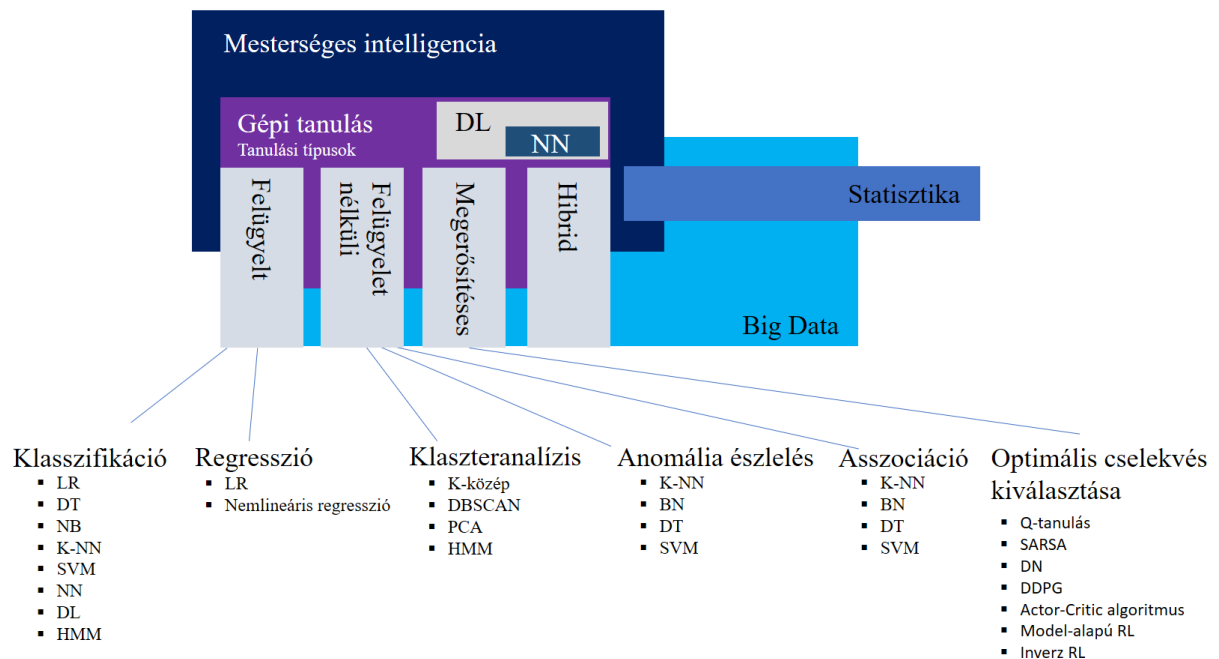
A fentiekben egy AI-rendszerhez kapcsolódó szabadalom (US-20200175424-A1) tovább gondolt, banki környezetbe helyezett felhasználási lehetőségét ábrázolom. A saját interpretációs ábra annak megértését szolgálja, hogy az AI és a kapcsolódó innovatív technológiák miképpen kapcsolódnak egymáshoz, és alkotnak egy komplex rendszert az emberi gondolkodás imitálására. Ebből következően az AI-rendszert nem lehet azonosítani kizárólag valamely rendszer komponensét alkotó technológiákkal, mint az ML és NLP. Ez összefüggésben áll Panigutti és szerzőtársai azon megállapításával, amely szerint az AI modell csupán egy összetevője az AI rendszernek (Panigutti et al., 2023). Vagyis a gondolkodás (AI motor) és az a rendszer által produkált viselkedés (output) számos AI rendszer al-komponens együttműködés révén valósul meg. Ez a megállapítás alátámasztja a robot-és AI-címkezésnél/washingnál leírtakat, amelyek a mögöttes technológiák megismerésére és az összefüggő kockázatok kezelésére hívják fel a figyelmet. Meglátásom alapján, bár ezek a rendszer komponensét alkotó technológiák fontos szerepet játszanak a rendszer felépítésében, önállóan nem reprezentálják a rendszerszinten megvalósuló autonóm működési képességet. A mesterséges intelligenciát csak az összetett rendszer működésének eredményeként értelmezhetjük, és nem önálló alkategóriaként. Eredményképpen az AI (jellemzően), mint rendszer kerül definiálásra (European Commission, 2018). Ennek ellenére előfordulnak olyan publikációk, amelyek az AI-t - az AI-címkezés eredményeképpen - szinonimaként alkalmazza valamely ernyőfogalma alá tartozó technológiával. (Szándékolt esetben ez az AI-washing jelenséget eredményezi.)

2.2.2.3. *Machin learning*

A gépi tanulás az ISO/IEC 38505-1:2017 meghatározásában olyan folyamat, amely meglévő adatok alapján, algoritmusok használatán keresztül lehetővé teszi a jövőre vonatkozó előrejelzések készítését (ISO, 2021), illetve előre beprogramozott menetű feladatok végrehajtására (EBA, 2020). A ML modellépítés fontos kérdése a tanulási módszer típusa. Az EBA az algoritmusok tanulási folyamatát az alábbiak szerint csoportosítja: (1.) felügyelt (feladat vezérelt, regresszió, klasszifikáció), (2.) felügyelet nélküli (adat-vezérelt, klaszterek kialakítása), (3.) megerősítő tanulás (környezettel lezajló interakció által vezérelt), (4.) félig felügyelt tanulás (a felügyelt és a felügyelet nélküli hibrid verziója) (EBA, 2020). A népszerű ML algoritmusokhoz rövidítései a rövidítésjegyzékben kaptak helyet.

Amint a következő fejezetben látni fogjuk banki területenként (célonként) eltérő algoritmusok kerülnek alkalmazásra és töltenek be célorientált működésük hatékonyságánál fogva benchmark szerepet. Bár az algoritmusok összehasonlítása nem képezi jelent értekezés témáját, a 10. ábra a leggyakrabban alkalmazott algoritmusokat és azok csoportosítását mutatja.

10. ábra: Az AI ernyőfogalma alá tartozó ML algoritmusok



Forrás: Saját forrás

A népszerű algoritmusok gyengeségeit és erősségeit a 3. számú melléklet, míg a ML modellépítés folyamatát a 4. számú melléklet, a kiválasztott algoritmusok összehasonlítását a számítási komplexitás tényezői alapján pedig az 5. számú melléklet ismerteti.

A ML modellek kockázatával összefüggésben kezelendő jelenség a diszkriminatív döntéshozatal és a negatív visszacsatolási hurkok megléte (HLEG, 2019, 2020). A prudens működést támogató alapvető követelményként jelentkezik az alkalmazott modellek átláthatósága és megmagyarázhatósága (Samek – Müller, 2019; Arrieta et al., 2020; Leung – Chung, 2020), a fekete doboz (black box) jelenségek megakadályozása (EBA, 2021; EBA, 2023).

2.2.2.4. Természetes nyelvek feldolgozása

A természetes nyelvfeldolgozást támogató technológia a nyelvszabályok halmazaként/szimbólumkészletként történő értelmezésén alapul, ahol a szimbólumok kombinációja lehetőséget biztosít az információ kinyerésre (Khurana et al., 2023). Az NLP segíti az AI ügynököt abban, hogy a természetes emberi nyelvet használva kommunikáljon a humán-robot/AI interakció során. Az NLP a természetes nyelv megértése (Natural Language Understanding, NLU), illetve természetes nyelvgenerálás (Natural Language Generation, NLG)

technikái révén támogatja. Az NLP felhasználási lehetőségeit az alább, 4. táblázat összegzi, míg banki front/middle/back office területen való alkalmazásáról a 4. fejezet értekezik.

4. táblázat: Az NLP banki felhasználásának lehetőségei

NLP felhasználása	Technológia rövid leírása
Automatikus összegzés	szöveghalmaz érthető összefoglalása
Társreferencia lebontás	szövegrészben előforduló ugyanazon entításra utaló említések azonosítása
Diskurzus elemzés	a diskurzusszerkezet (szöveg, korpusz) kontextushoz történő viszonyítása
Gépi fordítás	a szöveg automatikus fordítása egy adott nyelvről egy másikra
Morfológiai szegmentáció	fonológiai tartományon belül a szavak egyéni jelentéstartalmának lehatárolás
Nevesített entitás felismerés	adott entítások azonosítása és osztályozása a szövegben
Optikai karakterfelismerés	dokumentumokból, képekből származó szöveg felismerése
Beszédrész-címkézés	a korpuszban lévő szavak kontextus alapú kategorizálása
Hangul/érzelelemelés	a beszélő érzelmi állapotának, reakciójának elemzése

Forrás: Saját táblázat

Az exponenciálisan fejlődő természetes nyelvfeldolgozás segíti az ügyfelek és banki alkalmazottak döntéshozatalát azáltal, hogy hiteles ügyfélinterakciókat és jobb betekintést biztosít az ügyfeladatokba, csökkentve ezzel a manuális elemzések költségeit, miközben elkerüli a diszkriminatív gyakorlatokat és biztosítja a magánélet védelmét (Sheetal et al., 2024). A banki felhasználási lehetőségek a 4. fejezetben tárgyalom.

2.2.2.5. Gépi látás

A képek kiértékelése alapján adatokat szolgáltató eljárások gyűjtőfogalmaként a gépi látás technológia magába foglalja a gépi képfeldolgozás, kiértékelés feladatokat ellátó gépi mechanizmust (dokumentumok kezelése, műveletek). A képfeldolgozás a vezérléssel, illetve értelmezéssel összefüggő feladatokat is magába foglalja, így a valós világ és benne lévő objektumok érzékelése során kiemelt szerepet tölt be a robotok adatfeldolgozásakor – jellemzően valamilyen ML algoritmus támogatásával. A bankok esetében a biztonsági rendszerek és ATM-ek valós-idejű biometrikus adatainak feldolgozásában, az abnormális mintázatok (támadás, tűz) felismerése is szerepet játszhatnak (Oko – Oruh, 2012; Nar – Singal – Kumar, 2016; Chai et al, 2021), illetve sikeresen támogathatják a dokumentumok információ feldolgozását és a KYC folyamatok során az ügyfelek azonosítását (Hannan, et al., 2023; Diksha – Poonam –Awadhash, 2022). A gépi látás banki front/middle/back office területen való alkalmazásáról a 4. fejezet értekezik bővebben.

2.2.2.6. *Elosztott főkönyvi technológia, blokklánc*

Az elosztott főkönyvi technológia egy olyan tranzakciós adatbázis, amely egy dedikált központi helyen való tárolás helyett több számítógépből álló hálózaton oszlik el. Leggyakrabban előforduló formája a blokklánc, amelyben a tranzakciók csoportonként (blokkonként) kronologikus sorrendben egymáshoz kapcsolódva egy láncot képeznek. Az innovatív blokklánc technológia pénzügyi kriptoeszközök esetén történő alkalmazhatóságát vizsgálja Eyal (2017). A blockchain, mint elosztott főkönyvi technológia típusa, egy decentralizált hálózaton keresztül működő adatbázis, amely egy kriptográfiailag összekapcsolt, rekordokból álló láncot hoz létre. A láncolatban minden elem az előzőhöz egyedi hash függvény révén kapcsolódik, biztosítva az adatok biztonságát (Hannan, et al., 2023). A technológia jelentősége az alábbi területeken kiemelkedő: a tranzakciók rekordkezelésében, a kriptográfiai biztonság növelésében, a decentralizált kontroll biztosításában, az okos szerződések automatizálásában, a pénzügyi tranzakciók valós idejű elszámolásában és az átlátható auditálható tranzakciós történetek létrehozásában (Nitin – Saurabh – Jayesh, 2023). A bankszektorban történő alkalmazása a kockázatok csökkentése révén jelentős, hiszen olyan biztonsági intézkedéseket is magába foglal, mind a kriptográfiai és a biometrikus hitelesítést. A fejlett titkosítási technikák (encryption/titkosítás, hash-elés, digitális aláírás) kulcsszerepet játszanak a megbízható rendszerek kialakításában.

2.2.2.7. *Robotok, intelligens robotok*

A szoftver- és hardver robotok a robot-címkézés témakörnél már előzetesen tárgyalásra kerültek. A banki front office területen való alkalmazhatóságukat a 4. fejezet ismerteti.

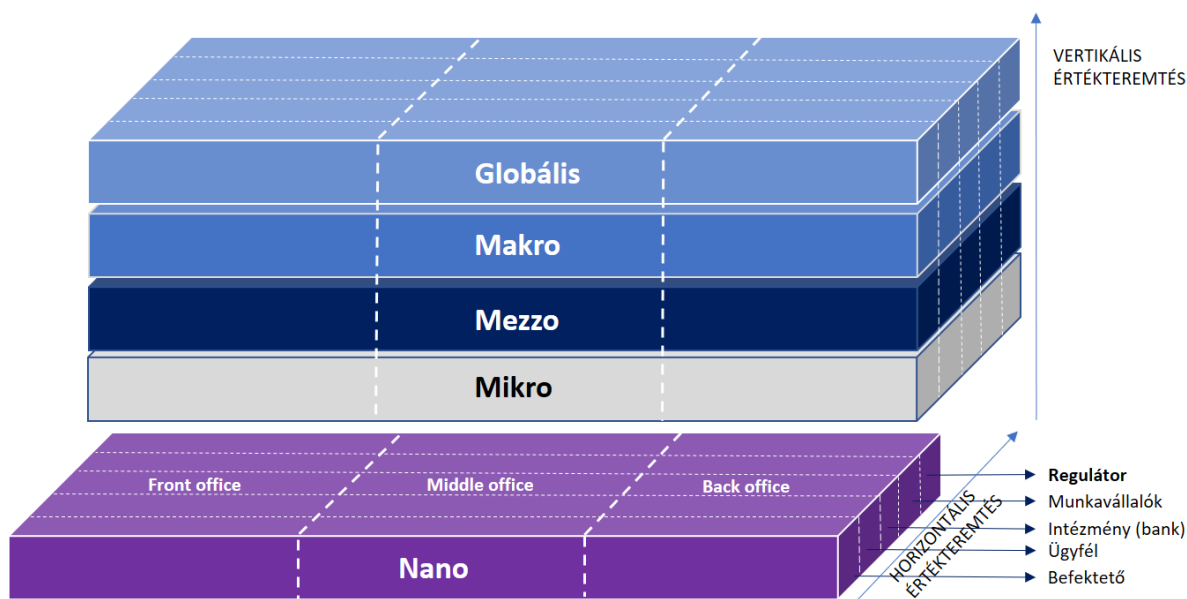
2.2.3. A bankrobotika vertikális és horizontális értékteremtésének keretrendszere

A bankok szerepe – saját digitális transzformációjuk mellett – nem kizárólag a nemzetgazdaság digitális átalakulásának finanszírozásában, hanem annak globális szintű társadalomformáló hatásában (kockázatkezelés, innovációk bevezetése, társadalmi érzékenyítés) is kiemelkedő. (Tomašev et al., 2020). Az intenzív digitális technológia alkalmazása (zöld robottanácsadás, zöld közösségi finanszírozás) a zöld pénzügyek társadalmi kibontakozását is jelentős mértékben támogatja (Horvát, 2019).

A bankrobotika technológiák hatását és értékteremtését a vertikális és horizontális dimenziók mentén mutatom be (9. ábra, 6. táblázat). Választ adva a kérdésre, hogy a bankrobotika-technológiák kinek, milyen szinten és milyen értéket teremtenek? Vertikális

értékteremtés szempontjából az alábbi szintek elkülönült vizsgálatát javaslom: (1.) nano (operatív szint, vizsgált szereplő aspektusa); (2.) mikro (banki intézmény szintjén), (3.) mezzo (bankszektor szintjén), (4.) makro (nemzetgazdasági szint), (5.) globális. Az egyes szintek esetében tovább finomítom a vertikális értékteremtési dimenzióik vizsgálatát úgy, hogy az alábbi szereplők aspektusából is elvégzem az elemzést: (1.) befektető, (2.) a fogyasztó, (3.) a szervezet (bank), (4.) a munkavállalók. A modell korlátjaként jelentkezik, hogy nem tárgyalja az egyéb stakeholder csoportokat. Az érintett stakeholder csoportok számára a bankrobotika technológiai beruházások haszna eltérő formában jelentkezik, amelyet a 11. ábra szemléltet.

11. ábra: A bankrobotika horizontális és vertikális értékteremtésének modellje



Forrás: Saját forrás

A vertikális és horizontális dimenziókban eltérő kihívásoka az 5. táblázat foglalja össze.

5. táblázat: A bankrobotika horizontális és vertikális értékteremtésének dimenziói

	Befektető	Fogyasztó	Szervezet	Munkavállalók	Regulátor
Nano	<ul style="list-style-type: none"> ▪ befektetési lehetőségek ▪ personalizált kockázatkezelési stratégia alapú azonosítása, ▪ döntéstámogatás ▪ befektetői bizalom fokozás ▪ tranzakciós költségek csökkentése 	<ul style="list-style-type: none"> ▪ ügyfélélmény és szolgáltatás színvonalának javítása ▪ personalizáció fokozása ▪ objektív elbírálás ▪ pénzügyi inklúzió ▪ új termékek és szolgáltatások elérhetősége 	<ul style="list-style-type: none"> ▪ szakterületi kooperáció (üzlet/IT/ jog), felelősök, felelősség és kockázatkezelés ▪ operáció optimalizálás (erőforrás-szükséglet csökkentése, minőség javítás) - KPI-ok ▪ digitális szolgáltatások körének szélesítése ▪ omnichannel kommunikáció ▪ adatgyűjtés és elemzés 	<ul style="list-style-type: none"> ▪ munkaerő magasabb hozzáadott értékű feladatra allokálása, ▪ monoton feladatok kiváltása ▪ AI/robot csapatba integrálása 	<ul style="list-style-type: none"> ▪ működési hatékonyság javítása, ▪ intézményi feladatok ellátásának támogatása
Mikro	<ul style="list-style-type: none"> ▪ innovatív technológia által optimalizált portfólió kezelés, vagyongazdálkodás ▪ trendek azonosítása, piaci hangulat elemzése 	<ul style="list-style-type: none"> ▪ AI-támogatott omnichannel kommunikáció (chatbot, AI-tanácsadó, 7/24) ▪ személyes adatok védelme 	<ul style="list-style-type: none"> ▪ AI stratégia, és felelős szakterület ▪ digitális szervezeti képességek építése (in-house/partnerség/felvásárlás) és támogató szervezeti kultúra ▪ AI, robotok szervezeti kultúrába illesztése ▪ üzleti modell transzformáció támogatása; ▪ változásmenedzsment („mindset” váltás) ▪ (kiber)biztonság megteremtése 	<ul style="list-style-type: none"> ▪ érzékenyítés, képzése ▪ új feladatkörök kialakulása ▪ feladatkörök és felelősök újradefiniálása ▪ AI-tehetségek vonzása 	<ul style="list-style-type: none"> ▪ bankszabályozás szabályozói kultúrájának átalakulása
Mezzo	<ul style="list-style-type: none"> ▪ csökkenő ügyleti költségek hatása a kereskedés élénkítésére (piaci likviditás elősegítése) 	<ul style="list-style-type: none"> ▪ banki költségek általános csökkenése ▪ fiókracionalizálási trend ▪ fogyasztói élménynyújtás versenyalapú növelése 	<ul style="list-style-type: none"> ▪ digitális termék/szolgáltatáskínálat transzformációja ▪ neobankok elterjedésére ▪ bankszektori AI-ökoszisztéma kialakítása ▪ etikus AI bankszektori irányelvek ▪ adat és tudás „pool”-ok kialakítása 	<ul style="list-style-type: none"> ▪ AI szakemberek keresletének növekedése a bankszektorban ▪ a bankszakma átalakulása (szükséges képességek, tudás, kompetenciák) 	<ul style="list-style-type: none"> ▪ modellezés és tesztelés elősegítése ▪ Regtech ▪ Sandbox-ok ▪ Innovációs Hub-ok ▪ továbbfejlesztett szabályozás

Makro	<ul style="list-style-type: none"> ▪ bankrobotika szabályozása hatása a befektetésekre ▪ az algoritmikus kereskedés növelheti a pénzügyi piacok hatékonyságát és sebességét 	<ul style="list-style-type: none"> ▪ alulbankolt makrogazdasági szereplők pénzügyi inklúziójának elősegítése ▪ AI iránti társadalmi érzékenyítés, oktatás támogatása (FinTech, fenntartható bankolás) 	<ul style="list-style-type: none"> ▪ hatékonyabb, alacsony költségű és gyorsabb pénzügyi tranzakciók az egész gazdaságban (termelékenység-növekedésének támogatása) ▪ digitális szervezeti képességek építésének finanszírozása, javítása (kiberbiztonság támogatása) ▪ gazdasági egyenlőtlenségek csökkentése (pénzügyi inklúzió) ▪ piaci torzulások (AI-kockázat) kezelése ▪ szabályozási költségek csökkentése ▪ pénzügyi rendszer átláthatóságának, stabilitásának támogatása (pénzmosás és csalásnyűs ügyletek), bizalom növelése 	<ul style="list-style-type: none"> ▪ munkaerőpiac-polarizáció, súrlódásos munkanélküliség ▪ munkavállalói digitális kompetencia fejlesztése 	<ul style="list-style-type: none"> ▪ fejlett bankszabályozás és etikai irányelvek mentén operáló gazdaság
Globális	<ul style="list-style-type: none"> ▪ átalakuló nemzetgazdasági befektetői környezet ▪ befektetői bizalom és piaci hangulat hatása az AI-hype ciklusokra ▪ kereskedés generális demokratizálása (szaktudást nem igénylő robot támogatás) 	<ul style="list-style-type: none"> ▪ digitális fogyasztói szokások átalakulása ▪ humán-robot interakció társadalmi kihívásai (robot jogok, jogi személyiség) ▪ AI és kapcsolódó innovációk társadalmi diffúziója és gátló tényezői (incidenek) ▪ bizonyos emberi képességek fejlődése ▪ hatása a társadalmi egyenlőtlenségre ▪ a nem etikus AI-használat következményei 	<ul style="list-style-type: none"> ▪ fenntartható bankolás és ESG célok támogatása ▪ technológia hatása a határokon átnyúló szolgáltatásokra és globális kereskedelemre ▪ fejlődő országok pénzügyi integrációja (átmeneti visszaesés- tanulási szakasz) ▪ felelősségi és biztosítási kérdések tisztázása ▪ nemzetközi kollaboráció (AI-ökoszisztéma) ▪ adat- és biztonságsszabályozás kidolgozása a nemzetközi banki tevékenységre vonatkozóan 	<ul style="list-style-type: none"> ▪ (fizikai) robotok térnyerése, ▪ munkaerő-kereslet átalakulása ▪ társadalmi jövedelmi különbségek növelése ▪ társadalmi konfliktus (?) 	<ul style="list-style-type: none"> ▪ modern bankrendszer globális szintű működésének összehangolása a bankszektort érintő AI jogszabályok és iránymutatások mentén

Forrás: Saját táblázat

2.2.4. A bankrobotika terület lehatárolásának szükségessége

A pénzügyi technológiai vállalatok (FinTech-ek) olyan technológia alapú vállalkozások, amelyek célja, hogy javítsák és automatizálják a pénzügyi szolgáltatások nyújtását (MNB, 2017). A nyílt bankolás révén teret nyerő FinTech, BigTech vállalatok tevékenysége elősegítette a mainstream pénzügyi intézmények (tradicionális bankok, biztosítók) szolgáltatásából kirekesztett csoportok kiszolgálását. A FinTech-ágazatban a fizetési szolgáltatás-megoldások, a blokklánc, a robottanácsadás és egyéb hiperperszonalizációval társuló megoldások kiemelkedő jelentőségűvé váltak (Bagó 2023). A FinTech térnyerés eredményeképp a bankok felülvizsgálják meglévő üzleti modelljüket, bővítik innovatív termék és szolgáltatáskínálatukat és fokozzák a fogyasztói élménynyújtásukat (Diener – Špaček, 2021). Az innovatív technológiákba investálás hozzájárul a bankok válaszadási képességének javításához (Pintér – Herczeg, 2023). A digitális éra kihívásaira reagálva számos piacvezető nagybank alakított ki a szervezeti stratégiába illeszkedő AI stratégiát (Kitsios – Giatsidis – Kamariotou, 2021), valamint indított AI és robot alapú projekteket. Az bankok innovatív FinTech-technológiákba történő beruházási céljai közül kiemelkedik a versenyképesség javítása, a működési hatékonyság növelése, a költségoptimalizálás (fiókhálózat, munkaerő racionalizálás) (Sefik – Alper, 2017; Chen, 2018; Kou et al., 2021), az új csatornákon (mobil) keresztül történő értékesítési volumen növelése (Shaikh – Hanafzadeh – Karjaluoto, 2017), és a piaci érték növelése (Eyal, 2017). Ugyanakkor az adaptáló vállalatok működési teljesítménye nem növekedik automatikusan a digitális technológiák implementációjával (Szalavetz, 2022).

A hiperperszonalizáció révén megváltozott fogyasztói igények indukálták az új, innovatív termékek (BNPL) és szolgáltatások megjelenését (drive-through bankolás, beyond banking, conversation banking, platformok és ökoszisztémák) (Alt – Beck – Smith, 2018; El-Gohary et al., 2021; KPMG, 2023). Ugyanakkor az innovatív pénzügyi termékek (BNPL) rendszerek, szabályozásának hiányosságai (hitelminősítési, kockázatkezelési követelmények) miatt ezek a rendszerek különösen veszélyeztethetik a pénzügyi stabilitást és a fogyasztói védelmet (Langenbucher, 2023). Az AI rendszerek alkalmazása a hitelminősítés és profilalkotás területén is magas kockázatot jelent, mivel ezek szigorú szabályozást igényelnek az átláthatóság és etikai aggályok kezelésére (Langenbucher, 2022; Bonaccorsi di Patti et al., 2022; Addy et al., 2024). A prudens és transzparens működés jegyében a bankszektor speciális jogszabályi környezete akadályozhatja a FinTEch technológiák implementációját (Diener – Dvouletý – Špaček, 2023; Prisznyák, 2023b, 2024) (6. táblázat).

6. táblázat: Példa a bankrobotika lehatárolását támogató tényezőre

Tényező	Általános megfogalmazás	Probléma specifikálása	Hivatkozás	Probléma leírása
Speciális igények és problémák I. innovatív termékek, szolgáltatások	Az innovatív pénzügyi terméket kínáló FinTech vállalatok esetében gyakran hiányoznak a hagyományos pénzügyi intézményekre vonatkozó szigorú hitelminősítő és kockázatkezelési követelmények, ami potenciálisan növeli a pénzügyi kockázatokat.	BNPL termékek esetén hitelminősítő rendszerek működtetésének szükségessége kérdéses az AIA elégtelen definíció alapján.	Legendbucher (2023)	Az AIA a hitelminősítő rendszerek magas kockázatú besorolását 'a pénzügyi erőforrásokhoz való hozzáférés' tényéhez kötik. Szűkebb értelmezés tekintetében ez csak a formális hitelszerződésekre (banki kölcsönök), így a hitelintézetekre irányul, ami azt jelenti, hogy csak az ilyen típusú pénzügyi szolgáltatások esnek a szabályozás alá. Tágabb értelmezésben minden olyan vállalatra kiterjedhet, amely nem hagyományos hitelszerződés formájában nyújt BNPL-t, és ennek keretében AI rendszert alkalmaz a hitelképesség értékelésére. A banki hiteltermékek esetén azonban a CRR követelményeknek is meg kell felelni.
Speciális igények és problémák II. innovatív technológiák	Az AI rendszerek, ML modellek hibás működése etikai problémákhoz vezethet (átláthatóság, magyarázhatóság, diszkrimináció-mentes).	Az AIA kiegészíti, de nem helyettesíti az érvényes szektor-specifikus szabályozást	Addy et al., (2024); Langenbucher, (2022); (EU) 2024/1689); Bonaccorsi di Patti et al., 2022	A FinTech cégek kevésbé szigorú szabályozás alá esnek, míg a bankoknak a CRR szigorú további követelményeket támaszt az AI rendeleten, GDPR-on túlmenően például az alábbiakra: modellek kialakítása, validációja, alkalmazása, monitoringja.
Piaci, szakmai igény	Pénzügyi rendszer stabilitása; fogyasztóvédelmi kockázatokat (adósság-visszafizetési képesség értékelését, az átlátható díjsszabást és a vitás tranzakciók rendezése), ügyfelek pénzügyi nehézségei	új termékek és technológiák alkalmazása során	CFPB (2022), FCA (2021)	A FinTech vállalatok által nyújtott BNPL szabályozási hiányosságokat (pénzügyi piacok stabilitása), fogyasztóvédelmi kockázatokat (például adósság-visszafizetési képesség értékelését, az átlátható díjsszabást és a vitás tranzakciók rendezése, ügyfelek pénzügyi nehézségei) vizsgálják. Az ezeket biztosító rendszer kialakítás szektor-specifikus megfelelést kívánhat.
Technológia-vezérelt üzleti modellek	A technológia nemcsak az ügyfeleknek nyújtott lehetőségekre de a bankok működésére is hatással van.	FinTech Bank engedélykérelmek követelményei	ECB (2018)	Az alkalmazott eljárásokat és kritériumokat a CRD IV definiálja. Főbb területei: (1) irányítás (vezető testületi tagok/ részvényesek alkalmassága), (2) belső szervezet (kockázatkezelési, megfelelőségi és audit keretrendszerek), (3) működési program, (4) tőke, likviditás és fizetőképesség, amelyek egyúttal a technológia lehetőségeit is meghatározzák.
Szektor specifikus szabályozási, jogi követelmények	Biztosítják a pénzügyi intézmények stabilitását, megbízhatóságát és elősegítik a pénzpiacok átláthatóságát és védik az ügyfelek érdekeit.	tőkekövetelmény, likviditás	MNB, 2017; Fáykiss et al., 2018, ECB (2018)- iránymutatás tervezet	Specifikus előírások (CRD IV és CRR) a tőkekövetelményre (szavatoló tőke, kiegészítő tőke), a kockázati éhségre, a váratlan veszteségek nyomán követésére (kockázatkezelésre).

Forrás: Saját táblázat

A 7. táblázatban összeszedettek alapján látható, hogy a bankszektor jogszabályi keretrendszere az innovatív termékek, technológiák, üzleti modellekkel szemben szigorúbb elvárásokat támaszt, amelyeket a jogszabályi megfelelésért biztosításra érdekében figyelembe szükséges venni. (Erről jogszabályi szinten a 4.,5. fejezet is értekezik.)Ezen megfontolásokból kiindulva a bankrobotika eredeti koncepciójában a bankrobotikát a FinTech-től lehatárolt területként kezeltem, hangsúlyozva, hogy bár ugyanazon technológiák kerülnek alkalmazásra, a felhasználás lehetséges módjait ágazati szabályozások gátolhatják (Prisznyák, 2023c).

2.2.5. A bankrobotika fogalom iterációja és a bankszektor DNS modellje

A digitális transzformáció folyamatában az AI és kapcsolódó innovatív technológiák a változás katalizátorának tekintendők (Lanzolla et al., 2020). A FinTech és BigTech versenytársak térnyerésére az inkubens tradicionális bankok szükségképpen növelték digitális képességeiket, amit a bankok szervezeti reorganizációja kísért (Szikora – Nagy, 2020; European Parliament, 2022; EBA, 2020; El-Gohary et al., 2021; Prisznyák 2023a). Ezt a folyamatot a szakirodalom digitális transzformációként írja le, amely technológia-központú (Lanzolla et al., 2020; Prisznyák, 2023c), szervezet-centrikus (Vial, 2019; Kitsios – Giatsidis – Kamariotou, 2021), illetve ezek kettőse (technológiai implementáció által indukált szervezeti változás) révén valósul meg.

Yip és Bocken a digitális átalakulást a technológiai innovációk és új megoldások bevezetésének szemszögéből vizsgálják (Yip – Bocken, 2018). A változás technológiai aspektusának keretében a bankok AI rendszereket, ML modelleket vezetnek be előrejelző és döntéstámogató céllal, felhőalapú megoldásokra és API-kra épülő nyitott digitális ökoszisztémákat alakítanak ki, adatvédelmi megoldásokat alkalmaznak, hogy javítsák a működési folyamataikat és bővítsék szolgáltatásaikat (Parne, 2021a; 2021b; Vinoth et al., 2022; Premchand – Choudhry, 2019; Zhang – Zhu – Qingyang, 2020). Vial (2019) a technológiai adaptáció eredményeként létrejövő folyamatként értékeli, amely alapjaiban véve változtatja meg a szervezetek szerkezetét. Az implementált technológia a szervezet látásmódjának (mindeset) átalakulásán keresztül megváltoztatják a szervezet struktúráját, folyamatait, üzleti modelljét, piacát, termék-és szolgáltatáskínálatát, valamint képességeit (Alt – Beck – Smits, 2018).

A digitális transzformáció a szervezeti képességek, struktúrák, folyamatok és az üzleti modell komponensek együttesének átalakulásaként is értelmezhető, amely során az adaptáció technológiai, valamint szervezeti és stratégiai szinten szükséges hogy megtörténjen (Nadkarni – Prügl, 2017). Ez a változás a szervezet külső és belső környezetét egyaránt érinti (Kitsios –

Giatsidis – Kamariotou, 2021). A belső környezetet érintően a digitális transzformáció a meglévő banki modellek újragondolását igényli (platform alapú operáció, bankfiókhálózat racionalizálása, innovációs lab-okat, spin-off cégek indítása) (Sefik – Alper, 2017) és kapcsolódóan a szervezeti kultúra átalakulását indukálja. A szervezeti képességek építése révén (technológiai beruházások, munkavállalói képességek) a folyamatok átalakítását, új termékek és szolgáltatások, szolgáltatási csatornák (omnichannel, elektronikus platformok, mint az e-banki, virtuális bankolás, valamint a szolgáltatási pontok, mint a POS, e-áruházak) bevezetését is maga után vonhatja. E tekintetben a változás egyfajta többdimenziós megújulási folyamatként értelmezhető (Kitsios – Giatsidis – Kamariotou, 2021). A digitális technológiák implementálása az üzleti modell, a termékek és szolgáltatások, illetve a szervezet struktúrájának megváltozásához vezetnek, amely folyamat előmozdításában a menedzsment szerepe kiemelkedő (Hess et al., 2016). Másképp fogalmazva, a digitális átalakulása nem kizárólag az innovatív információs és kommunikációs technológiák bevezetését jelenti, hanem a szervezeti kultúra szempontjából történő megértést és kapcsolódó kockázatkezelést (változásmenedzsment) a szabályozási keretek között (Diener – Špaček, 2021).

Diener és Špaček megfogalmazása alapján a bankok egy *kettős alkalmazkodási folyamattal szembesülnek* (Diener – Špaček, 2021). *Ez a kettős alkalmazkodási folyamat felfogható a DNS kettős spirál szerkezetű, hélix formájaként.* A DNS az örökítőanyag hordozását végzi az élőlények sejtjeiben. Az egymással kölcsönhatásban lévő és komplementer módon kapcsolódó két DNS szál a bankrobotika hasonlatán értelmezve:

- *Az egyik spirál a bankrobotika technológiák, vagyis a mesterséges intelligencia, gépi tanulás, intelligens robotok és kapcsolódó innovatív technológiák bankszektori adaptációját jelenti.*

Yip és Bocken a *digitális átalakulást a technológiai újdonságok, új típusú megoldások aspektusából* értékeli, amikor a dokumentumok digitalizálását, az elektronikus aláírás lehetőségét, az e-learning szervezeti oktatási anyagokat, az online kereskedési platformok előretörését, az e-kivonatokat és mobilfizetési lehetőségeket, a tranzakciók azonnaliságát, és a bank non-stop elérhetőségét (24/7) említi (Yip – Bocken, 2018). A technológia adaptáció keretében a bankok kialakítják a felhő (Parne, 2021a, 2021b; Vinoth et al., 2022) és API-alapú nyitott digitális ökoszisztémájukat („OpenBanking”) (Premchand – Choudhry, 2019; Zhang – Zhu – Qingyang, 2020). A banki operációt é a szolgáltatásnyújtást fokozzák az adattárolásra és adatküldésére fókuszáló blokklánc technológia (Guo – Liang, 2016; Cocco – Pinna – Marchesi, 2017), illetve a személyes adatvédelmet szolgáló PET technológia (Baum et al., 2022;

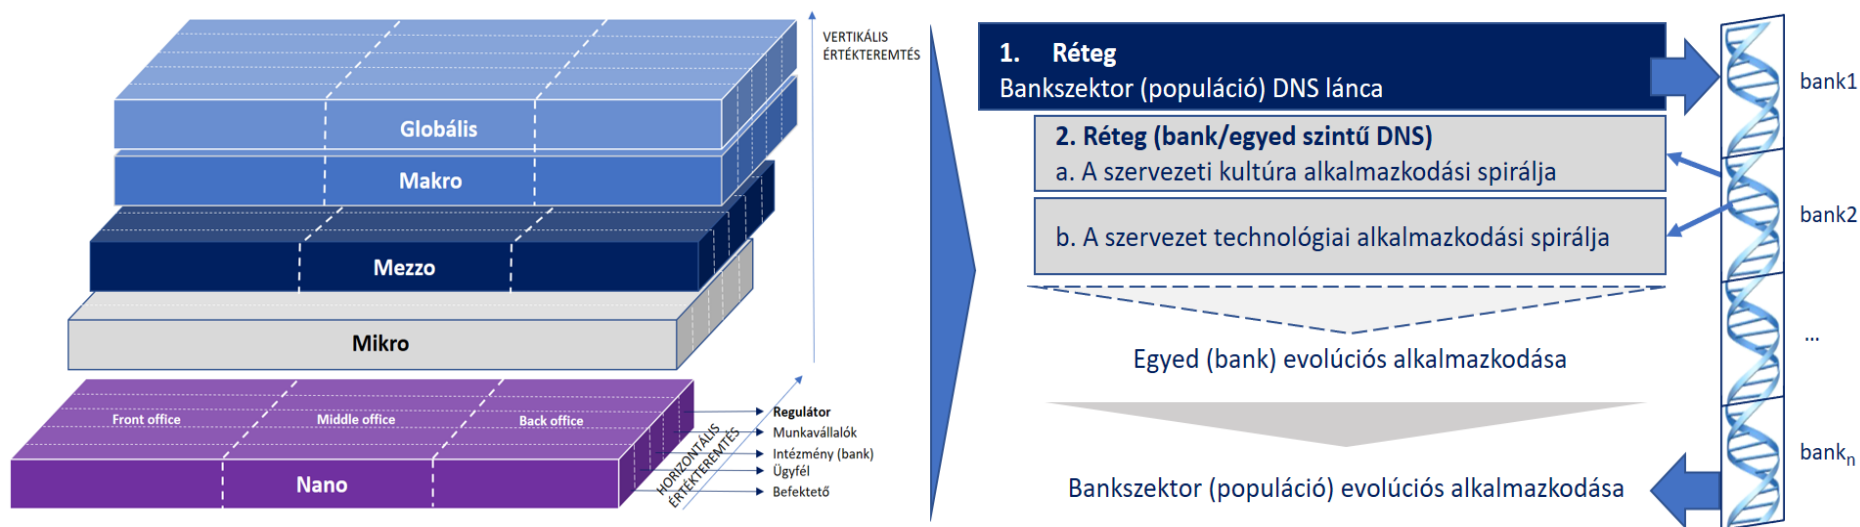
Panagiotis et al, 2023) kiaknázásával, valamint párhuzamosan ezen technológiák alkalmazásával növeljék kiberbiztonságukat (Wang et al., 2020). A digitalizációból származó mögöttes trendként pedig olyan szolgáltatásokat kínálnak, amely túlmutat a tradicionális banki kereteken (beyond banking) (Brewis, 2004; McKinsey, 2019). Bár nem létezik általánosan hatékony megoldás a bankrobotika-innovációk szabályozói oldali ösztönzésére, az Innovation Hub és Regulatory Sandbox gyakorlati alkalmazása támogató tényezőként jelentkezik a technológiák gyakorlati alkalmazás során (Fáykiss et al., 2018).

- *A másik spirál pedig a bankok digitalizáció által előidézett szervezeti adaptációját reprezentálja.*

A szervezet adaptációs képessége meghatározza a digitális átállást kísérő szervezeti kultúra átalakulását, a munkavállalók, a szervezeti értékek fejlődését, a banki stratégiát, az alkalmazott üzleti modellt. A stratégia változása keretében a bankok igazodnak a big data alapú banki működéshez („smart banking”) (Deloitte, 2021; McKinsey, 2020). Ez a fajta technológia és szervezeti adaptáció megváltoztatja a bankok „genetikai” szerkezetét, amelynek kódolt információtartalma hatással van az egyedek (bankok) alapvető tulajdonságaira, működésére és fejlődésére.

Ezen két spirál (2. réteg a,b) együttműködése és kölcsönhatása határozza meg a bankszektor (1. réteg) fejlődését és adaptációját a technológiai innovációk és a digitalizációs folyamat eredményeképpen (12. ábra).

12. ábra: A bankszektor DNS modellje – szervezeti aspektus nano, mikro és mezo szintjei



Forrás: Saját ábra

A bankok az elmúlt évszázadok során folyamatosan alkalmazkodtak a technológiai változásokhoz (IT-rendszerekre való áttérés, ATM-ek, derivatívák) a túlélésük és nyereségük növelése érdekében (Berger, 2003). A digitális éra kihívásaira reagálva számos piacvezető nagybank alakított ki a szervezeti stratégiába illeszkedő technológia/AI stratégiát, hogy modernizálják a központi („core”) banki rendszerek infrastruktúráját (Megargel – Fan, 2018; Resano – Ramon, 2021). A megkülönböztetés és költségoptimalizálási stratégiai visszamérését célozva a China Construction Bank Corporation 2018-ban megnyitotta a világ első humán erőforrás nélkül operáló bankfiókját (Zhang, 2018). A fiókhálózat racionalizálása és leterheltségük csökkentése (Sefik – Alper, 2017), valamint a digitális technológia ügyfél elfogadási hajlandóságának felmérése céljával (Flavián et al., 2021). A robotizációval párhuzamosan megjelenő fiókhálózat racionalizálás az euroövezet bankjainál is megfigyelhető (Discanno, 2023).

A digitális átalakulás korszakának versenykörnyezetében a bankok aszimmetrikus alkalmazkodása kockázatot jelenthet a bankszektor egészének genetikai kódjára és a bankok fennmaradására nézve. A problémát az jelenti, amikor az egyed szempontjából a DNS szintű változás során a két DNS-szál nem azonos mértékben fejlődik, így egyensúlyhiány alakul ki az alkalmazkodási folyamatban. Ez az aszimmetria az egyedek evolúciójának eltérését eredményezi, aminek eredményeképpen:

- a) különböző megjelenési formák (fenotípusok) jönnek létre az egyedek eltérő alkalmazkodásának következtében (eltérő tulajdonságok, jellemzők, megjelenési formák). Gondoljunk itt például a tradicionális bankokra, neobankokra, challenger bankok kialakulására. Továbbá,
- b) az egyes intézmények eltérő szervezeti adaptációs képessége fejlődik, így a szervezet digitális transzformációja eltérő sebességgel és mértékben valósul meg.

A két DNS-szál bankspecifikus és bankonként egyedi, jellemzően aszimmetrikus egymáshoz viszonyított mértéke indukálja a környezeti erőforrásokért folytatott versenyt és a versenyben felsorakoztatott képességek meglétét, amely végső soron meghatározza az egyedek túlélését és gyarapodását.

Hosszú távon pedig az életképes egyedek, így a populáció (bankszektor) genetikai összetételére van hatással – kapcsolódóan a BIS által felvetett jövőkép forgatókönyvekhez (például tradicionális bankok, bankfiókok eltűnése). Másképp fogalmazva, *az egyedek adaptációs folyamata meghatározza a bankszektor egészének genetikai kódját. Adaptációs*

képességük pedig kialakítja az egyedek és végsősoron a szektor egészének alkalmazkodási képességét és dinamikáját. Következésképpen, az alkalmazkodási folyamat kényes egyensúlyra igényli, hogy a két terület fejlesztése párhuzamosan valósuljon meg.

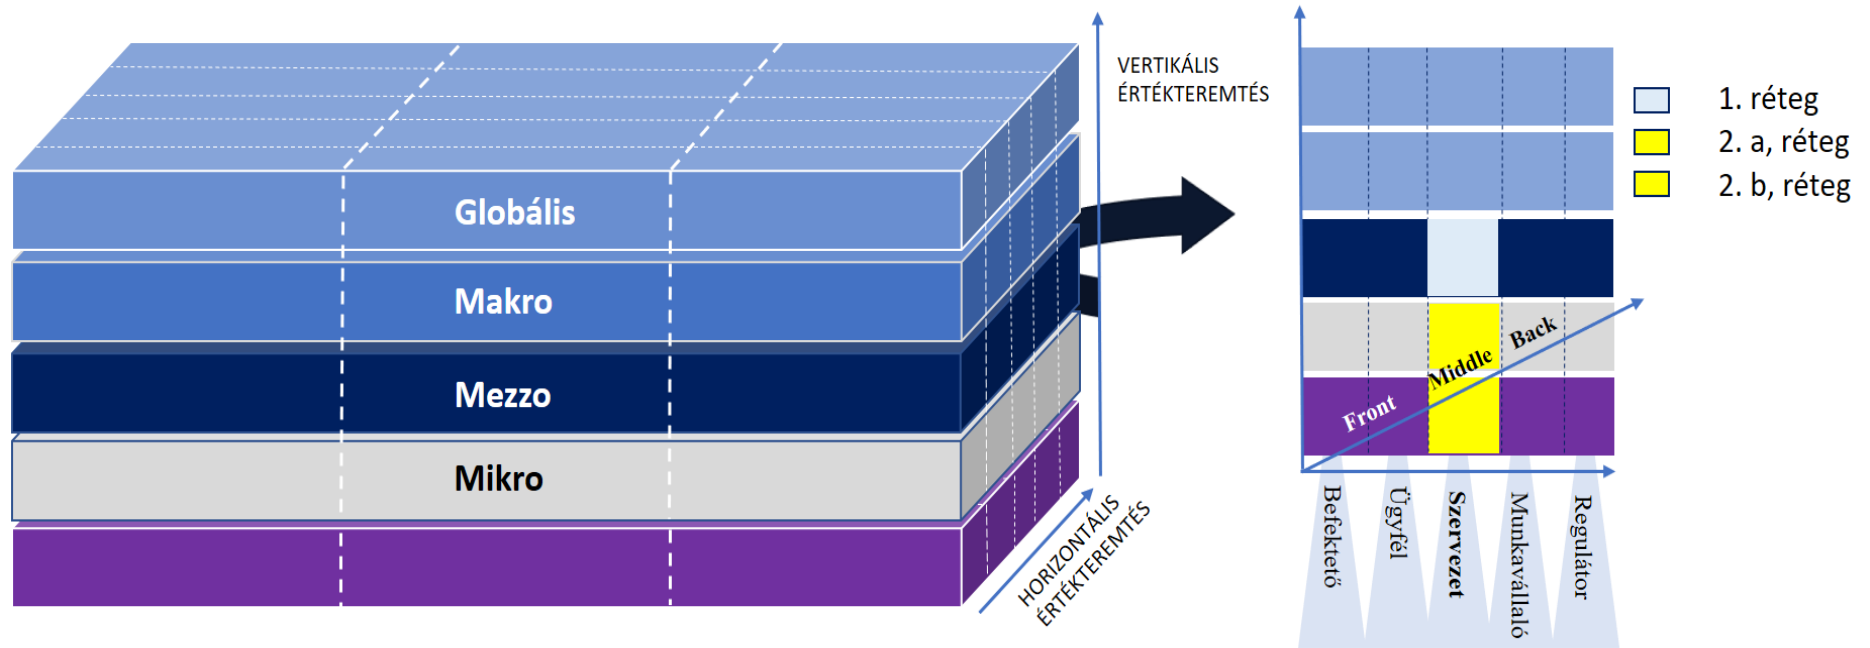
Ugyanakkor figyelembe szükséges venni a DNS szintű változások kedvezőtlen irányba történő módosulása által előidézett *genetikai instabilitást*. Ez a jelenség rövidtávon a bankszektor genetikai kódjának változásával össze nem egyeztethető „rendellenes” működéshez (elmaradt/alacsony fokú digitális transzformáció), míg hosszú távon – az alkalmazkodási képesség kialakulásának hiányában – a piaci versenyben való alulmaradáshoz vezethet. Az alkalmazkodási képességben (két DNS szál: technológiai, szervezeti változás) bekövetkező egyensúlyhiány rövidtávon az egyes egyedek, vagy hosszútávon akár a teljes populáció kihalásához is vezethet. Átengedve helyüket az új piaci szereplőknek.

A bankszektor erőteljes szabályozottsága lassíthatja a bankszektor genetikai módosulásának folyamatát. Az inkumbens egyedek fontos genetikai jellemzője az szigorú szabályozói környezethez való alkalmazkodás képessége, amely versenyelőnyt jelenthet a bankszektor tevékenységéből piaci részt hasítani kívánó FinTech, BigTech vállalatokkal szemben. *A bankok digitális transzformációs képessége tehát kulcskérdésként jelentkezik a piacon maradás érdekében.*

Következésképpen, a bankrobotika koncepció nem csupán a bankok technológiai képességében bekövetkező változását jelenti, hanem a szervezeti alkalmazkodási folyamatát is. A bankrobotika szűk (technológiai) és tágabb (szervezeti) értelmezéseit az empirikus résznél fogom kibővíteni a vizsgálódás eredményeképpen.

A bankrobotika DNS-szintű alkalmazkodásának illeszkedését a horizontális és vertikális értékteremtési modelljbe a 13. ábra szemlélteti.

13. ábra: A bankrobotika horizontális és vertikális értékteremtési modelljébe illeszkedő DNS szintű alkalmazkodás



Forrás: Saját ábra

3. A bankrobotika jogszabályi keretrendszere

Az AI és kapcsolódó innovatív technológiák alkalmazása sebezhetőbbé tette a pénzügyi rendszert a megjelenő (új típusú) AI kockázatok következtében (Bank of Italy, 2022; EBA, 2023; Uddin et al., 2023; Schnitzer et al., 2024). A FinTech versenytársakkal szemben a bankok olyan szigorú jogszabályi környezetben működnek (MNB, 2017; Fáykiss et al., 2018), amely a mesterséges intelligencia alkalmazás természetes korlátjaként jelentkezik az AI és ML modellekre vonatkozó indirekt előírások (például CRR, 174. cikk: a modellek használata) révén (Mgieri – Pasquale, 2024; Botunac – Parlov – Bosna, 2024; Langenbucher, 2022). A jogszabályi környezet bankszektor specifikus volta a bankrobotika terület elszeparált vizsgálatának szükségességét (FinTechtől való lehatárolását) indukálja (Prisznyák, 2023c). A bankrobotika terület lehatárolásának szükségességét indokolja továbbá, hogy az AI rendelet ((EU) 2024/1689) generális megközelítést alkalmaz, így az nem specifikusan fedi le a bankok esetében alkalmazott AI rendszereket (Malgieri – Pasquale, 2024; Botunac – Parlov – Bosna, 2024; Langenbucher, 2022). Az AI rendszerekkel kapcsolatos követelmények teljesítése során az AIA 9. preambulumbekzdése hangsúlyozza az AI rendelet egyidejű figyelembevételét az érintett szektorban alkalmazott már meglévő EU-s (Alapjogi Charta), valamint másodlagos uniós jogforrásokkal (például GDPR), továbbá egyéb ágazati/szakterületi rendeletekkel (CRR, CRD IV), jogszabályokkal és iránymutatásokkal (HLEG, 2019, (EU) 2024/1689), valamint a kapcsolódó sztenderdekkel (ISO). Mindez összefüggésben áll azon korábbi megállapításommal, hogy a szakirodalom jelenleg nem jelöl ki egy olyan kutatási területet, amely a maga szigorú jogszabályi és prudens működésre vonatkozó elvárások környezetében elemezné az erőteljesen ügyfélbizalmon alapuló, társadalmilag és gazdaságilag mélyen beágyazott bankszektorban alkalmazott AI és kapcsolódó innovatív technológiákat (Prisznyák, 2023c). Összefüggésben ezen elgondolásommal, az AI rendelet véglegesítése előtt, illetve azt követően megjelentek, az AI rendszerekkel összefüggő jogszabályi környezetet vizsgáló publikációk (Bonaccorsi di Patti et al., 2022; Langenbucher, 2022; Malgieri – Pasquale, 2024; Botunac – Parlov – Bosna, 2024) szintén hangsúlyozzák a komplex jogi keretrendszer létezését, de nem kezelik különálló kutatási területként, amelynek célja az lenne, hogy támogassa a bankszektort az AI rendszerek és bankrobotika technológiák fejlesztésében és alkalmazásában. *Visszatérve a Bankrobotika fejezetnél tárgyalt lehatárolás szükségességére, adódik tehát a kérdés: miért fontos ez?*

A terület lehatárolásának jelenlegi hiánya kiemelt jelentőségű, mivel az AI rendszerek és a kapcsolódó technológiák alkalmazása a bankszektorban számos területre fej ki hatást (ügyfélbizalom fenntartása, társadalmi-gazdasági hatások, pénzügyi rendszer stabilitása). Az AI rendszereket, ML modelleket vizsgáló publikációk jellemzően nem vizsgálják a modellépítés során a szabályozói keretrendszert. Így előfordulnak olyan publikációk a feldolgozott irodalom között, amelyek nem az Európai Unióban alkalmazott AI rendelet, illetve bázeli bankszabályozási keretrendszer mentén javasolnak felhasználási lehetőségeket az AI rendszerek számára (például social media adatok felhasználása a bankoknál scoring tevékenységre, HR profilozás a munkavállalók képzési szükségleteinek megállapítására). Ezért a célom, hogy a jövőbeli kutatásokban nagyobb hangsúlyt kapjon az AI rendszerek jogszabályi keretek közötti alkalmazásának vizsgálata a bankszektorban, annak tudatában, hogy mi is az AI-címke mögött lévő technológia. Ennek érdekében az alábbi alfejezetekben a bankrobotika jogszabályi keretrendszerét, annak főbb komponenseit, illetve bankszektori relevanciáját tárgyalom.

3.1. A bankrobotika komplex jogszabályi keretrendszere

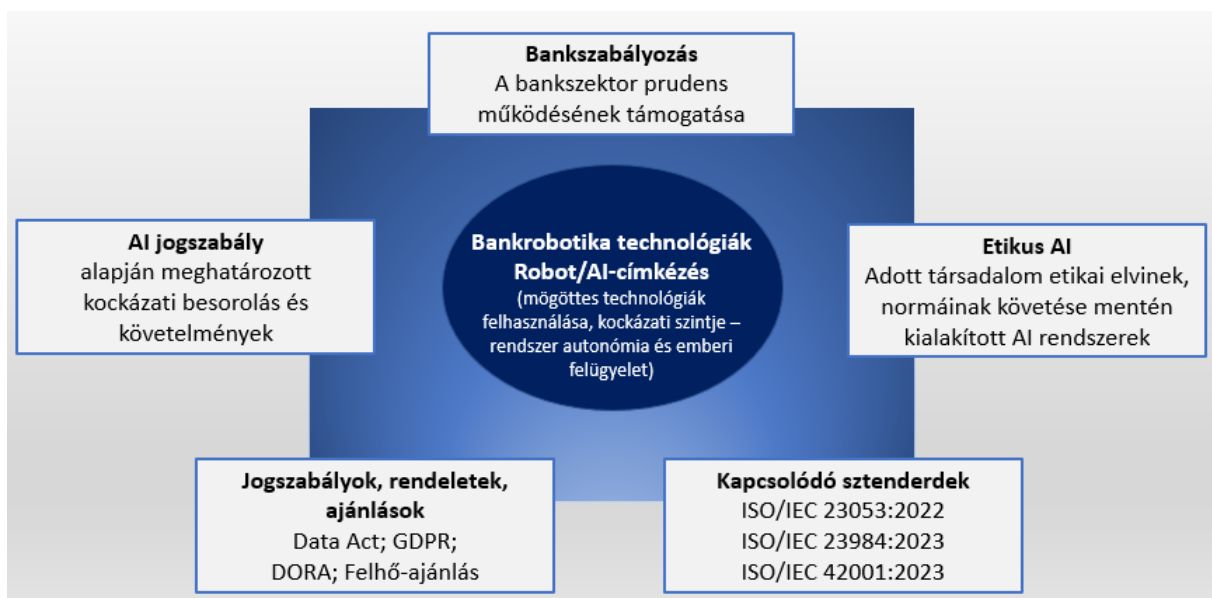
Az AI rendszerek bevezetésével kapcsolatosan a szakirodalom számos bevezetést gátló tényezőt azonosít, amelyek közül az alábbiak körvonalazódnak a szabályozási kihívások kapcsán: (1) a szabályozásra vonatkozó jogi bizonytalanságok (a nemzetközi és hazai szabályozói környezet lassú adaptációja), (2) kapcsolódó adatvédelmi aggályok (adatok gyűjtése, tárolása, felhasználásra, adatbiztonság), (3) az AI rendszerekhez kapcsolódó jogszabályi megfelelési biztosítási (compliance) kihívások komplexitása (követelmények), (4) felhasználási lehetőségek jogi korlátai (AI rendszerek kockázati osztályozása, személyes adatok felhasználása), (5) az AI rendszerekkel szemben előírt kockázatkezelési keretrendszerek kialakítása és integrációja a már meglévőbe, (6) az etikai iránymutatások érvényre juttatása a tervezés során, (7) jogszabályok értelmezési nehézségei (banki IT-/AI-szakértők megléte, illetve jogszabály értelmezése), (8) támogatás regulátor oldaláról (sand box-ok, FinTech jogtárak), (9) tagállami szintű AI szabályozás (rendeletek, iránymutatások kidolgozás, felelős intézmények kijelölése és felkészítése, szektor specifikus konzultációk), (10) az előírásoknak megfelelő kötelezettségek betartatása (adatszolgáltatási kötelezettség, illetve kapcsolódó követelmények, mint a műszaki dokumentáció, a nyilvántartás követelményeinek, egyebek) (Ulrich-Diener–Spacek, 2021 Kumar et al., 2021; BMWi, 2021; OECD, 2021; Singhal – Dube – Jain, 2022; Statistik Austria, 2023; Grünbichler, 2023; Prisznyák, 2023c). (A szakirodalom alapján összegyűjtött bevezetést gátló tényezők listáját lásd az 6. számú mellékletben.)

A banki területen alkalmazott AI és kapcsolódó innovatív technológiák esetében egy rendkívül komplex, többszörösen összetett jogszabályi keretrendszerrel találkozunk. Ennek a fő oka egyrészt, hogy az AI rendelet generális megközelítése nem specifikusan fedi le a pénzügyi szolgáltatások, így a bankszektor területét (Malgieri – Pasquale, 2024; Botunac – Parlov – Bosna, 2024; Langenbucher, 2022). Másrészt, a bankszektorban érvényes prudenciális szabályozása (CRR, 575/2013/EU) az AI és ML modellekre vonatkozóan kizárólag indirekt előírásokat tartalmaz (például CRR, 174. cikk: a modellek használata, 175. cikk: a hitelminősítő rendszerek dokumentációja, 176. cikk: az adatok karbantartása), amelyeket további ágazat-specifikus standardok és iránymutatások, jó gyakorlatok egészítenek ki (EBA, EKB, MNB ajánlásai) (Bonaccorsi di Patti et al., 2022). Harmadrészt, a ML technikák alkalmazása a banki modellekben olyan problémákat is felvet, amelyek túlmutatnak a bankszektorra érintő szabályozói megfontolásokon és további jogi keretrendszerekhez (GDPR, DORA rendelet, illetve felhő ajánlások – EBA/REC/2017/03, MNB: 4/2019. (IV.1.)) (EBA, 2021; EBA, 2023), illetve sztenderdekhez kapcsolódnak (ISO /IEC 42001:2023, ISO/IEC 23053:2022) (ISO, 2022; 2023a). Továbbá, a technológia iránti bizalom megteremtését (versenyképesség) és az európai normák, illetve az európai uniós alapvető jogokkal érvényesülését az Megbízható mesterséges intelligenciára vonatkozó etikai iránymutatás (HLEG, 2019) is támogatja. Az AI rendelet 9. preambulumbekzdése előírja ezen jogi keretrendszerek együttes figyelembevételét az AI rendszerekkel szemben támasztott (teljes) jogszabályi követelményeknek való megfelelés érdekében (EU) 2024/1689). Ezek figyelembevételével megállapítható, hogy a bankrobotika jogszabályi környezete egy olyan komplex, többszörösen összetett jogszabályi keretrendszer eredményez (Langenbucher, 2022), amely minden eleme sajátos irányultsággal bír (például GDPR személyes adatok kezelése és felhasználása), és különböző elvárásokat, valamint korlátokat támaszt az AI rendszerekkel szemben (Langenbucher, 2022; Malgieri – Pasquale, 2024; Botunac – Parlov – Bosna, 2024). Következésképpen, előfordulhatnak az elemek között átfedési hiányosságok (Botunac – Parlov – Bosna, 2024). Például az AI rendelet az algoritmusok átláthatóságára és az etikára helyezi a hangsúlyt, addig a GDPR az adatok védelmét szabályozza. Jelentkezhetnek továbbá definíciós, taxonómiai hiányosságok is (Langenbucher, 2022; Malgieri – Pasquale, 2024). Ez egyúttal azt is jelenti, hogy az AI rendelet önmagában történő betartása nem jelenti automatikusan más teljesítendő jogszabályoknak, rendeleteknek (GDPR) való megfelelés biztosítását is (Langenbucher, 2022), mivel ezek külön-külön irányulnak adott részterületek szabályozására. Vagyis, a bankoknak a bankrobotika technológiák bevezetése során az AI rendszerekkel kapcsolatos különböző

jogforrások által nevesített előírások betartását az ágazat-specifikus előírások mellett szükséges biztosítaniuk.

Ezen szükségességből kiindulva, ezt a komplex jogszabályi keretrendszert, amely a banki AI és kapcsolódó innovatív (bankrobotika) technológiák szabályozására szolgál, **bankrobotika jogszabályi keretrendszernek neveztem**. A bankrobotika jogszabályi keretrendszere figyelembe veszi az AI rendszerek kialakítását és működtetését szabályozó AI rendeletet, a bankszektorra vonatkozó szabályozásokat (mint a CRR, CRD és kapcsolódó rendeletek), valamint azokat a további jogszabályokat, amelyek az AI alkalmazásához kapcsolódó fontos területeket szabályozzák, mint az adatfelhasználás (GDPR, Data Act), a felhőszolgáltatások és harmadik fél beszállítók (DORA), illetve a nemzetközi kapcsolódó szabványokat (ISO, 2023a) (14. ábra). Természetesen a bankrobotika szabályozási keretrendszer a technológia fejlődésének előrehaladtával folyamatos felülvizsgálatot igényel.

14. ábra: A bankrobotika komplex jogszabályi keretrendszere – főbb komponensek



Forrás: Saját ábra

3.1.1. A bankrobotika jogszabályi keretrendszerének főbb komponensei

Az AI rendelet kiegészíti, de nem helyettesíti a már létező bankszektor-specifikus és egyéb kapcsolódó jogi kereteket (AIA, (EU) 2024/1689), 9. preambulumbekzdése). Kapcsolódóan, az alábbiakban a bankrobotika jogszabályi keretrendszerének főbb komponenseit ismertetem röviden.

3.1.1.1. A bankszektor szabályozói keretrendszere

A szabályozási tevékenységet intézményi, jogi és kulturális tényezők is meghatározzák. Annak ellenére, hogy léteznek nemzeti és regionális sajátosságok a bankszabályozásban, megfigyelhető az a világszintű törekvés, hogy a szabályozásban meghatározóvá váljon a nemzetközi együttműködés. A prudenciális szabályozásokat érintően a Nemzetközi Fizetések Bankja (BIS – Bank for International Settlements²⁰) keretén belül működő Bázeli Bankfelügyeleti Bizottság (BCBS – Basel Committee on Banking Supervision) a legfőbb globális normaalkotó. A Bizottság a nemzetközi bankfelügyeleti együttműködés előmozdításának fórumaként is működik. Tevékenységének köszönhetően a bankszabályozási gyakorlat globális szintű összehangolása zajlik a BCBS szabályozócsomagjai (Bázel I, Bázel II, Bázel III – módosítás utolsó csomagja 2022-ben) révén. Az érvényben lévő Bázel III-as csomag szabályait és alapelveit az Európai Unióban is bevezették, azzal a különbséggel, hogy míg a Bázeli Bizottság ezen szabályok érvényesítését csak a nemzetközi téren aktív nagybankoknál várja el, az unióban ezek a szabályok minden bankra vonatkoznak. Az Európai Unióban a bázeli ajánlások két lépcsőben válhatnak az egyes tagállami szabályozások részévé: első körben az európai uniós szintű szabályozás; második körben a tagállami szintű szabályozás révén (15. ábra).

15. ábra: A bankszabályozás szintjei



Forrás: Saját ábra

Az Európai Unió szabályozásában megfigyelhető, hogy az irányelvek mentén való szabályozás helyett egyre inkább előtérbe kerül a rendeleti szabályozás. A Bázel III szabályozócsomag – amely 2014. január 1-jétől hatályos – jelentős részét már nem is direktíva, hanem rendelet formájában vezették be az alábbi jogszabályokkal:

- Az Európai Parlament és a Tanács 575/2013/EU rendelete (2013. június 26.) a hitelintézetekre és befektetési vállalkozásokra vonatkozó prudenciális követelményekről (CRR – Capital Requirement Regulation) és a 648/2012/EU rendelet módosításáról, amely az EU-ban közvetlenül alkalmazandó a bankokra;
- Az Európai Parlament és a Tanács 2013/36/EU irányelve (2013. június 26.) a hitelintézetek tevékenységéhez való hozzáférésről és a hitelintézetek és befektetési vállalkozások prudenciális felügyeletéről (CRD IV – Capital Requirement Directive) (közvetlenül nem, csak irányelvek mentén hatályos, így implementálni szükséges a nemzeti jogrendszerbe).

Az Európai Unióban működő bankok szabályozásának gerince az ún. egységes szabálykönyv (Single Rulebook). Ez olyan jogszabályokon és azok alapján kiadott értelmezéseken, állásfoglalásokon alapul, amelyeket az EU-ban minden pénzügyi intézményre – köztük körülbelül 8300 bankra – és minden pénzügyi termékre alkalmazni kell. Az egységes szabálykönyv célja, hogy az unióban ne csak egységes szabályok érvényesüljenek, hanem azok egységes gyakorlata és értelmezése is megvalósuljon. Az egységes szabálykönyv elemei: (1) a már korábban említett CRD IV direktíva és CRR-rendelet; (2) az egységes szanálási mechanizmus (BRRD – Bank Recovery and Resolution Directive), a csődközeli helyzetbe került bankok rendezett szanálására szolgáló direktíva és rendszer; (3) a betétbiztosítási rendszer; (4) az Európai Bankhatóság által kiadott (az Európai Bizottság által jóváhagyott), jogszabályokhoz kapcsolódó, kötelező jellegű szabályozói (RTS – Regulatory Technical Standards) és végrehajtási (ITS – Implementing Technical Standards) technikai sztenderdek; (5) EBA-iránymutatások, ajánlások és állásfoglalások (Kovács – Marsi, 2018).

3.1.1.2. *AI rendelet*

Az Európai Unió számos ízben tárgyalta az európai gazdaság számára a technológiai vezetőserepet biztosítani képes AI szabályozás lehetőségeit. Az Európai Unió stratégiai célja (COM (2018)237) (Artificial Intelligence for Europe/A közös európai adattér kialakítása felé) hogy megerősítse technológiai és ipari kapacitásait, elősegítse a mesterséges intelligencia széleskörű hasznosítását a gazdaságban, mind a magán-, mind a közszférában, miközben biztosítja a megfelelő etikai és jogi kereteket (European Commission, 2018). Az Európai Bizottság 2021. április 21-én közzétette javaslatát (COM/2021/206 final), amelynek keretében egységes szabályokat határoz meg a megbízható mesterséges intelligenciára vonatkozóan. Az AI rendelet javaslatának célja egy bizalmi ökoszisztéma megteremtése volt, amely az Európai

Unió Alapjogi Chartával összhangban biztosítja az állampolgárok alapvető jogait, biztonságát, miközben támogatja az európai értékrenden nyugvó mesterséges intelligencia fejlődését, valamint elkerüli a piac fragmentációt az Európai Unióban létrehozott, üzembe helyezett és értékesített AI-rendszereket illetően, továbbá támogatja az EU globális sztenderdalkotóvá válását (European Commission, 2018). 2024. júniusában az Európai Parlament jóváhagyta az **AI rendeletet ((EU) 2024/1689)**, amely **generális (szektor-agnosztikus), technológia-orientált, kockázati osztályozás-alapú megközelítést alkalmaz**. Az AI rendelet célja, hogy az AI rendszerek kockázati osztályozásához kapcsolódóan **(ex ante) megfelelőségi követelményeket** vezessen be, amelyek kiküszöbölik, vagy elfogadható szintre csökkentik a kapcsolódó kockázatokat (Malgieri – Pasquale, 2024; Botunac – Parlov – Bosna, 2024; Langenbucher, 2022). Az AIA fogalmi meghatározása alapján az AI rendszer olyan gép-alapú rendszer, amely (a kapott inputok alapján) eltérő autonómia szinteken képes működni, és alkalmazkodni a környezetéhez az explicit vagy implicit célok elérése érdekében. Eredményképpen pedig olyan kimeneteket (előrejelzés, ajánlás, tartalom, döntés) produkál, amelyek befolyásolhatják a fizikai vagy virtuális környezetet.

3.1.1.3. *Megbízható mesterséges intelligencia etikai iránymutatása*

Az Európai Unió AI rendelet kialakításával párhuzamosan, az Európai Bizottság 2018-ban létrehozta a mesterséges intelligenciával foglalkozó magas szintű független szakértői csoportját (High-Level Expert Group on Artificial Intelligence, továbbiakban HLEG), amelyet az etikus AI irányelvek kidolgozásával bízott meg. A HLEG 2019-ben közzétette - az érintett felek konzultációja során szerzett tapasztalatokon nyugvó- Megbízható mesterséges intelligenciára vonatkozó etikai iránymutatását, amelyet egy gyakorlati implementációt támogató értékelési listával egészített ki (Megbízható mesterséges intelligenciával kapcsolatos értékelési lista, továbbiakban ALTAI) (HLEG, 2019; HLEG, 2020). Az iránymutatás három – egymást átfedő – komponens nevesít az AI rendszerekkel szembeni elvárásként, amelyeknek a rendszer egész életciklusa alatt teljesülniük kell, hogy megbízhatónak minősüljön: 1) jogszerűnek kell lennie, vagyis meg kell felelnie a hatályos törvényeknek és rendelkezéseknek, 2) etikusnak kell lennie, vagyis biztosítani kell az etikai elveknek és értékeknek való megfelelést, valamint 3) műszaki és társadalmi szempontból is stabilnak kell lennie (HLEG, 2019; HLEG, 2020). Az iránymutatásban hét etikai alapfeltételt is megfogalmaz, hogy elősegítse az etikus AI-rendszerek fejlesztését. Ezek az alábbiak: (1.) az emberi cselekvőképesség támogatása és emberi felügyelet; (2.) műszaki stabilitás és biztonság; (3.) adatvédelem és adatkezelés; (4.) átláthatóság; (5.) sokféleség, megkülönböztetésmentesség, méltányosság, (6.) környezeti és

társadalmi jólét biztosítása, (7.) elszámoltathatóság (HLEG, 2019). Bár a mesterséges intelligencia etikai irányelvei jogilag nem kötelező erejűek, kiegészítik a jogilag kötelező érvényű szabályozást és iránymutatásul szolgáljanak az etikai normák szervezeten belüli „ön”kormányzásának elősegítésében (Jobin – Lenca – Vayena, 2019; Calo, 2017).

A 7. számú melléklet részletesen tárgyalja az etikus AI szakirodalmat, míg a 8. melléklet a korábbi publikációmban bemutatott jogszabályi gap elemzés eredményét, valamint a kapcsolódó javaslatokat tartalmazza az etikus AI rendszerek fejlesztésével kapcsolatosan.

3.1.1.4. *Általános adatvédelmi rendelet (GDPR)*

A mesterséges intelligencia és kapcsolódó innovatív technológiák gyors fejlődés és a globalizáció új kihívások elé állította a személyes adatok védelmét (Bekum – Borgesius, 2023). Az Európai Unió Alapjogi Charta-ja által rögzített alapvető jogok (mint a megkülönböztetés mentesség, adatvédelem és magánélethez való jog) igényli a személyes adatok megfelelő védelmét és kezelését. Ezt a feladatot a jellegét tekintve ex post (előzetes adminisztratív engedélyezést nem igénylő) GDPR ((EU) 2016/679) látja el (Botunac – Parlov – Bosna, 2024), a technológiák teljes életciklusa alatt (EU) 2024/16896, AIA 2(7) cikk, illetve a 9. és 10. preambulumbekzdése). A GDPR főként az automatizált döntéshozatal és a profilalkotás, valamint az adatkezelés, illetve az automatizált döntések logikájához való hozzáférés joga révén kapcsolódik az AIA-hoz (Bonaccorsi di Patti et al., 2022). A GDPR a tisztességtelen diszkrimináció megelőzése céljából alapvetően tiltja az egyének bizonyos típusú, magánéletével kapcsolatos érzékeny adatok rögzítését, feldolgozását (Bonaccorsi di Patti et al., 2022). A diszkriminációmentes, etikus AI döntéshozatal érdekében a személyes adatok védelme az AIA-ben számos helyen rögzítésre kerül (például 10., 28. preambulumbekzdésében). Hangsúlyozandó, hogy a GDPR a kapcsolódó rendeletként kiegészíti, nem helyettesíti az AIA-t és a CRR-t. (Malgieri – Pasquale, 2024). Ennek keretében a nemzeti adatvédelmi hatóságok, mint például Magyarországon a Nemzeti Adatvédelmi és Információszabadság Hatóság (NAIH), elemzik, hogyan érvényesülnek az adatvédelmi szabályok az AI alkalmazások terén (EDPB, 2024).

3.1.1.5. *Kapcsolódó egyéb rendeletek (Digital Act, DORA) és sztenderdek (ISO)*

Digital Act

A Digital Act (COM/2022/68 final) az adatok szélesebb körű hozzáférhetőségére és megosztására összpontosít, különösen az IoT termékek és kapcsolódó szolgáltatások által generált adatokra. Fontos szerepet játszik a nagy mennyiségű adatokat használó banki AI

rendszerek adatkezelési gyakorlatainak szabályozásában, mint például az IoT eszközökön keresztüli adatok gyűjtése és felhasználása. Ugyanakkor nem közvetlenül a személyes adatok védelmét szolgálja, mint a GDPR (Botunac – Parlov – Bosna, 2024). Az adatminimalizálás keretében a szolgáltató csak a szükséges adatokat gyűjtheti (összhangban a Data Act, 6. cikkével). Az AI rendelet és a Data Act összhangban működnek annak érdekében, hogy a mesterséges intelligencia rendszerek fejlesztéséhez és működtetéséhez szükséges adatokat szabályozott és biztonságos keretek között lehessen felhasználni. Ennek keretében a Data Act támogatja az interoperabilitási (rendszerek közötti adatmegosztási) szabványok fejlesztését az adatmegosztás akadályainak felszámolása érdekében (8. cikk, az adatok biztonságos megosztásáról). A rendelet előírja Továbbá, hogy a felhasználók hozzáférhetnek az általuk használt termékek vagy szolgáltatások során keletkezett adatokhoz (például virtuális asszisztensek által rögzített adatok), és felhasználhatják azokat harmadik felekkel való adatmegosztás céljából (4. cikk, adatok hozzáférhetősége alapján). A banki AI rendszerek esetében ez a gyakorlat azt jelenti, hogy az ügyfeleknek joguk van megismerni és kezelni azokat az adatokat, amelyeket a bankok gyűjtenek róluk, például tranzakciós adatokat vagy ügyfélszolgálati interakciókat (COM/2022/68 final).

DORA rendelet

2024-ben az európai felügyeleti hatóságok (EBA, az EIOPA és az ESMA) benyújtották a digitális működési ellenálló képességről szóló rendeletet ((Digital Operational Resilience Act, DORA, (EU) 2022/2554)) rendeletet és a kapcsolódó technikai standardok végleges verzióját az Európai Bizottsághoz felülvizsgálatra (MNB, 2024). (A felülvizsgálat jelenleg folyamatban van.) A DORA célja az Európai Unió pénzügyi szektorán belüli digitális ellenállóképesség és kiberbiztonság növelése. A rendelet egységes követelményeket határoz meg a pénzügyi intézmények, illetve a számukra szolgáltatást nyújtó harmadik feles IT szolgáltatókhoz kapcsolódó ICT kockázatkezelés területén. A DORA-ban foglaltak kiegészítéseként technikai standardok (RTS-ek) határozzák meg az ICT kockázatkezelési követelményeket, beleértve az eszközök, módszerek és szabályzatok harmonizálását. Ezek az előírások kezelik az ICT-alapú incidensek osztályozását (kritikus ICT szolgáltatásokat érintő incidens/kibertámadások és ICT incidensek/hírnévre gyakorolt hatás/szolgáltatás kiesési idő/földrajzi hatókör és gazdasági hatás) és jelentési rendszerét, valamint a harmadik fél ICT-szolgáltatókhoz kapcsolódó kockázatkezelést és belső ellenőrzést. Továbbá, mintadokumentumokat biztosítanak a pénzügyi intézmények számára a harmadik fél szolgáltatókkal kapcsolatos információ-nyilvántartás és kockázatkezelés támogatására. A DORA rendelet szektor-agnosztikus (nem korlátozódik

egyetlen szektorra) módon technológia semleges megközelítést alkalmaz (vagyis nem specifikálja a technológiákat) (EBA, 2024b). A digitális ellenállóképesség növelését célzó DORA rendelet a bankok biztonságos AI implementációját is támogatja (Botunac – Parlov – Bosna, 2024).

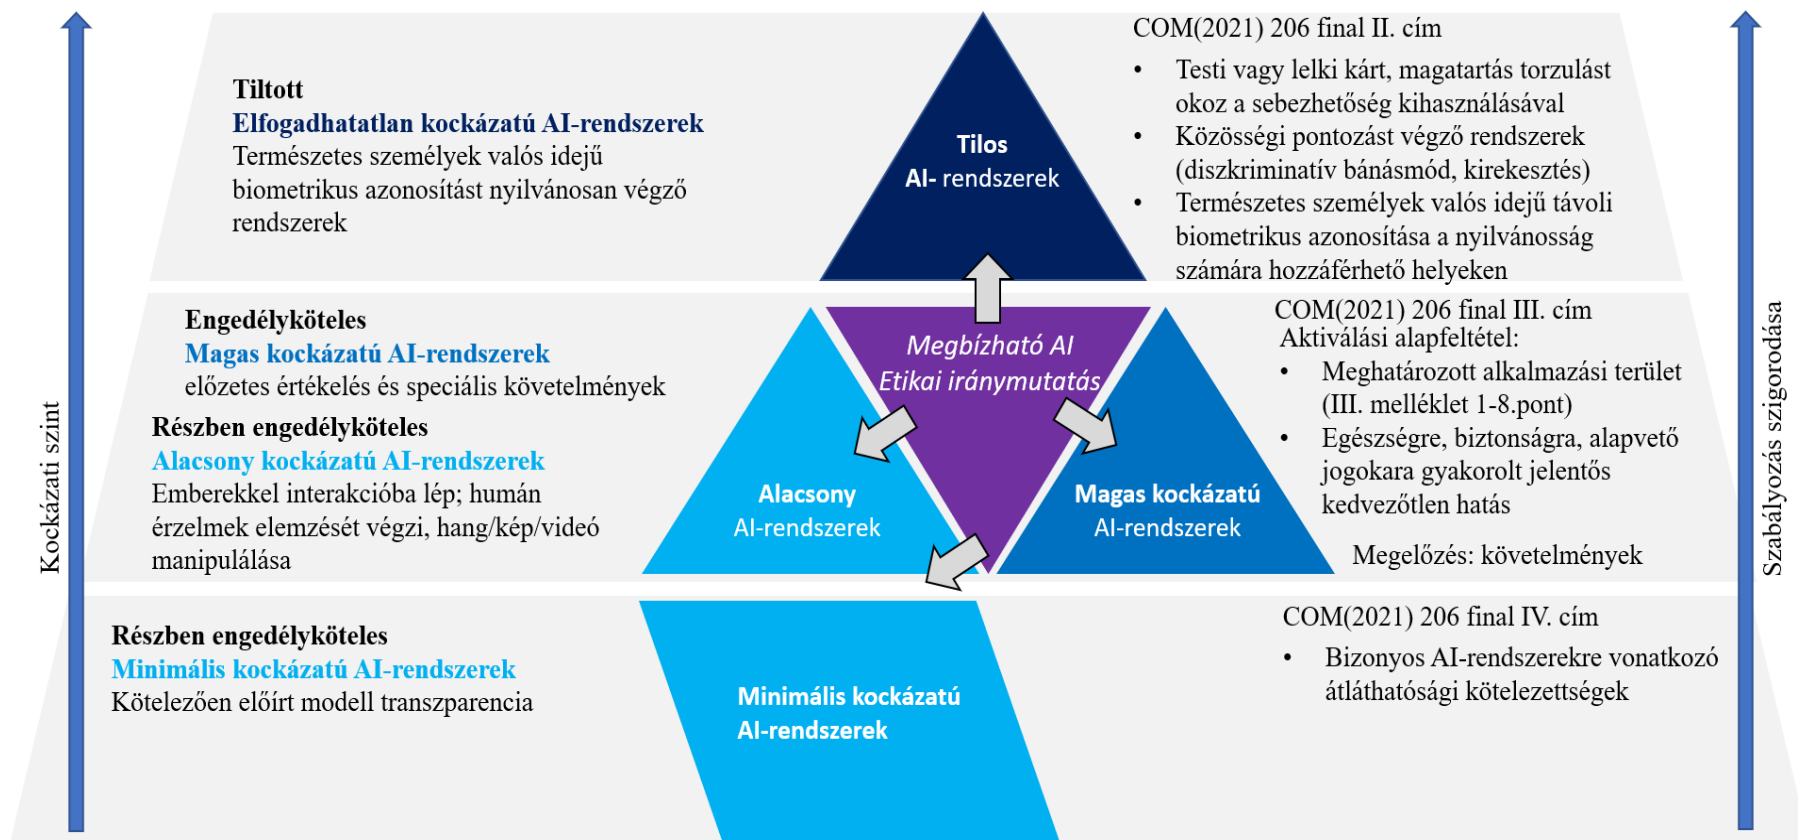
ISO sztenderdek

Az AI bevezetésével, fejlesztésével, üzemeltetésével kapcsolatos kockázatok kezelését előíró ISO szabványok hangsúlyozzák a szervezeti aspektusokat és támogatást nyújtanak a jogszabályoknak való megfelelésben (Botunac – Parlov – Bosna, 2024). Az ISO/IEC 23053:2022 szabvány egy olyan keretrendszert biztosít a mesterséges intelligencia rendszerek és a gépi tanulás technológiák egységes és érthető módon történő leírásához (ISO, 2022). Az ISO/IEC 23984:2023 szabvány útmutatást nyújt az AI-alapú termékek, rendszerek és szolgáltatások fejlesztésével, gyártásával, telepítésével vagy használatával foglalkozó szervezetek számára a kockázatok kezelésére. Célja, hogy az AI felelős használatának biztosítása érdekében, segítse az AI kockázatkezelést (AI Risk Management Framework, AI RMF) a szervezetek meglévő kockázatkezelési rendszerébe integrálni egy átfogó, strukturált és integrált megközelítéssel, amely figyelembe veszi az új lehetőségeket, a kockázati étvágy változásait (ISO, 2023a). Az ISO/IEC 42001:2023, amely az információtechnológia és mesterséges intelligencia menedzsment rendszereit szabályozza, különösen az AI rendszerek létrehozását, végrehajtását és fenntartását célozza meg, és olyan iránymutatást ad, mint az etikai megfontolások és átláthatóság, amelyek segítik a mesterséges intelligenciával kapcsolatos kockázatok rendszeres kezelését és a felelős AI fejlesztést (ISO, 2023b).

3.2. AI rendszerek kockázati osztályozása

Az AI rendelet kockázati besorolást (elfogadhatatlan/magas/korlátozott/ minimális kockázat) alkalmaz az AI rendszer tervezett célja alapján, amely egyúttal meghatározza a kockázati osztályhoz tartozó követelményeket (Schuett, 2023; Langenbacher, 2022; Malgieri – Pasquale, 2024) (16. ábra). Az alábbiakban az AI rendszerek kockázati osztályozását ismertetem.

16. ábra: Az AI-rendszerek kockázati osztályozása



Forrás: Prisznyák, 2023, pp.:177

3.2.1. Tiltott AI rendszerek

A tiltott AI rendszerek között tartjuk számon azokat a rendszereket, amelyek az emberi viselkedést tudat alatt befolyásolják/manipulálják, illetve kihasználják azon sérülékeny társadalmi csoportokat (például életkor, fogyatékoság vagy speciális társadalmi vagy gazdasági helyzet) létezését. Az Európai Unióban tiltott AI rendszernek minősülnek a társadalmi csoportok osztályozását végző AI rendszerek, amelyek az állampolgárok viselkedése, személyes jellemzői alapján profilozást végeznek (pontozó rendszerek), kivétel a bűnüldözés területe, amelyek arcfelismerési adatbázist hoznak létre. Továbbá, a munkahelyen és oktatási intézményben alkalmazott azon AI rendszerek, amelyek ez emberi érzelmeket elemzik, illetve a biometrikus adatokat alapján faji, politikai, vallási, filozófiai meggyőződést, szexuális és politikai beállítottságot igyekeznek megállapítani.

A tiltott AI rendszer minősítés alól kivételt a biometrikus adatok törvényes címkézése, szűrése, illetve azon valós idejű biometrikus azonosító rendszerek jelentenek, amelyeket bűnüldözési célra használnak nyilvános helyeken, amennyiben használatuk a helyzet súlyosságához, céljához mérten arányosan kerül alkalmazásra.

3.2.2. Alacsony kockázatú AI rendszerek

Az AI rendelet 53. preambuluma értelmében az AI rendszerek az alábbi négy feltétel valamelyikének teljesülése esetén nem jelentenek jelentős kockázatot, mivel nem befolyásolják lényegesen a döntéshozatalt, illetve az eredményét.

1. Minimális kockázatot jelentő szűk feladatokat végzése (például dokumentumok kategorizálása, duplikációk szűrése).
2. Befejezet humán oldali tevékenység output termékének javítása (például nyelvi ellenőrzés).
3. Döntéshozatali minták és eltérések észlelése - amelyet emberi értékelés követ, mint az ellenőrzés része (például tranzakciós adatok rendezése).
4. Előkészítő feladatok végzése a humán munkavállalók munkájának támogatására (például iratkezelési feladatok, szöveg- és beszédfeldolgozás, vagy dokumentumok fordítása).

Ezen szerepkörökben az AI rendszerek alacsony kockázatúnak minősülnek, mivel a humán oldali munkavállaló munkavégzését támogató eszközként a munkafolyamatból eredő kockázatkezelést támogatják, és nem célja az emberi döntést helyettesíteni vagy befolyásolni megfelelő emberi felülvizsgálat nélkül.

3.2.3. Magas kockázatú AI rendszerek

Egy AI rendszert magas kockázatúnak szükséges tekinteni, ha az egészségi és biztonsági kockázatot jelent, vagy hátrányosan befolyásolja az alapvető jogokat ((EU) 2024/1689, 7.cikk (1.) definíciók)). A kockázatkezelés jegyében a rendelet arányosan magasabb követelményeket támaszt a magas kockázatú rendszerekkel kapcsolatban, így hangsúlyozza: a kockázatkezelési rendszer kialakításának és működtetésének; az adatok és adatkezelés; a technikai dokumentáció; a nyilvántartás, a dokumentációs követelmények; az átláthatóság és információszolgáltatás; az emberi felügyelet, valamint a pontosság, robusztusság és kibervédelem fontosságát (AIA, 8.15.cikk). Ezen követelmények teljesülését az AI rendszer teljes életciklusa alatt biztosítani szükséges.

A magas kockázatú AI rendszerekre vonatkozó szabályozás két fő forrásból származik: a 6. cikk általános kritériumaiból és a III. melléklet konkrét felhasználási eseteiből. A 6. cikk (1) értelmében magas kockázatúnak minősül az az AI rendszer, amely:

- a) Biztonsági komponensként van használva egy termékben, vagy maga a rendszer termék, és
- b) A termék, amelynek biztonsági komponense az AI rendszer, vagy maga az AI rendszer, harmadik fél általi megfelelőségi értékelést igényel, hogy a terméket forgalomba lehessen helyezni vagy használatba lehessen venni az Európai Unió harmonizációs jogszabályok szerint.

Továbbá, a III. melléklet specifikus AI felhasználási esetek és alkalmazási területek listájával egészíti ki a 6. cikk feltételeit, amelyek esetében magas kockázatúnak minősül a rendszer. Ezek az alábbiak: (1) biometria (pl. távoli biometrikus azonosítás, érzélemfelismerés), (2) kritikus infrastruktúra (pl. közlekedés, víz-, gáz-, fűtés- vagy áramellátás), (3) oktatás és szakmai képzés, (4) munkavállalás, munkavállalói menedzsment és önálló vállalkozás, (5) alapvető magán- és közszolgáltatásokhoz és juttatásokhoz való hozzáférés és élvezet, (6) törvény végrehajtás, (7) migráció, menedékjog és határkezelés, (8) igazságszolgáltatás és demokratikus folyamatok ((EU) 2024/16896, III. melléklet, Magas kockázatú AI rendszerek a 6. cikk (2) bekezdésében hivatkozva). Megjegyzendő, hogy amennyiben a III. mellékletben hivatkozott alkalmazási területeknél érvényesülnek az alacsony kockázatú AI rendszer kritériumai (lásd korábban), úgy nem tekinthetők magas kockázatúnak. Azonban, függetlenül az alacsony kockázatú AI rendszerek kritériumainak teljesülésétől, magas kockázatúnak szükséges tekinteni

az AI rendszert, amennyiben természetes személyek profilalkotását végzik ((EU) 2024/16896 6. cikk (3)).

A fekete doboz modellek összetettségük miatt komoly problémát jelenthetnek a modell átláthatósága, magyarázhatósága tekintetében (Samek – Müller, 2019; Arrieta et al., 202; Panigutti et al., 2023), Ezek a modellek hajlamosak káros torzításokat elsajátítani az adatokból (akár káros visszacsatolási hurkok létezése révén), amik miatt diszkriminatív döntésekhez vezethetnek (Langenbacher, 2022) így jelentős (etikai) kockázatot eredményeznek (Addy et al., 2024). Ezzel szemben az értelmezhető és magyarázható AI modellek (explainable AI, XAI) átláthatóbb döntéshozatali folyamatokat kínálnak, elősegítve az etikus, fair és torzításmentes (megbízható) AI rendszerek létrehozását (Panigutti et al., 2023). Az AI rendszerekkel kapcsolatosan további problémaként jelentkezhettek az az alábbiak: adatvédelem (személyes adatok védelme), a generatív AI modellek hallucinációi, a platforminfrastrukturákkal járó megnövekedett kibertámadások (lásd a korábbi incidens táblázat), illetve a ML modellek emberi felügyelet nélküli autonóm döntéshozatala (Bank of Italy, 2022; Schnitze et al., 2024).

3.2.4. Generatív AI rendszer szabályozása

A nagy nyelvi modellek (Large Language Models, továbbiakban: LLM) az alapmodellek (foundation modellek) kategóriájába tartoznak, amelyek finomhangolhatóak és különböző specifikus feladatok ellátására alkalmazhatóak (Bommasani et al., 2022). Ezen modellek nyelvi inputot vesznek alapul a működésük során, eredményképpen pedig szintetikus kimenetet generálnak. Következésképpen, számos kontextusban használható és számos más AI rendszerbe integrálható. Az alapmodellek a szervezet saját specifikus céljaihoz illesztés, az adatainak felhasználása, valamint a modell –adott specifikus célt szolgáló- finomhangolása révén túllépik a nyelvi modellek területét és a generatív célú modellekké válnak, mint a GPT-4.o, a DALL-E, a BERT) és különböző szolgáltatásnyújtás (például Microsoft Azure AI, Google Cloud Vertex AI) alapjául szolgálnak (Bommasani et al., 2022). Ezen generális célú AI rendszerek olyan AI rendszerek, amely széles körű adatokon, olyan általános célú feladatok elvégzésére lettek tervezve, mint a kép- és beszéd felismerés, a hang- és videó generálás, a minta felismerés, a kérdés-válasz-alapú kommunikáció, fordítás, egyebek. Specifikációtól, finomhangolástól és adatfelhasználástól függően különböző üzleti feladatok támogatására képesek. Az AI jogszabályban lefektetett külön szabályozási szükségletet a generatív AI rendszerek széles körű alkalmazási hatóköre indukálja, amely miatt jelentős potenciállal rendelkeznek arra, hogy rendszerszintű kockázatokat generáljanak az Unió pacára a biztonságra, közbiztonságra, alapvető jogokra, vagy a társadalom egészére a modell negatív

hatásai által. Mindenképpen szükséges megjegyezni, hogy a 100. preambulum felhívja a figyelmet arra, hogy amennyiben egy GPAI modellt integrálnak egy AI rendszerbe, akkor az adott rendszert általános célú AI rendszernek kell tekinteni, ha az integráció következtében a rendszer általános célokra is használható.

Az AI rendelet alapján az általános célú AI modellek a jelentős hatásuk és rendszerszintű kockázati tényezőjük alapján kerülnek kategorizálásra az alábbi feltételek mentén:

- magas hatású képességekkel bír (51.cikk, 1. pont) (64.cikkben definiált fogalom alapján), vagy
- a modell képessége meghaladja az általános célú AI modellekben rögzített képességeket – 10^{25} számítási képesség a floating pont műveletekben mért küszöbértéket, amely a Bizottság által elfogadott technológiai állapotot tükrözi (51.cikk, 2. pont)-

A genAI modellek magas hatású képességének megállapításához a Bizottság az alábbi faktorotokat vizsgálja a XIII. mellékletben előírtaknak megfelelően: (a) modell paramétereinek száma, (b) adatállomány minősége vagy mérete, (c) betanításhoz használt számítási mennyiség, (d) modell bemeneti és kimeneti modalitásai, (e) modell képességeinek referenciaértékei és értékelései, (f) modell hatása a belső piacra, (g) regisztrált végfelhasználók száma (AIA, 51. cikk, 1.). Kapcsolódóan a 110. preambulum felhívja a figyelmet arra, hogy a rendszerszintű kockázatok a modell képességeivel és elérhetőségével növekednek.

3.3. Magas kockázatú banki AI rendszerek

3.3.1. Hitelminősítő rendszerek, HR profilozó rendszerek

A szektor agnosztikus fókuszterülete miatt az AI rendelet nem specifikusan a bankszektorban alkalmazott AI rendszerekre irányul (Malgieri – Pasquale, 2024; Botunac – Parlov – Bosna, 2024; Langenbacher, 2022). *A bankrobotika jogszabályi keretrendszerének értelmében, az AI rendszerek banki kialakítása, fejlesztése során a szektor specifikus szabályozáson túl, minden olyan meglévő EU-s jogforrást, illetve másodlagos uniós jogforrást figyelembe szükséges venni.* Ezen rendeletek (az AI rendelet mellett) további előírásokat fogalmaznak meg az AI rendszerekkel kapcsolatos adatfelhasználás, döntéshozatali mód, modell transzparencia, illetve kockázatkezelés tekintetében.

Az AIA III. számú mellékletének 5. pontjának (b) és (c) pontja meghatározza azokat a felhasználási eseteket, amelyek alapján bizonyos banki területen alkalmazott AI rendszereknek magas kockázatúnak minősülnek:

- (b) azok az AI rendszerek, amelyeket a természetes személyek hitelképességének értékelésére vagy hitelpontszámuk megállapítására szándékoznak használni, kivéve azokat az AI rendszereket, amelyek pénzügyi csalások felderítésére szolgálnak;
- (c) azok az AI rendszerek, amelyeket kockázatértékelésre és árazásra szándékoznak használni természetes személyek esetében élet- és egészségbiztosítás kapcsán.

A banki hitelminősítő AI rendszerek magas kockázati besorolása mögött az a tény áll, hogy ezek a rendszerek meghatározzák a természetes személyek hozzáférését pénzügyi forrásokhoz vagy alapvető szolgáltatásokhoz, így élethelyzetükre esetleges hátrányos hatást gyakorolhatnak, illetve fenntarthatják a hiteltörténeti adatbázisokban rejlő történelmi diszkriminációs mintákat (például faji, nemi, életkor vagy szexuális orientáció alapján), vagy új diszkriminatív hatásokat eredményezhetnek (AIA 58. preambulumbekzdése).

A hitelminősítésre használt AI rendszerek és ML modellek esetében kiemelkedő etikai aggályként jelentkezik az átláthatóság, a diszkrimináció és a magyarázhatósága (Addy et al., 2024). A modellek tanításához felhasznált, nem megfelelően tisztított historikus hitelezési adatkészlet (a modellezési elfogultság miatt) hátrányos hitelezési döntéshez vezethet (EBA, 2021; 2023; Langenbucher, 2022; Addy et al., 2024). A hiteltörténeti adatokon alapuló statisztikai elfogultság a mintában szerelő alulreprezentált (alulbankolt) csoportok esetében diszkriminatív döntéshozatalhoz vezethet (Langenbucher, 2022). A problémát az adatok minősége, a korábbi megfelelő rögzítés módja is befolyásolhatja és az adatprofiljuk alapján korábban elutasított csoportokhoz hasonló profilú ügyfél esetén kedvezőtlen döntést eredményezhet (Langenbucher, 2022). Figyelembe szükséges venni továbbá a diszkriminatív döntéshozatal kiküszöbölése érdekében a modellben esetlegesen előforduló szubjektív (emberi) elfogultság meglétét is (Addy et al., 2024). Ezen torzítások révén az AI rendszerek, ML modellek döntéshozatala akadályozhatja az ügyfelek (AI rendelet III. melléklet, 5. a. pontja által előírt) pénzügyi erőforrásokhoz való hozzáférését, mint alapvető jog teljesülését (EU 2024/1689) (European Commission, 2024). Az alapvető jogok sérelmének eshetősége (Langenbucher, 2022), illetve a potenciális diszkriminatív döntéshozatal miatt ezen modellek jelentős hatással vannak az Európai Unió állampolgárainak életére (Bonaccorsi di Patti et al., 2022), így a bankszektorban hitelminősítés, scoring (profilalkotás) céljából alkalmazott AI

rendszerek és ML modellek magas kockázatúnak minősülnek (Addy et al., 2024). A magas kockázatú besorolás alól azok a profilalkotást végző modellek jelentenek kivételt, amelyek a pénzmosás-és terrorizmusfinanszírozás (Anti-Money Laundering, AML, valamint Counter Financing Terrorism, CFT), illetve csalások elleni bűnüldözést támogatják – kapcsolódóan a bankokra érvényes, rendeletekben megfogalmazott jogszabályi előírásokhoz (például 2017. évi LIII. a pénzmosás és a terrorizmus finanszírozása megelőzéséről és megakadályozásáról szóló törvény).

Az Európai Unióban a hitelkérelmezőnek joga van információt kapni az automatizált döntéshozatali logikáról. Az AI rendszerek és ML modellek elfogultságának kiküszöbölése, Továbbá, a magyarázhatóság és az átláthatóság biztosítása érdekében a GDPR (15. cikk, az Adatkezelés átláthatósága és az érintett jogai) lehetővé teszi az ügyfelek számára a személyes adataik felhasználásával készített hitelminősítésre vonatkozó modell döntések eredményeinek és okainak megismerését. Így az ügyfélnek joga van információt kapni arról, hogy az automatikus döntéshozatal során a hitelminősítés milyen alkalmazott logika mentén hozta meg az adott döntést. Bár az érzékeny személyes adatok feldolgozását a GDPR ((71)) tiltja, kivételes esetekben, a modell elfogultság észlelésének és korrigálásának céljából, biztosítja ((GDPR (71) kivételek)) azok felhasználását a magas kockázatú AI rendszerek, ML modellek átláthatóság és magyarázhatóság érdekében (megbízható, etikus AI). A GDPR alapján az AI rendelet (10. cikk, 5. b.) is lehetővé teszi bizonyos személyes adatok felhasználását a modellkockázat (torzítások, diszkriminatív döntéshozatal, negatív visszacsatolási hurkok), kezelése érdekében az alapvető jogok és szabadság védelmének garanciája mellett. A különleges személyes adatok feldolgozása csak akkor engedélyezett, ha a torzítás észlelése és korrigálása nem érhető el más adatok, például szintetikus vagy anonimizált adatok felhasználásával, ha a személyes adatok újrafelhasználására szigorú technikai és biztonsági intézkedéseket alkalmaznak, biztosítva a hozzáférés megfelelő szabályozását, az adatok biztonságos törlését a szükség megszűnésekor, valamint ha a feldolgozás indokoltságát megfelelő dokumentációval alátámasztják ((AIA 10. cikk, (5) b)). Az etikus elvek érvényre juttatása és a kockázatkezelés érdekében az AI rendszer egész élettartama alatt működtetni szükséges az AI kockázatkezelési rendszer, amely szükség esetén biztosítja a korrekciós intézkedések megtételét, monitoringját, felülvizsgálatát (AIA 9. cikk; Addy et al., 2024) .

További magas kockázatú területként azonosítható az AI rendszerek HR területen történő felhasználása (AIA, 57. preambulumbekzdés). Az AI rendszerek különösen a HR alábbi területein: személyek toborzása és kiválasztása, a munkavégzés feltételeire vonatkozó döntések

meghozatala, előléptetés és a munkavégzéssel kapcsolatos szerződéses kapcsolatok megszüntetése, feladatok kiosztása egyéni viselkedés, személyes jellemzők vagy tulajdonságok alapján, továbbá a munkával kapcsolatosan a személyek megfigyelése vagy értékelése, magas kockázatú kategóriába sorolandók, mivel ezek a rendszerek jelentős hatással lehetnek a jövőbeni karrierlehetőségekre, a személyek megélhetésére és a munkavállalói jogokra. Fennáll ugyanis annak veszélye, hogy a modellek megőrzik az adatbázisban rejlő diszkriminációs mintázatokat bizonyos csoportokkal szemben (nők, bizonyos életkorú csoportok, fogyatékossgal élő személyek, faji vagy etnikai háttérrel rendelkező személyek). Továbbá, azon AI rendszerek, amelyek a teljesítmény és viselkedés nyomon követésére szolgálnak (profilozás), szintén alááshatják az alapvető adatvédelmi és magánélethez való jogokat.

3.3.2. Magas kockázatú banki generatív AI modellek

A bankszektorban alkalmazott generatív AI modellek kockázati besorolása a modell hatásától és számítási kapacitásától is függ. Itt mindenképpen szükségesnek tartom figyelembe venni az 51.cikk a, pontjával kapcsolatosan a XIII. mellékletben nevesített (f) és (g) pontokat, amely alapján a GPAI modell magas hatással lehet a belső piacra, ha az legalább 10 000 regisztrált üzleti felhasználó (f) /végfelhasználó (g) számára elérhető az Unió területén. Ily módon elméletileg az ügyféltámogatásra szánt banki chatbotok is érintettek lehetnek (regisztráció kritériumként való szerepeltetése esetén pedig a banki mobil applikációkba épített intelligens chatbotok). A szakirodalmi és szürkeirodalmi kutatások alapján ugyanakkor nem találtam olyan publikációt, amely a végleges AI jogszabály elfogadását követően került publikálásra és a regisztráltak számával összefüggésben tárgyalná az alkalmazott GPAI rendszerek rendszerszintű kockázati besorolását. (A felhasználói küszöbérték ugyanis nincs meghatározva az AIA tervezetében, amely alapján számos tanulmány készült 2023 végén, illetve 2024 elején.)

3.3.3. MNB Sandbox, InnovationHuB

Az alkalmazott ML modelleknek magyarázhatónak szükséges lenniük a szabályozó hatóság felé (Samek – Müller, 2019; Arrieta et al., 2020; EBA, 2021; EBA, 2023). Következésképpen, azok a modellek, amelyek a benchmark modellekhez képest magasabb teljesítményt nyújtanak a validációs adatok alapján, ugyanakkor nem képesek az előrejelzéseket teljes mértékben magyarázni, nem alkalmasak a gyakorlati alkalmazásra (Ala'raj – Abbod – Majdalawieh, 2021; Liu – Fan – Xia, 2022; Munkhdalai et al, 2020).

Az AIA előírja, hogy a szolgáltatók regisztrálják a magas kockázatú AI rendszereket és fejlesztőiket az uniós adatbázisban ((EU) 2024/1689 71. cikk) (European Commission, 2024).

Ezáltal a szolgáltatók igazolják, hogy az AI rendszer megfelel az AIA követelményeinek, és biztosítják, hogy az AI rendszer nem megkülönböztető, nem manipulatív, nem tisztességtelen, nem pontatlan, illetve jogilag megfelelő célra kerül felhasználásra (Malgieri – Pasquale, 2024). A megfelelőségértékelés (AIA, 43. cikk) (minőségirányítási rendszer, műszaki dokumentáció értékelése) biztosítja az AI rendelet ex ante jellegét és ezáltal a megbízható mesterséges intelligencia rendszerek fejlesztését és üzembe helyezését az Európai Unióban. A jogszabályi előírásoknak nem megfelelő banki AI rendszerek esetében a nemzeti adatvédelmi hatóságok bírságokat rónak ki a bankra, továbbá kötelezik őket a korrekciós intézkedések megtételére (például a Budapest Bank, illetve a Berlin SA esete.)

A megfelelőség támogatását felügyeleti oldalról az MNB Innovation Hub és Regulatory Sandbox eszközei látják el. A Regulatory Sandbox olyan ellenőrzött keretet jelent, amely szabályozói felügyelet mellett teszi lehetővé az AI rendszerek szolgáltatói számára az AI rendszerek, ML modellek gyakorlati alkalmazásához hasonló feltételeket imitáló környezetben történő tesztelését és validálását. Kapcsolódóan, a FinTech Jogtár szolgáltatása segít a vállalatoknak a vonatkozó jogszabályok és kötelezettségek megértésében, valamint az engedélyezési folyamat zökkenőmentes lebonyolításában (Fáykiss et al., 2018). A szabályozói támogatás lehetőséget ad arra, hogy a FinTech vállalatok közvetlenül konzultáljanak az MNB-vel a szabályozási kérdésekről, így elősegítve a jogszabályi megfelelést és a piaci innovációk gyorsabb bevezetését.

Az elképzelés összefüggésben áll a bankrobotika terület lehatárolásának elképzelésével. A honlap jelenlegi státusza alapján az AI technológiákhoz kapcsolódó jogszabályi linek még nem elérhetőek (17. ábra).

17. ábra: Az MNB Innovation Hub bankrobotikával kapcsolatos elképzelése



Forrás: <https://www.mnb.hu/innovation-hub/fintech-jogtar#szabalyok>

A magas kockázatú AI rendszerek kockázatkezelési követelményei be kell, hogy épüljenek a bankok meglévő kockázatkezelési rendszereibe – összhangban a CRD IV 74. cikkével –. Az AI kockázatkezelési rendszerek *integrálása* a bankok kockázatkezelési rendszerének megújítását igényli (EBA, 2024; ISO, 2023a; Schuett, 2023; Deloitte, 2023; NIST, 2024; Schnitzer et al., 2024). Ezen kockázatkezelési rendszereket a jogszabályok mellett nemzetközi sztenderdek (ISO, 2022; 2023a; 2023b) és iránymutatások is támogatják (EBA, 2023). A humán felügyelet támogatja, hogy a bankok megbízható belső irányítási rendszerekkel rendelkezzenek, amelyek átlátható szervezeti struktúrát, egyértelmű felelősségi köröket, és hatékony eljárásokat tartalmaznak a kockázatok azonosítására, kezelésére és jelentésére. Ezért a következő alfejezetben az autonóm robotok felügyeletét biztosító felügyeleti lehetőséget tekintem át a banki kockázatkezelés jegyében (Prisznyák, 2024a alapján).

3.4. Az autonóm AI rendszerek emberi felügyelete

A megbízható, etikus AI rendszerek kialakítása során a cél, hogy az AI rendszereket olyan eszközként fejlesztik és használják, amely az embereket szolgálja, tiszteletben tartja az emberi méltóságot és személyes autonómiát, és amely megfelelően irányítható és felügyelhető az emberek által (AI jogszabály, 27. preambuluma alapján). A banki kockázatkezeléssel foglalkozó szakembereknek és törvényhozóknak tisztában kell lenniük az AI (mögöttes technológia) fejlődése és a növekvő autonómia révén jelentkező kockázatokkal (Beer – Fisk – Rogers, 2014; Shneiderman, 2020; Morris et al., 2024). A BCBS elismerte, hogy a módosított Operatív Kockázat Megfelelő Kezelése nem fedett le megfelelően bizonyos fontos működési kockázati forrásokat (BIS, 2011). Az AI és kapcsolódó technológiák okozta kockázatok kezelése érdekében a bankoknak ki kell alakítaniuk saját AI kockázatkezelési rendszerüket – integrálva azt a már meglévő kockázatkezelési rendszerükbe – (ISO, 2023a; Schuett, 2023; Deloitte, 2023; NIST, 2024; Schnitzer et al., 2024; Prisznyák, 2023c, 2024a). Az EU-ban az AI Jogszabály és a Megbízható mesterséges intelligenciára vonatkozóan etikai iránymutatás olyan követelményeket állítanak fel, amelyek hangsúlyozzák az emberi felügyelet szükségességét, amely magába foglalja az AI rendszerek megértését, a döntések nyomon követhetőségét, az AI döntésekbe történő beavatkozás vagy azok felülírásának lehetőségét - biztosítva, hogy a rendszer autonómiája ne veszélyeztesse az emberi alapjogokat. (EU) 2024/1689, 14. cikk; HLEG, 2019). Az autonóm robotok mint nem-morális ügynökök alapvető kérdése a felelősség problémája, amely nem értelmezhető az ügynök szintjén. Kapcsolódóan, az AI Törvény és az etikai irányelvek összehasonlítását az autonóm magas kockázatú AI rendszerek esetében, az emberi felügyeleti mechanizmusok alapján, a 7. táblázat tartalmazza.

7. táblázat: Az emberi felügyelet az AI Törvényben és az Etikai iránymutatás a megbízható mesterséges intelligenciára vonatkozóan: összehasonlítás

Szempont	AI ACT	Etikai iránymutatás a megbízható mesterséges intelligenciára vonatkozóan
	Emberi felügyelet (14. cikk)	Az emberi cselekvőképesség támogatása és emberi felügyelet (II. fejezet, 1.1.)
Az emberi szerepvállalás és felügyelet tervezése és fejlesztése	AI rendszereknek hatékonyan felügyeltnek kell lenniük természetes személyek által (14. cikk (1)).	A felhasználóknak rendelkezniük kell a szükséges tudással és eszközökkel az AI rendszerek megértésére, interakcióra és, ha lehetséges, az autonóm értékelésre vagy kihívásra (HOTL, HITL, HIC).
Kockázatsökkentés és	A cél az egészség, biztonság vagy alapvető jogok kockázatainak megelőzése vagy minimalizálása és az előrelátható visszaélések elkerülése céljából (14. cikk (2)).	Az AI rendszerek nem veszélyeztethetik az emberi autonómiát, és nem okozhatnak negatív hatásokat vagy befolyásolhatják az emberi viselkedést manipuláció, megtévesztés, herd immunizáció vagy kondicionálás révén.
Felügyeleti, kontroll mechanizmusok	Az intézkedések arányosak kell legyenek a kockázatokkal, autonómia szinttel és a használat kontextusával a magas kockázatú AI rendszerek életciklusa során (14. cikk (3)).	Biztosítani kell a biztonságot és a kontroll intézkedéseket az alkalmazástól és a kapcsolódó potenciális kockázatoktól függően.
Működési képességek és korlátozások megértése	A rendszer működését, beleértve annak képességeit és korlátozásait (anomáliák, működési zavarok, váratlan teljesítmény) monitorozni kell (14. cikk (4.a.)).	A felhasználóknak tájékozott autonóm döntéseket kell hozniuk a rendszer képességeinek és korlátozásainak megértésén alapulón.
Túlságos függőség elkerülése	Az emberi felügyeletnek pontosan meg kell értenie és értelmeznie kell a magas kockázatú AI rendszer által generált kimeneteket, figyelembe véve a rendelkezésre álló értelmezési eszközöket és módszereket (14. cikk (4.b)).	<i>nem specifikált</i>
Kimenetek helyes értelmezése	Az emberi felügyeletnek tartózkodnia kell a következtetések és ajánlások figyelmen kívül hagyásától, ellenállásától vagy visszavonásától a magas kockázatú AI rendszer által (14. cikk (4.c)).	Tartalmazhatja a rendszer alkalmazásának elkerülését, az emberi diszkreció kiigazítását működés közben, vagy a döntések felülbírálatát.
Felülbírálati képessége	Az emberi felügyeletnek képesnek kell lennie eldönteni, hogy nem használja a rendszert, vagy felülírja annak kimenetét (14. cikk (4.d)).	
Beavatkozás és leállítás	Az emberi felügyelet beavatkozhat vagy biztonságosan leállíthatja a rendszert (14. cikk (4.e)).	<i>nem specifikált</i>
Kétlépcsős hitelesítés (négy szem elve)	Legalább két kompetens személynek kell ellenőriznie és megerősítenie az intézkedéseket vagy döntéseket a rendszer kimenete alapján (14. cikk (5)).	<i>nem specifikált</i>

Forrás: Saját táblázat

Amint az összehasonlító táblázatból is látszik, az etikusság és a robotok autonómiájának kérdésköre tehát olyan formán áll összefüggésben az AI szabályozással, hogy a humán oldali szereplő folyamatok integráltsága miképp biztosítja az emberiség – ez esetben az Európai Unió - számára kiemelt értékek és célok megvalósulását. *De mit is jelent a robot/AI rendszer autonómia?*

Az autonómia és a képesség fontos elemei az ember-robot interakció (HRI) fejlesztésének (Beer – Fisk – Rogers, 2014; Baraka – Alves-Oliveira – Ribeiro, 2020). Az autonómia olyan entitásokra, gépekre, természetes személyekre és intézményekre vonatkozik, amelyek saját magukat irányítják és szabályozzák (Formosa, 2021). Robotok esetében azonban az autonómia olyan önálló mesterséges ügynököket jelent, amelyek előre programozott algoritmusok alapján működnek, anélkül, hogy szabad akarattal rendelkeznének, és részleges vagy teljes emberi felügyelet alatt állnak (Parasuraman – Sheridan – Wickens, 2000; Etzioni – Etzioni, 2016). A robot/AI rendszer automatizálása/autonómiája esetén a cél, hogy a korábban elkerülhetetlen emberi komponens mechanikai elemekkel helyettesül (Parasuraman – Sheridan – Wickens, 2000). Huang (2004) az autonómiát a rendszer képességeként tárgyalja, amely érzékelést, észlelést, elemzést, kommunikációt, tervezést, döntéshozatalt és cselekvést foglal magában, hogy a tervezett HRI részeként előre meghatározott célokat érjen el az emberi operátor által. Ezzel összefüggésben Bekey (2005) hangsúlyozza a rendszer képességét arra, hogy külső irányítás nélkül működjön a valós világban az idő múlásával. Baraka, Alves-Oliveira és Ribeiro (2020) a definíciókat a robotok valós idejű interakciójára összpontosítva finomították. Russell és Norvig (2003) az autonómia témáját az AI ügynökök képességein keresztül közelítik meg, és hatféle AI ügynököt különböztetnek meg. A robotok autonómiája a szakirodalomban széles spektrumot ölel fel, a teljesen autonóm rendszertől a teljesen nem autonóm rendszerig (Bekey, 2005; Beer – Fisk – Rogers, 2014).

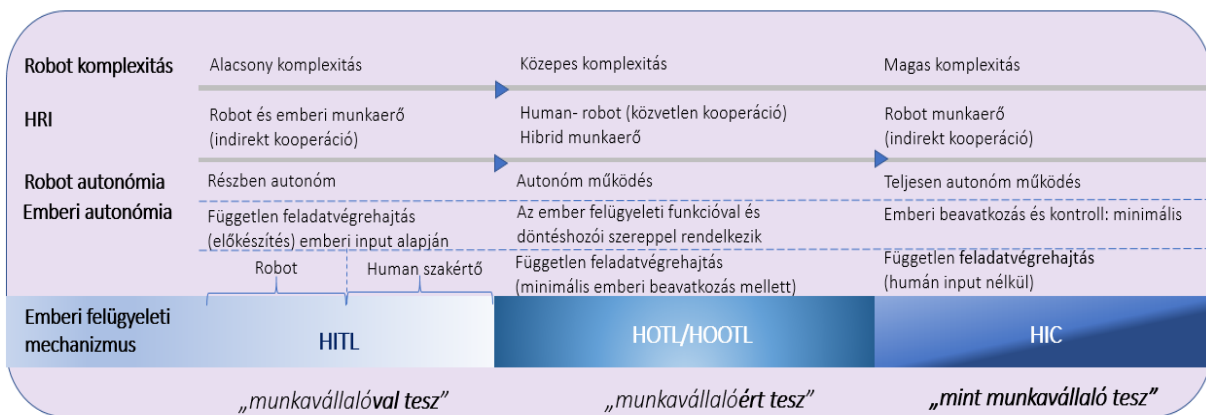
Az AI rendszerek autonómiájával összefüggően a humán felügyeleti és ellenőrzési mechanizmusok szükségességét mind az akadémiai szakirodalom, mind a kapcsolódó jogszabályok és szakpolitikai dokumentumok hangsúlyozzák. A humán munkavállalók felelősek a felügyeleti mechanizmusokért, amelyek az AI és kapcsolódó technológiák szintjétől és alkalmazási eseteitől függően változnak (Morris et al., 2024). Az emberi felügyelet szintjének megkülönböztetésére Verdiesen, Santoni de Sio és Dignum életciklus-alapú megközelítést javasolnak (Verdiesen – Santoni de Sio – Dignum, 2021). Shneiderman (2020) egy kétdimenziós keretrendszert vezetett be, amely elkülöníti az autonómia/automatizálás szintjeit az emberi irányítás szintjeitől.

A magas autonómia és a magas emberi irányítás kombinációja megbízható, biztonságos és megbecsült AI rendszerekhez és emberközpontú AI működésekhez vezethet (Shneiderman, 2020). Morris és szerzőtársai (2024) az autonómia szintjeit az AGI modellek képességei és jellemzői alapján különböztetik meg (L0: nincs autonómia-tól L5: szuperintelligencia-ig) (Morris et al., 2024). A robotok autonómiája és az emberi felügyelet hatékonysági

problémákhoz vezethet, mivel a megbízható működés és a magas megbízhatóság biztosítása érdekében megnövekedett ellenőrzésre lehet szükség (autonómia paradoxon). A robotok autonómiája és az emberi munkaerő autonómiája nem zéró összegű játék (Formosa. 2021). Például az érthető AI rendszerek szükségessége elősegíti az emberi ítélőképesség fejlesztését is (Cao, 2021).

Az autonóm AI rendszerek alkalmazásából adódó kockázatok helyes kezelése érdekében, ahelyett, hogy egyszerűen azt kérdeznénk, mit tud a technológia, az operatív kockázatkezelésnek a következőket kell kérdeznie: (1) mit tud tenni egy robot egy alkalmazottért (az emberek együtt dolgoznak a robottal), (2) mit tud tenni egy robot egy alkalmazottal (az ember irányít és a rendszer az ő nevében működik), (3) mit tud tenni egy robot mint alkalmazott (az emberek nem vesznek részt a rendszer működésében, a robot autonóm módon működik mint alkalmazott) - hogy tükrözze a robot/ember autonómia közötti trade-off-ot. Ez a megközelítés illusztrálja a rendszer autonómiája és a potenciális felügyeleti mechanizmusai közötti kapcsolatot, nevezetesen HITL (human-in-the-loop), HOTL (human-on-the-loop) vagy HIC (human-in-command), amelyek felelősek az AI rendszerek feletti kontroll fenntartásáért (18. ábra) (HLEG, 2019).

18. ábra: Az autonómia és felügyeleti mechanizmusokkal kapcsolatos operatív kockázati szemléletváltás



Forrás: Saját ábra (Prisznyák, 2024a)

Az emberi felügyeleti mechanizmusok gyakorlati érvényesülésének vizsgálata érdekében a HunOR adatbázist vizsgáltam. Az eredményeket az empirikus résznél tárgyalom.

A következő fejezetben az AI, ML, intelligens robotok és kapcsolódó technológiák banki front/middle/back office területeken történő alkalmazásainak szakirodalmát tekintem át.

4. Bankrobotika a banki front/middle/back office-ban

A mesterséges intelligencia és kapcsolódó technológiák megteremtették a lehetőséget az emberi döntéshozatali folyamat részleges/teljes átvételére, a szociális szituációkban való részvételre, s ezáltal növekvő kihívást jelentenek a természetes intelligencia dominanciájára bizonyos területeken (Song - Kim, 2022). A felhasználási körök szélesedésének következtében a banki front, middle, back office területeken is egyre inkább teret nyernek (Zheng, Zhang, és Zhang 2023; Prisznyák 2022a,b; Wang, 2023). Belharet és társai az AI alkalmazásának hét kulcsfontosságú területét azonosították: (1) magas fokú szolgáltatás perszonalizáció (hiperperszonalizáció), (2) autonóm rendszerek kialakítása, (3) prediktív elemzés alapú döntéstámogatás, (4) ügyfélkommunikáció, (5) minták és anomáliák azonosítása, előjelzése, (6) felismerő rendszerek, (7) cél-vezérelt rendszerek (Belharet et al., 2020). Az AI rendszerek felhasználása a front office területek ügyfélorientált banki folyamataival kezdődően (intelligens chatbot, robot tanácsadók befektetés kezelése, lemorzsolódó ügyfelek előrejelzése, optimalizált CRM), a middle office területeken át (hitelezési és működési kockázat kezelés, monitoring, követeléskezelés) egészen a back office területekig terjed (e-KYC, csalásfelderítés, pénzmosás- és terrorizmusfinanszírozás megakadályozása, stressztesztek, jogszabályi megfelelés támogatása) (Kaya, 2019; Vijai – Suriyalakshmi – Elayaraja, 2020; Malali – Gopalakrishnan, 2020). Kutatómunkám során a 19. ábrán szemléltetett funkcionális területi felosztással élek a bankrobotika technológiák egyes területeken megvalósuló felhasználási lehetőségeinek vizsgálata érdekében.

19. ábra: A banki front, middle, back office szakterületek - saját felosztás

Front office	Middle office	Back office
MARKETING & CRM ÉRTÉKESÍTÉS <ul style="list-style-type: none">• Befektetés Kereskedés• Hitelezés• Számlakezelés és fizetési kezdeményezés• Termék tanácsadás• Pénzügyi tanácsadás• Portfólió és vagyonkezelés	Operáció Kockázatkezelés <ul style="list-style-type: none">• Hitelelemzés,• Scoring tevékenység,• Ügyfélminősítés,• Ügyfél profil kialakítás	Kockázatkezelés <ul style="list-style-type: none">• Csalásmegelőzés, AML, CFT• Compliance (KYI, KYC)• Modell validáció (Scoring hitelkockázati modellek; Stressz teszt) és egyéb banki kockázatok menedzselése (hitelezési, működési, likviditási, piaci, egyebek) <p>Továbbá: HRM, IT& Bankbiztonság, Data management, Ügyfélszolgálat, treasury, pénzügy, kontrolling, egyebek)</p>

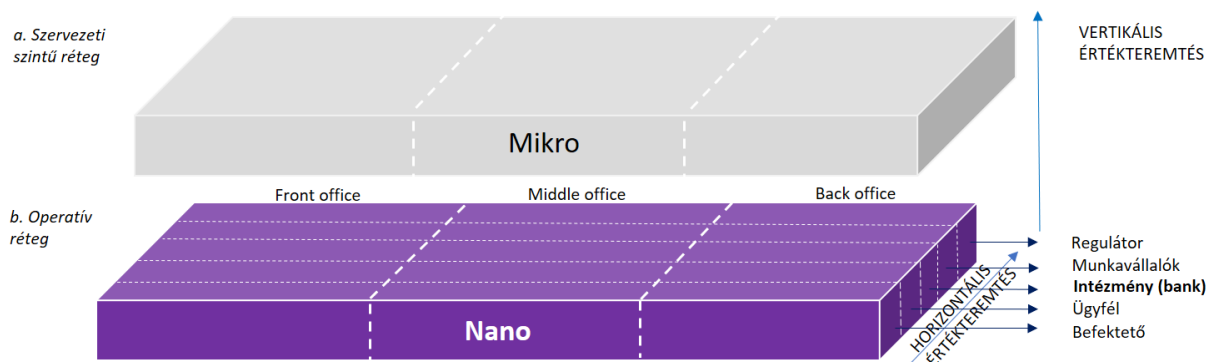
Forrás: Saját ábra

Az AI, ML, intelligens robotok és kapcsolódó innovatív technológiák banki front/middle/back office területeken történő alkalmazása komplex, jellemzően a

munkafolyamatok számos pontjához csatlakozva teremtenek értéket (Prisznyák 2022a, 2023c). A szakirodalomban az ML modellek teljesítményének mérésére szolgáló benchmarkok széles körben elterjedtek. Ezeket általában különálló szakterületeken definiálják és elemzik, átfogó keretrendszer vagy jogszabályi megfontolások nélkül, főként a technológiák alkalmazásához kapcsolódó benchmarkok felállítására fókuszálva.

Következésképpen, az AI és kapcsolódó innovatív technológiák banki front, middle, back office területeken megvalósuló alkalmazásának vizsgálatát a bankrobotika HVM modelljének az intézmény (bank) aspektusához illeszkedő nano szintű vizsgálódási keretébe végzem el (20. ábra) – kapcsolódva a DNS modell 2. réteg b (technológiai alkalmazkodás) részéhez.

20. ábra: A bankrobotika technológiák front/middle/back office területi illeszkedése a szervezet nano szintjén



Forrás: Saját ábra

4.1. Front office területek és a bankrobotika

Az ügyfelek megtartása hozzájárul a kereskedelmi bankok nyereségességének növeléséhez (Verma, 2019). Következésképpen, a banki front office területen alkalmazott ML megoldásokkal foglalkozó szakirodalom jelentős hangsúlyt fektet: az ügyfélviselkedés megértésére (vásárlási szokások, mintázatok,) az értékesítés/volumenitás előrejelzésére (kampányok, up/cross selling, ügyfél lemorzsolódás), az ügyfélpreferenciához illeszkedő marketing és értékesítési kampányok támogatására, valamint a portfólió- és vagyongazdálkodási terület támogatásának lehetőségeire (portfólió kiegyensúlyozás, portfólió képzés, diverzifikáció, kereskedés) (Verma, 2019; Loukili – Messaoudi – El Gazi, 2022; Bartram – Branke – Motahari, 2020; Zheng – Zhang – Zhang, 2023; Xiaotian – Jiang – Jionglong, 2021; Lee et. al., 2021). A következő alfejezetekben a Sales és marketing, portfólió- és vagyongazdálkodás területeken alkalmazott ML és kapcsolódó innovatív technológiák

felhasználási lehetőségeit elemzem. Ezt követően pedig kitérek a portfólió-és vagyongazdálkodási területen, valamint a bankfiókokban alkalmazott AI megoldásokra.

4.1.1. Sales, Marketing

4.1.1.1. Alkalmazott algoritmusok

Az adatalapú AI, ML alkalmazások a sales és marketing, CRM területén olyan fejlesztésekre irányulnak, mint a személyre szabott pénzügyi szolgáltatások, az intelligens pénztárcák, a hangvezérelt banki megoldások, ügyféltámogatás és költségcsökkentési intézkedések (Jewandah, 2018). Az értékesítési és marketing stratégia személyre szabása keretében az ügyfelek demográfiai, viselkedési és egyéb jellemzőin alapuló ügyfélszegmentációt végeznek, amelynek keretében olyan homogén ügyfélcsoportokat alakítanak ki, amely elősegíti a vásárlási hajlandósággal bíró ügyfelek pontosabb azonosítását (cross-selling, up-selling lehetőségei⁹, a lojális ügyfelek elégedettségének fokozását célzott kampányokon keresztül, a lemorzsolódó ügyfelek előrejelzését, valamint az ügyfélkapcsolat hatékonyságának növelését (Sharahi – Aligholi, 2015; Ayoubi, 2016; Palaniappan, et al., 2017; Mandurkar et al., 2022; Dawood – Elfakhrany – Maghraby, 2019). A bank és ügyfele közötti kapcsolat a kínált termékek sajátosságai (konstrukciók és lejáratidő) miatt jellemzően hosszú élettartamú kapcsolatot feltételez, amelynek köszönhetően a bank célja az ügyfél megtartása és az élettartam értékének (Customer Lifetime Value, továbbiakban: CLV) maximalizálása (Verma, 2019; Leung – Chung, 2020). Amennyiben az ügyféllemorzsolódás bekövetkezik az ügyfél CLV-je csökken (Seymen et al., 2022). Kapcsolódóan teret nyertek az ügyfélszegmentáció ügyféllemorzsolódást előrejelző ML modellek vizsgálatát és benchmarkok felállítását célzó kutatások (Seymen et al., 2022; Loukili – Messaoudi – El Gazi, 2022). Ellenben kevés azon kutatások száma, amelyek a modell megmagyarázhatóságának javítását (Samek – Müller, 2019), az ügyfél magatartásának időbeni (dinamikus) változásának vizsgálatára irányulnak (Leung – Chung, 2020), vagy az ügyfélszegmentáció hatékonyságára gyakorolt hatást elemzik (Van – Nguyen – Nguyen Thi, 2017). Az úgynevezett „churn”, vagyis lemorzsolódó ügyfelek előrejelzése az árazási stratégia, kampánytervezés (termék, szolgáltatáskínálat ajánlat, promóció) esetében is kiemelkedő jelentőségű (Loukili – Messaoudi – El Ghazi, 2022). (Kapcsolódóan az értékesítési folyamathoz, a banki hitelezés egy általános folyamatát illusztrálja a 9. számú melléklet.)

A ML modellek kampánytervezésben betöltött szerepe kiemelkedő a CLV alapú megtérülés javítása és a személyre szabott érkeztetési kampányok tervezése és a lemorzsolódás megakadályozása során (Moro – Cortez – Rita, 2015; Verma, 2019). Patil és Dharwadkar a

megfelelő ügyfélszegmentáció kialakítását a lemorzsolódó ügyfelek hatékony azonosításának és menedzselésének elengedhetetlen eszközének tekinti (Patil – Dharwadkar, 2017). Tran, Le és Nguyen a hitelkártya adatokon alapuló vizsgálata nem támasztja alá az ügyfélszegmentációnak hatását a modell ügyféllemorzsolódás előrejelzési képességére (Tran – Le – Nguyen, 2017). Ezen ML modellek jellemzően kiegyensúlyozatlan adatbázisokon szükséges, hogy működjenek, mivel a banki churn ráta kedvező esetben alacsony (Guliyev – Tatoğlu, 2021; Mandurkar et al., 2022). Következésképpen, előtérbe kerülnek az adatbázist kiegyensúlyozó és különböző mintavételezési technikák, mint a SMOTE (Leung – Chung, 2020; Mandurkar et al., 2022), illetve az ügyféladatokon végzett dinamikus osztályozási megközelítések (Leung – Chung, 2020).

A szakirodalom a churn ráta előrejelzésében a felügyelt gépi tanulási modellek, mint például a K-közép, a fuzzy c-közép és a mesterséges neurális hálók (ANN) pontosságát hangsúlyozza a felügyelt gépi tanulási modellek általános teljesítményével szemben (Dawoo, Elfakhrany, és Maghraby, 2019). Ugyanakkor az alkalmazott modellek teljesítménye között koránt sincs egyetértés. A churn ráta előrejelzésben legjobban teljesítő algoritmusként számos esetben a RF algoritmust (Verma, 2019), illetve a hosszabb futási idővel rendelkező mélytanuló algoritmusokat (mint az ANN, CNN) (Seymen et al., 2022), illetve az SVM algoritmust (Tran – Le – Nguyen, 2017) jelöli meg a szakirodalom, amelyet jellemzően a LR, illetve k-NN követ (Seymen et al., 2022). A DT algoritmus uralmát hangsúlyozza a k-NN, NB, RF, SVM modellekkel szemben Elrefai, Elgazzar és Khodeir, míg Oyeniyi és Adeyemo alátámasztja a K-közép algoritmus hatékonyságát az ügyfelek viselkedési mintázatainak feltérképezése során (Oyeniyi – Adeyemo, 2015; Elrefai – Elgazzar – Khodeir, 2021). Sabbeh (2018) az együttes tanulási technikák révén elérhető magas előrejelző képességet hangsúlyozza.

A javasolt ML modellekkel szemben Hea és szerzőtársai az SVM algoritmus kiegyensúlyozatlan adatbázisokon való alkalmazásának problémája alapján megállapítják, hogy az ügyféllemorzsolódás előrejelzésére önmagában nem ad kielégítő megoldást az algoritmus. Viszont a véletlenszerű mintavételezés jelentősen javítja az SVM modell előrejelzési pontosságát (Hea et al., 2014). Seymen és társai a CNN (mélytanuló algoritmus) alkalmazhatóságát kérdőjelezzik meg a jellemzően alacsony lemorzsolódó ügyfélszámot tartalmazó adatbázisok miatt (Seymen et al., 2022). Cao a legjobb előrejelzőként a GB algoritmust azonosítja, szemben a vizsgált RF, LR és NB modellekkel (Cao, 2021). Mindez kapcsolódik korábbi back office területet érintően tett megállapításomhoz, amely szerint

működési logika és teljesítmény szempontjából nincs egyetlen olyan ideális algoritmus, amely bármely feladatra alkalmazhatóan jobb megoldást kínál (Prisznyák, 2022b).

A ML modellek teljesítményének optimalizálására használt módszerként a hiperparaméterek keresztvalidációval történő beállítását javasolja Loukili, Messaoudi and El Ghazi (2022), ami hozzájárul a modellek előrejelzési pontosságának növeléséhez, és képes az SVM, k-NN, LR és RF esetében is magas pontosságú előrejelzést létrehozni. Hasonlóképpen keresztvalidációval támogatott validáció és hiperparaméterezés mellett az XgBoost és a RF modell magas pontosságát mutatja ki Guliyev és Tatoğlu (2021). Ugyanakkor a ML modellépítés során az eltérő modellek által a különböző változóknak tulajdonított fontosságot (célváltozót melyik változó befolyásolja leginkább) is szükséges figyelembe venni (Cao, 2021).

A ML modellek szempontjából kihívásként jelentkezik a megfelelő adatok elérhetősége, a modellhibák kezelése, valamint a modell átláthatóság és magyarázhatóság biztosítása (Samek – Müller, 2019; Arrieta et al, 2020), amelyeket nehezítenek az AI rendeletben, illetve a CRR-ben megfogalmazott modellekkel kapcsolatos követelmények teljesülését (AIA, (EU) 2024/1689; CRR 174., 175., 177. cikkei). Ezen problémák a fekete doboz jelenségekhez vezethetnek el (Bussmann et al., 2020; Guliyev – Tatoğlu, 2021; Cao, 2021; Bank of Italy, 2022). A fekete doboz modellek fehér doboz modellekké (átláthatóvá) alakítására szolgáló (CAM, LIME, SHAP) módszerek elősegítik a modellek, algoritmusok értelmezhetőségének javítását (Cao, 2021). A SHAP (Shapley Additive exPlanations, Shapley additív magyarázatok,), modellfüggetlen módszer, amely a modell megmagyarázhatóságát támogatja a változók és az eredmény között lévő kapcsolat feltérképezésével (Cao, 2021; Bussmann et al. 2020) s ezáltal hozzájárul a feketedoboz jelenségek transzparensbbé tételéhez (Lundberg – Lee, 2017). Megjegyzendő, hogy a modell futási ideje lineárisan növekszik a feldolgozott adatok mennyiségének függvényében (Cao, 2021). A SHAP módszer a lemorzsolódás előrejelzés mellett a hitelminősítési rendszereknél is gyakran használt (Torrent – Visani – Bagli, 2020). Guliyev és Tatoğlu az ügyféllemorzsolódás előrejelzése során felhívja a figyelmet a súlyosan kiegyensúlyozatlan adatbázisokból eredő osztályozási problémára (Guliyev – Tatoğlu., 2021). A szakirodalom szintetizálása alapján a lemorzsolódó ügyfelek aránya (éves, átlagos szinten) 0,91% (Hea et al., 2014) és 16,07% közé tehető (banki ügyfélkör függvényében) (Cao, 2021). Ez azt jelenti, hogy az adatkészlet erősen kiegyensúlyozatlan. Másképp, a lemorzsolódó ügyfelek aránya jóval kevesebb azon ügyfelek számánál, akik tartósan aktív kapcsolatot ápolnak a bankkal (Hea et al., 2014; Leung – Chung, 2020). Az alacsony lemorzsolódási arány megnehezíti a ML modellek megbízható, pontos osztályozási arányának elérését. Így

előfordulhat, hogy a gépi tanulási modellek osztályozása magas pontossági arányokat mutat, mégis a lemorzsolódó ügyfelek előrejelzésében viszonylag alacsony pontosságot képes produkálni (túlillesztés problémája) (Seymen et al., 2022). Következésképpen, a kiegyensúlyozatlan adatbázisok a ML modellek gyenge tanulási teljesítményét eredményezhetik (Leung – Chung, 2020; Guliyev – Tatoğlu, 2021; Uzair, et al, 2019; Verma, 2019). Az egyensúlyhiányos adatbázisok esetében alkalmazott osztályozási algoritmusok általában elfogultak a többségi osztályok (nem lemorzsolódó ügyfél) irányába, ami növeli a lemorzsolódott ügyfelek előrejelzésének hibaszázalékát. Ezen probléma feloldására az osztályok eloszlásának kiegyenlítésére szolgáló eljárások (a minta újraválasztása, a túl/alulmintavételezési technikák, a mesterséges adatgenerálás, a minta súlyozása), illetve a hibrid algoritmusok, valamint a felügyelt tanítású modellek szolgálnak (Leung – Whingyan, 2020; Guliyev – Tatoğlu, 2021). Guliyev és Tatoğlu az adatbázis kiegyensúlyozatlan jellege miatt alulmintavételezési eljárást vagy olyan döntési fa alapú algoritmusokat javasolnak, mint a DT, RF, XGBoost algoritmus (Guliyev – Tatoğlu, 2021). Leung és Chung (2020) egy dinamikus osztályozási megközelítést dolgoz ki, amely során SMOTE túlmintavételezési technika kiegyensúlyozza az adatokat úgy, hogy a kisebbségi osztály (például a lemorzsolódott ügyfelek) esetében szintetikus példányokat hoz létre, ezzel növelve az ilyen adatok számát a valós lemorzsolódási adatok alapján. Ezen technikákat az 10. számú mellékletben hasonlítom össze.

Megjegyzendő, hogy az algoritmusok teljesítményének összehasonlítását nehezíti a ML modellépítés kiinduló folyamata (adatgyűjtés, adatbázisok, attribútumok), az alkalmazott mintavételi technikák (alul/túlmintavételezés), valamint az adatbázis kiegyenlítő megoldások és hiperparaméterezés szerzőnként eltérő alkalmazása.

A szakirodalom elemzés alapján, a Sales és marketing területen alkalmazott algoritmusok körét a 8. táblázat tartalmazza. (Az alábbi táblázatban az együttes tanuló modellek jele: ET.), míg a Sales és marketing területen alkalmazott ML modellek feldolgozott szakirodalmainak rendszerezett áttekintését a 11. számú melléklet ismerteti.

8. táblázat: Sales és marketing területen alkalmazott ML algoritmusok

Szerző(k), év	NN	XGBoos t	DT	RF	k-NN	SVM	FT	LR	GB	ANN	CNN	CART	NB	adaBoos t	K-közép	fuzzy-c mean
Moro – Cortez – Rita (2015)	x															
Guliyev, Tatoğlu (2021)		x	x	x												
Mandurkar et al. (2022)		x	x		x	x	x	x								
Verma (2019)		x	x					x		x						
Leung, Chung (2020)				x				x	x							
Tran – Le – Nguyen (2017)			x	x	x	x		x								
Seymen et al. (2022)					x	x		x		x	x					
Cao (2021)				x				x	x				x			
Sabbeh (2018)				ET	x	x		x	ET	ET		x	x	ET		
Hea et al. (2014)						x		x								
Loukili – Messaoudi – El Ghazi (2022)				x	x	x		x								
Elrefai – Elgazzar – Khodeir (2021)			x	x	x	x							x			
Dawood – Elfakhrany – Maghraby (2019)										x					x	x
Sharahi – Aligholi (2015)															x	
Ayoubi (2016)	x															
Palaniappan et al. (2017)			x	x									x			
Patil – Dharwadkar (2017)										x						
Oyenyi – Adeyemo (2015)															x	

Forrás: Saját táblázat

4.1.1.2. *Tipikus attribútumok az ügyféllemorzsolódás modellezésénél*

Az ügyféllemorzsolódás ténye (igen/nem), illetve a potenciálisan lemorzsolódó ügyfelek az elemzésbe bevont változók révén kerül előrejelzésre. A vizsgált szakirodalmak alapján ML modellépítés során használt alapvető ügyfélváltozókra példa: az életkor, a nem, az oktatás, a családi állapot jövedelem, a foglalkozás, a bankkal lévő kapcsolat kezdete, céginformációk, egyéb. Az ügyfélváltozók mellett alapvető üzletindikátorokat is figyelembe vesznek a modellépítésnél, amelyet további alkategóriákra oszthatunk. A hitel-és pénzügyi adatok esetében jellemzően az alábbiakkal dolgoznak: hitelkeretek, késedelmes fizetésekkel kapcsolatos információ, előző fizetések összege, hiteltípusok, betéti és egyéb számlák, hitelösszeg, fedezet típusok, kommunikációs adatok (kontakt adatok és típus, hívási időtartam, hívás eredménye, előző kapcsolattartások eredménye), kampányok száma, POS eszközhasználat, a tranzakciós adatok (jellemzően utalt összeg, tipikus utalási időpontok, közlemény tárgy), vállalati hitelezésnél céginformációk (bejegyzés helye, foglalkoztatottak száma, vagyoni és jövedelmezőségi, eredményességi adatok), illetve egyéb adatok.

4.1.2. Portfólió– és vagyongazdálkodás

A ML algoritmusok hozzájárulnak a portfólió–és vagyongazdálkodás hatékonyságának növeléséhez, a tranzakciós költségek csökkentéséhez, és a befektetési inklúzió növeléséhez (Bartram – Branke – Motahari, 2020; Mirete – Ferrer et al., 2022). Az alábbiakban szakirodalmi áttekintést nyújtok arról, hogyan segíthetnek a ML modellek és robot-tanácsadók a részvényárfolyamok előrejelzésében, a hatékony portfóliók kialakításában és menedzselésében, valamint a kereskedés támogatásában.

4.1.2.1. *Részvényárazás és hozam előrejelzése ML modellekkel*

A gépi tanulás alkalmazása a portfólió- és vagyongazdálkodás terén egyre nagyobb teret hódít a pénzügyi szektorban. Az eszközárzás és a hozamok előrejelzése területén a gépi tanulási algoritmusok kivételes hatékonysággal bizonyítottak. Az eszközárzás, a portfólió várható hozamainak és a befektetési eszközök kockázati prémiumának előrejelzése terén a neurális hálózatok és a döntési fák algoritmusai kimagasló teljesítményt nyújtanak (Gu – Kelly – Xiu, 2020). Kaczmarek és Perez (2022) a RF modellt a várható hozamok előrejelzése alapján az optimális portfólió építésére alkalmazza magas hatékonysággal.

A pénzügyi piacokon egyre inkább előtérbe kerülnek a fejlett ML-algoritmusok, amelyek jelentős mértékben hozzájárulnak a befektetési stratégiák kialakításához. A részletes pénzügyi adatok fundamentális elemzését a RF mellett, a SGD boosting algoritmust is hatékonyan

támogatja (Chen et al., 2021). A pénzügyi eszközök árfolyam előrejelzését a genetikus algoritmus által kidolgozott befektetési stratégiák is hatékonyak képesek követni (Agudelo – Medina – Méndez, 2020). A részvények árazási irányváltásainak előrejelzésére, illetve az alul/túteljesítő részvények előrejelzésére a szakirodalom által gyakran alkalmazott algoritmusként jelentkeznek a mélytanuló algoritmusok. Ezek közül kiemelkedik az LSTM és CNN, amelyek jellemzően túteljesítik a velük szembe állított benchmark modelleket (Fischer – Krauss, 2017; Shukla, 2019; Chaweewanchon – Chaysiri, 2022; Wang et al., 2020; Wu et al., 2021; Vivek et al., 2022; Lee et. al., 2021; Wang; 2023).

A nyereséges tőzsdei kereskedést a tőzsdeindexek hozamának ML-alapú előrejelzése segítheti, amit Jasic és Wood neurális hálózatokkal végeznek, globális részvénypiaci adatok alapján (Jasic – Wood, 2004). Rouf és szerzőtársai a részvények a tőzsdeindexek és részvényárfolyamok előrejelzéséhez alkalmazott algoritmusok körének elemzését követően megállapítják, hogy az SVM és az ANN az egyik legnépszerűbb algoritmus (utóbbit a pontossága és gyorsasága miatt részesítik előnyben) (Rouf et al., 2021). A neurális hálózatok hatékonyságát a tőzsdei előrejelzések során Strader és társai is megerősítik (Strader et al., 2020). Ugyanakkor fontos megjegyezni, hogy a robot-tanácsadók legjobban stabil vagy jól teljesítő piaci körülmények között működnek (Bartram – Branke – Motahari, 2020). A részvényindexekkel kapcsolatos kereskedési stratégia kialakítását a fuzzy kiterjesztésű együttes tanulók hatékonyabban képesek támogatni, mint a különálló algoritmusok fuzzy kiterjesztés nélkül (Zheng – Zhang – Zhang, 2023).

A tőzsdei kereskedési stratégiák fejlesztése során a hibrid megközelítések különösen eredményesnek bizonyulnak. A minél pontosabb részvényárfolyamok előrejelzése érdekében, gyakori az egyes algoritmusok kombinációjaként előálló új modellek kialakítása, így például a CNN és LSTM kettőségek keretrendszer (Wu et al., 2021). Hasonlóképpen, Shukla (2019) által javasolt O– LSTM algoritmus piacfüggetlen, mivel a mélytanulás LSTM dinamikáját alkalmazza, ahelyett, hogy mereven rögzítettek lennének az adatok. A részvények előválogatásának elősegítését a hibrid modellek (CNN, LSTM) rendszerint felülmúlják a többi modellel szemben a Sharpe-ráta, az átlagos hozam és a kockázat szempontjából is (Chaweewanchon – Chaysiri, 2022).

4.1.2.2. *Portfólió optimalizálás és portfólió menedzsment (újra egyensúlyozás) ML modellekkel*

A modern portfólióelméleten alapuló ML algoritmusok hatékonyan képesek kezelni a portfóliókat, figyelembe véve az ügyfelek kockázati és hozamelvárásait, és segítenek az

optimális eszközallokációs (részvények, kötvények, befektetési alapok) döntések meghatározásában (Phoon – Koh, 2018). Ily módon a portfóliók az egyes kockázati szintekhez tartozó optimális hozamok elérésére vannak optimalizálva (Cocca, 2016). A szakirodalom alapján, a ML modellek által létrehozott kockázat- és hozamoptimalizált portfóliók (Sharpe hányados alapján 16%-kal) jobb teljesítményt nyújtanak, mint az $1/N^*$ portfóliók (a portfóliók egyszerű, egyenlő súlyozású elosztása) (Kaczmarek – Perez, 2022). A ML modellek elősegíthetik a portfóliókonstrukciók megbízhatóságát és stabilitását azáltal, hogy a hagyományos eljárásokhoz képest pontosabb portfólió súlyozásokat alakítanak ki az optimalizáció során, előre meghatározott kritériumokhoz (például VaR, CVaR maximalizálás) igazodva.

A részvényhozamok, a kockázati prémiumok és opcióárak prognózisának készítésére az egyik legnépszerűbb algoritmus az ANN és az SVM (Alberg –Lipton, 2017; Abe –Nakayama, 2018; Bianchi – Büchner –Tamoni, 2019; Becker – Cheridito – Jentzen, 2019). A RF algoritmus az optimális portfólió építést és a várható hozamok előrejelzését is képes támogatni (Kaczmarek – Perez, 2022). Az e téren alkalmazott algoritmusok körét a szakirodalom tovább árnyalja. Aithal és szerzőtársai megállapítják, hogy a portfólió optimalizálás során a K-közép algoritmus is magasabb hozamot biztosít a benchmark hozamokhoz képest (Aithal et al., 2023). Az alul-, illetve túlteljesítő (hozamú) részvények kiválasztásához és a részvényhozam előrejelzésének vizsgálata révén megvalósuló portfólió optimalizációhoz az LSTM algoritmus is hatékony segítséget nyújt, amely teljesítménye meghaladja benchmarkként alkalmazott RF, SV és DNN modellekét (Wang et al., 2020). A mélytanuló algoritmusok (például autoencoder algoritmus) hatékonyan alkalmazható a portfóliók gyakorisági alapú újra egyensúlyozására és a súlyok módosítására a minimális varianciájú portfóliók előállítása érdekében, miközben jobb megoldást nyújt a kockázatminimalizálásra, mint a hagyományos módszerek (Conlona et al., 2021).

Chaweewanchon és Chaysiri (2022) a Markowitz átlag-variancia alapú portfóliók optimalizálásához (részvényár előrejelzés és előválogatás) hibrid modellt alkalmaztak (CNN és BiLSTM kombináció), és megállapították, hogy a részvények előválogatásának integrálása javíthatja az ML modell teljesítményét. A javasolt módszer felülmúlja a benchmark modelleket a Sharpe-ráta, az átlagos hozam és a kockázat szempontjából is. Az együttes tanulás technikán alapulva az együttes tanulási modellek (ensemble model) bármely más egyéni algoritmushoz képest pontosabb előrejelzést képesek szolgáltatni.

4.1.2.3. *Portfólió szisztematikus és nem szisztematikus kockázatkezelése és diverzifikáció*

A portfólió diverzifikáció elérése érdekében gyakran tőzsdén kereskedett értékpapírokból álló befektetési kosarat vagy indexet használnak, amely lehetővé teszi, hogy néhány alap vásárlásával piaci portfóliót alakítsanak ki. A ML modellek és robot tanácsadók által alkalmazott befektetési stratégiák általában a Markowitz-féle portfólióelméleten alapulnak (Bartram – Branke – Motahari, 2020). Ugyanakkor a ML modellek használata során fontos figyelembe venni, hogy a piaci adatokban megjelenő anomáliák (például fekete hattyú események, pénzügyi válságok vagy piaci volatilitás) torzíthatják a mintákban lévő összefüggéseket, ami kihívást jelent a modellek megbízhatóságában és teljesítményében (Bartram – Branke – Motahari, 2020). Továbbá, a portfólióban lévő eszközök teljesítménye a kitétségtől függően eltérő pénzügyi és gazdasági változók által befolyásolt. A pénzügyi piacok (alul teljesítés, összeomlás, hozamok előrejelzése) és a makrogazdaságot érintő információra tett előrejelzések (kamatlábak, makrogazdasági mutatók) a portfólió kockázatkezelésének kulcsfontosságú információ forrásai (Manela – Moreira, 2017). Az ANN algoritmus alkalmazása hatékony segítséget nyújthat a gazdasági-és pénzügyi kockázati tényezők modellezésében is, figyelembe véve a kovariánsok nemlinearitását, valamint a diverzifikálható és nem diverzifikálható kockázatokat (Bartram – Branke – Motahari, 2020; Gu – Kelly – Xiu, 2019). A rendszerszintű kockázatok meghatározásánál gyakran használt algoritmusként jelentkezik a LASSO algoritmus is, amely képes kiválasztani a leginkább releváns szisztematikus kockázati tényezőket. A ML algoritmusokon alapuló stratégiák jóval magasabb kockázat-korrigált hozamot eredményeznek, mint az egyszerű lineáris regresszió (Hanauera – Kononova – Rapp, 2022).

A modellezési kockázatkezelése, valamint a kiberbiztonsági jogszabályi előírásoknak való megfelelés megteremtése a ML modellek és robot tanácsadók kialakításának fontos részét szükséges, hogy képezzék (European Commission, 2021). A hagyományos algoritmusokhoz képest nagyobb rugalmasságot és komplexitást biztosító evolúciós algoritmusok különösen a kockázatkezelésben jelentkeznek új, támogató megoldásként, míg kiberbiztonsági szempontokból a hagyományos biztonsági intézkedések és előírások alkalmazása továbbra is érvényben marad. Az evolúciós algoritmusok képesek kezelni az összetett korlátokat és több cél egyidejű optimalizálását, ami lehetővé teszi a befektetők és portfóliómenedzserek számára, hogy pontosabb és személyre szabottabb befektetési stratégiákat dolgozzanak ki (Bartram – Branke – Motahari, 2020).

4.1.2.4. *Egyéb pénzügyi előrejelzések támogatása ML modellekkel*

A ML modellek különösen hasznosak a pénzügyi szektorban. Ezek segíthetnek például a nyugdíjtervezés hatékonyabbá tételében (Fisch – Laboure – Turner, 2018), az ideális részvénykereskedelmi stratégiák kidolgozásában (Zheng – Zhang – Zhang, 2023), valamint a rövid távú árfolyammozgások előrejelzésében, amelyhez a mélytanulási technológiák, mint az LSTM (Long Short-Term Memory) is hozzájárulnak (Lee et. al., 2021). Ezen kívül, a gépi tanulás segítségével pontosabban előrejelezhetők a kriptovaluták hozamai és a piaci trendek, mint a medve- és bikapiacok, mint a hagyományos módszerekkel (Xi Xiaotian – Jiang – Jionglong, 2021).

4.1.2.5. *Kereskedés és robot tanácsadók*

A kereskedés dinamikus automatizálása nagymértékben hozzájárult a pénzügyi piacok szabályozásának, összetettségének, méretének, sebességének növekedéséhez, amely megnehezítette a humán befektetők számára a valós idejű piackövetést és beavatkozást. Szükségképpen a kereskedés területén is teret nyertek az automatikus előrejelzést és döntéstámogatást nyújtó ML megoldások és robot tanácsadók, amelyek képesek a profitot-termelést javítani. (Puhle, 2016). Kapcsolódóan a humán munkaerő alacsony költségű alternatívájának szánt robot-tanácsadók olyan (ügyfél irányítású) automatizált online platformok (szoftverek), amelyek algoritmusokat alapul véve szolgálnak ki üzleti célokat (például vagyongazdálkodás esetén befektetési portfóliók menedzselését végzik) (Jung et al., 2018; Abraham – Schmukler – Tessada, 2019).

A robot-tanácsadó feladata közül az alábbi négy egymástól élesen elkülöníthető: (1.) befektető kockázati profiljának kialakítása („túlzottand sztenderd” kérdőívek), igények felmérése, (2.) befektetési lehetőségek ajánlása és a befektetési stratégia végrehajtása, (3.) portfóliók figyelemmel kísérése és értékelése, szükséges korrekciók (eszközök eladása, súlyok állítása) kivitelezése. Működésüket a klíringházakkal, brókerekkel biztosított kapcsolattartásuk biztosítja (Ivanov et al, 2018). Vagyis, a robot-tanácsadók, mint automatizált platformok, az ügyfél (befektető) előzetesen felmért kockázati profiljához, és befektetési céljaihoz igazodva jellemzően kockázatértékelési, piaci előrejelző ML modell segítségével állítják össze az egyéni befektetési stratégiához illeszkedő portfóliót. Ennek alakulását aztán folyamatosan nyomon követik, és elvégzik a szükséges portfólió kiigazítást (kiegyensúlyozás, adás-vétel végrehajtás) (Phoon – Koh, 2018; Zheng – Zhang – Zhang, 2023; Wang, 2023). A vagyongazdálkodás robot tanácsadókkal és intelligens chatbotokkal történő támogatásának egyik legnagyobb előnye a személyre szabott portfólió- és vagyongazdálkodás lehetősége (Phoon – Koh, 2018).

A rendszerek lehetnek teljesen automatizáltak vagy hibrid (humán-robot) rendszerek, attól függően, hogy van-e emberi beavatkozás a folyamat során (például a portfóliók kiegyensúlyozásánál). Az automatizált rendszerek a humán erőforrás bevonás hiányában költséghatékonyabb szolgáltatásnyújtást eredményeznek. Továbbá általában alacsonyabb díjakat (adminisztrációs és egyéb költségek) számítanak fel, és kisebb minimális befektetési összegekkel (befektetések küszöbérték) is működnek, amelyek akár negyedére is csökkenthetik a hagyományos befektetési folyamatok költségeit. Ezzel hozzájárulnak az inklúzió vagyongazdálkodási területén történő növeléséhez (Jung et al., 2018; Abraham – Schmukler – Tessada, 2019; Marchinares – Alonso; 2020). A robot tanácsadók alkalmazása – az említett előnyök mellett – növelhetik azon befektetők esetében a bizalmi faktort, akik a portfóliókezelő érdekeinek saját célú érvényesítésétől (csalás) tartanak (Brenner – Meyll, 2020).

Az automatizált kereskedés nem jelent garanciát. Ennek oka, egyrészt az AI rendszerekkel összefüggő kockázatokra (nem szándékosan beprogramozott diszkrimináció, negatív visszacsatolási hurkok, egyebek) vezethetőek vissza, másrészt (ahogyan a 2. fejezet AI incidens táblázatában 2017/07/27-es dátumú eseténél láthattuk) előfordult már, hogy valamely bank algoritmusai olyan befektetési alapokat részesítettek előnyben, amelyeket harmadik felek finanszíroznak, és akik cserébe nagy összegeket fizettek a banknak azért, hogy hozzáférjenek a tehetősebb ügyfelekhez. Kapcsolódóan előtérbe kerülnek az adatvédelmi és az etikai kérdések, amelyeknek szükségképpen meg kell jelenniük az AI rendszer, ML modellek tervezési folyamatában is (Fisch – Laboure – Turner, 2018, Prisznyák, 2023b). Az aggodalmakat tovább fokozzák a kiberbiztonsággal, valamint a felhasználók oktatásával (és pénzügyi tudatosságával) és a kockázati profil meghatározásával kapcsolatos meglátások is (FINRA, 2016). Fontos Továbbá, hangsúlyozni, hogy nem minden esetben húzódik meg valós AI a platform által szolgáltatott befektetési tanács mögött (Leffrang – Mueller, 2023) az AI-címkézés jelenége következtében (Federal Trade Commission 2021, 2023; Prisznyák, 2023c). A portfólió-és vagyongazdálkodási területen alkalmazott ML modellek kiinduló adatbázisa rendszerint valamilyen részvényekre (FTSE-100, S&P 500, SET50), befektetési alapokra/ termékekre (opciók és futures), részvényindexeket (NASDAQ) követő portfólióra vonatkozó adatbázis.

A portfólió-és vagyongazdálkodás területen alkalmazott ML modellek szakirodalmi áttekintését a 12. számú melléklet tartalmazza, míg az A alkalmazott algoritmusokat az alábbi 9. táblázat szemlélteti. (A dőlt betűvel jelölt X azt fejezi ki, hogy az adott szerző az algoritmus egy speciális verzióját alkalmazza.)

9. táblázat: Portfólió-és vagyongazdálkodás területen alkalmazott ML algoritmusok

#	Szerző(k), év	NN	LASSO	DT	RF	k-NN	SVM	FT	LR	GB	ANN	CNN	LSTM	NB	SGD boosting	K-közép	Genetikus algoritmus
# 1	Kaczmarek – Perez (2022)				X												
# 2	Gu – Kelly – Xiu (2020)	X		X					X								
# 3	Shukla (2019)	X							X				X				
# 4	Chaweewanchon – Chaysiri (2022)	X											X				
# 5	Fischer – Krauss (2017)	X			X				X				X				
# 6	Wang et al. (2020)	X			X		X						X				
# 7	Wu et al. (2021)	X					X					X	X				
# 8	Aithal et al. (2023)															X	
# 9	Vivek et al. (2022)						X				X		X				X
# 10	Wang – Li – Li (2020)															X	
# 11	Lee et. al. (2021)												X				
# 12	Agudelo – Medina – Méndez (2020)																X
# 13	Chen et al. (2021)				X										X		
# 14	Conlona – Cotter – Kynigakisc (2021)	X													X		
# 15	Hanauera – Kononova – Rapp		X		X				X	X							
# 16	Zheng. – Zhang – Zhang (2023)	<i>ezeiktől teljesen eltérő algoritmusok</i>															
# 17	Xiaotian – Jiang – Jionglong (2021)	X															
# 18	Wang (2023)	X			X								X				

Forrás: Saját táblázat

4.1.3. Intelligens robotok az ügyféltérben

Az első fejezetben korábban már értekeztem a fizikai/digitális robotokról. Kapcsolódóan az alábbiakban a testet öltött banki robotokat tárgyalom röviden.

Az autonóm módon, szoftverekkel és fizikai robotokkal működő, ember nélküli bankfiókok már valósággá váltak (Financial Times, 2017; Nepal SBI Bank, 2017; The Guardian, 2018; Prisznyák, 2024). A bankokban alkalmazott robotok jellemzően a szolgáltató robotok körébe sorolhatóak (Prisznyák, 2023c). A bankszektorban számos humanoid, antropomorf robot létezik (Prisznyák, 2024b) – bár magyarországi bankfióki bevezetésük egyelőre még várat magára (Prisznyák, 2023c). Az alkalmazott fizikai robotok célja, hogy humán-robot interakciókat biztosítsanak, támogatva a banki ügyfelek kiszolgálását és az ügyfélélmény javítását. A szolgáltató robotok tervezése során gyakran az antropomorfizmus elve érvényesül, amely során az emberek emberi tulajdonságokkal ruházzák fel a robotokat annak érdekében, hogy a robotokat szociális aktorként érzékeljék az ügyfelek - ezzel is elősegítve a humán-robot interakció sikerességét (Epley – Waytz – Cacioppo, 2007; Fox – Gambino, 2021).

Az automatizált bankfiókok és a tradicionális bankok ügyfélélményének fokozására különféle humanoid robotokat alkalmaznak (NAO, Pepper, Sberbasha, Robot Anna, Promobot, Lakshmi, Pari, OPBA, Link 237) (21. ábra) (Prisznyák, 2023c). A banki robotok elfogadottságát három fő dimenzió befolyásolja: a funkcionalitás, az emberszerű megjelenés és a szociális képességek reprodukálásának képessége (Epley – Waytz – Cacioppo, 2007). Azok a robotok, amelyek képesek hatékonyan és megbízhatóan végrehajtani funkcionálni (például információ nyújtás, tanácsadás), pozitívan befolyásolják a felhasználók percepcióját (Bhatti – Leidner, 2021). Megjelenésüket tekintve az emberi vonásokkal (például fej, karok és mimika) rendelkező robotok, általában kedvezőbb fogadtatásban részesülnek, mivel az emberek hajlamosak magasabb intelligenciát és képeséget tulajdonítani ezeknek a robotoknak, amíg nem morbid módon hasonlóak az emberre (Mori, 1970). A robotok szociális képességei (verbális és non-verbális kommunikáció), valamint az érzelmi reakciók (például a boldogság, düh) kifejezése, illetve a kapcsolódó mozgásformák, (gesztusok, mimika, karok mozgása) jelentős befolyásolják az elfogadottságukat (Asprino et al., 2022). Ezek megléte pozitívan hat a robotok érzékelésére és a fogyasztói élményre (Cafaro, Vilhjálmsson, – Bickmore, 2016). A témáról bővebben a további kutatási irány fejezetben értekezek Prisznyák (2024b) alapján.

21. ábra: Intelligens robotok a banki ügyfélterekben



	2010	2014	2015	2016	2016	2016	2017	2018	2019	2019
Robotics company	YDreams	Softbank Robotics	Aldebaran Robotics	Softegy Innovations	Nautilus Hyosung	IDMind	Paaila Technology	Sberbank Robotika laborja	Nam A Bank	Promobot
Bank deploy the robot	Santander Group	HSBC, Mízuho Bank, Rabobank, Capital Bank of Jordan, Emirates NBD, Leumi Group, DSK Bank	Mitsubishi UFJ bank	City Union Bank	Sberbank	Banco Bradesco	Paaila Technology Sberbank's robot lab	Nam A Bank	National Bank of Oman, Sberbank	
Hungarian robot landscape	X	X	X	X	X	X	X	X	X	X

Forrás: Saját ábra (Prisznyák, 2023c)

4.2. *Middle office és a bankrobotika technológiák*

A bankok, mint a pénzügyi közvetítőrendszer kiemelt szereplőinek működése során a kockázatkezelés és a potenciális veszteségek számszerűsítése valamennyi terület tevékenységében kiemelt szerepet tölt be (Kovács – Marsi, 2018; Meshkova – Wawrzyniak - Wójcik-Mazur, 2019). A bankok a meghatározott kockázati stratégia és kockázati étvágy mellett is prudens módon, a jogszabályi előírásoknak (tőkekövetelmények) megfelelően szükséges, hogy működjenek a bizalom és stabilitás alapjain - elkerülendő a bankrendszerből kiinduló gazdasági válságokat. A kockázattípusok közül a hitelezési, működési, piaci kockázatok a legjelentősebbek a bankok életében, amelyeket mellett számos egyéb kockázatkategória is létezik (koncentrációs, befektetési, ország, hírnév, pénzmosás-és terrorizmusfinanszírozási, makrogazdasági, modell, egyéb kockázat) (Kovács – Marsi, 2018). Ebből kiindulva, a szabályozás is elsősorban ezen kockázattípusokkal kapcsolatosan határoz meg elvárásokat és módszertanokat. Ugyanakkor az elmúlt évek digitális transzformációja magával hozta ML modellek térnyerését a hitelezési területeken, elősegítve a hitelértékelési folyamat felgyorsítását, valamint a pontosabb előrejelzések készítését (Brotcke, 2022; El Qadi et al., 2023). Ezen technológiák által a leggyakrabban támogatott tevékenységek között szerepelnek az alábbiak: kockázati korlátok kialakítása, kockázatértékelés, portfólió elemzés, scenárió elemzés, érzékenység vizsgálat, stressz tesztek, scoring, rating tevékenység, a várható veszteség meghatározása és a kockázatotott érték meghatározása (El Qadi et al., 2023).

A kockázatkezelési mechanizmusok keretében az AI rendelet kockázatalapú megközelítést alkalmaz, amely mentén az AI-rendszereket a magas kockázati kategóriába szükséges sorolni, amennyiben jelentős hatást gyakorolnak az állampolgárok pénzügyi forrásokhoz való hozzáférhetőségére, így élethelyzetére gyakorolt esetleges hátrányos hatásokra (diszkriminatív modelldöntés) (Bank of Italy, 2022). A middle office területen ilyen kiemelt döntést a hitelminősítő rendszerek gyakorolnak a társadalomra, Következésképpen, a hitelminősítő rendszerek esetében alkalmazott ML modellek magas kockázattúnak tekintendők ((COM(2021) 206 final)) (European Commission, 2021). Az ilyen esetekben alkalmazott modellekre vonatkozó követelményeknek illeszkedniük szükséges a szakág specifikus bankszabályozást biztosító jogszabályi keretrendszerbe. Az alábbiakban a middle office területen alkalmazott bankrobotika technológiák áttekintése következik.

4.2.1. Az adósminősítés ML-alapú támogatása

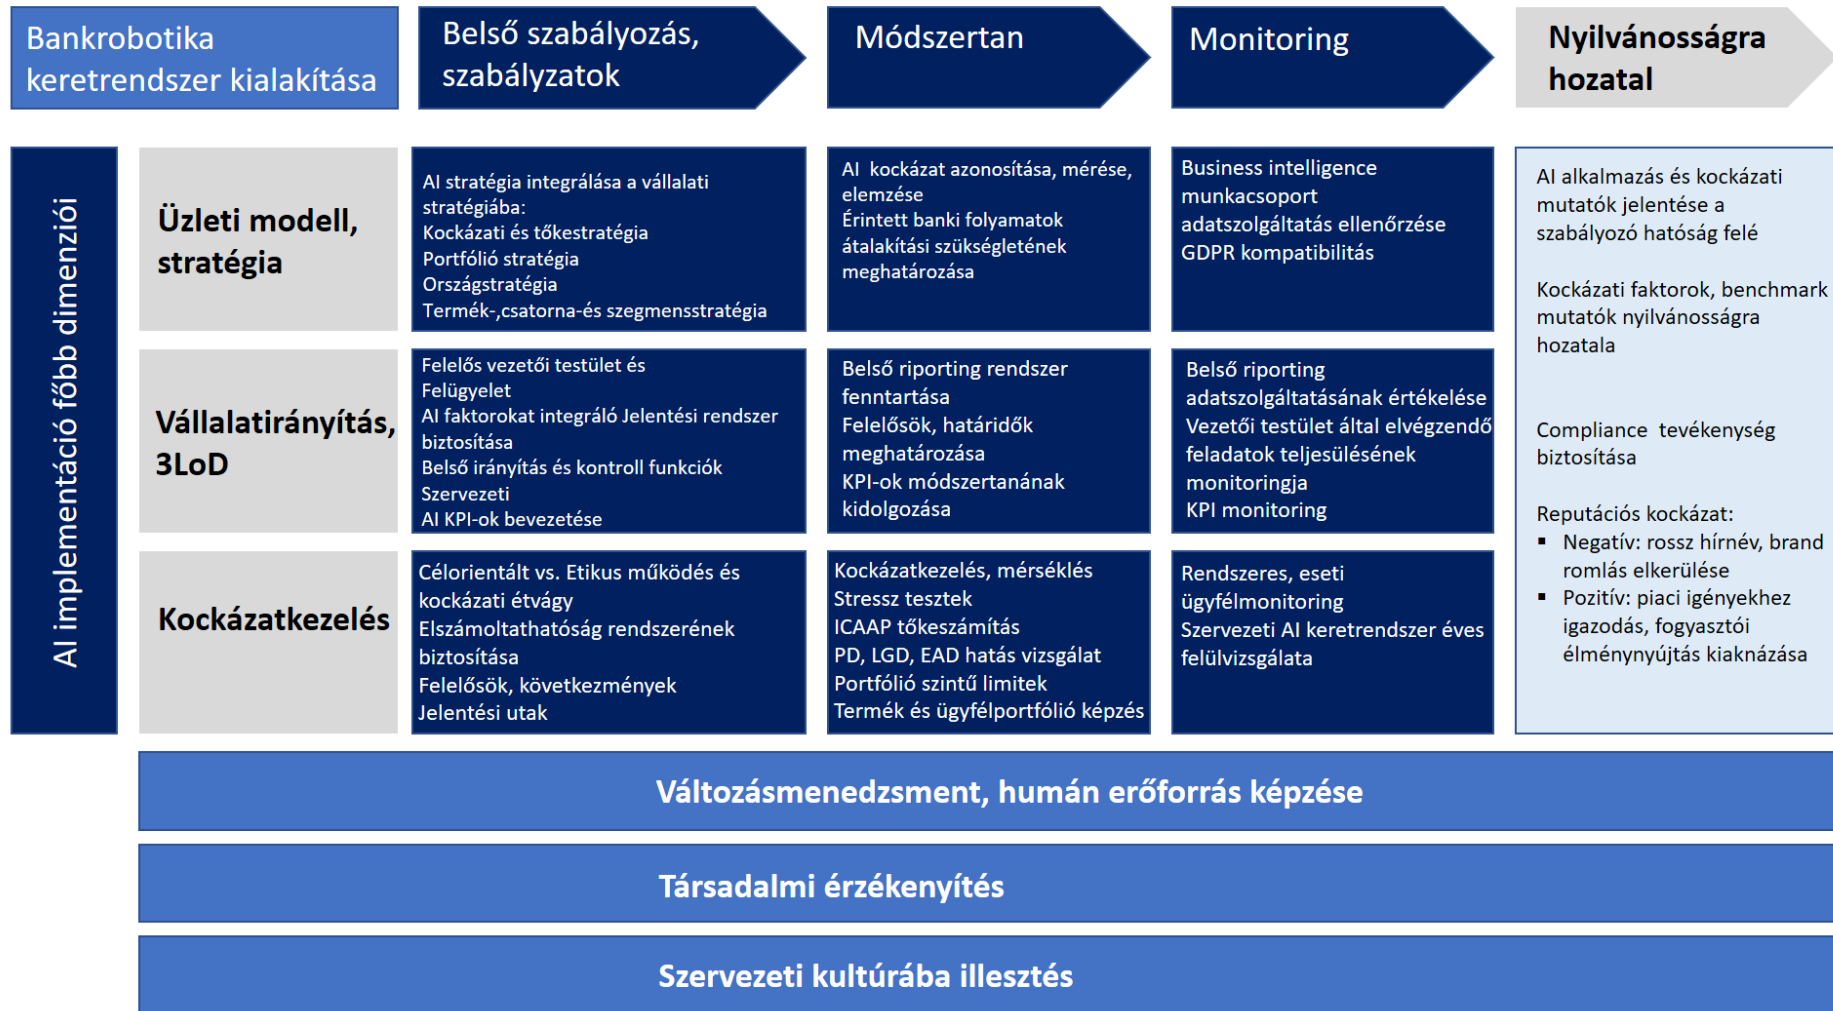
A hitelezési döntések meghozatalakor a kockázatkezelés fontos része a várható hitelezési veszteség előrejelzése, a várható veszteségek mérséklése, az optimális tőkeszint meghatározása, a hitelezendő potenciális ügyfelek kiválasztása (adósminősítési rendszerek), majd a hitelfolyósítást követően a hitelvisszafizetések előrejelzése, a követeléskezelés támogatása. A hitelezési kockázat kezelésének egyik kiemelkedő komponense a hitelkockázat értékelése, a hitelminősítések előrejelzése (Zhang et al., 2021; Mokheleli – Museba, 2022).

A hitelminősítési folyamat célja a fizetőképes és „rossz ügyfelek” megkülönböztetése, vagyis azon ügyfelek kiválasztása, akik magas valószínűséggel vissza fogják fizetni a kapott kölcsönt (Ghodselahe – Amirmadhi, 2011; Kovács – Marsi, 2018; Anjali – Priyanka, 2018). Az ML modellek az ügyfelek visszafizetési hajlandóságának előrejelzése érdekében egyrészt statikus (demográfiai, pénzügyi), másrészt dinamikus információ (törlesztés fizetése) kerül feldolgozásra (Boz, et al., 2018). Amennyiben a hitelkérelmező hitelkockázati pontszáma meghaladja a bank által állított küszöbértéket, úgy a hitel folyósításra kerülhet (Anjali – Priyanka, 2018). Az ügyfelek kategorizálása a hitelkérelmek bírálatakor tehát egy klasszifikációs problémát jelent (Boz, et al., 2018). A bankoknak ez az információ kiemelten fontos, hiszen a viselkedési pontozás területén alkalmazott előrejelző modellek hozzájárulnak az információs aszimmetria csökkentéséhez (Tripathi et al., 2021), és a hitel portfóliók rendszeres nyomon követésén keresztül a tőkeallokációs döntések meghozatalához. Mivel a hitelbírálati döntések esetében a folyósított összegek jelentsek lehetnek, így a modellek százalékpontos javulása is jelentős nyereséghez/kockázat csökkentéshez vezethet (hitelezési kockázat csökkentése) (Anjali – Priyanka, 2018).

A magas kockázatú modellek alkalmazására való tekintettel a modellek közüli választás esetében nem kizárólag a teljesítmény dominál. Azok a modellek, amelyek a benchmark modellekhez képest magasabb teljesítményt nyújtanak a validációs adatok alapján. Ugyanakkor nem képesek az előrejelzéseket teljes mértékben magyarázni, így nem alkalmasak a gyakorlati alkalmazásra (Ala'raj – Abbod – Majdalawieh, 2021; Liu – Fan – Xia, 2022; Munkhdalai et al, 2020;).

Az ML modellek olyan hitelminősítési adatokban lévő problémával szembesülnek, mint a nemlinearitás, a kiegyensúlyozatlan adatállományok (Boz, et al., 2018). Ezek kezelésére a korábban említett módszerek (SMOTE) alkalmazhatóak (Pamuk – Schumann, 2023). A bankrobotika technológiák integrálása a banki folyamatokba a tisztességes hitelezési gyakorlathoz és a bankszabályozáshoz illeszkedve szükséges, hogy megvalósuljon (22. ábra).

22. ábra: A bankrobotika technológiák beágyazódása a banki folyamatokba



Forrás: Saját forrás

4.2.1.1. Alkalmazott algoritmusok

A hitelminősítési rendszerek által felhasznált hitelkérelmi és ügyféladatok növekvő komplexitása szükségessé tette a megbízható modellek alkalmazását (Addy et al., 2024). Kapcsolódóan a tisztességes hitelezési gyakorlathoz (Verma – Rubin, 2018; Brotcke, 2022; Gajane – Pechenizkly, 2018) szabályozó törvényekhez és jogszabályokhoz, a modellek átláthatósága és magyarázhatósága indokán a bankok által legkeresettebb modell az XGBoost és a light GBM, mivel ezek viszonylag egyszerű elméleti alapokon nyugszanak és könnyen összehasonlíthatók a tradicionálisan alkalmazott logisztikus regressziós modellekkel (Brotcke, 2022). A kulcsfontosságú jellemzők kiválasztását rendszerint a főkomponens analízis (PCA), vagy a Shapley módszer támogatja (Li et al., 2022).

A hitelkérelmek értékelése, a rating és a scoring modellek esetében leggyakrabban alkalmazott ML algoritmusok között szerepel az XGBoost és a lineáris/logisztikus regresszió mellett az RF. A modellek közül számos benchmarkolást végző tanulmány az XGboost teljesítményének dominanciáját hangsúlyozza (Mushava – Murray, 2022; Pamuk – Schumann, 2023), szemben a DT, RF, vagy egyéb regressziós fák teljesítményével (CART) (Anjali – Priyanka, 2018). A LR, NN, K-közép és SVM modellekkel kapcsolatosan is széles szakirodalom kutatja a benchmarkokat, bár ezek jellemzően alulmaradnak teljesítmény szempontjából az XGBoost modellekhez képest (Pamuk– Schumann, 2023). Az alternatív megközelítések közé tartoznak a k-NN, illetve a mélytanuló algoritmusok (CNN) (Hayashi, 2022), a GB (Thornhill, 2008; Liu – Fan – Xia, 2022), a LSTM (Ala'raj – Abbod – Majdalawieh, 2021), illetve az együttes tanuló modellek (He – Zhang – Zhang, 2018; Zhang et al., 2021; Mokheleli – Museba, 2022; Runchi – Liguó – Qui, 2023).

A modellek karbantartása és rendszeres frissítése a hitelminősítő rendszerek esetében biztosítja az emberi felügyeletet, amely lehetővé teszi a szükséges beavatkozásokat és a kockázatok hatékony kezelését (Anjali – Priyanka, 2018).

A magas kockázatú AI rendszerek komoly követelményekkel és etikai, adatvédelmi kihívásokkal járnak, amelyek miatt az összehasonlításuk torz eredményeket adna, ezért összehasonlító táblázatot a middle office-t illetően nem készítettem.

4.3. *Banki back office és a bankrobotika technológiák*

4.3.1. **Compliance**

Az új technológiák kibővítik a visszaélések lehetőségeit, amely komoly kihívást jelent a kockázatkezelés terén erős múlttal és kultúrával rendelkező bankok számára (FATF, 2021). Ezen technológiák banki adaptációja a jogszabályi megfeleléség biztosításában a pénzmosás- és terrorizmusfinanszírozást megakadályozásában, valamint a csalásmegelőzés területén is kiemelt jelentőséggel bír (van Liebergen, 2017; Johari et al., 2020). A Pénzügyi Akciócsoport (Financial Action Task Force, továbbiakban: FATF), az új technológiákra vonatkozó ajánlás (R.15-ös ajánlása) keretében felhívja a figyelmet az AI csalásmegelőzésben betöltött potenciális támogató szerepére (FATF, 2021; Prisznyák, 2022b; FATF, 2023).

A bankok működésének jogszabályi megfeleléségét biztosítandó, az (EU) 2017/565 irányelv (2014/65/ EU irányelv kiegészítése) 22. cikke a szervezeti struktúrának és nyújtott szolgáltatásnak megfelelő, a testreszabott és független Compliance funkció működtetését és kockázatalapú monitoring rendszer üzemeltetését írja elő. Kapcsolódóan a 2013. évi CCXXXVII. törvény a Hitelintézetekről és pénzügyi vállalkozásokról (Hpt.) is előírja (illetve kapcsolódó MNB-s előírások és ajánlások) a jogszabályoknak történő megfelelésért felelős szervezeti egység működtetését (Hpt. 154. §). A Compliance fontos szerepet tölt be a prudens működés biztosításában és az ügyfelek, tulajdonosok gazdasági és társadalmi érdekeinek védelmében, aminek elmulasztása jogi, hírnév kockázatot – illetve kapcsolódó szankciót, bírságot-, von maga után. Ugyanakkor a jogszabályi megfeleléség nemcsak a jogszabályi elvárásoknak való megfelelés biztosítását, hanem az etikai alapértékek betartatását is jelenti (Kovács – Marsi, 2018). A compliance tranzakciósűrő rendszereinek célja a jogszabályokban tiltott vagy bejelentési kötelezettség alá eső banki tranzakciók szűrése. Ennek keretében az AML, CFT, a bennfentes tőkepiaci kereskedelem, illetve a tiltott piacbefolyásolás megakadályozása tranzakció előtti (kapcsolat létrehozás megtagadása), alatti (valós idejű szűrők), illetve utólagos szűrők (bejelentési kötelezettségek) használata révén. Amint látható, a Compliance tevékenység a szervezet egészét áthatja, számos szakterületen keresztül kerül érvényesítésre. Az alábbiakban a pénzmosás-és terrorizmusfinanszírozás, illetve csalásmegelőzési területeken alkalmazott AI, ML és kapcsolódó innovatív technológiák felhasználási lehetőségeit elemzem a szakirodalom áttekintésén keresztül.

4.3.2. Pénzmosás-és terrorizmusfinanszírozás megakadályozása, csalásmegelőzés

A ML segíti a bankokat és pénzintézeteket a pénzügyi bűncselekmények ellen folytatott harcban (Johari et al., 2020; Rouhollahi, 2021). A pénzmosás és terrorizmusfinanszírozás megelőzését számos nemzetközi szervezet (ENSZ, FATF, Európa Tanács, IMF, Világbank, BIS), illetve szakértői bizottság (MONEYVAL), kiemelt ügyként kezeli, hangsúlyozva, hogy a ML modellekkel a korábbi rendszerek gyengeségeit kiküszöbölik (Savage et al., 2016, FATF, 2021, Prisznyák, 2022b). A ML modellek alkalmazása a pénzmosásmegelőzés területen hatékonyan támogatja az ügyfélprofilok kialakítását és osztályozási szabályok megalkotását (Alexandre – Balsa, 2018). Az AI rendelet kockázati besorolásának megfelelően a csalás gyanús ügyletek, valamint a pénzmosás-és terrorizmusfinanszírozás felderítésére használt AI rendszerek kivételnek minősülnek a magas kockázatú kategóriába sorolás alól (European Commission, 2024). Ugyanakkor az ügyfelek adatainak védelme, illetve az azt elősegítő eljárások (anonimizálás, hashelés, masking, tokenizáció) alkalmazása szükséges e területen is. A ML támogatott AML, CFT folyamat általános folyamatábráját a 13. számú melléklet tartalmazza.

4.3.2.1. Alkalmazott ML modellek

Az AML, CFT támogatására használt ML modellek jellemzően az alábbi kihívásokkal szembesülnek: rossz adatminőség, az adatvédelmi szabályzatok miatt a megfelelő információ hiánya, illetve kiegyensúlyozatlan adatbázisok (igazolt esetszám alacsony a kezelt esetszámhoz viszonyítva) megléte (Wei et al., 2012). Következésképpen, az igazolt és gyanús esetek címkézése szakértői közreműködést igényelhet. A ML modellek kialakítása során a felügyeletlen tanulás jellemző (Wei et al., 2012; Savage et al., 2016, Patil – Dharwadkar, 2017).

Wang és Yang a pénzmosás felderítésére szintén döntési fát alkalmazott, alapvető vizsgálódási kiindulópontként a tranzakciók klaszterezését használva (Wang – Yang, 2007). Drezewski, Sepielak és Filipkowski szintetikus adatbázist alkalmaznak az ügyfelek tranzakciós viselkedésének historikus jellemzői alapján történő csoportképzésre, amelyhez a BIDE algoritmus módosításával létrehozzák a BIDEMax algoritmust (a maximális gyakori sorozatok bányászatához), így elkerüli a teljes adatbázis átvizsgálását minden lehetséges sorozatra, ezáltal csökkentve a számítási időt és az erőforrásigényt. (Drezewski – Sepielak – Filipkowski, 2012). Khan és társai a Bayesi hálózat, RF modellekben rejlő lehetőségeket hangsúlyozzák, amelyek elősegíthetik a gyanús ügyfelek, bankszámlák hálózatának azonosítását a számlák és tranzakciós adatok közötti kapcsolatok feltérképezésével (Khan et al., 2013). Luo (2014)

szimulált időszoron alapuló tranzakciós adathalmazt alkalmaz adatbányászati motorhoz, és egy osztályozó algoritmust javasol, amely FP-fát épít a hatékonyság javítása érdekében. Drezewski és szerzőtársai adatbányászatot alkalmaztak a pénzmozgási folyamatok gyakori mintáinak elemzéséhez (Drezewski – Sepielak – Filipkowski, 2012). Savage és kollégái hálózatelemzés és felügyelt tanulás (SVM, RF) kombinációján alapuló detektáló rendszert alkalmaznak, amely képes csoportos viselkedések elemzésére több millió interakciót tartalmazó hálózatokon, és sikeresen észleli a gyanús tevékenységeket alacsony hamis pozitív aránnyal (Savage et al., 2016). Az ügyfél tranzakciós történetén alapuló pénzmosási mintázatokat felismerő riasztási modell kialakításához Zhang és Trubey (2019) döntési fa, SVM, neurális hálózatot, véletlen erdők módszert alkalmaznak (Zhang – Trubey, 2019). Martínez-Sánchez, Cruz-García és Venegas-Martínez historikus banki tranzakciós adatokon és ügyféljellemezőkön alapuló regressziós fákat alkalmaz a pénzmosási tevékenységnek való kitettség meghatározásához (Martínez-Sánchez – Cruz-García – Venegas-Martínez, 2020). A külön-külön alkalmazott ML modellek javítására, Chen és Guestrin a gradiensnövelő döntési fák megvalósításához XgBoost gépi tanulási algoritmus alkalmazását javasolják a modell sebességének és teljesítményének javítása érdekében (Chen – Guestrin, 2016). Kannan és Somasundaram (2017) két különböző megoldást javasolnak a pénzmosás gyanús tevékenységek valós idejű észlelésére: az AROMLD technika csökkenti a számítási bonyolultságot és a végrehajtási időt, míg a TBOD algoritmus nagyobb pontosságot biztosít. Az AROMLD technika az Inter Quartile Range (IQR) közelítést alkalmazza a gyanús tranzakciók valós idejű azonosítására, amely révén a kiugró értékek észlelése 0,3%-kal és 2%-kal növelte a pontosabb észlelést a Decision Tree Random Forest, Naïve Bayes, K-Means-IBK és TBOD algoritmusokhoz képest (Kannan – Somasundaram, 2017).

Az AML, CFT és csalásmegelőzés területen alkalmazott ML modellek szakirodalmi áttekintését (üzleti cél, eredmény, felhasznált adatbázis, attribútumok, eredmények) a 14. számú melléklet tartalmazza, míg a szakirodalom elemzés alapján, alkalmazott algoritmusokat az alábbi 10. táblázat szemlélteti.

10. táblázat: AML, CFT és csalásmegelőzés területén alkalmazott ML algoritmusok

#	Szerző(k), év	NN	XGBoost	DT	RF	k-NN	SVM	FT	LR	GB	ANN	SOM	FP-growth	NB	BIDE	K-közép	iForest	IBK
1	Zhang – Trubey (2019)			X	X		X		X		X							
2	Wang – Yang (2007)			X														
3	Chen – Guestrin (2016)		X							X								
4	Wei et al. (2012)	<i>ContrastMiner (modelleket kombinál)</i>																
5	Khan et al. (2013)													X				
6	Kannan – Somasundaram (2017)			X	X									X		X		X
7	Jullum – Løland – Huseby (2020)		X															
8	Patil – Dharwadkar (2017)										X							
9	Álvarez et al. (2017)	X		X	X				X									
10	Savage et al. (2016)				X	X	X											
11	Deng et al. (2009)						X							X				
12	Luo (2014)												X					
13	Alexandre – Balsa (2018)															X		
14	Le-Khac – Markos – Kechadi (2010)	X																
15	Drezewski – Sepielak – Filipkowski (2012)												X		X			
16	Rocha-Salazar – Segovia-Vargas – Camacho-Miñano (2021)	X		X								X				X		
17	Rouhollahi (2021)	X			X	X			X					X			X	

Forrás: Saját táblázat

Korábbi kutatásom során szintetizáltam a feldolgozott szakirodalmak alapján a pénzmosás- és terrorizmusfinanszírozás megakadályozását elősegítő ML modellek által használt tipikus attribútumokat (Prisznyák, 2022b). A különböző ML algoritmusok eltérő bemeneti adatformátumot és attribútum választást igényelnek. A feldolgozott szakirodalmak alapján a gyakran alkalmazott kulcsváltozókat alapján az alábbi, 11. táblázat tartalmazza.

11. táblázat: AML ML modell tipikus változói a feldolgozott szakirodalmak alapján

Attribútum kategória	Változó
Ügyféllel kapcsolatos attribútumok	<ul style="list-style-type: none"> ▪ ügyfél típusa (jogi személy, magánszemély, egyéb) ▪ ügyfélszegmens, ▪ politikai közszereplői státusz (PEP) ▪ életkor, ▪ állampolgárság, ▪ beáramló pénzeszköz (jövedelem) forrása, ▪ igénybe vett termék típus, ▪ gazdasági tevékenység, ▪ ügyfél belépésétől eltelt idő
Tranzakcióval kapcsolatos attribútumok	<ul style="list-style-type: none"> ▪ tranzakció típusa, ▪ tranzakcióba bevont ügyfelek nevei (küldő, fogadó fél) ▪ tranzakció gyakorisága, ▪ tranzakció dátuma, ideje, ▪ tranzakció összege, ▪ pénznem, ▪ átlagos összege, ▪ célbank, ▪ tranzakciós kód, ▪ fiók (ügyfél) típusa, ▪ tranzakció nyilatkozat
Egyéb attribútumok	<ul style="list-style-type: none"> ▪ termék/szolgáltatás típusa, ▪ földrajzi terület (kitettség), ▪ jogi személy képviselője
Kapcsolati háló	<ul style="list-style-type: none"> ▪ kliensek összefüggő üzleti kapcsolathálózata

Forrás: Saját táblázat (Prisznyák, 2022b)

4.3.3. Ismerd meg az ügyfeled! - ML modellek a KYC területén

A pénzmosás- és terrorizmusfinanszírozás megakadályozásaként és a pénzügyi bűncselekmények elleni védekezés részeként az EU 2015/849 irányelv mérvadónak tekinthető, amely előírja az ügyfélátvilágítás (Customer Due Dilligence vizsgálatokra, továbbiakban: CDD), valamint annak részeként megvalósuló „Ismerd meg az ügyfeled!” (Know Your Customer, továbbiakban: KYC), illetve „Ismerd meg a közvetítőd!” (Know Your Intermediary, továbbiakban: KYI) gyakorlatokat (BIS, 2001). A KYC/KYI folyamatok folytatását a hazai '2017. évi LIII. a pénzmosás és a terrorizmus finanszírozása megelőzéséről és megakadályozásáról' szóló törvény részletezi, amely ügyfélátvilágítási kötelezettséget ír elő a

bankoknak az ügyfelekkel történő üzleti kapcsolat létesítése, illetve a rendszeres ügyfélmonitoring során. A KYC/KYI folyamatok hozzájárulnak a rossz szándékú ügyfelek bankrendszerbe történő belépésének megakadályozásához, csökkentve a pénzügyi csalások kockázatát (Hannan et al., 2023). Továbbá előírja ezen eredményének (kockázatértékelés, üzleti kapcsolat, megbízások vonatkozó adatok) rögzítését. Az információ számos strukturált és strukturálatlan adatbázisból és forrásból származik, beleértve érvényes azonosító okmányokat (például személyi igazolvány, lakcímkártya, útlevél, jövedelemigazolás), szabadon elérhető céges dokumentumokat (mint éves jelentések, bejegyzések, tőzsdei adatok), valamint külső adatbázisokból, cégadattárházakból származó adatokat a tulajdonosi körökre, tényleges tulajdonosokra, cégbejegyzési információkra és egyéb adatokra vonatkozóan. Ezeknek az információknak az áttekintése rendkívül időigényes folyamatot eredményez. Az információ halmaz manuális ellenőrzése révén a folyamat munkaerő- és időigényes, valamint magába rejti a dokumentum feldolgozása, hitelesítése során vétett adatbeviteli hibákat, amely még költségesebbé teszi a folyamatot és hibás input adatokhoz vezethetnek a modellépítés során (Hannan, et al., 2023). Az innovatív technológiák fejlődésének következtében az elmúlt években világszerte bevezették a KYC digitális verzióját, az e-KYC-t. Az e-KYC jelentősen csökkentheti a folyamat időszükségletét, csökkentheti a költségeket, valamint növelheti az ügyfélélményt (Diksha – Poonam –Awadhesh, 2022). Az e-KYC során a Compliance szakember és az ügyfél között videókapcsolat létesül, amely alatt az ügyfél személyazonosságát biometrikus adatok (arc, ujjlenyomat), illetve a személyes adatok ellenőrzése révén ellenőrzi (Hannan, et al., 2023; Diksha – Poonam –Awadhesh, 2022). A folyamatban a gépi látáson és NLP algoritmusok kombinációján alapuló optikai karakterfelismerés (Optical Character Recognition, OCR) is segít, amely képes a készített/feltöltött fénykép alapján hatékonyan elvégezni az ügyfél azonosítását, kiszűrve a fényképen ejtett szándékos emberi torzításokat, manipulációkat és külső hivatalos forrásokból meggyőződni az információ hitelességéről. Képes Továbbá, elemezni az aláírásokat és a nyomtatott szöveget, illetve ezeket automatikusan a formanyomtatványba illeszteni, ezzel gyorsítva a feldolgozási folyamatot, illetve kiküszöböli a manualitásból eredő adatbeviteli hibákat ejtését. A program az adatok validációja során (szükséges további adatok: hiteltörténeti audit, szankciós listák, egyebek bevonásával) kialakítja/felülvizsgálja az ügyfélhez tartozó kockázati profilt. A monitoring során a bank elvégzi a jogszabályokban meghatározott rendszeres, ad-hoc (eseti, prioritás alapján), valamint éves (magas kockázatút évente, alacsony kockázatút ötévente) ellenőrzéseket. Mivel a KYC adatok rendkívül érzékenyek, védeni szükséges őket a bűnözők általi illetéktelen hozzáféréstől

és kibertámadásoktól. Ez az, ahol a blockchain hatékonyan képes támogatni a KYC nyilvántartások biztonságát és változtathatatlanságát (Nitin – Saurabh – Jayesh, 2023). A blokklánc alkalmazás kitételeként jelentkezik, hogy a szenzitív KYC adatokat offchain adatbázisban szükséges tárolni, valamint az adatok bizalmasságát erős titkosítási mechanizmusokkal (hash-elés) révén szükséges biztosítani (Hannan, et al., 2023). A jelenlegi banki működés alapján azonban valamennyi ügyfélnek minden banknál külön KYC ellenőrzésen szükséges átmennie, amely feloldása lehetne egy blokklánc-alapú központosított adatbázis üzemeltetése a bankok között (Diksha – Poonam –Awadhesh, 2022).

4.3.4. AI lehetőségei az emberi erőforrásmenedzsment területén

Mivel az AI rendelet a HR területen alkalmazott rendszereket jellemzően magas kockázatúként kezeli, az alábbiakban áttekintett szakirodalmat annak fényében szükséges értékelni, hogy az Európai Unióban érvényes szabályozás eltérhet a világ más részein alkalmazott AI felhasználási előírásoktól.

Az AI és kapcsolódó innovatív technológiák integrálása az emberi erőforrások területére, lehetővé tette a platform-alapú e-HRM megjelenésével a HR szervezetet támogató szerepköréből a szervezet stratégiaorientált megoldását szolgáló szerepkör felé orientálódását (Premnath – Arun, 2019). Az emberi erőforrásmenedzsment területen alkalmazott technológiák modernizálásával a hagyományos HR-menedzsment módszerek átalakítása is kulcskérdéssé vált (Karacsony, 2022). A bank digitális transzformációja a digitális képességek építésével párhuzamosan igényli szervezeti tudásbázis, és a munkavállalók tudásának bővítését (Jaiswal – Arun – Varma, 2020). Alábbiakban azt vizsgálom, hogy az AI és kapcsolódó technológiák miképp képesek hatékonyan támogatni a HRM munkafolyamatait.

4.3.4.1. Toborzás és kiválasztás

A mesterséges intelligencia teszi a stratégiai célokat támogató, korábban idő- és költségigényes feladatok optimalizálását. Az AI rendszerek, ML modellek képesek a munkaerőállomány megújítását a toborzási, kiválasztási, képzési/training folyamatok megújításán keresztül támogatni (Vasantham, 2021). Berhil, Benlahmar és Labani a ML HR kockázatok (sztrájk előrejelzés, működési kockázathoz kapcsolódó munkavállalói biztonság, motiváció hiányból eredő fluktuáció) előrejelzésében és kezelésében betöltött prognosztizáló képességét hangsúlyozza (Berhil – Benlahmar – Labani, 2020). Az AI, ML modellek a magas teljesítményű munkavállalók kiválasztása révén hozzájárulnak a szervezetek versenyképességének javításához (Geetha – Reddy, 2018). További alkalmazási területként

jelentkezik a teljesítményértékelés, kompenzációmenedzsment, a munkavállalók képzési programjának meghatározása. Ezen felhasználási lehetőségek alapján az AI a HRM-en keresztül indirekt módon hozzájárul a szervezeti képességépítéshez (Ahmed, 2018).

A HR munkafolyamatot támogató eszközként az AI és kapcsolódó innovatív technológiák számos feladatot látnak el, amelyek a manuális folyamatokat váltják fel/egészítik ki. A toborzási folyamat lerövidítéséhez a ML algoritmusok, NLP, és gépi látás technológiák támogatják a jelölt azonosítást (OCR, NLP), az önéletrajzok áttekintését és értékelését, a videóinterjúk során megvalósuló elemzéseket és végezetül a megfelelő jelöltek szűrését (Ahmed, 2018). A videóinterjúk során a kép- és hang tanulmányozás kiterjedhet a beszédre (szókincs), a testtartás elemzésére, egyebek, amelyek összevetésre kerülnek a meghirdetett pozícióval kapcsolatos elvárásokkal (Kshetri, 2020). A ML modellek a csaláson alapuló önéletrajzok kiszűrését is támogathatják és csökkenthetik a háttérellenőrzés idejét és költségvonzatát (Kshetri, 2020). Valamint sikeresen támogatják a jelölt megfelelő kiválasztását és a korábban elutasított „jelölt újrafelfedezését” (Kshetri, 2020). A toborzási chatbot-ok applikációkba integráltak is megjelenhetnek, támogatva a különböző nyelvi megkereséseket és a jelölt és a szervezet között végbemenő kommunikációt (a megpályázott állással, a céggel kapcsolatos kérdések, jelentkezés állapotának lekérdezése, interjú ütemezésről információ szolgáltatás, egyebek) (Kshetri, 2020). A folyamat automatizálási fokától függően elképzelhető, hogy a jelölt nem találkozik HR szakemberrel a folyamat során (Karacsony, 2022). A szingapúri székhelyű DBS bank chatbotja, Jim (virtuális toborzó asszisztens), az önéletrajzok alapos vizsgálatát követően szűrőkérdések révén, mindössze 8 perc alatt (ami humán HR-es esetben fél óra) elvégzi a jelölről gyűjtött (pszichometriai) adatokat értékelését (DBS, 2018), majd a kiválasztási kritériumok alapján objektív módon elutasítja vagy elfogadja a jelölt jelentkezését.

4.3.4.2. *Képzés és fejlesztés*

Egyes szakirodalmi (Európai Unió AI jogszabályán kívül eső országbeli szerzők) források alapján az adat-alapú technológiák által támogatott képzések hozzájárulnak a munkavállalói profilok (képzett célcsoport, persona) edukációs szükségleteinek azonosításához, és a (költséghatékony) e-platform alapú hozzáférés (online belső tanulási rendszer) biztosításához (Premnath – Arun, 2019). A munkavállalók érdeklődésének és fejlődési ütemének mérése alapján a ML algoritmusok a karriertervezés elősegítése számára is megnyitották az ajtókat. Bár a bankszektorban egyelőre még nem elterjedt, az iparágon kívül az AI-alapú coaching

kiterjesztett és virtuális valóság (Augmented/Virtual Reality, AR/VR) alapú training eszközeit is igény beveszik (Xu et al., 2020). Az adatalapú AI-rendszerek működtetésének van egy fontos gyengepontja: a hiányos vagy nem megfelelő minőségű adatok. A személyre szabott képzésért felelős digitális asszisztensek esetében korlátozó tényezőként jelentkezhet a rendelkezésre álló korlátozott historikus adatmennyiség (Maettig – Foot, 2020).

4.3.4.3. *Teljesítményértékelés, juttatási rendszer és bevezetési nehézségek*

A teljesítményértékelés új perspektíváját jelenti a munkavállalói teljesítmény adatok (indikátorok) gépi tanulási modellel történő elemzése révén a személyre szabott képzési programok (fejlesztendő kompetenciák), kompenzáció, ösztönzőrendszer kialakítása. Az algoritmus alapú munkavállalói fluktuáció a tehetséges munkavállalók megtartásának egy fontos előrejelző eszköze, amely biztosítja a döntéshozók időbeli beavatkozását az elégedetlen munkavállaló elvándorlása előtt (Karacsony, 2022). A jövőre vonatkozóan kihívásként jelentkezik továbbá a személy nélküli, kizárólag AI alapú HR folyamatok menedzselése a munkavállalói motiváció szempontjából (Pratt et al., 2021). Ezen aggályok főleg az algoritmus alapú döntéshozatal veszélyekből (diszkrimináció, hiányos adatokon alapuló teljesítményértékelés) táplálkoznak (Bhattacharyya – Nair, 2019).

A sikeres változásmenedzsment a vizionárius menedzsment jelenlétét és a változás körütekintő levezénylését igényli (Prisznyák, 2022c). Ennek keretében a bankrobotika beruházások bevezetése szükségképpen együtt kell, hogy járjanak a szervezeti kultúra és gondolkodásmód átalakulásával (Karacsony, 2022). Az AI kérdése egyben etikai kérdés is (Prisznyák, 2023b), ennek megfelelően a munkavállalói diverzitás a sikeres változásmenedzsment kiemelt területét szükséges, hogy képezzen. Kapcsolódóan Tambe, Cappelli és Yakubovics az AI HRM területen való alkalmazásának négy fő korlátozó tényezőjét azonosítják: az események komplexitását, a korlátozott adatmértetet, az etikai és jogi korlátozásokat, valamint az alkalmazottak attitűdjét (Tambe – Cappelli – Yakubovics, 2019).

Az alábbiakban az NLP és gépi látás potenciális felhasználási lehetőségeit tárgyalom, amelyek a HR szakirodalomhoz hasonlóan, nem mindig alkalmazhatók az Európai Unió piacán az AI és adatvédelmi rendeletek értelmében.

4.3.5. Az NLP felhasználási lehetőségei a banki front/middle/back office területeken

A ChatGPT a pénzügyi szektorban hatékonyan alkalmazható a strukturálatlan pénzügyi szövegek feldolgozásában és elemzésében (Khurana, et al., 2023). Front office területen a chatbotok fejlesztése és információk nyújtása során is fontos szerepet játszik, mivel hozzájárul az adatok feldolgozásához és a felhasználói interakciók javításához (Elcholiqi – Musdholifah, 2020; Kulkarni et al., 2017). Az NLP (természetes nyelvfeldolgozás) technológia képes hatékonyan kinyerni információkat különböző forrásokból, például hírforrásokból (Gu – Kelly – Xiu, 2019), éves üzleti jelentésekből (Azimi – Agrawal, 2021), valamint közösségi média adatból. Az ontológiai elemzés segít az éves beszámolókból származó adatok értékes információkká alakításában, ami támogatja a hitelezési folyamat hitelminősítési tevékenységét és a csőd előrejelzését. A biztonsági intézkedések terén Verma, Shashidhar és Hossain az email-es adathalászat elleni védelemben is használják, valamint az adathalászó weboldalak elleni védelemben is fontos szerepet játszik terén (Verma – Shashidhar – Hossain, 2012). A külső forrásokból merítő NLP technológia által végzett hír- és információelemzés értékes információkat nyújt a pénzmosás és terrorizmusfinanszírozás megelőzésére, valamint a Compliance (KYC, KYI) területeken (Khurana et al., 2023). A gépi tanulás által kivitelezett adatmező elemzések során az NLP segít azonosítani a szokatlan szavakat és tranzakciós adatokat (például tárgyszavak, nem megszokott bevételek) (van Liebergen, 2017; Johari et al., 2020). Zhang és El-Gohary a természetes nyelvfeldolgozáson alapuló szemantikai címkézés és ML algoritmusok alkalmazási lehetőségeit is vizsgálják (Zhang – El-Gohary, 2021). Az alábbi táblázat (12. táblázat) az NLP banki front, middle, back office területeken való alkalmazásának lehetőségeit tárgyalja.

12. táblázat: Az NLP alkalmazási lehetőségei

Technológia	Főbb banki felhasználás	Főbb banki alkalmazási területek
Automatikus összegzés	Ügyfélpanaszok, pénzügyi jelentések, jogi dokumentumok, hírcikkek összegzése	Ügyfélszolgálat, Kockázatkezelés (AML CFT, csalásmegelőzés), Compliance (KYI, KYC), Sales, Jogi részleg, Data management
Társreferencia lebontás	chatbotok, virtuális asszisztensek fejlesztése, fogyasztói élmény növelése, csalásmegelőzésnél számlák említése	Ügyfélszolgálat, Sales, Kockázatkezelés (csalásmegelőzés)
Diskurzus elemzés	ügyfelek-bank közötti és szervezeten belüli kommunikáció, viselkedés elemzése ((indirekt (közösségi média) /direkt kapcsolatfelvétel)); ügyfélszolgálati transcript-ek (gyakori problémák azonosítása).	Sales, Ügyfélszolgálat, marketing, HR, IT&Bankbiztonság
Gépi fordítás	az ügyfél megkeresések, panaszok, dokumentumok fordítása a kívánt nyelvre.	Sales, marketing, Ügyfélszolgálat, HR, copliance, kockázatkezelés,

	Szervezetten belüli kommunikáció, dokumentáció elősegítése. Szabályozói követelmények fordítása.	Data management, Compliance, jogi részleg
Morfológiai szegmentáció	ügyfél megkeresés osztályozása és válaszadás; ügyfél interakció, trendek elemzése, család tevékenységgel összefüggő szavak azonosítása;	Sales, Ügyfélszolgálat, marketing, kockázatkezelés (csalásmegelőzés), IT& Bankbiztonság, Compliance
Nevesített entitás felismerés	ügyfélezonosítás, gyanús tevékenységek, piaci trendek azonosítása; hitelkockázat felmérése (ügyfél dokumentumok) alapján, szabályozási elvárások hatékonyabb kezelése	Ügyfélszolgálat, marketing, Sales, kockázatkezelés (csalásmegelőzés), Compliance
Optikai karakterfelismerés	hitelkérelmek, számlakivonatok, beszámolók szövegének felismerése, dokumentum digitalizációja, verifikáció (ügyfélezonosítás), szkennelt dokumentum kereshetősége	Ügyfélszolgálat, marketing, Sales, KYI, KYC, data management
Beszédrész-címkezés	ügyfél beszédelemzése, tranzakció elemzés (előrejelzés, rejtett család mintázatok), információ kinyerés, kereshetőség javítása	Ügyfélszolgálat, data management, kockázatkezelés
Hangul/érzelelemzés	ügyfél elégedettség mérése, gyanús tevékenység azonosítása, ügyfélhitelkockázat, pénzügyi trendek értékelése	Sales, Marketing, Ügyfélszolgálat, Compliance, Kockázat-, Követeléskezelés

Forrás: Saját táblázat

4.3.6. A gépi látás lehetőségei a banki front/middle/back office területeken

A bankok biztonsági rendszerei és ATM-jei esetében a gépi látással rendelkező AI rendszerek nemcsak az arc- és biometrikus adatgyűjtésben, hanem az abnormális mintázatok (például támadások, ATM manipulációjával történő pénzszerzési törekvések), felismerésében is szerepet játszanak. A normálistól eltérő mintázatok/események felismerése a belső tereket figyelő biztonsági rendszerek (például tűz felismerése) esetében is üdvözítő (Oko – Oruh, 2012; Nar – Singal – Kumar, 2016; Chai et al., 2021). Az AML, KYC területeken sikeresen támogatják a dokumentumok adatainak feldolgozását, valamint a KYC folyamatok során az ügyfelek azonosítását is (például okmányokon található kép vagy valós idejű (arc)kép feldolgozásán keresztül például online számlanyitás esetén) (Hannan et al., 2023; Diksha – Poonam – Awadhes, 2022).

Az AML és KYC területeken az AI rendszerek sikeresen támogatják a dokumentumok adatainak feldolgozását, lehetővé téve az automatikus adatkiolvasást a kormány által kibocsátott személyazonosításra alkalmas okmányokból, valamint az ügyfelek azonosítását a valós idejű (arc)képek esetében az e-KYC folyamatok során. (Nar – Singal – Kumar, 2016; Hannan et al., 2023; Diksha – Poonam – Awadhes, 2022).

Az NLP (természetes nyelvfeldolgozás) technológiával ellátott robotok felismerik és megértik a beszélt nyelvet (Spiliotopoulos – Androutsopoulos – Spyropoulos, 2001; Suhel et al., 2020), valamint információt nyernek ki hírekből, chatbeszélgetésekből (Gu – Kelly – Xiu, 2020) és éves jelentésekből (Azimi – Agrawal, 2021).

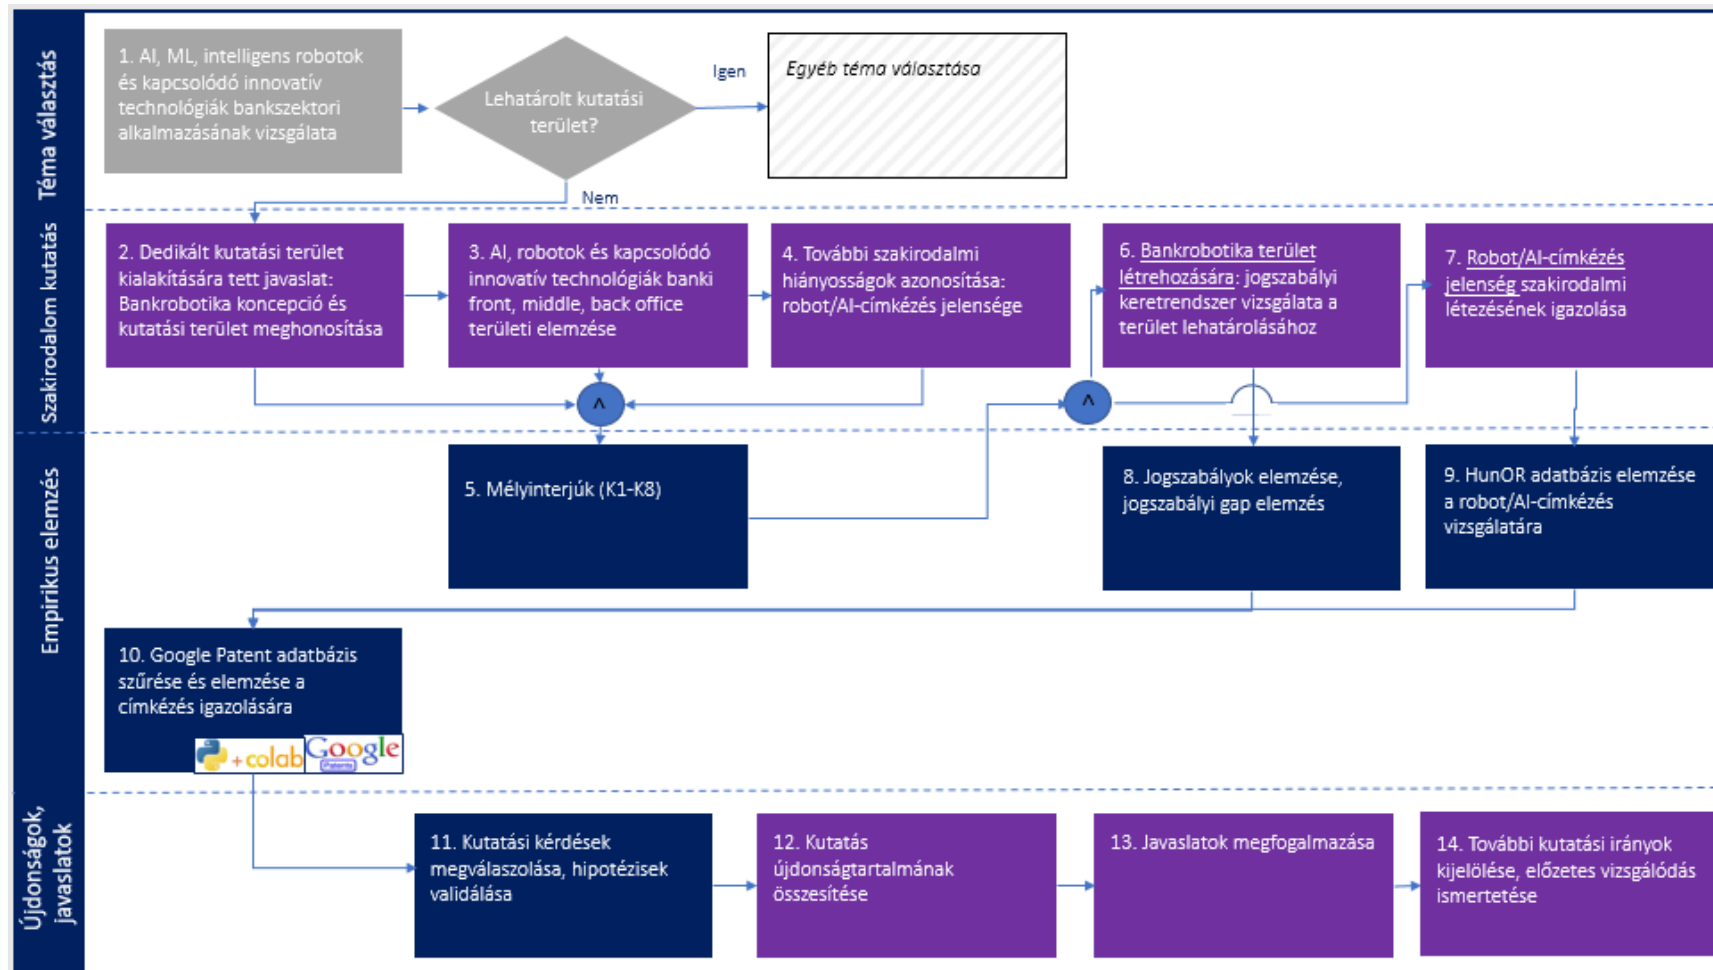
5. Empirikus elemzés: bankrobotika és AI-címkézés

Az előző fejezetekben a robot/AI-címkézés jelenséget valamint a bankrobotika koncepció és kutatási terület lehatárolásának szükségességét vizsgáltam. A strukturált keretek közötti vizsgálódás lefolytatása érdekében kialakítottam a bankrobotika VH modelljét. A bankrobotika terület lehatárolásának szükségességét a bankrobotika jogszabályi keretrendszerének koncepcióján keresztül alapoztam meg. Ezt követően a robot/AI-címkézés mögöttes technológiáinak a banki front, middle, back office területeken lévő alkalmazásának lehetőségeit tekintetem át a VH modell keretében nano szinten, szervezeti aspektusból. Az értekezés két nagy területének elemzését (bankrobotika kutatási terület, illetve robot/AI-címkézés jelensége) ezen fejezet keretein belül egyesítem, hogy a bankrobotika területen alkalmazott robot/AI-címkézés empirikus vizsgálatán elvégezhessem – ahogyan a disszertáció címében is szerepel. Ennek érdekében az empirikus elemzés első felében a bankrobotika területi lehatárolás szükségességére, illetve a robot/AI-címkézés jelenségére fókuszálok mélyinterjúk, jogszabályi elemzés, valamint a HunOR adatbázis módszertanok révén. A fejezet második felében pedig a bankrobotika területen érvényesülő robot/AI-címkézés jelenséget igazolom szabadalmi adatok felhasználásával.

5.1. *Az empirikus elemzés során alkalmazott módszertanok*

Az empirikus vizsgálódásom menetét négy fő szakaszra tagolom, amelyek során különböző kutatási módszereket alkalmazok (lásd az 1. ábrán is). Az első lépésben, a primer kutatás keretében, mélyinterjúk révén kijelöltem a disszertáció két fő témáját: (a) a bankrobotika kutatási területének kialakítását/ lehatárolását, illetve (b) a robot/AI-címkézés jelenség létezésének igazolását. Ezt követően a második lépésben jogszabályok elemzésével támogatom a bankrobotika területének lehatárolását, és felhívom a figyelmet a robot-címkék mögött rejlő technológiákhoz kapcsolódó kockázatokra. A két kijelölt terület tehát szorosan kapcsolódik egymáshoz. A harmadik lépésben a robot-címkézés gyakorlati érvényesülését a HunOR (működési kockázati események) adatbázis elemzésén keresztül vizsgálom - kiegészítve az e téren szerzett mélyinterjúk kutatási eredményeket. Végül, negyedik lépésként a két témát (banki területen alkalmazott bankrobotika technológiák AI/robot-címkézése) együttesen vizsgálom a Google szabadalmi adatbázisának felhasználásával Google Collaboratory környezetben (23. ábra).

23. ábra: Empirikus vizsgálódás menete és az alkalmazott módszertanok



Forrás: Saját ábra

Az alábbiakban röviden ismertetem az elemzési módszertanokat, majd a bevezetőben kijelölt sorrendet követően elvégzem az empirikus vizsgálódást.

Mélyinterjúk

2022. december és 2023. május között strukturált mélyinterjúkat folytattam a bankrobotika technológiák, valamint a robot/AI-címkézés gyakorlati megvalósulásával kapcsolatosan. Az interjúalanyok olyan banki üzleti, illetve szoftverfejlesztő szakemberek voltak, akik részt vettek AI, robot, ML bevezetési projekteken. A strukturált mélyinterjúk minden esetben másfél-két órát vettek igénybe. Az interjú időbeli korlátja 120 perc volt. A 14 interjúalannyal mindösszesen 24,7 órát értekeztem előre definiált kérdések mentén. Az eredmények anonim módon kerültek publikálásra a Hitelintézeti Szemlében (Prisznyák, 2023c), illetve a Gazdaság és Pénzügy (Prisznyák, 2023b) folyóiratban. A mélyinterjúk korlátját az interjúalanyok tapasztalata, valamint számosságuk jelenti, ami korlátozhatja a felmérés általánosítását. Az eredmények hozzájárultak a bankrobotika kutatási terület lehatárolására, illetve a robot/AI-címkézés jelenségére vonatkozó kutatási kérdések megválaszolásához.

Jogszabályok, rendeletek elemzése, gap elemzés

Korábbi kutatásom során (Prisznyák, 2023b) a banki etikus AI rendszerek kialakítása érdekében összehasonlító gap elemzés végeztem az AI rendelet, illetve az Európai Unió megbízható mesterséges intelligenciára vonatkozó etikai iránymutatás követelményei alapján (Prisznyák, 2023b) (8. számú melléklet). Továbbá, a szakirodalomelemzéssel összhangban, vizsgáltam az AI rendelet, valamint a GDPR, illetve a prudenciális szabályozást biztosító CRR kapcsolódó pontjait. Az elemzést az egyes rendeletek, jogszabályok pontjainak szintetizálásán keresztül végeztem el. A jogszabályi környezet vizsgálata megerősítette a bankrobotika terület lehatárolásának szükségességét.

HunOR adatbázis elemzése – AI/robot-címkézés jelensége

A HunOR adatbázis vizsgálat célja az volt, hogy a működési kockázati események rögzített leírását felhasználva feltárja a robot/AI-címkék gyakorlati alkalmazását (Prisznyák, 2024a). Az elemzés során arra a következtetésre jutottam, hogy a jelenlegi oprisk működési gyakorlatok során nem definiálják, és nem dokumentálják a szükséges részletezettséggel a robotok (robot-címke) mögött lévő technológiákat, azok feladatát, autonómiai szintjét, valamint a kapcsolódó emberi felügyeleti mechanizmusokat. Az elemzést (első fejezetben részletezett) a bankrobotika

kulcsszólistája alapján végeztem el az adatbázis kockázati eseményeinek leíró mezőjén kivitelezett szűrés, illetve a kapott találatok tárgyalása révén.

A Google Patent Public adatbázisa

A bankrobotika technológiák gyakorlati alkalmazásának elemzésére, illetve a robot, valamint AI-címkézés jelenségének gyakorlati igazolására szekunder adatként a Google Patent keresőmotor által elérhető Google Patent Public Database-t alkalmaztam. Az összes eszköztérték alapján a világ top 50 legnagyobb bankjára vonatkozó célirányos (bankrobotika kulcsszó lista) szűréseket követően összeállítottam a saját adatbázisomat (Top50Bank_Patents.xlsx). (A kapcsolódó korlátok a bevezetőben kerültek ismertetésre.) Ezen szabadalmakat a Google Collaboratory elemzési környezetében Python kódok segítségével elemeztem a szavak vektorizációján (NLP) keresztül, illetve K-közép ML algoritmus segítségével, hogy megállapítsam és csoportosítsam az egyes technológiák felhasználási területeit a gyakran ismétlődő szavakat által. Az elemzés révén a robot/AI-címkézés jelenségének vizsgálatát az egyes technológiák és az univerzálisan használt robot és AI szavak együttes használatának vizsgálatán keresztül kiviteleztem.

Alkalmazott elemzési környezet

A szabadalmi adatok elemzéséhez a Google Collaboratory (Google Colab) nevű felhő-alapú adatelemzési környezetet használtam. A Google Colab lehetővé tette számomra, hogy hatékonyan dolgozzam fel a kialakított adatbázisomat. Az interaktív Python kódok lehetőséget adtak számomra a rugalmas és dinamikus vizualizációk és statisztikai elemzések elkészítésére.

5.2. Primer kutatási eredmények - mélyinterjúk

Az AI és kapcsolódó innovatív technológiák banki front, middle, back office területeken érvényesülő felhasználási lehetőségeinek szakirodalmi vizsgálatán keresztül meghatározott kutatási irányok:

- bankrobotika kutatási terület lehatárolása,
- a robot-címkézés jelenség létezésének igazolása,
- a bankrobotika területen alkalmazott robot/AI-címkézés vizsgálata érdekében

primer kutatásként 2022. december és 2023. május között strukturált mélyinterjúkat folytattam. Az interjúalanyok olyan banki üzleti, illetve szoftverfejlesztő szakemberek voltak, akik részt vettek AI, ML, robot bevezetéssel, fejlesztéssel kapcsolatos projekteken (13.

táblázat). Az interjú alanyok közül hét fő rendelkezett banki területen szerzett tapasztalattal (4 kiskereskedelmi bankot érintően), míg az interjúalanyok másik fele az IT oldalról érintette az AI, robotok bevezetését. (A banki tapasztalattal bíró interjúalanyok sorszáma félkövér, dőlt betűtípussal szerepel a táblázatban.) A strukturált mélyinterjúk minden esetben másfél-két órát vettek igénybe. Az interjú időbeli korlátja 120 perc volt. Az eredmények anonim módon kerültek publikálásra, átfogó megállapítások levonása révén (Prisznyák, 2023b; 2023c).

13. táblázat: Az előzetes mélyinterjú résztvevői

#	Foglalkozás	Tapasztalat (év)	Interjú (perc)	Iparág, (tapasztalat) szektor
1.	AI-divízió-vezető	9	120	Bankszektor, információtechnológiai
2.	K+F-igazgató	15	120	Információtechnológiai
3.	Szoftverfejlesztő	6	90	Információtechnológiai
4.	Machine learning engineer	7	90	FinTech, healthtech
5.	Projektmenedzser	25	120	Információtechnológiai
6.	Informatikai menedzser	25	80	Bankszektor
7.	Automatizálási vezető	12	90	Bankszektor
8.	Machine learning engineer	17	120	Bankszektor, gyógyszeripar
9.	Programtervező informatikus	23	120	Bankszektor, gyógyszeripar
10.	Szoftverfejlesztő mérnök	7	120	Információtechnológiai
11.	K+ F, AI-fejlesztő	6	120	Információtechnológiai
12.	Informatikai projekt vezetője	6	120	Bankszektor, gyógyszeripar
13.	Informatikus	20	90	Bankszektor
14.	Termék kontroller	6	84	Bankszektor
Interjúk összesen (óra)			1484	(24,7 h)

Forrás: Saját táblázat

A disszertáció két fő témájához: (1.) A bankrobotika terület lehatárolásának és kutatási területként történő értelmezésének szükségessége, (2) Robot/AI-címkézés jelenség létezésének igazolása kapcsolódóan a levont következtetéseket – további specifikus vizsgálódással kiegészülve – három publikáció keretében tettem közzé (Prisznyák, 2023b; 2023c; 2024a). A harmadik témát (e két terület találkozását) korábban nem publikáltam.

A mélyinterjúk keretében (K1-K8) (és kapcsolódó hipotézis) mentén folytattam vizsgálódást, azzal a céllal, hogy alátámasszam a szakirodalomkutatás révén azonosított két fő kutatási irányt a disszertációnak és igazoljam a disszertáció felállított hipotéziseit e téren (14. táblázat). Felhívnom a figyelmet arra, hogy a mélyinterjúk során korábban alkalmazott kutatási kérdések –lásd az alábbi táblázatban- nem azonosak a disszertáció kutatási kérdéseivel (amik a bevezetőben, illetve az érintett fejezetekben is ismertetésre kerültek).

A publikációkban érintett területek miatt Mélyinterjú I. (K1- K5), Mélyinterjú II. (K6-K7), illetve Mélyinterjú III. (K8, illetve érintve K5) alfejezetek alatt ismertetem a mélyinterjú során megállapított kutatási eredményeimet, illetve ezek keretében tárgyalom a javaslataimat.

14. táblázat: A mélyinterjúk során vizsgált kutatási kérdések és kapcsolódásuk a disszertáció kutatási kérdéseihöz/hipotéziseihez

	Mélyinterjúk kutatási kérdés	Módszertanok a disszertáció hipotéziseinek igazolásához	Disszertáció kutatási kérdés, hipotézis
Prisznayák, 2023c	K1: Mi a bankrobotika technológiák beruházás tervezésének megközelítési módja?	Mélyinterjú kérdések I.	
	K2: Mi az AI, a ML, az intelligens robotok és a kapcsolódó innovatív technológiák beruházásának jellemző megközelítési módja az adott szervezetnél?		
	K3: A menedzsment támogató hozzáállása tapasztalható az AI-rendszer bevezetési projekteken?		
	K4: A bankrobotika beruházások megvalósulását milyen tényezők képesek akadályozni?		
	K5: Milyen AI/robot technológiákat alkalmaznak?		
Prisznayák, 2023b	K6: Az etikai megfontolások vizsgálat tárgyát képezik az AI-rendszerek fejlesztése, implementációja során?	Mélyinterjú kérdések II. + Jogszabályi (és gap) elemzés	K1- H1, K3-H3
	K7: Kapnak oktatást AI-témában és a bevezetést illetően a munkavállalók? (képzés, workshop, dokumentáció)		
Prisznayák 2024a)	K8: Mi jellemző a banki menedzsment technológiai ismereteire? + K5 eredményei alapján a címkézés vizsgálata	Mélyinterjú kérdések III. + HunOR adatbázis	K2-H2, K4-H4

Forrás: Saját táblázat

K1-K8-ig terjedő kérdéseket vizsgáltam a mélyinterjúk során, annak érdekében, hogy generális képet kapjak a bankszektorban megvalósuló AI, ML, robotok és kapcsolódó innovatív technológiákról (K5), azok bevezetéséről (K1-K2), a menedzsment hozzáállásáról (K3), illetve az AI bevezetést gátló akadályokról (K4), továbbá az etikai AI rendszerek kialakításáról (K6, K), valamint a menedzsment AI tudásáról (K8). A kutatási kérdésekre adott válaszok összesítőjét a 15., 16., 17. számú mellékletek tartalmazzák. (A téma fókuszja miatt a banki szakterületen tapasztalatot szerzett interjúalanyok válaszai témánként kerülnek szöveggözen kifejtésre, ellentétben a korábbi publikációm közlési módjától, ahol átfogóan összegeztem az eredményeket.)

A mélyinterjúk során szerzett tapasztalatokat második lépésként a bankrobotika jogszabályi keretrendszerének vizsgálatával egészítem ki (lásd a következő alfejezetben). A bankrobotika koncepció és kutatási terület meghonosításával kapcsolatos eredményeket a Hitelintézeti

Szemlében (Prisznyák, 2023c), míg az etikus AI gyakorlati megvalósulásának lehetőségei a Gazdaság és Pénzügy folyóiratban (Prisznyák, 2023b) publikáltam.

Harmadik lépésként a robot/AI-címkézés terület vizsgálatához a K5, K8 kérdések mellett felhasználtam a HunOR adatbázist. (Ezeket szintén a következő alfejezetekben ismeretetek.) A robot/AI-címkézéssel összefüggő meglátásokat (a címkézés jelenségének létezése, a robot/AI-incidensek jelentette kockázat, illetve a működési kockázati események vizsgálatán keresztül szerzett kutatási eredményeket) az Operational Risk Management folyóiratban a „The robot-labelling phenomenon. Robot-Ready Modern Operational Risk Management” című cikkemben tárgyalom (Prisznyák, 2024a) – sürgetve a működési kockázatkezelési szemléletváltását.

Negyedik lépésként (az empikus elemzést második felében) a szabadalmi adatokat elemzem.

5.2.1. Mélyinterjú I. - A bankrobotika terület lehatárolásának szükségessége

Alábbiakban a K1, K2, K3, K4, K5 kérdések mélyinterjú keretében történő vizsgálata során szerzett megállapításokat összegzem.

A mélyinterjúk alapján az AI rendszerek tervezése és bevezetése során a top down megközelítés (K1) dominál. A bankok többsége az AI és kapcsolódó technológiai fejlesztések esetén top-down megközelítést alkalmaz, ahol a kezdeményezés a menedzsment szintjéről indul (esetenként anyavállalati nyomás hatására) jellemzően költségcsökkentési, hatékonyságnövelési céllal (1., 12., 13. interjúalany). A stratégiai irányok meghatározása mellett további indokot szolgáltat a top-down megközelítéshez, hogy az üzleti oldal gyakran nincs teljesen tisztában az AI, ML és automatizáció lehetőségeivel, ezért a menedzsment szerepe kiemelkedő a bankrobotikai beruházások stratégiai tervezésében (1. interjúalany). A top-down megközelítést kívülről jövő (IT cég) kedvező ajánlata is előidézheti (6. interjúalany). Kapcsolódóan a nem banki tapasztalattal bíró szakemberek számos esetben említették, hogy a top-down megközelítés során ezen technológiák bevezetése iránti nyomást a befektetői, ügyfél, valamint egyéb értéklánc szereplőtől érkező nyomás indukálja (2., 3., 4. interjúalany). A bottom-up megközelítés esetében az üzleti oldal vagy az IT részleg (biztonság) kezdeményezései kerül előtérbe (8., 9. interjúalany). A fejlesztési kezdeményezések jellemzően a front office (sales, CRM), illetve a back office területről indulnak (8., 9. interjúalany). Számos esetben a kezdeményezések mindkét irányból (hibrid módon) érkeznek (7., 12., 14. interjúalany). Ekkor az AI projektek kezdeményezése gyakran fentről indul, például a költségcsökkentési célok miatt, de a részletek kidolgozása a csapatok részéről történik (14.

interjúalany). A belső innovációs kezdeményezések (ötletversenyek, start-up programok, egyetemi kooperációk) egyaránt szerepet játszanak a fejlesztési és beruházási folyamatokban (7. interjúalany).

A bankrobotika-beruházás megvalósulási módját tekintve (K2) az in-house fejlesztési megközelítés is jelentős szerepet kap a bankrobotika terén (7.,8.,9.,14. interjúalany). Számos bank teljes mértékben házon belül végzi a fejlesztéseket dedikált csapatok által (14. interjúalany), amit az ágazat specifikus szaktudás, illetve az adatvagyon védelme, a kódbázis tulajdonlás indokol (6., 7., 8., 9. interjúalany). Ez lehetővé teszi a technológiák a bank egyedi, üzleti igényei szerinti közvetlen testreszabását (8. interjúalany). Az in-house fejlesztés mellett szól az adatok átadásával szemben támasztott menedzseri aggályok (7. interjúalany). A hibrid/partnerségi megközelítés lehetővé teszi a bankok számára, hogy a jelentős szaktudást igénylő területeken (jellemzően K+F intenzív) beszállítót alkalmazzanak, már a projekt kezdeti szakaszától, és ezzel az in-house fejlesztéshez képest gyorsabban gyorsan érik el a kívánt technológiai szintet (1. interjúalany). Ez jelentkezik dobozos termék megvásárlása során is, amikor a termékfejlesztés véglegesítését az in-house csapat látja el (perszonalizáció) (12. interjúalany). Esetenként a kívánt a kívánt tudás szervezeti beépülését követően a külső szállítók fokozatosan kivonásra kerülnek, és a bank dedikált csapata folytatja a fejlesztést (13., 14. interjúalany). A partnerek bevonását jellemzően a back office, feldolgozó rendszerek esetében veszik igénybe, míg a front officet területeken alkalmazott adat/kódvagyon védelme miatt ez kevésbé jellemző (6. interjúalany). A beszállító bevonása lehetőséget biztosít a bank számára a szükséges szakértők és tudás bevonására, valamint az erőforrásainak optimalizálására és költséghatékonyság elérésére.

A menedzsment pozitív, nyitott, támogató hozzáállása (K3) elősegíti az új technológiák integrálását a szervezetbe (1.,7.,8., 12.,13.,14. interjúalany). A menedzsment általában támogatja az AI projekteket, mivel ezek hozzájárulhatnak a bank adatvagyonának védelméhez és az üzleti folyamatok támogatásához (7. interjúalany). A nyitottsággal szembeni tényezőként jelentkezik az adatvagyon védelme (7. interjúalany), illetve a költségbecsléskor jelentkező finanszírozási igény (9. interjúalany), valamint a menedzsment felületes tudásából eredő AI-al szemben támasztott elvárások tisztázása a szakértők által (12. interjúalany). A menedzsment attitűdjét Ugyanakkor befolyásolhatja a technológiai ismeretek hiánya, amely révén elzárkózást tanúsíthat (6., 13. interjúalany).

Az alkalmazott bankrobotika technológiák (K5) esetében az interjúalanyok a front, middle, back office területeket érintően az alábbi felhasználási lehetőségeket említették:

Front office: Értékesítés, CRM területen: vásárlási (volumenitás) előrejelzések és ügyfél célzás (targeting), legközelebbi legjobb ajánlatok (next-best-offer), cross-selling, up-selling stratégiák kialakításának, illetve a vásárlási szokások mélyebb megértése céljából alkalmazott előrejelző, klasszifikációs ML modellek (1., 6. interjúalany).

Middle office: Kockázatkezelés területen: scoring (7. interjúalany), kockázatkezelés-és monitoring esetében előrejelző ML modellek (1., 7., 8. interjúalany). Továbbá, a jelentéskészítési kötelezettséget támogatóan speciális területek elősegítése, például FATCA jelentések készítésének támogatása profílozó modellek révén, amelyek az ügyféladatokat és tranzakciós adatokat anonim módon vizsgálják, azonosítva a FATCA-gyanús ügyfeleket (8. interjúalany). A bankbiztonság és működés támogatása érdekében az AI-t sérülékenységmentes területen is alkalmazzák, ahol a szoftver ágens a felhasználók laptopjaira telepítve keresik az operációs rendszert érintő biztonsági problémákat (12. interjúalany).

Back office: csalásfelderítés, ügyfélkezelési területen alkalmazott ML modellek és NLP-alapú intelligens chatbotok (6., 7., interjúalany), valamint email klasszifikációt, dokumentum feldolgozást támogató NLP-alapú megoldások jellemzőek(8., 9. interjúalany). A back office rendszerek támogatása céljából gyakran alkalmaznak szoftver robotokat (RPA), vagyis folyamatautomatizációs megoldásokat a manualitásból származó hibák csökkentésére és a napi folyamatok (például riportok készítése) gyorsítására (13., 14. interjúalany).

A mélyinterjún kapott válaszok alapján az AI-bevezetést gátló tényezőket (K4) 7 főkategóriába és 29 alkategóriákba rendszereztem, amelyeket az alábbi 15. táblázat ismeret.

15. táblázat: Bankrobotika technológiák bevezetését akadályozó tényezők (K4)

Fő kategória	Alkategória	Alkategória elemei
<i>Szervezet</i>	AI-stratégia	AI-stratégia kialakítása összhangban az anyavállalat AI -stratégiájával
	Dedikált szervezeti egység és szervezeti fórumok kialakítása	Felelős szervezeti egység, munkakörök, felelősök és elszámoltathatóság kialakítása
	AI-támogató szervezeti kultúra	Innovációt támogató környezet; „robot” szervezetbe illesztése (csapattag)
	AI iránti érzékenyítés	Munkavállalók AI-érzékenyítése és képzése
	Szervezet mérete és globális jelenlét	Igazodás a kulturális, regionális és helyi AI-szabályozási környezethez
	Költség/profit húzó tényezők	Értékteremtő és költség tényezők meghatározása, folyamatos felülvizsgálata
	Banki adatvagyon védelme és a kiberbiztonság támogatása	Adatbiztonsági szabályok és irányelvek betartása; üzemeltetési és biztonsági követelmények, rendszervédelem (jogosultságok, banki kiberbiztonság) megteremtése, támogatása és megfelelés biztosítása
	Szervezeti képesség építése	Szükséges eszközpark (hardver, szoftver); tudástranszfer, AI-tudástár
	Társadalmi felelősségvállalás és külső tudástranszfer	Kollaboráció egyetemekkel, start-up cégekkel; ügyfelek és társadalom érzékenyítésének támogatása
<i>Vezetőség, menedzsment</i>	Változásmenedzsment	Organikus átalakulás irányítása, mindset-váltás, elköteleződés (tettekben is); támogató szervezeti kommunikáció
	Technológiai ismeretek	Alapvető AI-ismeretek, technikai képességek (elkerülve az AI-hype okozta túlzott elvárásokat)
<i>Operatív munkavállalók</i>	Munkavállalói félelem és ellenállás menedzselése	Munkavállalói ellenállás (munkahely elvesztésének félelme, IT-oldalról leterheltség növelése) menedzselése a szervezeti változásmenedzsment révén
	AI-szakemberek, munkavállalói képességek, edukáció	AI-szakemberek vonzása; tehetségmenedzsment
<i>Egyéb stakeholder csoportok</i>	Befektetők, piac	Valós technológiai képességek kommunikálása (AI-washing), bankrobotika investícióval kapcsolatos kommunikáció a fogyasztók és befektetők felé
	Versenytárs- és piactrend-elemzés	Versenytársak és technológiai trendek elemzése
	Ügyfelek	Ügyfél-igények és elvárások (felmérés, diskurzus); technológia adaptáció és elégedettség mérése; ügyfél-educáció: felelősségteljes termék-használat és ítélőképesség
	Partner, beszállító	Speciális AI-szakértelemmel bíró beszállító kiválasztása, tudásátvitel; partnerkockázat kezelése
<i>Adatok és adatkezelés</i>	Szükséges adatok beszerzése, tárolása	Szükséges adatmennyiség, minőség biztosítása (adatminőségi problémák kezelése, megfelelő adattisztítás), tárolás (szerver/felhő)
	Adatbetöltés, adat-feed, rendszerkapcsolatok	Banki és külső adatsilók elérhetősége, API-integráció; leányvállalati és partner-rendszerek összehangolása
	Adatbiztonság	Ügyféladatok védelme, anonimitás, technológiai workflow átgondolása
<i>Technológia</i>	Projektmenedzsment: Menedzsment/üzleti/fejlesztő/jogi csapat kooperációja	Rövid kommunikációs lánc alkalmazása és a kommunikációs híd megteremtése a bank és beszállító között: banki oldali IT-/AI-szakember kulcsfontosságú a reális ütemezés, elvárások tisztázása és erőforrás-szükséglet megbízható becslése érdekében, pontos üzletiigény-specifikáció (kapcsolódó KPI-ok)

	AI-kockázatkezelési rendszer	Kockázatkezelési rendszer működtetése
	Modellépítés – algoritmusválasztás	Megfelelő adatszámok; reprezentativitás; megfelelő algoritmus választása és modell-kalibráció; modellkritériumok (transzparens, diszkriminációmentesség, magyarázhatóság) biztosítása
	Üzemeltetés, monitoring és emberi felügyelet	Rendszer folyamattámogatása: emberi felügyelet; rendszerteljesítmény ellenőrzése (pontosság, negatív visszacsatolási hurkok), szükség esetén újraparaméterezés, beavatkozási scenáriók (rendszer-leállítás) definiálása
<i>Jogszabályi megfontolások</i>	Compliance-jogszabályok betartása	Jogszabályoknak (AI-jogszabály, DORA-, GDPR-rendelet, egyebek) megfelelő működtetés, kockázati osztályozás; etikai iránymutatások érvényre juttatása
	Ügyfélértékelés és szerződések	Ügyfélértékelés a jogszabályi előírásoknak megfelelően – ügyfélértékelésbe integrálás
	Alkalmazási korlátok	Nemzetközi és hazai szabályozói környezet lassú adaptációja
	Regulációs sand box	Modell tesztelési lehetőségének megteremtése az üzleti terület számára (banki IT-/AI-szakértők támogatása)
	Adatszolgáltatási kötelezettség, dokumentáció	Modell és üzemeltetési követelményeknek (műszaki dokumentáció, nyilvántartás követelményeinek) való megfelelés

Forrás: Saját táblázat Prisznyák (2023c, pp.: 111-112) alapján

5.2.2. Mélyinterjú II.

Az etikai kérdések (K6) jellemzően nem képezik elkülönült vizsgálat tárgyát az AI rendszerek, ML modellek tervezésének. Részben azért, mivel az alkalmazott technológia még nem jutott el arra a szintre, ahol ezek a kérdések relevánssá válnának (7.,8., 9., 13. interjúalanyok), vagy a technológia folyamatautomatizálást támogat (14. interjúalany). Az AI, ML és kapcsolódó technológiákat már használók megállapítsa alapján az érzékeny adatok kezelése (vallási hovatartozás), valamint a rendszer- és adatbiztonság (GDPR megfelelés szempontjából is) kiemelt jelentőséggel bír (1, 6., 7., 12. interjúalany). A diszkriminatív döntéshozatal, illetve a szolgáltatásból való kizárás elkerülése érdekében ezen érzékeny adatokat nem kerülnek felhasználásra a modellépítésnél, vagy titkosítási módszerek révén kezelik őket (1., 6., 8. interjúalany). Ez biztosítja az adatbiztonságot és a jogszabályoknak való megfelelést. Előfordul, hogy a GDPR előírásainak betartása érdekében az ügyfélszerződésekbe (adatfelhasználás) próbálják meg beépíteni a hozzájáruláshoz elégséges jogi elemeket (6. interjúalany). Egyes bankok a biztonságos működés érdekében még csak primitív ML modelleket üzemeltetnek bizonyos területeken (amelyek nem döntéstámogató szerepkörben vannak), vagy az adatfelhasználást korlátozzák, elejét véve az etikai aggályoknak (6., 7., 9. interjúalany).

A mélyinterjúk megállapítások alapján ez AI rendszerek alkalmazásával kapcsolatosan megfogalmazott oktatási és képzési igények (K7) eltérő képet nyújtanak. Egyes bankok a projektszempontok számára rendszeres workshopokat és dokumentációkat biztosítanak, amelyek segítik a munkavállalókat a technológia megfelelő alkalmazásában (1. interjúalany). kompetencia központban dolgozó munkavállalók általában kapnak képzést (dokumentált tudásanyag révén is), valamint on-the-job traininget. Az ügyintézők és egyéb érintettek számára inkább érzékenyítést nyújtanak nyílt napokon vagy belső tudásmegosztó anyagok (például white paperek) formájában, amelyek bemutatják az AI technológiák előnyeit és működését (7. interjúalany). Biztosítva az alkalmazottak és a menedzsment megfelelő edukációját az új technológiák bevezetésekor jellemző a workshopok tartása, valamint a rendszerhasználat bemutatása és a kapcsolódó fogalmi tisztázás (12., 13. interjúalany). Új szoftverek bevezetésekor fontos, hogy a képzési idő biztosítva legyen, és ellenőrizték az alkalmazottak képességeit a rendszer fenntartására és használatára (14. interjúalany). Ugyanakkor egyes banki tapasztalattal bíró interjúalanyok arról számoltak be, hogy az oktatás és érzékenyítés az AI bevezetése során nem jellemző (9. interjúalany), vagy költségvetési korlátok miatt visszaszorulóban van, illetve jellegüket tekintve túl általánosak (6. interjúalany).

5.2.2.1. Mélyinterjú I. – II.: Javaslatok

A szakirodalom áttekintés és a mélyinterjúk során levont tapasztalatok alapján az alábbi javaslatokat fogalmaztam meg a témát érintően (Prisznyák, 2023; 2023b).

A bankrobotik beruházások jellemzően nem kizárólag az adott üzletégység számára, hanem az összefüggő tevékenységek révén, a szervezet egésze számára teremtenek értéket. Az értékteremtés mérési nehézségei ráirányítják a figyelmet a bevezetett technológiai kockázatokra és osztályozásuk szükségességére, továbbá a kapcsolódó kockázatkezelési rendszerek működtetésére. Kockázati osztályozáshoz javaslom a szervezetspecifikus társterületi láncok definiálását. A társterületi láncok alatt olyan egymással szoros munkakapcsolatban álló társterületeket értek, amelyek közös üzleti folyamata, alkalmazott rendszere és adathasználata révén egymás tevékenységére ugyan közvetett, de mégis jelentős hatást képesek gyakorolni. Ezen társterületi láncokban alkalmazott AI-rendszerek kockázati osztályozását érdemes a társterületek egymásra hatásának és a technológia egyes területeken megvalósuló felhasználásának ismeretében meghatározni.

A bankrobotikai beruházások nyilvánosságra hozatalának keretében a bankoknak és a felügyeleti hatóságnak közösen kell kidolgozniuk az azokra vonatkozó követelményeket az alábbi szempontok szem előtt tartásával:

A bankrobotikai beruházás mértéke és hatása: azokat a beruházásokat, amelyek jelentős hatással lehetnek a bankok működésére és az ügyfelekre, kiemelt figyelemmel szükséges kezelni (például ML-alapú IRB-modellek) és nyilvánosságra hozni.

Biztonság és adatvédelem: a beruházásoknak meg kell felelniük a szigorú biztonsági és adatvédelmi előírásoknak, valamint az etikus AI-ra vonatkozó Európai Unió irányelveknek és jogszabályoknak. A nyilvánosságra hozatal során ezen szempontokat kiemelten szükséges kezelni, hogy az ügyfelek megfelelő tájékoztatást kapjanak a rendszer használatának tényéről, a biztonságáról, a képességeiről és az adataik védelméről.

A jelenlegi gyakorlat (a FinTech és Digitalizációs Jelentés) kiegészítéseképpen a bankrobotika beruházások üzemeltetése során fellépő incidensekről nyilvánosan hozzáférhető AI-incidens adatbázis vezetését javaslom, minimálisan az alábbi attribútumokkal: incidens ID, incidens cím (rövid összefoglaló); incidens részletes leírása; bejelentés/hiba észlelés dátuma; intézkedés/javítás dátuma; érintett banki terület(ek); (potenciálisan) érintett

ügyfelek/ügyfélkörök; az AI-rendszert fejlesztő vállalat/vagy a bank (in-house fejlesztés esetén); üzemeltető bank. A javaslatot az alábbi főbb megfontolások támogatják:

Bizalom és felelősségvállalás: Az Európai Unió által publikált AI rendelet az AI rendszerek fejlesztésével, üzemeltetésével, terjesztésével kapcsolatosan meghatározza a felelősségvállalás szabályait az okozott károkért, amelyek esetében bizonyos esetekben a magas kockázatú AI-rendszerekre szigorúbb szabályok vonatkozhatnak, így tanúsítást is előírhat a rendszer megfelelőségének biztosítására. Ezzel összefüggésben a javasolt adatbázis transzparens módon járulna hozzá a piaci szereplők és érintett körök közötti kölcsönös bizalom megteremtéséhez és fenntartásához, elősegítve az átláthatóságot és a felelősségvállalást, az etikus AI-rendszerek kialakítását és működtetését, összhangban az Európai Unió etikus AI-iránymutatásával.

Bankszektor fejlődése: Az incidensek nyilvánosságra hozatala hozzájárul az innováció és szükséges fejlesztések ösztönzéséhez, elősegítve a szervezeti képességek fejlesztését és a banki felelősségvállalási kultúra fejlődését.

Felhasználó-/ügyfélvédelem és ügyfélélmény: Az érintett ügyfélkör (lakossági, vállalati, egyéb) megnevezése mellett az incidens alapvető részletei is megismerhetővé válnak az ügyfelek számára, javítva az incidensben érintett felhasználók védelmét, illetve növelve az AI rendszerek iránti bizalmat az átláthatóságon (meghozott intézkedések) keresztül.

5.3. Bankrobotika jogszabályi keretrendszerének elemzése

A bankszektor különösen szigorú szabályozási környezetében figyelembe kell venni a pénzügyi szektor sajátos prudenciális előírásait, (CRR), valamint egyéb kapcsolódó rendeleteket (GDPR, DORA, Felhő-ajánlás egyebek), amelyek együttesen határozzák meg azt a keretrendszert, amit a bankoknak az AI rendszerek fejlesztése, működtetése során figyelembe szükséges venniük. Erről bővebben a harmadik fejezetben értekeztem. Ezen szabályozások együtt biztosítják a technológiai innovációk biztonságos és etikus alkalmazását a bankszektorban, miközben garantálják az ügyfélbizalom és a szabályozói megfelelés fenntartását. Az alábbiakban a jogszabályok (CRR, AI rendelet, GDPR) közötti kapcsolódási pontokat vizsgálom (16. táblázat), hogy alátámasszam a bankrobotika terület lehatárolásának szükségességét.

16. táblázat: Bankrobotika komplex jogszabályi környezet – követelmény kapcsolódási példák az AI rendelet, CRR, GDPR között

Téma	AI rendelet	GDPR	CRR
Kapcsolódás más jogszabályokhoz, rendeletekhez	Kapcsolódás a CRR-el: Az AI rendelet alkalmazása az adott szektorban érvényes EU-s jogszabályokkal való együttes figyelembevétel (AIA, 9. preambulumbekzdés) Kapcsolódás a GDPR-al: A személyes adatokat feldolgozó AI rendszereknek GDPR tekintetében is megfelelően kell lennie (AIAI, 5. cikk).	Kapcsolódás más jogszabályokkal: Meghatározza az adatkezelés jogalapjait, beleértve azt is, hogy az adatkezelés szükséges lehet egy adott jogi kötelezettség teljesítése érdekében (Hatály és Együttműködés (GDPR, 6. cikk – Jogalapok)	Kapcsolat a GDPR-al: A belső modellek validálására vonatkozóan előírja, hogy a validálási folyamatoknak biztosítaniuk kell a kockázati modellek átláthatóságát és értelmezhetőségét. Ez közvetlenül összefügghet a GDPR által előírt követelményekkel, ha a modellek személyes adatokat is kezelnek, mivel az adatkezelési elvek betartása kötelező az EU-s jogszabályok szerint (CRR 185. cikk)
Személyes adatok védelme (alapvető jog)	Személyes adatok és magánélet védelme (Alapjogi Charta-ban lefektetett alapvető jog) és diszkrimináció mentes döntéshozatal (AIAI, 10., 28. preambulum). A személyes adatok védelme érdekében a legkorszerűbb biztonsági és adatvédelmi intézkedések alkalmazandók. (10. cikk, 5. b, pontja)	Az érzékeny személyes adatok (faji/etnikai származás; politikai vélemény, vallási vagy világnézeti meggyőződés, szakszervezeti tagság, genetikai, egészségi állapot, szexuális irányultság, nemi identitás) felhasználásának tilalma. Szükséges adatok minimalizálására kell törekedni (5. cikk).	Kifejezetten nem tárgyalja a személyes adatok felhasználását.
Kockázatkezelés, diszkrimináció-mentes döntéshozatal, magas kockázatú AI kategória	A természetes személyek hitelképességének értékelését, hitelponszámuk megállapítását végző AI rendszerek magas kockázatúnak számítanak, mivel meghatározzák a természetes személyek hozzáférését pénzügyi forrásokhoz, így élethelyzetükre esetleges hátrányos hatást gyakorolhatnak ((AIA III. sz. melléklet 5. (b), 58. preambulumbekzdés). Ezen rendszerek esetében kockázatkezelési rendszert kell létrehozni, üzemeltetni, és fenntartani a teljes életciklus alatt (AIAI, 9. cikk). Az intézkedések arányosak kell, hogy legyenek a kockázatokkal, autonómia szinttel és a használat kontextusával a magas kockázatú AI rendszerek életciklusa során (AIA, 4. cikk (3)).	Személyes adatok feldolgozásának lehetősége statisztikai célból a modell torzítás kiküszöbölése érdekében (9. cikk). A személynek joga van az adatainak törlést kérni (törléshez/ elfeledtetéshez való jog (GDPR, 17. cikk). A GDPR (adatvédelmi hatásvizsgálat) előírja, hogy a személyes adatok kezelésének jelentős kockázatot jelentő hatásait a feldolgozás előtt értékelni kell. (GDPR, 35.cikk)	A pénzügyi intézményeknek megfelelő kockázatkezelési keretrendszerrel kell rendelkezniük, amely magában foglalja a kockázatok azonosítását, értékelését és kezelését (CRR, 74. cikk). Aktív részvétel a minősítési eljárásban alkalmazott modellek kialakításában, kiválasztásában, bevezetésében, validálásában (CRR, 190. cikk) – MI, mint alternatíva, viszont akkor AI rendszer kockázati osztályba sorolásra figyelni kell!

<p>Automatikus döntéshozatal, profilalkotás tilalma</p>	<p>A bankszektorban hitelminősítés, scoring (profilalkotás) céljából, illetve a munkavállaló értékelésére alkalmazott profilozó AI rendszerek. Kivételt a pénzmosás-és terrorizmusfinanszírozás, valamint csalásmegelőzés céljából alkalmazott modellek jelentenek ((AIA III. számú mellékletének 5. (b)).</p>	<p>Automatizált döntéshozatal egyedi ügyekben (beleértve a profilalkotást) tilos, kivétel bizonyos esetekben (GDPR, 22. cikk). Bizonyos személyes adatok meghatározott feltételek mellett kezelhetők automatizált adatkezelésen alapuló döntéshozatal és profilalkotás céljából, például: ha uniós/tagállami jog kifejezetten engedélyezi (AML, CFT, csalás nyomon követése céljából), vagy ha ehhez az érintett kifejezetten hozzájárulását adta (GDPR, 6.cikk) – de ekkor is csak megengedő garanciák mellett (magyarázhatóság, emberi felügyeleti lehetőség) ((GDPR, (71)).</p>	<p>Nem tárgyalja az automatikus döntéshozatalt.</p>
<p>Modell átláthatóság, érthetőség, magyarázhatóság</p>	<p>A magas kockázatú AI rendszereket úgy kell megtervezni és fejleszteni, hogy működésük kellően átlátható legyen ahhoz, hogy az alkalmazók értelmezhessék a rendszer kimenetét és megfelelően használhassák azt, továbbá magas fokú átláthatóságot kell biztosítani (AIAI, 13. cikk). Az AI rendszerek magyarázhatósága és átláthatósága alapján az AI rendszereknek olyan módon kell kialakítaniuk, hogy azok magyarázhatóak legyenek, és ne legyenek túl komplexek ahhoz, hogy a humán ügyintézők könnyen megértsék őket. (AIA, 10. cikk)</p>	<p>Átláthatóság és intézkedések biztosítják az érintettek számára, hogy a személyes adatok kezeléséről szóló információk világosak, értelmezhetőek és könnyen hozzáférhetőek legyenek (GDPR, 12. cikk). Továbbá a modell transzparencia jegyében információt szükséges nyújtani a felhasználó számára a modell döntéshozatalának logikájáról (GDPR, 13. cikk), illetve az érintettnek hozzáférési joga van az automatizált döntéshozatal megismeréséről beleértve a profilalkotást is (GDPR, 15. cikk).</p>	<p>A banknak rendszeresen időközönként validálnia szükséges a modellt: a teljesítményének és stabilitásának monitorozásán, a modellspecifikációk felülvizsgálatán, valamint a modell eredményeinek a tényleges eredményekkel való összevetésén keresztül (CRR, 174. cikk).</p>
<p>Dokumentáció, ellenőrzés</p>	<p>Adatok és adatkezelés - Előírja, hogy az AI rendszerek adatai és modellek megfelelő dokumentációval és átláthatósággal rendelkezzenek, hogy azok ellenőrizhetők és érthetőek legyenek (AIA, 10. cikk).</p>	<p>A modell által hozott döntés megismerésének joga feltételezi a dokumentáció készítését (GDPR, 15.cikk)a</p>	<p>Ha az intézmény statisztikai modelleket alkalmaz a hitelminősítési folyamatban (hitelminősítő rendszerek), úgy dokumentálnia szükséges a módszertanát, amelynek tartalmaznia kell a modell validálás folyamatát és a teljesítményteszteket is (CRR, 175. cikk (4)), illetve szakértői vélemények és a modell együttes alkalmazásának módját (174. cikk).</p>

Tesztelés, validáció	<p>A magas kockázatú AI rendszerek esetében rendszeresen tesztelni és értékelni kell a rendszerek teljesítményét, beleértve a kockázat- és diszkriminációs teljesítményt is (AIA, 15. cikk)</p> <p>A tanítási, validálási és tesztelési adathalmazoknak relevánsnak, kellően reprezentatívnak, hibáktól mentesnek és teljesnek kell lenniük a szándékolt cél szempontjából (az adatok megfelelő statisztikai tulajdonságokkal kell rendelkezzenek). Továbbá a tanítási, validálási és tesztelési adathalmazokat az adott célra megfelelő adatkezelési és kormányzási gyakorlatoknak kell alávetni a magas kockázatú AI rendszer esetében. Az adathalmazok elérhetőségének, mennyiségének és alkalmasságának felmérése szükséges. A tanítási, validálási és tesztelési adathalmazoknak relevánsnak, megfelelően reprezentatívnak, és a lehető legnagyobb mértékben hibamentesnek és teljesnek kell lenniük (AIA, 10. cikk).</p>	kifejezetten nem tárgyalja	<p>A kitettségek ügyfél- vagy ügyletkategóriákba, illetve halmazokba sorolása során alkalmazott statisztikai vagy egyéb mechanikus módszereknél az adatoknak pontosnak, teljesnek, reprezentatívnak kell lenniük ügyfeleinek vagy kitettségeinek csoportjára vonatkozóan, és a modell nem tartalmazhat lényeges torzítást (CRR, 174. cikk, modellek alkalmazása). A belső becslések validálása érdekében a belső validálási folyamatnak lehetővé kell tennie a kockázatbecslési rendszerek teljesítményének következetes és értelmezhető módon történő értékelését (CRR 185. cikk).</p> <p>A fejlett technológiai eszközök használata a modellek validálási gyakorlatának javítása céljából üdvöztető, hiszen a validálási technikák és bevált gyakorlatok idővel fejlődnek (CRR 369. cikke).</p>
Emberi felügyelet, felügyeleti mechanizmus	<p>Biztosítani kell az AI rendszereknek hatékonyan emberi felügyeltét (AIA, 14. cikk). A rendszer működését, beleértve annak képességeit és korlátozásait (anomáliák, működési zavarok, váratlan teljesítmény) nyomon kell követni (14. cikk). (Megjegyzés: az etikus AI iránymutatás: HOTL, HITL, HIC felügyeleti mechanizmusokat nevesít.)</p>	kifejezetten nem tárgyalja	<p>A banknak megfelelő létszámú, szakértővel kell rendelkeznie a kockázatellenőrzés céljából (CRR, 368. cikk). A validálást a modellfejlesztéstől függetlenül kell elvégezni, és minden jelentős kockázatot figyelembe kell venni (CRR, 369.cikk). A felülvizsgálat célja a modell hiányosságainak, hibáinak feltárása és mérséklése (CRR, 174. cikk.)</p>
Műszaki stabilitás és biztonság	<p>Az AI-rendszereknek pontosnak, stabilnak és biztonságosnak kell lenniük, védekezve a manipuláció és hibák ellen. A rendszert úgy kell tervezni, hogy ellenálljon meghibásodásoknak és torzításoknak, és kezelje a visszacsatolási hurkokból eredő problémákat (AIA, 15. cikk).</p>	kifejezetten nem tárgyalja	<p>A hitelkockázati modellek folyamatos felülvizsgálata –indirekt utalása formájában– célozza a műszaki stabilitást, a modellek stabilitásának és megbízhatóságának biztosítását, hogy azok pontosan tükrözzék a valós kockázatokat (CRR 368. cikk).</p>

Forrás: Saját táblázat

5.3.1. Eredmények szintetizálása: Hipotézis vizsgálat

A szakirodalomelemzés, a mélyinterjúk, illetve a jogszabáylelemzések révén megállapítom, hogy az alábbi indokoknál fogva a bankrobotika terület lehatárolása szükséges a FinTechtől a jövőbeni körültekintő kutatások lefolytatása érdekében:

Komplex szabályozói környezet: az AI rendelet ((EU) 2024/1689) generális megközelítést alkalmaz így az nem specifikusan fedi le a pénzügyi szolgáltatásokat. Következésképpen, az AI rendszerek bankszektori kialakítása során nem elegendő az AI rendeletnek való megfelelés biztosítása, hanem egyidejű figyelembevétele szükséges a bankszektor prudenciális szabályozásának (AIA, 9. preambulumbekzdés).

Társadalmi-gazdasági hatás: A FinTech versenytársakkal szemben a bankok olyan szigorú jogszabályi környezetben működnek, amely a mesterséges intelligencia alkalmazás természetes korlátjaként jelentkezik, mivel a bankszektor számos társadalmi-gazdasági területre fej ki hatást. Ezek közül a pénzügyi rendszer stabilitása és a természetes személyek élethelyzetére kifejtette hatása kiemelkedő jelentőségű.

Innovatív szolgáltatások és kockázatkezelés: Az innovatív termékek/szolgáltatások, például BNPL, felveti a hitelminősítő rendszerek működtetésének szükségességét a FinTech vállalatoknál is, illetve rávilágít azon piaci, szakmai igényekre, amelyek az erőteljes ügyfélbizalmon alapuló bankrendszer kockázatkezelésével is kapcsolatosak: Pénzügyi rendszer stabilitása; fogyasztóvédelmi kockázatok (adósság-visszafizetési képesség értékelését, az átlátható díjszabást és a vitás tranzakciók rendezése), ügyfelek pénzügyi nehézségein keresztül kihatás az EU állampolgárainak életére.

Korlátozott AI alkalmazhatóság: A szektor jelentőségéből eredően, bizonyos AI rendszerek alkalmazási lehetőségeit (például hitelképesség értékelése, HR felhasználás a munkavállók profilozására) korlátozhatja. Kapcsolódóan a ML technikák banki alkalmazása során a modellek átláthatósága, magyarázhatósága, illetve a diszkrimináció-mentes döntéshozatal kiemelt jelentőségű a bank, mint kockázatkezelő intézmények számára. Ez egyúttal az AI rendszerek felhasználási lehetőségeinek és a felhasználható adatok korlátozásával is együtt jár.

Szabályozói „út” keresés: A jogszabályi megfelelés támogatás jegyében az MNB is igyekszik az AI technológiák felhasználásához csatornázni a jogszabályokat, rendeleteket és ajánlásokat. Bár ezek az InnoHub honlap alapján egyelőre még csak a szándékot tükrözik,

egyúttal illusztrálják az AI és kapcsolódó innovatív technológiák bankszektor-specifikus kezelésének és kutatásának szükségességét.

Bankszakmai követelmények: A FinTech banki engedélyek követelményeit a CRD IV definiálja ((1) irányítás, (2) belső szervezet és kockázatkezelési mechanizmusok, (3) működési program, (4) tőke, likviditás és fizetőképesség), amelyek olyan szektor-specifikus tényezők, amik meghatározzák a technológia lehetőségeit és az azt üzemeltető és kontrolláló munkavállalók szükséges képességeit

Hosszú Távú Nyereségesség és Kockázatkezelés: A bankszektor specifikus előírások (CRD IV és CRR) a tőkekövetelményre (szavatoló tőke, kiegészítő tőke), a kockázati éhségre, a váratlan veszteségek nyomon követésére (kockázatkezelésre) a rövidtávú profitmaximalizálás ellenében, a hosszútávú nyereségességet motiválják – ami szintén a technológia lehetőségeit szabályozza a kockázati éhség szabályozásán és a kockázatkezelési mechanizmusok mentén.

A szakirodalom elemzés, mélyinterjúk és a jogszabály elemzés alapján a H1 hipotézisemet elfogadom. Megállapítható, hogy a bankszektor szigorú prudenciális szabályozása természetes akadályt képez az AI és a kapcsolódó technológiák implementálásában és fejlesztésében. A szektor-specifikus sajátosságok figyelembevételével indokolt, hogy a bankszektorban történő AI alkalmazást önálló, lehatárolt területként kezeljük.

Az elfogadott hipotézis alapján az alábbiakban a bankrobotika kutatási terület fogalmát és az értelmezésének végső iterációját ismertetem.

5.3.1.1. A bankrobotika fogalom végső iterációja

Az AI (technológiai) forradalmat követő banki transzformációs időszak alapvetően egyetlen kérdésről szól: Hogyan alakulnak át a bankok AI-alapon működő szervezetekké (egyedekké), ha alapvetően hiányzik belőlük az AI és kapcsolódó innovatív technológiák kialakításának/létrehozásának képessége (szemben a FinTech, IT vállalatokkal, amelyek lételeme)? A rövid válasz: hogy a bankok a (1) komplex jogszabályi keretrendszer és az (2) AI területet célzó kutatási tevékenység révén elképzelt és kodifikált rendeket hoznak létre és szervezetüket az implementált technológiához igazítják, hogy DNS-es szinten képessé váljanak az adaptációra. Ez a két 'találmány' (1-2) tölti ki a bankok örökségében (új-tradicionális banki modellek) keletkező réseket. Ilyen formán a bankrobotika terület az egyed szintű változást biztosító elképzelt rend (rendszerezett, lehatárolt kutatási területként meghatározott tudásbázis és kutatási irány) a digitális éra gyorsan változó banki környezetében.

A terület ilyen formán történő lehatárolása szolgáltatja a fogalom harmadik iterációját a korábban részletezett bankrobotika fogalom iterációi mellett (1) technológiai aspektus: AI és kapcsolódó technológiák alkalmazása a bankszektorban, (2.) szervezeti aspektus: AI technológiák adaptációja által előidézett szervezeti alkalmazkodási folyamat). Ez a megállapítás szolgáltatja a fogalom értelmezésének harmadik szintjét, (3.) a stratégiai aspektust, amely nemcsak a meglévő rendszerek optimalizálását célozza, hanem új üzleti lehetőségeket is teremt, amelyek révén a bankok versenyképesek maradhatnak a digitális korban.

A bankszektor DNS láncának rétegei alapján a bankrobotika fogalom az alábbiakként értelmezhető:

- 1) **Technológiai aspektus/spirál (szűkebb értelmezés, 2. réteg a.):** technológiai adaptáció. Vagyis a FinTech területen is megjelenő innovatív technológiák (AI, ML, robotok és kapcsolódó innovatív technológiák) bankszektori alkalmazása.
- 2) **Szervezeti aspektus/spirál (tágabb értelmezés, 2. réteg b.):** szervezeti átalakulás. Vagyis a szervezet adaptációs képessége, amely meghatározza a digitális átállást kísérő szervezeti kultúra átalakulását, a munkavállalók, a szervezeti értékek fejlődését, a banki stratégiát, az alkalmazott üzleti modellt.
- 3) **Stratégiai aspektus (legtágabb értelmezés, 1. réteg): a bankszektor egészének alkalmazkodási képességét leíró DNS lánc** (egyedek alkalmazkodási képessége alapján). Az elképzelt rend/ a bankszektor átfogó hosszútávú alkalmazkodási folyamat, amelyet rövidtávon megvalósuló szervezeti és technológiai képességekben bekövetkező változások indukálnak.

5.3.2. Mélyinterjúk III.

A robot/AI univerzális szóhasználat a menedzsment hiányos ismereteivel is összefügg. A mélyinterjúk tapasztalatok alátámasztották, hogy a menedzsment technológiai ismeretei (K8) felületesek (8., 9. interjúalany), kedvezőtlenebb esetben gyakran teljesen hiányosak (1., 6., 7., 12., 13., 14. interjúalany). Utóbbi esetében nincsenek teljesen tisztában ezen technológiák pontos jelentésével és a közöttük lévő különbségekkel, ami főleg az idősebb menedzserek körében jellemző (12. interjúalany). Ez téves, túlzó elképzelésekhez vezethet az AI rendszerekkel kapcsolatosan a projektek során (6., 7. interjúalany), ami megnehezíti a partnerekkel, beszállítókkal való tárgyalásokat, illetve a projektek időszükséglet, valamint költségbecslést, illetve hátráltatja a kommunikációt az üzleti területtel és az IT-val. Ezért a

menedzsment edukációja és a fogalmak tisztázása kiemelt fontosságú a sikeres technológiai implementációk érdekében (13. interjúalany). Ezt kiegészítendő, a túlzó elképzelések realitások talajához láncolását elősegíti, amennyiben a beszállítóval tárgyaló bizottságban helyet kap a banki oldalon egy AI területen jártas szakértő kolléga az IT oldaláról (6. interjúalany).

A robot/AI-címkéket jellemzően az adott felhasználási területen alkalmazott innovatív, intelligens technológiák leírására alkalmazzák. Az interjún elhangzottak és a mögöttes technológia (K5) alapján a robot/AI az alábbi technológiákra utalnak: ML, virtuális asszisztens, chatbot, intelligens chatbot, felhő-alapú megoldások, szuperszámítógépek, egyszerűbb adatfeldolgozó rendszerek, NLP, szoftver robotok, RPA (17. táblázat).

17. táblázat: Robot/AI-címkék és mögöttes technológiák – a mélyinterjúk tapasztalata alapján

#	Robot- és AI-címkék K5 alapján
1.	az AI vagy robot technológia címkét a menedzsment univerzálisan különböző kontextusokban alkalmazza.
6.	Az AI, ML, virtuális asszisztens, intelligens chatbot és automatizáció fogalmát gyakran szinonimaként használják. Jellemzően a predikciós ML modellekre utalnak.
7.	virtuális asszisztens, chatbot, ML; felhő- alapú megoldások és a szuperszámítógépek
8.	gépi tanulás, automatizáció, egyszerűbb adatfeldolgozó rendszerek
9.	ML, NLP, automatizáció (RPA)
12.	ML modellek
13.	ML, automatizáció (RPA), szoftver robotok
14.	automatizáció (RPA)

Forrás: Saját forrás

Az alábbiakban a mélyinterjú kérdésekre eredményeit összegzem (18. táblázat).

18. táblázat A mélyinterjúk eredmények összefoglaló táblázata

Hipotézis	Kutatási eredmény és a hipotézis elfogadása/elutasítása	Döntés
H1: Top-down megközelítés.	Top-down megközelítés dominál. A bottom-up megközelítés azokra a szervezetekre jellemző, ahol a szervezet nem rendelkezik AI-stratégiával, a menedzsment AI-tudása hiányos. Hibrid megoldásként a top-down átalakításra kerül a bottom-up üzleti/IT/beszállítói oldali specifikáció révén.	Elfogadás
H2: In-house, partnerség, felvásárlás és hibrid forma egyaránt megjelenik.	In-house, partnering, felvásárlás és hibrid forma egyaránt megjelenik.	Elfogadás
H3: Pozitív, támogató magatartás.	Főleg a támogató, pozitív menedzsmenti hozzáállás figyelhető meg	Elfogadás
H4: Jogszabályi korlátok, adat, munkaerőszükséglet, szervezeti kultúra.	Az előirányoztnál több, az AI-bevezetést gátló tényezőt (7 főkategória, 29 alkategóra) azonosítottam	Részleges elfogadás
H5: ML modelleket, NLP, gépi látás technológiákat.	ML, virtuális asszisztens, chatbot, intelligens chatbot, felhő-alapú megoldások, szuperszámítógépek, egyszerűbb adatfeldolgozó rendszerek, NLP, szoftver robotok, RPA	Részleges elfogadás
H6: Igen, számos etikai érv felmerül a felhasználók jogainak és biztonságának biztosítása érdekében	Kifejezetten nem, indirekt módon (adatfelhasználás, diszkriminatív döntések) felmerül a fejlesztés során, de nem a tervezési szakaszban.	Részleges elfogadás
H7: Az AI-rendszerek bevezetése során a munkavállalók képzésben részesülnek	Beszállító bevonása esetén workshop-ok és dokumentáció; külön AI specifikus, illetve etikai érzékenyítési képzés sehol sem volt. Jellemzően a training-ek túl általánosak, idő és költségvetési korlátok akadályozzák a meglétét	Részleges elfogadás
H8: A menedzsment technológiai ismerete kellőképpen megalapozott a projektek támogatásához.	Az AI-hype és menedzser oldali hiányos AI-ismeretek beszállítói kooperációs problémákat okozhatnak a nem reális technológiai és értékteremtési elvárások következtében.	Részleges elfogadás

Forrás: Saját forrás

5.3.2.1. Mélyinterjú III. és a HunOR adatbázis vizsgálat eredményei

A szakirodalom alapján korábban megállapítottam, hogy az alábbi technológiák kapcsolódnak a 'robot' és 'AI' címkéhez: mesterséges intelligencia (AI), gépi tanulás (ML), természetes nyelvfeldolgozás (NLP), gépi látás, kvantum számítás, blokklánc, API, adatvédelmi technológiák (PET), felhőalapú megoldások, elosztott főkönyvi technológia (DLT), kiterjesztett és virtuális valóság (AR/VR), és internet of things (IoT). A mélyinterjúk alapján a 19. táblázatban lévő technológiákat azonosítottam. Ezt kiegészítendő, a robot/AI-címkézés gyakorlati megvalósulás vizsgálata érdekében, a HunOR működési kockázati eseményeket rögzít adatbázisát használtam (Prisznyák, 2024a). A cél az volt, hogy feltérképezzem, az incidensek rögzítése esetén: (1) Mennyire gyakori az esemény leírásánál a robot/AI-incidens? (2) Hogyan kategorizálják? (3) Hogyan rögzíti a bankok jelenlegi működési folyamata a robotok autonómiai szintjeit és az emberi felügyeleti mechanizmusokat?

A HunOR adatbázis vizsgálata eredményei: robot/AI-címkézés

A működési kockázati adatkonzorciumot, a HunOR-t 2007-ben hozta létre a Magyar Bankszövetség vezetésével, 13 magyarországi tagbank részvételével. A kezdeményezés célja az új működési kockázatkezelési kihívásoknak való megfelelés támogatása és a saját működési kockázati profiljuknak a magyar piacon jelenlévő iparági jellemzőkkel való összehasonlításának lehetővé tétele volt, egy közös adatbázis létrehozásával. Jelenleg a konzorciumnak 6 tagja van (összeolvadások, bezárások miatt), amelyek együttesen a magyar bankszektor hozzávetőleg 50%-át képviselik teljes mérlegük alapján. Az adatgyűjtés a hitelintézetekre vonatkozó CRD IV, CRR, valamint a Basel-ajánlások szabványait követi. A 17 év adatgyűjtése során a bankok körülbelül 61 000 működési kockázati veszteségeseményt jelentettek. Az adatgyűjtés anonim módon történik; a veszteségesemények nyilvántartásai nem tartalmaznak információt a feltöltő bankok kilétéről. A HunOR adatbázisban a tagok csak olyan negatív pénzügyi eseményeket jelentenek, amelyek hatással vannak az intézmény számvitelére, befolyásolják pénzügyi eredményeit vagy tőkéjét, veszteséggel járó következményekkel (a majdnem bekövetkezett eseményeket nem kötelező rögzíteni). Az adatgyűjtési küszöb viszonylag alacsony, 50 000 HUF.

Az adatbázisban szereplő attribútumok a következőkre vonatkoznak: (1) a működési kockázati események leírása (állapot, dátumok, események leírása stb.), valamint (2) veszteségek és megtérülések (üzleti vonalak, veszteségek/megtérülések típusai, kiváltó okok, kapcsolódó kockázatok). A kulcsszólista alapján (18. számú melléklet) mindössze három rekordot (19. táblázat) azonosítottak, amelyek a robotcímkézés jelenségéhez kapcsolódnak. Ahogy a megadott példák is mutatják, a robotokkal kapcsolatos leírások nem tartalmaznak információkat a robotokról/AI-ról, sem a címke mögött lévő mögöttes technológiáról. Nem térnek ki továbbá a robot (adott technológia) autonómiájának fokára, sem az emberi felügyelet jellegére, illetve nem tárgyalják a humán munkaerő-robot szerepét (trade-off) az adott munkafolyamatban. A felsorolt incidensek kockázati oka kategóriájában a végrehajtás, szállítás és folyamatmenedzsment (1. szint) szerepel. Csak feltételezések tehetők az autonómia szintjére vonatkozóan (20. táblázat). Az eredmények alapján kijelenthető, hogy továbbra is emberközpontú (esemény oka: ember) megközelítéseket alkalmaznak a BCBS kockázati események kategorizálásával összhangban, valamint a robot/AI incidensek nem gyakoriak, vagy a leírás nem nevesíti a technológiát, továbbá nem vizsgálják a robot autonómia és az emberi felügyelet szerepét az eseményt kiváltó ok elemzése során.

19. táblázat: Robot Oprisk események a HunOR adatbázis alapján kivonatolva 2024.08.02-án

Jellemzők	#1	#2	#3
Státusz	Befejezett	Befejezett	Befejezett
Bankszintű	Nem bankszintű	Nem bankszintű	Nem bankszintű
Az esemény leírása (felhasználási eset)	Adminisztratív hiba miatt helytelen elszámolás történt ügyfelünk számláján 2021. november 11-én. A panaszkezelési osztály által küldött összeg nem volt alkalmas a robot általi feldolgozásra, mert a hitel devizája nem egyezett meg a számla devizájával. Ezért le kellett volna venni a listáról. Azonban a felelős kolléga ezt figyelmen kívül hagyta, aminek eredményeként 10 772 EUR-t írtak jóvá 10 772 HUF helyett az ügyfél számláján. Kijavítottuk a hibát, megterheltük az ügyfelet a helyes összeggel, és jóváírtuk az 10 772 Ft-nak megfelelő összegét EUR-ban.	A Takarnet (Földhivatal) rendszeréből kapott ingatlan igazolások díjainak elengedése: 42 hiteles ingatlanigazolást kértek duplikáltan (mind manuálisan, mind a robot által).	A közös kérelmező kedvezményezettje nem volt megadva a szerződésben. A hibát az ingatlanellenőrzés hiányos kitöltése okozta a robot által végzett automatizált folyamat során. Az emberi felügyelet hiánya miatt az ingatlanellenőrzés során helytelenül rögzítették az információkat, és a robot ezt az adatot használta a szerződéskészítés során. Ennek eredményeként új közjegyzői okiratot kellett készíteni, és a bank fedezte a kapcsolódó díjakat.
Az esemény oka	Ember	Ember	Ember
Az esemény dátuma	11/11/2021/11/11	2019/11/06	2020/09/25
Taxonómiai besorolás	Végrehajtás, Kiszállítás és Folyamatmenedzsment / Tranzakció rögzítés, végrehajtás és karbantartás	Végrehajtás, Kiszállítás és Folyamatmenedzsment / Ügyfélbevonás és dokumentáció	Végrehajtás, Kiszállítás és Folyamatmenedzsment /
Teljes veszteség	3933396 HUF	189000 (HUF)	51100 (HUF)
Teljes megtérülés	3933396 HUF	0 (HUF)	0 (HUF)
Kapcsolódó kockázat	Nincs	Egyéb kockázatok (reputációs, stratégiai kockázatok)	Üzleti működési kockázat és egyéb (stratégiai, reputációs) kockázatok
Veszteségeket viselő üzletág	Kereskedelmi banki tevékenységek (100%)	Lakossági banki tevékenységek (100%)	Lakossági banki tevékenységek (100%)
Veszteség típusa	Leírás	Leírás	Kompenzáció
Biztosítva volt?	Nem	Nem	Nem

Forrás: Saját forrás

20. táblázat: A HunOR adatbázisban fellelt robot-incidensek potenciális részletezési lehetősége

Jellemző	#1	#2	#3
Robot mögöttes technológia	Nem részletezett	Nem részletezett	Nem részletezett
Azonosított felhasználási lehetőség (use case)	Teljes autonómia a feldolgozási feladatokban	Teljes autonómia az adatok lekérdezésében a külső adatbázisból	Teljes autonómia a feldolgozási feladatokban
Robot autonómia	Teljes autonómia a feldolgozási feladatokban	Teljes autonómia az adatok lekérdezésében a külső adatbázisból	Teljes autonómia a feldolgozási feladatokban
Felügyeleti mechanizmus	HOOTL	HITL	HOOTL
Humán munkavállaló feladata	Az adatok ellenőrzése és előkészítése a robot számára, beleértve a tranzakciók validálását és előkészítését (teljes autonómia)	Tulajdoni lapok ellenőrzése és hitelesítése és/vagy azok kérése (a földhivatali rendszerből), ha azt a robot nem kérte	Ingatlan ellenőrzése (a robot által készített szerződés tartalmának ellenőrzése)

Forrás: Saját forrás

Az elemzett szakirodalom és a gyakorlatban végzett mélyinterjúk, illetve HunOR adatbázis elemzése alapján H2 hipotézist elfogadottnak tekintem. Vagyis a robot/AI-címkezés létező jelenség. A 'robot' és 'AI' univerzális szóhasználat mögött különböző technológiák állnak, amelyek eltérő felhasználási területeken és kockázati profilokkal bírnak a banki front, middle, és back office szektorokban. Ennek figyelembevétele szükséges tényezője a proaktív kockázatkezelési rendszerek működtetésének.

5.3.2.2. Mélyinterjú III. - Javaslatok

A robot/AI-incidensek kezelésének javítására az alábbiakban megfogalmazott javaslataimmal élek:

1. Robotok kockázati profiljának kidolgozása:

- a) Robotok kockázati profiljának katalógusa: Írjuk le a robotok kockázati profiljához kapcsolódó attribútumokat: alkalmazott technológia, technológiai infrastruktúra (és rendszerintegráció), funkcionalitás, adatkezelés, küszöbértékek, kulcs teljesítménymutatók (pontosság, megbízhatóság), irányítási mechanizmus, megfelelőségi követelmények, etikai aggályok stb. a potenciális, előre nem látható kockázati események azonosítása érdekében.
 - i. Ez a teljes életciklust le kell, hogy fedje: kezdve a biztonsági kérdésektől, a technikai integráción, a folyamat-újratervezésen át a karbantartásig.

- ii. Rendszeresen frissíteni kell, és tartalmaznia kell a banknál alkalmazott összes robot kockázati profilját.
- iii. Bővítsék a működési kockázati adatok gyűjtésére szolgáló szótárakat az IT osztály segítségével, hogy azonosítsák a legfejlettebb technológiákkal kapcsolatos kulcsszavakat.

2. Robotok autonómiai szintje és felügyeleti mechanizmus:

- b) Hozzanak létre és tartsanak fenn egy ember-robot munkamegosztási katalógust, hogy jobban megértsék a robotok autonómiájából fakadó potenciális és előre nem látható kockázatokat.
- c) Azonosítsák az egyes üzleti egységek munkafolyamataiban a robotokhoz rendelt feladatokat és ezek autonómiai szintjeit.
 - iii. Azonosítsák azokat az eseteket, ahol a robot 100%-os autonómiával működik. Az emberi felügyelet hiánya ilyen alkalmazási területeken szűk keresztmetszetekhez vezethet.
- d) Azonosítsák az (a) pontban említett esetek felügyeleti mechanizmusát.
 - i. Azonosítsák azokat az osztályokat, amelyek felelősek a robot által végrehajtott feladatokért.
 - ii. Vezessenek be ellenőrzési pontokat a munkafolyamatok különböző szakaszaiban (kulcs teljesítménymutatók), hogy meghatározzák a várt teljesítmény benchmarkjait, és összehasonlítsák a robotok tényleges teljesítményét, ezáltal azonosítva az anomáliákat (pl. modellhibák, negatív visszacsatolási hurkok). Ez a megközelítés segíthet a robot hibáinak a munkafolyamat legkorábbi szakaszában történő felismerésében.
 - iii. A robotok által okozott teljes veszteséget osszák fel az ellenőrzésért és felügyeletért felelős alkalmazottak üzletági szerint.

3. **Robotok által okozott incidensek katalógusa:** Az AI rendszerek/robotok által okozott incidensekből tanulva, célravezető volna a tanulságokat incidens adatbázisban rögzítése.

4. **A működési kockázati adatbázisok modernizálása:** A robotok által okozott működési kockázati események száma várhatóan jelentősen növekedni fog a közeljövőben az AI fejlődésével. Következésképpen,:

- a) az AI/robotok okozta incidensek leírásának a lehető legrészletesebbnek szükséges lennie, hogy tudásbázisként szolgáljon a kockázati események helyes kezeléséhez

- b) fontolóra szükséges venni egy „robot flag” bevezetését a működési kockázati adatbázisban. Továbbá,
- c) biztosítani szükséges a robot-specifikus jellemzők mellett az esemény leírására szolgáló alapvető attribútumokat (állapot, dátumok, kapcsolódó kockázatok, érintett üzletágak stb.) nyomon követhetőséget.

5. **Munkavállalók képzése (AI kompetenciák építése):** Képzést szükséges biztosítani a működési kockázatkezelők számára a telepített szoftver/hardver robotokkal kapcsolatban.
6. **Szervezeti Robotikai Fórum:** Rendszeres robotika Fórumot szükséges létrehozni az IT, illetve a kockázatkezelő szakemberek részvételével, hogy elkerüljék az incidensek téves besorolását a képzés hiánya miatt, illetve megvitassák a technológia fejlődésének figyelembevétele mellett a kockázatkezelés jó gyakorlatát a bankon belül, továbbá átgondolják a kockázati eseménycategóriák és rögzített információ körét. Ez a fórum platformként szolgálhat az új technológiák és az ezzel kapcsolatos potenciális kockázati események megvitatására, valamint a robotok kockázati profiljának rendszeres frissítésére.

5.4. Bankrobotika területen alkalmazott robot/AI-címkézés vizsgálata

A bankrobotika terület lehatárolásának szükségességére, Továbbá, a robot/AI-címkézés jelenség létezésére vonatkozó hipotéziseim elfogadását követően, az elemzést a bankrobotika területen megvalósuló AI/robot-címkézés vizsgálatával folytatom. A témát az összes eszközték alapján a világ vezető bankjainak (top50 bank) szabadalmi adatain keresztül vizsgálom, az disszertáció harmadik témájához tartozó kutatási kérdéseken és hozzájuk tartozó hipotézisek révén:

- **K3:** Milyen főbb felhasználási lehetőségei vannak a bankrobotika technológiáknak a banki front/middle/back office területeken?
- **H3:** A feldolgozott szakirodalmak alapján a főbb alkalmazási területek a Sales, marketing, portfólió-és vagyongazdálkodás, hitelezési tevékenység, AML, CFT, csalásmegelőzés terület igényei által meghatározottak, amelyeket az irodalmi összefoglaló táblázatokban is szerepeltetek.
- **K4:** A bankrobotika technológiák mennyire kerülnek együttesen használatra?

- **H4:** Az alkalmazott bankrobotika technológiák önállóan, de más technológiákkal együttesen is jelentős mértékben kerülnek alkalmazásra, igazodva a terület specifikusan megfogalmazott üzleti célokhoz.
- **K5:** Az AI-címkézés tekintetében mi jellemző a bankrobotika technológiák fedésére? Jellemzően mit takarnak ezek az AI-címkék?
- **H5:** A bankrobotika technológiákat érintően (AI és kapcsolódó technológiák a banki front, middle, back office területeken) a robot-és AI-címkézés jellemzően az alábbi technológiák esetében kerül alkalmazásra: ML, NLP, gépi látás, intelligens chatbotok, intelligens robotok.

Az elemzés keretében előbb a bankrobotika kulcsszólista segítségével összeállítom a Google Patent Public adatbázis alapján a saját adatbázisomat (Top50Bank_Patents.xlsx), amelyet a Google Collaboratory környezetben Python kódok segítségével elemzek a szavak vektorizálásán keresztül, K-közép algoritmus segítségével. A klaszterezési eljárás esetén a hasonlóság mérésére Davies-Bouldin indexet alkalmazok. A szabadalmi adatok címkézése során a bankrobotika kulcsszólistám alapján manuális címkézéssel élek, amely listát tovább bővítek a vizsgálódás eredményeképpen. A címkézést végül gépi címkézéssel egészítem ki a szabadalmak mögött rejlő technológiák felhasználási területének azonosítása érdekében a szabadalmak címének vektorizációján (NLP) és K-közép algoritmus (ML) révén történő csoportosításán keresztül.

Az elemzés során alkalmazott programozási nyelv a Python 3, az alkalmazott hardveres gyorsítás: CPU. Az elemzett minta nagysága 4409 szabadalmi rekord.

Az elemzés korlátját a szabadalmi adatok elérhetősége, nyelvi akadályok (bővebben az elemzési résznél kerül részletezésre) jelentik.

Az adatbázis és az alkalmazott módszertan egyediségét az adja, hogy a szakirodalom alapos áttekintése során nem találtam a banki területen alkalmazott AI és kapcsolódó innovatív technológiák szabadalmi elemzését szolgáló publikációt és ehhez tartozó módszertani leírást, valamint statisztikai modellt. Így két feladat állt előttem, egyrészt a kutatási célkitűzéseimet kiszolgáló egyedi adatbázis összeállítása az elérhető szabadalmi adatok alapján, másrészt az ezt támogató statisztikai módszertan implementálása a banki területet érintő AI és kapcsolódó technológiai szabadalmak vizsgálatához.

5.4.1. Az AI szabadalmak világszintű növekedése

A szabadalmi adatok kulcsfontosságú mutatói az egyes országok, régiók, vállalatok, egyéb intézmények innovációs teljesítménynek (OECD, 2019). A bejegyzett szabadalmak vizsgálata jó kiindulópont a bankszektor átalakulásának megértéséhez (Lisset – Cano-Kollmann – Álvarez, 2020; OECD, 2019), mivel a szabadalmak a világ technológiai innovációinak jelentős részét lefedik és ezáltal hatékony kiindulópontot biztosítanak a modern technológiák gyakorlati megvalósulásának méréséhez. De mi is a szabadalom?

A szabadalom olyan jogi védelmet biztosító dokumentum, amely sztenderd formátumú információt tartalmaz a szabadalmaztatni kívánt technológiára vonatkozóan. A szabadalmaztathatóság főbb feltételeit a 19. számú melléklet, míg a szabadalmi kérelmek főbb elemeit a 20. számú melléklet tartalmazza. Az adott szabadalom linkjén információt kaphatunk a szabadalomról, a támogató ábrázolásokról, a CPC kódséma alapján a szabadalomhoz rendelt kódokról, a szabadalom egyedi kódjáról, a szabadalmi bejegyzés helyéről, a feltalálóról, a felhasználásra jogosult személyről/szervezetről, a szabadalomhoz tartozó kiemelt dátumokról, illetve a szabadalom státuszáról (aktív, függőben lévő, visszavont, elutasított). Amennyiben bővebb információra is szükségünk van, a teljes szabadalmi dokumentum megnyitásával bővebb információ tárul elénk a feltaláló nemzetiségére, a bejegyzés helye szerinti országra vonatkozóan, ovábbá részletes szabadalmi leírást kapunk (24. ábra).

24. ábra: Szabadalmi minta a Google Patent adatbázisából

Szabadalom rövid leírása

Szabadalmi leírás megértését támogató ábrázolás

CPC séma alapú hozzárendelt kódok

Google Patents

Employing machine learning and artificial intelligence to generate user profiles based on user interface interactions

Abstract

A computing platform having at least one processor, a memory, and a communication interface may receive, via the communication interface from a content management system, a first content stream containing bibliographic information and account information for a plurality of clients. A persona profile is assigned to each client, based on the bibliographic information and account information, from a plurality of predetermined persona profiles. A first set of user interface instructions is generated based on the assigned persona profile for each client and transmitted to respective remote client devices via the communication interface. A second content stream containing data of user interface interactions for the plurality of clients is received via the communication interface from an enterprise tagging server. Based on a machine learning dataset, a modified and personalized set of user interface instructions is generated and transmitted to the respective remote client devices via the communication interface.

Images (23)

Classifications

- G06N99/005
- G06F16/168 Details of user interfaces specifically adapted to file systems, e.g. browsing and visualisation, 2d or 3d GUIs
- G06F16/23 Updating
- G06F16/906 Clustering; Classification
- G06F17/30002
- G06F3/0481 Interaction techniques based on graphical user interfaces [GUI] based on specific properties of the displayed interaction object or a metaphor-based environment, e.g. interaction with desktop elements like windows or icons, or assisted by a cursor's changing behaviour or appearance
- G06N20/00 Machine learning
- G06N5/048 Fuzzy inferencing
- G06Q40/06 Asset management; Financial planning or analysis

Hide more classifications

US20180349793A1
United States

Download PDF Find Prior Art Similar

Inventor: Cory Triolo, Steven Lucas, Patrick W. Higgins, Jeffrey J. Dansereau
Current Assignee: Bank of America Corp

Worldwide applications
2017 [US](#)

Application US15/610,701 events ⓘ

- 2017-06-01 • Application filed by Bank of America Corp
- 2017-06-01 • Priority to US15/610,701
- 2017-06-01 • Assigned to BANK OF AMERICA CORPORATION ⓘ
- 2018-12-06 • Publication of US20180349793A1

Status: Abandoned

Info: Patent citations (5), Cited by (5), Legal events, Similar documents, Priority and Related Applications

External links: USPTO, USPTO PatentCenter, USPTO Assignment, Espacenet, Global Dossier, Discuss

Szabadalom kódja,
Szabadalmi bejegyzés helye
Teljes szabadalmi dokumentum

Feltaláló(k)
Felhasználási jogosultsággal
rendelkező természetes/nem
természetes személy

Szabadalomhoz tartozó
kiemelt dátumok

Státusz információ

Forrás: Saját ábra

5.4.2. Modell választás a szabadalmi adatok elemzéséhez

A szabadalmak elemzése a technológiák elemzése keresztül fontos input információ forrása lehet a vállalatok kutatás és fejlesztési tevékenységének tervezéséhez (Park – Jun, 2020). Mivel a szabadalmi dokumentumok rendkívül részletezettek és komplex képet szolgáltatnak az adott technológiáról, így a természetes nyelvfeldolgozási technológia a szabadalmi adatelemzés kiemelt elemző eszköze (Park – Jun, 2020). A szabadalmi adatok szövegbányászaton alapuló elemzése a felemelkedőben lévő technológiák azonosításában is kiemelt szereppel bír (Kim et al, 2019).

A szakirodalmi elemzés jellemzően az NLP technológia segítségével végrehajtható kulcsszavak kinyerésére és ML modell révén történő elemzésére koncentrál (Kim et al., 2019; Park – Jun, 2020; Yoo – Lim – Kim, 2021). Yoo és szerzőtársai a szabadalmak automatikus osztályba sorolását végzik el a kulcsszavak kinyerését követően (Yoo – Lim – Kim, 2021). A szerzők egy természetes nyelvfeldolgozási mélytanulási modellt, a BERT-et, és a vektorteres modellt javasol az AI-al kapcsolatos szabadalmi adatok elemzésére. Az alábbiakban ennek megfelelően én is ezt az eljárást fogom alkalmazni a bankrobotika technológiák címkéséhez (Yoo – Lim – Kim, 2021). A szerzők tanulmánya alapján a szabadalmakból való kulcsszavak kinyeréséhez a K-means modellt választottam. Eredményeként azonosítani fogom a fontos kulcsszavakat, az alkalmazott bankrobotika technológiákat, illetve a terjedőben lévő technológiákat.

Az elemzésem során az NLP és ML kombinációján alapuló modellt egy előre címkézett adatbázison futtatom meg. A kulcsszavak listájának összeállítását az alábbiakban részletesebben is kifejtem.

5.4.3. Az adatbázis: Google Patent Public Database

A H3-H5 hipotézisek igazolására szekunder adatként a Google Patent keresőmotor által elérhető Google Patent Public adatbázist alkalmaztam. A kiválasztott bankokat az összes eszközérték alapján a világ top 50 legnagyobb bankja képezi, amelyek szabadalmi adatai alapján elkészítettem a Top50Bank_Patents.xlsx adatbázisomat. Futtatókörnyezetként a Google Collaboratory felületét alkalmazom, amelynek futtatókörnyezet típusa: Python 3, illetve az alkalmazott hardveres gyorsítás: CPU.

A Google Patent Public adatbázis alapján összeállítottam a saját kutatási témámat leginkább szolgáló adatállományt, amelyet az alábbiakban ismertetek.

5.4.4. A szűrt adatállomány bemutatása: Top50Bank_Patents.xlsx

Mivel a Google Patent teljes adatbázis eléréséhez és API-on keresztüli meghívására előfizetés hiányában nem volt lehetőségem, így az adatok hozzáféréseinek másik módját, a bankonkénti keresést alkalmaztam. A letöltött dokumentumok információ tartalma korlátozott, így az alábbiakra terjed ki: azonosító (ID); cím (title); szabadalom használatára jogosult (assignee); feltaláló (inventor/author); legkorábbi dátum, amelyre a szabadalmi kérelem hivatkozást tehet (priority date); benyújtás dátuma (filing/creation date); közzététel dátuma (publication date); szabadalmi jogosultság megállapításának dátuma (grant date); szabadalomra hivatkozó link (result link); reprezentatív ábra(k) hivatkozása (representative figure link).

A kiválasztott bankokhoz tartozó csv. file-ok letöltését követően elkészítettem saját adatbázisomat. A leggyűjtött banki adatok alapján összeállítottam a Top50Bank_Patents.xlsx adatbázist. Az fentiek alapján előállított adatsémát a 21. táblázat tartalmazza. (A táblázatban a manuálisan hozzáadott mezők szürkével szerepelnek.)

21. táblázat: Top50Bank_Patents.xlsx adatbázis adatsémája

Adatok	Formátum	Adattípus	Leírás
Bank_Nev	szöveg	szöveg	A szabadalmat alkalmazó bank megnevezése.
Szabadalom_ID	szöveg	szöveg	A szabadalom egyedi ID-ja
Cim	szöveg	szöveg	A szabadalom rövid, tömör címe a technológia megjelölésével
Jogosult	szöveg	szöveg	A szabadalom használatra jogosultjának neve
Feltalalo	szöveg	szöveg	Feltaláló(k)
application date	mm/dd/yy	dátum	az a dátum, amikor egy szabadalmi kérelem hivatalosan benyújtásra került a szabadalomértékelő hatóságnál
priority date	mm/dd/yy	dátum	A legkorábbi dátum, amelyre a szabadalmi kérelem hivatkozhat
filing date	mm/dd/yy	dátum	a szabadalmi kérelem hivatalos benyújtásának dátuma a szükséges formula kitöltésével
publication date	mm/dd/yy	dátum	a szabadalmi kérelem nyilvánosságra hozatalának dátumát jelöli, amikor a kérelem nyilvánosan hozzáférhetővé vált a nagyközönség számára.
grant date	mm/dd/yy	dátum	a szabadalom hivatalos jóváhagyásának dátuma, amikortól hivatalosan szabadalmi jogvédelemmel rendelkező szabadalomná vált a kérelem.
Manuálisan bővített adatok			
label_fokategoria	szöveg	kategorikus	19 bankrobotika címke (manuális címkézés)
label_alkategoria	szöveg	kategorikus	36 bankrobotika címke (manuális címkézés)

Forrás: Saját táblázat

Kezdő lépésként ellenőriztem a rendelkezésre álló adatok körét, és a szabadalmi adatok linkjének megnyitásával manuálisan feltöltöttem a hiányzó dátum mezőket, illetve egységesítettem ezen mezők formátumát.

5.4.5. Limitáció és az elemzéshez rendelkezésre álló adatmennyiség

Az adatgyűjtés főleg a kínai bankok esetében nyelvi korlátokba ütközött. Ezt követően megpróbáltam a szűrést a bankok adott anyanyelvű honlapján található írásjelekre történő szűréssel, ám ez sem vezetett eredményre a speciális karakterek excel kezelés révén. Következésképpen, az eredetileg tervezett top 50-es mintából 28. bankra sikerült a sikeres szűrés révén szabadalmi adatokhoz hozzáférnem, míg ez 22 bank esetében meghiúsult, amiből 13 bank kínai bejegyzésű. A próbálkozások kiterjesztéseképpen a szabadalmak kódja alapján is megpróbáltam visszakeresni a bank nevét a szabadalmak linkje segítségével. Így sikerült azonosítanom az angol elnevezéssel illetett bankot az adatbázisban lévő szabadalmi kódhoz (ennek igazolására szolgál a 21. számú mellékletben elhelyezett szabadalmi kóddal felcímkézett kínai nyelvű szabadalmi dokumentum). Ugyanakkor ez a módszer rendkívül időigényesnek bizonyult, Továbbá, nem garantálta az adott bankhoz tartozó valamennyi szabadalom megtalálását. Ezen problémák mérlegelését követően arra a következtetésre jutottam, hogy a torzítási hatás (egy kínai bank esetében alulazonosított szabadalmak száma) elkerülése céljából kihagyom ezen bankokat az elemzésből. Következésképpen, az elemzésbe 28. bank került bevonásra, amelyek mindegyike esetében sikeres volt a szűrés, és angol nyelvre lefordított szabadalmi dokumentumok álltak rendelkezésre (22. táblázat).

22. táblázat: A top50 bank szabadalmi adatainak rendelkezésre állása

Rangsor 2022	Rangsor 2021	Rangsor változás	Bank	Szkhely_ország	Összes eszköz (US\$ milliárd)	Szabadalom	Szabadalmak száma
1	1	nincs	Industrial and Commercial Bank of China Ltd.	Kína	5,742.86	nincs	-
2	2	nincs	China Construction Bank Corp.	Kína	5,016.81	nincs	-
3	3	nincs	Agricultural Bank of China Ltd.	Kína	4,919.03	nincs	-
4	4	nincs	Bank of China Ltd.	Kína	4,192.12	nincs	-
5	5	nincs	JPMorgan Chase & Co.	U.S.	3,665.74	nincs	-
6	7	▲	Bank of America Corp.	U.S.	3,051.38	van	1387
7	6	▼	Mitsubishi UFJ Financial Group Inc.	Japán	2,967.91	van	9
8	8	nincs	HSBC Holdings PLC	U.K.	2,864.59	van	38
9	9	nincs	BNP Paribas SA	Franciaország	2,849.61	van	12
10	10	nincs	Crédit Agricole Group	Franciaország	2,542.61	van	3
11	11	nincs	Citigroup Inc.	U.S.	2,416.68	van	49
12	14	▲	Postal Savings Bank of China Co. Ltd.	Kína	2,039.56	nincs	-
13	12	▲	Sumitomo Mitsui Financial Group Inc.	Japán	2,006.75	nincs	-
14	15	▲	Mizuho Financial Group Inc.	Japán	1,909.35	nincs	-
15	18	▲	Bank of Communications Co. Ltd.	Kína	1,883.72	nincs	-
16	16	nincs	Wells Fargo & Co.	U.S.	1,881.02	van	768
17	19	▲	Banco Santander SA	Spanyolország	1,853.86	van	4
18	17	▼	Barclays PLC	U.K.	1,823.84	van	231
19	13	▼	Japan Post Bank Co. Ltd.	Japán	1,719.92	van	93
20	34	▲	UBS Group AG	Svájc	1,679.36	van	148
21	20	▼	Groupe BPCE	Franciaország	1,636.35	van	1
22	21	▼	Société Générale SA	Franciaország	1,588.99	nincs	-
23	26	▲	Royal Bank of Canada	Kanada	1,544.17	van	261
24	23	▼	The Toronto-Dominion Bank	Kanada	1,524.83	van	875
25	25	nincs	China Merchants Bank Co. Ltd.	Kína	1,470.00	nincs	-
26	24	▼	Goldman Sachs Group Inc.	U.S.	1,441.80	van	148

27	22	▼	Deutsche Bank AG	Németország	1,428.65	van	2
28	27	▼	Industrial Bank Co. Ltd.	Kína	1,343.54	nincs	-
29	28	▼	China Citic Bank Corp. Ltd.	Kína	1,239.28	nincs	-
30	29	▼	Shanghai Pudong Development Bank Co. Ltd.	Kína	1,184.28	nincs	-
31	33	▲	Morgan Stanley	U.S.	1,180.23	van	223
32	30	▼	Crédit Mutuel Group	Franciaország	1,180.22	nincs	-
33	32	▼	Lloyds Banking Group PLC	U.K.	1,057.69	van	5
34	35	▲	China Minsheng Banking Corp. Ltd.	Kína	1,051.97	nincs	-
35	31	▼	Intesa Sanpaolo SpA	Olaszország	1,042.73	van	7
36	36	NC	ING Group NV	Hollandia	1,034.32	nincs	-
37	39	▲	The Bank of Nova Scotia	Kanada	1,029.80	van	5
38	38	NC	UniCredit SpA	Olaszország	916.72	van	9
39	40	▲	China Everbright Bank Co. Ltd.	Kína	913.49	nincs	-
40	37	▼	NatWest Group PLC	U.K.	867.59	nincs	-
41	42	▲	Bank of Montreal	Kanada	859.05	van	42
42	44	▲	Commonwealth Bank of Australia	Ausztrália	837.21	van	34
43	46	▲	Standard Chartered PLC	U.K.	819.92	van	6
44	43	▼	La Banque Postale SA	Franciaország	796.88	nincs	-
45	48	▲	Ping An Bank Co. Ltd.	Kína	771.55	nincs	-
46	47	▲	Banco Bilbao Vizcaya Argentaria SA	Spanyolország	762.15	van	32
47	41	▼	The Norinchukin Bank	Japán	753.26	van	2
48	53	▲	State Bank of India	India	694.94	van	1
49	55	▲	Canadian Imperial Bank of Commerce	Kanada	691.31	van	13
50	56	▲	National Australia Bank Ltd.	Ausztrália	679.76	nincs	-
					Összesen:	28 bank	1023

Forrás: Saját táblázat

Az összes eszközérték alapján a világ vezető (top50) bankjaira vonatkozó szabadalmi adatokat bankonként manuálisan töltöttem le csv. formátumban a Google Patent publikusan elérhető adatbázisából. Az adatgyűjtés eredményeképpen 4409 adat állt rendelkezésemre az elemzéshez. A szabadalmi adatokon belül az elsődleges kulcsszavas kereséssel 1023 bankrobotikához tartozó szabadalmat azonosítottam 22 bankra vonatkozóan.

5.4.6. A bankrobotika szabadalmak manuális címkézése

A bankokhoz tartozó adatok Top50Bank_Patents.xlsx dokumentumba integrálását követően a bankrobotika szabadalmi portfólió kialakításához manuális kulcsszavas címkézést végeztem a szabadalmak címe alapján. A feldolgozott szakirodalmak alapján előre meghatározott kulcsszó lista (artificial intelligence, machine learning, neural network, chatbot, computer vision, natural language processing, blockchain, Application programming interface, cloud, virtual reality, sensor, optical character recognition, privacy enhancing technology, distributed ledger, deep learning, robot, process automation, virtual agent, virtual-advisor, softbot) alacsony elemszámot eredményezett (449), így a kulcsszavakat a szabadalmak áttekintését követően tovább bővítettem.

Az alkalmazott kulcsszavak bővítésével a szabadalmak szűréséhez alkalmazott kulcsszavak száma 36 lett, így a szabadalmak száma $n=1023$. A kulcsszavak a szabadalmak alkategória címkéinek bizonyulnak: artificial intelligence, natural language (processing), machine learning, blockchain, API, neural network, Deep learning, Decision tree, intelligent agent, augmented reality, distributed ledger, cloud, robot, robotic process automation, chatbot, virtual assistant, optical sensor, optical character recognition, virtual reality, biometric, voice assistant, payment, cybersecurity, image processing, internet of things, recommendation, predict, pattern, cognitive, facial recognition, anomaly detection, cryptocurrency, Quantum computing, secure access, storage, transaction, data transfer, tokenization, encryption, Smart systems and methods, masking. Utóbbi kulcsszavakat alkalmaztam az NLP-t (szavak vektorizációja) és ML-t (K-közép) kombináló modell során.

A kulcsszavak bővítésével a szabadalmak szűréséhez alkalmazott kulcsszavak száma a kezdeti 20-ról 36-ra nőtt, így az azonosított bankrobotika technológiákhoz köthető szabadalmak száma magasabb elemszámot eredményezett, $n=1023$. A bővített kulcsszólista a 28 bankból 22 bank esetében eredményezett találatot szabadalmi adatok között.

A szűrést a kulcsszavak töredékére (például natural language, privacy) is elvégeztem, annak érdekében, hogy a keresés sikeres legyen. A manuális kulcsszavas szűrések eredményeképpen előállt a bankrobotika szabadalmi portfólió (23. táblázat), amely a címkézés révén 1023 bankrobotika szabadalmat tartalmaz a vizsgált bankok szabadalmi portfóliójának keretében (n=4409), vagyis a teljes minta 23%-át teszi ki.

23. táblázat: Bankrobotika szabadalmi portfóliók mérete

Bank	Székely_ország	Bankrobotika portfólió	Bankrobotika szabadalmak száma
Bank of America Corp.	U.S.	van	474
Mitsubishi UFJ Financial Group Inc.	Japán	van	1
HSBC Holdings PLC	U.K.	van	3
BNP Paribas SA	Franciaország	van	2
Crédit Agricole Group	Franciaország	van	3
Citigroup Inc.	U.S.	van	5
Wells Fargo & Co.	U.S.	van	200
Barclays PLC	U.K.	van	41
Japan Post Bank Co. Ltd.	Japán	van	5
UBS Group AG	Svájc	van	7
Groupe BPCE	Franciaország	van	1
Royal Bank of Canada	Kanada	van	75
The Toronto-Dominion Bank	Kanada	van	132
Goldman Sachs Group Inc.	U.S.	van	24
Morgan Stanley	U.S.	van	13
Lloyds Banking Group PLC	U.K.	van	1
Intesa Sanpaolo SpA	Olaszország	van	4
The Bank of Nova Scotia	Kanada	van	1
UniCredit SpA	Olaszország	van	3
Bank of Montreal	Kanada	van	13
Commonwealth Bank of Australia	Ausztrália	van	11
Banco Bilbao Vizcaya Argentaria SA	Spanyolország	van	4
	Összesen:	22 bank	1023

Forrás: Saját táblázat

5.4.7. Az elemzési környezet bemutatása: Google Colaboratory

A kutatás során az adatok elemzéséhez a Google Colaboratory (továbbiakban: Colab) nevű felhőalapú adatelemzési környezetet használtam. A Colab lehetővé tette számomra, hogy hatékonyan feldolgozzam a kialakított adatbázisomat. Az interaktív Python kódok lehetőséget adtak számomra a rugalmas és dinamikus vizualizációk és statisztikai elemzések készítésére.

Az elemzés során „szabadalmak” kifejezéssel a bankok szabadalmi adataira vonatkozóan értem, vagyis a teljes elemszáma, míg a „bankrobotika szabadalmak” kifejezéssel jelölöm a bankrobotika technológiákra irányuló vizsgálódást.

Az adatok betöltését a pandas Python könyvtár segítségével lehet elvégezni. A pandas biztosítja a táblázatok kezelésének eszközeit (függvényeket is), valamint az ún. data frame-eket (táblázatok), amelyek keretében a Colab-ban megvalósíthat az adatelemzés.

Az alias a pandas nevű könyvtárra való hivatkozáskor rövidítésként a pd-t használja a továbbiakban. Az elemzési folyamat során kihasználtuk a Google Colab által biztosított beépített könyvtárakat és azok rövid leírását, valamint egyéb eszközöket a 22. számú melléklet tartalmazza.


5.4.8. Bankrobotika szabadalmi adatok elemzése

A kialakított Top50Bank_Patents.xlsx adatbázis adatstruktúráját a 23. számú melléklet illusztrálja.

5.4.8.1. Bankrobotika technológiák földrajzi eloszlása a minta alapján

A bankrobotika szabadalmak megoszlása az országok tükrében egyértelműen az amerikai székhellyel bíró bankok dominanciáját mutatja, amelynek háttérében valószínűleg a szabadalmaztatási kultúra és innováció iránti motiváló faktorok is szerepet játszanak. Ugyanakkor ennek elemzése jelen téma keretén kívül esik és a bankrobotika technológiák vizsgálata szempontjából irreleváns (25. ábra).

25. ábra: Bankrobotika szabadalmak megoszlása országonként



Forrás: Saját ábra

A szabadalmi adatok földrajzi megoszlása alapján az USA-ban székhellyel bíró bankok az összes szabadalom 70%-át teszik ki, amelyet a Kanadában székhellyel bíró bankok követnek 22%-os részesedéssel. Az európai térségben bejegyzett bankok esetében további vizsgálandó vonhat maga után a jövőben, hogy mi a mögöttes oka az alacsony volumenű szabadalmaztatási tevékenységnek. Japán, illetve Ausztrália esetében a mintában reprezentált bankok szabadalmaztatási tevékenysége szintén alacsony, szemben az amerikai, kanadai bankokéval.

5.4.8.2. A szabadalmak időbeli alakulása

A letöltött szabadalmi adatok 1926-ig visszamenőleg tartalmaznak adatot. Az elemzés eredménye alapján megállapítható, hogy három jelentős töréspont körvonalazódik az elemzett bankok szabadalmaztatási tevékenységének növekedésben: 1999-2000, 2010, valamint 2018, amikor jelentős növekedésnek indult a bankok rendelkezésére álló szabadalmaztatási tevékenysége. A szabadalmak időbeli alakulásának vizsgálatához alkalmazott Python kódot (Kód1, 24. számú melléklet) a mellékletben helyeztem el, a kapott eredményt a 26. ábrán ábrázolom.

26. ábra: A szabadalmak számának alakulása a vizsgált időszak alatt



Forrás: Saját ábra

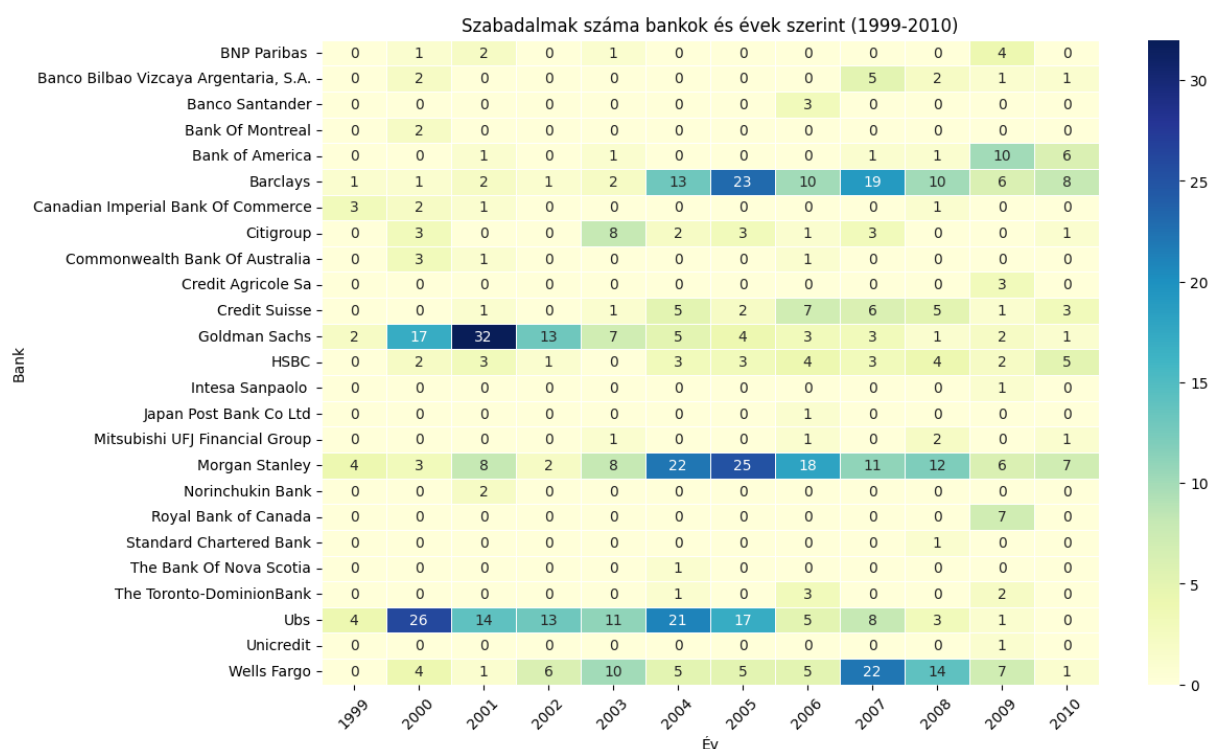
A szabadalmaztatási tevékenységben azonosított töréspontoknak megfelelően a banki szabadalmak bankonkénti megoszlását az egyes időszakokra hőtérkép segítségével ábrázolom 1999-2010-ig, 2010-től 2018-ig, valamint az azt követő időszakokra 2018-tól 2023-ig. Az

elemzéshez minden esetben a „priority” dátum került felhasználásra, hiszen ez a legkorábbi időpont, amelyre a szabadalom jogilag hivatkozhat. Az elemzéshez alkalmazott Python kódokat minden esetben a mellékletben helyeztem el, illetve az eredményeket az alábbiakban hőtésképen is ismertetem.

Szabadalmaztatási tevékenység alakulása 1999-2023 között

A kód lefutását (Kód2, 25. számú melléklet) követően kirajzolt hőtéskép alapján megállapítható, hogy az 1999 és 2010 közötti időszakban érintett bankok közül kiemelkedik a Barclays, a Goldman Sachs, a Morgan Stanley, az UBS, Citibank, HSBC, Credit Suisse, illetve a Wells Fargo. A Bank of America 2009-től kezdődően kezdi meg jelentős növekedését a szabadalmaztatási tevékenységben (27. ábra).

27. ábra: Szabadalmak száma bankonként 1999-2010 között

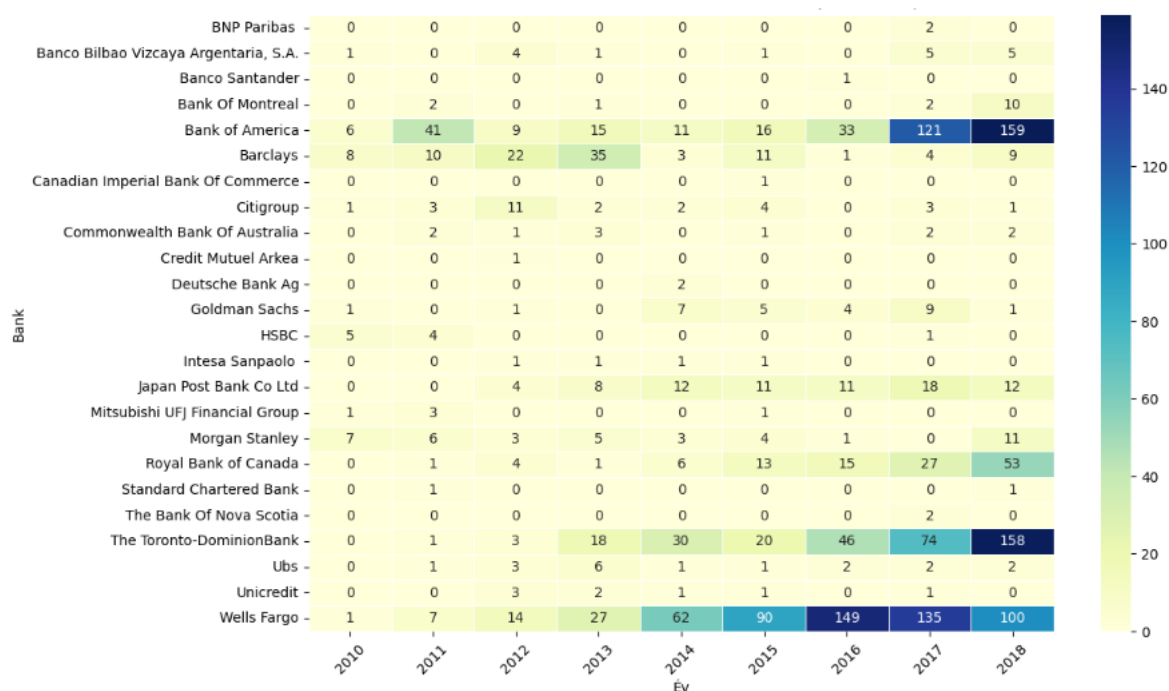


Forrás: Saját ábra

Szabadalmaztatási tevékenység alakulása 2010-2018 között

A kirajzolt hőtéskép alapján megállapítható, hogy 2010-től egy dinamikus növekedés vette kezdetét (26. számú melléklet, Kód3). Ugyanakkor a két hőtéskép alapjaiba véve eltérést mutat, mivel az 1999-2010-ig tartó időszakban a bankok szabadalmaztatási tevékenysége sokkal kiegyensúlyozottabb képet mutat, a piaci koncentráció kevésbé jellemző, míg 2010-től ez sokkal koncentráltabban jelenik meg (28. ábra).

28. ábra: Szabadalmak számának alakulása bankonként 2010-2018 között

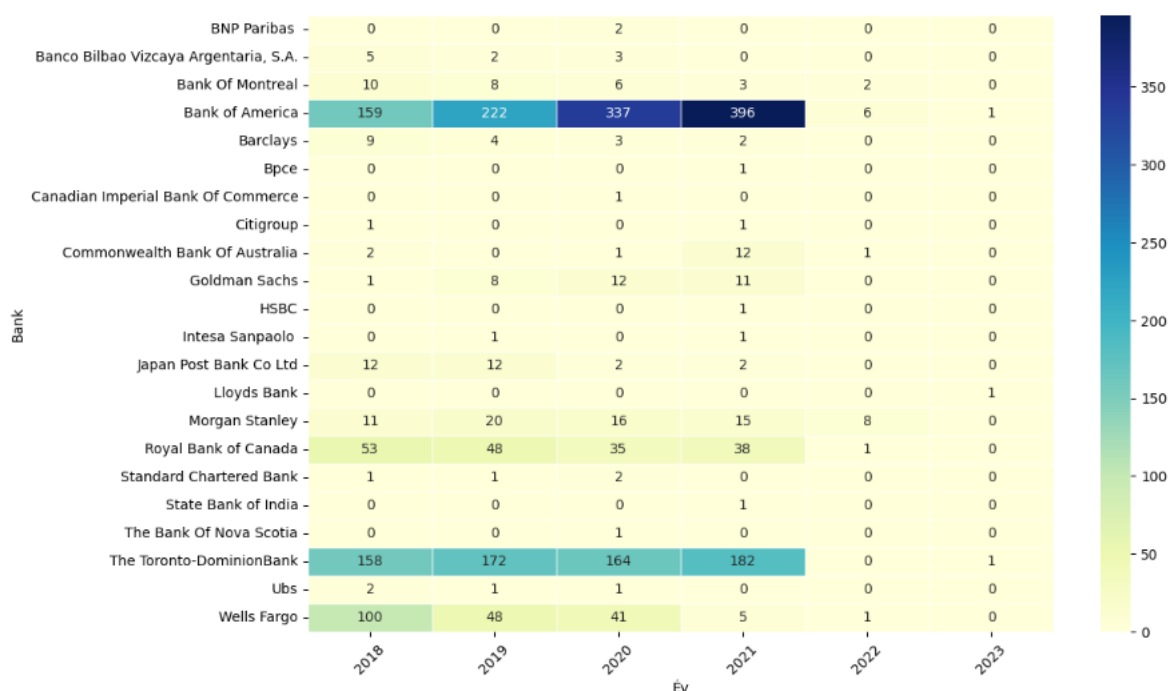


Forrás: Saját ábra

Szabadalmaztatási tevékenység 2018-2023 között

2018 és 2023 között a szabadalmaztatási tevékenység képe jelentős változásokat mutat az 1999-2010-es időszakhoz viszonyítva, hiszen alapvetően egy piaci koncentráció következik be. Ennek köszönhetően a szabadalmaztatási tevékenységet az elindított szabadalmaztatási folyamatok száma alapján már nem a korábbi bankok uralják, hanem a Bank of America, a The Toronto-Dominion Bank, illetve a Wells Fargo. E három bank közül az egyetlen, amelyik az 1999-2010-es időszakban is aktív szereplője volt a jelentős szabadalmaztatási tevékenységet produkáló bankok körének, az a Wells Fargo. Következésképpen, a Wells Fargo tekinthető a banki portfólióban az egyetlen olyan banknak, amely az 1999-es évektől egy folyamatos szabadalmaztatási tevékenységet végez, amelyet képes volt jelentősen növelni 2013-tól. 2013-hoz viszonyítva 2018-ig jelentős növekedést produkált, amely 2020-ig éves viszonylatban is növekedett. Ezt követően a szabadalmaztatási tevékenység az elért információ alapján alábbhagyott. Amint látni fogjuk a követő bankok felé vette az irányt, elszakadva a két piacvezetőtől, a Bank of America-tól, illetve a The Toronto-DominionBank-tól. Utóbbi kettő ugyanis egy dinamikus növekedést produkált 2016-tól kezdődően, amely napjainkban is töreltlen (27. számú melléklet, Kód4) (29. ábra).

29. ábra: Szabadalmak számának alakulása bankonként 2018-2023 között



Forrás: Saját ábra


A következő alfejezetben a bankrobotika szabadalmi portfólióra vonatkozó elemzést ismeretem. A bankrobotika szabadalmi portfóliók elemzése alatt, a kulcsszavas keresés eredményeképpen azonosított, bankrobotika technológiákra vonatkozó szabadalmak vizsgálatát értem.

5.4.9. A bankrobotika szabadalmi portfóliók alakulásának elemzése

5.4.9.1. A bankrobotika portfólió időbeli alakulása technológiánként

A bankrobotika technológiákat érintő szabadalmak időbeli megoszlásáról elmondható, hogy a bankrobotika technológiák esetében kivitelezett kulcsszavas szűrés eredményeképpen a legrégebben benyújtott szabadalom 1991-ig nyúlik vissza az időben a vizsgált bankok esetében (28. számú melléklet – Kód5). Hasonlóképpen az összesített szabadalmi portfólió időbeli alakulásához, a bankrobotika szabadalmak esetében is egyértelműen elkülöníthető a korábban is vizsgált három időszak: 1999-2010, 2010-2018, illetve 2018-napjainkig. Megjegyzendő, hogy a 2010-2018-as időszak esetében 2015 reprezentálja az évet, amelytől a szabadalmaztatási tevékenységben az ugrásszerű növekedés elindult. A bankrobotika szabadalmak esetében a 2015-ös év a bankrobotika technológiák adaptációjának egy fontos momentum, amelytől kezdődően a technológiai adaptáció jelentős mértékű növekedésen ment keresztül rövid idő alatt (30. ábra).


30. ábra: A bankrobotika szabadalmak számának alakulása a vizsgált időszak alatt



Forrás: Saját ábra

Az adatbázist 2013-2015 közötti időszakra szűrve megállapítható, hogy ezen változások legfőképpen a fizetési szolgáltatásokat és kapcsolódó titkosítási technológiákat (kriptográfia), a virtuális valóságot, az intelligens chatbotokat, a képfeldolgozást és az elosztott főkönyvi technológiát érintik, és ezek előretörésének kezdetét jelzik (29. számú melléklet, Kód6) (31. ábra).

31. ábra: Bankrobotika szabadalmak időbeli alakulása bankrobotika technológiáinként




Forrás: Saját forrás

Bankrobotika szabadalmi portfólió alakulása 1999 és 2010 között

A bankrobotika szabadalmak szofisztikált áttekintése érdekében elvégeztem a vizsgált időszak tört időszakokra vonatkozó vizsgálatát is. Az 1999-2010-es időszakra megállapítható, hogy a bankrobotika technológiákkal kapcsolatos bejegyzett szabadalmak a Barclays, a Goldman Sachs, a UBS, illetve a Wells Fargo kezében összpontosultak, míg a Bank of America a 2010-es időszakig két szabadalommal bírt e területen. A korábban vizsgált szabadalmi adatok megoszlása alapján (nem bankrobotika szabadalmak) alacsony a bankrobotika szabadalmak száma a szabadalmi portfólióban a Goldman Sachs, a Morgan Stanley, az UBS, Citibank, HSBC, Credit Suisse bankoknak. A kezdeti időszakban a bankrobotika technológiák terén a piaci versenyt a bejegyzett szabadalmak száma alapján a Wells Fargo vezeti, amelyet a Barclays és a Goldman Sachs, valamint a UBS követ (Kód7, 30. számú melléklet) (32. ábra).


32. ábra: Bankrobotika technológiák megoszlása 1999-2010 között



Forrás: Saját ábra

Az 1999-2010 közötti időszakban az alkalmazott technológiák közül kiemelkedik a fizetési szolgáltatások és a kapcsolódó kriptográfiai megoldások, valamint a képfeldolgozás és a gépi tanulás különböző banki folyamatokba integrálása, amelyeket a biztonságos megoldásokra irányuló fejlesztések kísérnek (Kód8, 31. számú melléklet) (33. ábra).

33. ábra: Bankrobotika szabadalmi portfólió alakulása 1999-2010




Forrás: Saját ábra

Bankrobotika szabadalmi portfólió alakulása 2010 és 2018 között

2010 - 2013 vízváltó időszak a bankrobotika szabadalmaztatási tevékenység kezdeti szakaszát illetően, amely során a korábban ilyen jellegű szabadalmakat birtokló bankok szabadalmaztatási tevékenysége vesztit növekedéséből, majd 2013-tól már csak éves szinten egy-két szabadalmat jegyeznek. Ugyanakkor itt kezdődik meg a virágzása és azóta is szakadatlan menetelése a Bank of America, illetve a The Toronto-DominionBank-nak, valamint a Wells Fargo felkapaszkodásának. Az innovációs hullámmal tartó bankok között található még – alacsony éves bankrobotika szabadalom számmal ugyan- a Royal Bank of Canada, a Barclays, valamint a Goldman Sachs (34. ábra). A versenyt e téren közel kétszer annyi szabadalommal, mint az őt követő Wells Fargo, a Bank of America vezeti, a the Toronto-Dominion Bank pedig jelentős növekedést kezd el produkálni 2014-től, növelve a felzárkózási képességét az előbbi két bankhoz (Kód9, 32. számú melléklet).

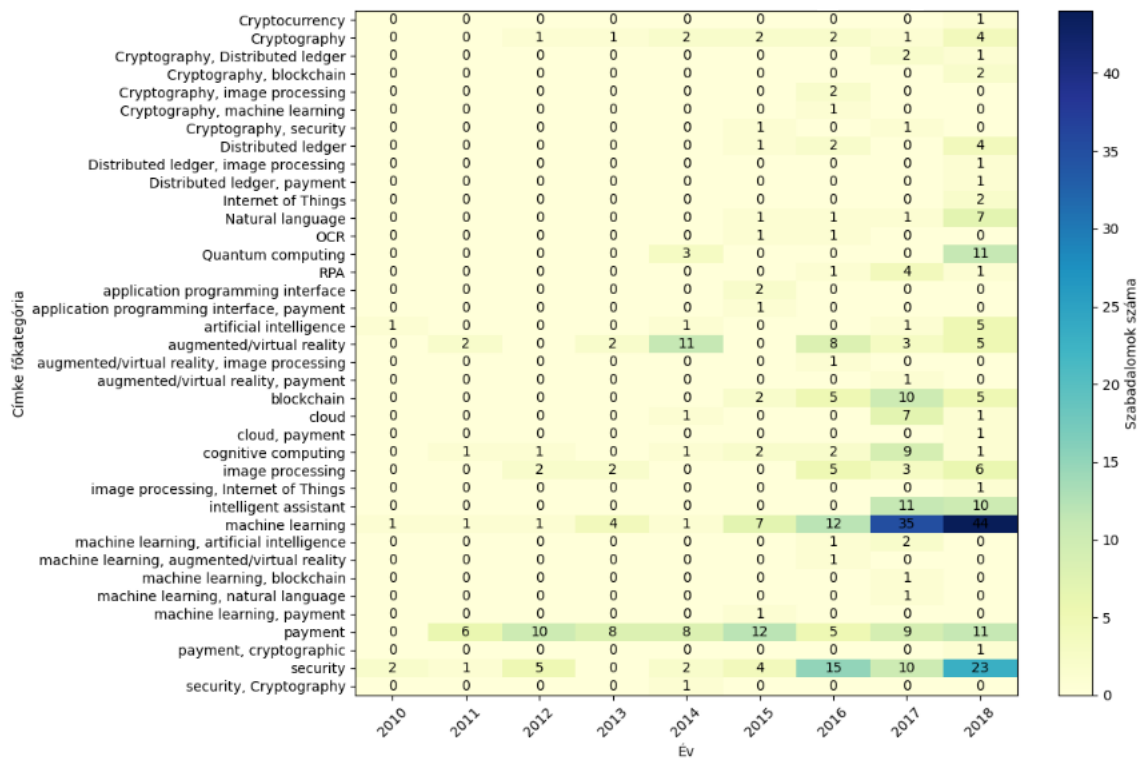
34. ábra: Bankrobotika technológiák megoszlása 2010 – 2018 között



Forrás: Saját ábra

A technológiai fókusz számú új területtel bővül, amelyek közül a gépi tanulás 2015-től, a blokklánc technológia 2017-től, illetve a természetes nyelvfeldolgozás és a kvantumszámítás-technológia területen beadott szabadalmak száma nő jelentősen 2018-tól, a korábban említett fizetési szolgáltatások, kapcsolódó biztonság megoldások, kriptográfia mellett (Kód10, 33. számú melléklet) (35. ábra).

35. ábra: Bankrobotika szabadalmi portfólió alakulása 2010-2018




Forrás: Saját ábra

Bankrobotika szabadalmi portfólió alakulása 2018 és 2023 között

2018-at követően átrendeződés figyelhető meg a bankrobotika szabadalmak tekintetében piacvezető bankok között. A Bank of America 2019-ről 2020-ra majdnem megduplázza egy év alatt a szabadalmainak számát. A Wells Fargo tevékenysége ennek ellentétéként közel megfeleződik ugyanezen időszakban, míg a The Toronto-Dominion Bank igyekszik egy kiegyensúlyozott, de hosszú távon 2018-hoz képest egy növekedési pályán tartani a bankrobotika szabadalmaztatási tevékenységét. A piacvezető és a követő bankok között jelentős szakadék kezd kialakulni. Míg a vezető bankok közül a leggyengébben teljesítő bankhoz, a Wells Fargohoz képest is, 2020-ban a követő bankok közül legmagasabb bankrobotika szabadalommal rendelkező The Royal Bank of Canada is közel 35%-kal van lemaradva. Ez a különbség még inkább szembevetendő a lemaradók csoportjához képest, akik éves szinten 1-2 jegyzett szabadalmat birtokolnak, bejegyzési helyüket tekintve Európai bankoknak minősülnek (36. ábra). Amint korábban említettem, jelent tanulmány részét nem képezni a mögöttes mozgatórugók feltárása. Ugyanakkor mindenképpen érdemes előirányozni az innováció menedzsment terület vizsgálódását a bankrobotika szabadalmi portfólió vonatkozásában, amennyiben meg szeretnénk érteni, hogy a tradicionális bankszektor szerelői milyen stratégia mentén alakulnak át a digitális transzformáció jegyében (Kód11, 34. számú melléklet).


36. ábra: Bankrobotika technológiák megoszlása 2018 – 2023 között



Forrás: Saját ábra

A szabadalmaztatási tevékenység alapján megállapítható, hogy 2018-tól növekedés áll be a mesterséges intelligencia, a természetes nyelvek feldolgozása, a kvantumszámítás, a kognitív számítástechnika, a kiterjesztett és virtuális valóság, a blokklánc technológia, a felhő-alapú megoldások tekintetében. Mindezeket jelentősen meghaladja a gépi tanulási modellek alkalmazása a banki folyamatokban. Párhuzamosan pedig tovább erősödik a fizetési szolgáltatásokat, a bankbiztonságot, illetve az ahhoz tartozó titkosítási, adatbiztonsági felhasználási területet érintő megoldások fejlesztése és szabadalmaztatása (37. ábra). A bankrobotika technológiák banküzemi folyamatokban betöltött szerepét az intelligens ügyintézők kapcsolják össze a fogyasztókkal, akik mind belső, mind külső ügyfeleket kiszolgálnak (35. számú melléklet, Kód12).

37. ábra: Bankrobotika szabadalmi portfólió alakulása 2018-2023



Forrás: Saját ábra

5.5. A bankrobotika technológiák közötti fedés

A bővített címkék alaposabb vizsgálata során észrevettem, hogy lehetőség van bizonyos technológia címkék összevonására. Ennek eredményeként 19. darab bankrobotika főcímkét, továbbá egy egyéb főcímkét, valamint 36 alcímkét hoztam létre (24. táblázat). A limitációt az adatbázis mérete és a címkézés szolgáltatja. Mivel az adatbázis angol nyelvű, így az alkalmazott kulcsszavakat az értekezés során szintén angol nyelven szerepeltetem.

24. táblázat: A vizsgált minta bankrobotika szabadalmi portfóliója

#	Bankrobotika címkék (alkategóriák)	Szabadalmak száma
1	Artificial Intelligence	64
2	Natural Language Processing	30
3	Machine Learning (ML, NN, DL, DT, recommendation, predict, pattern, anomaly detection)	342
4	Blockchain	42
5	API	14
6	Intelligent assistant (intelligent agent, chatbot, virtual assistant, voice assistant)	38
7	Augmented/virtual reality	47
8	Distributed ledger	27
9	Cloud	25
10	RPA (robotic process automation; robot)	16
11	OCR (optical sensor)	4
12	Image processing (image processing; facial recognition; biometric)	45
13	Payment	107
14	Security (cybersecurity; secure access, storage, transaction, data transfer)	113
15	Internet of Things	4
16	Cognitive computing (cognitive; smart systems, methods)	58
17	Cryptocurrency	2
18	Quantum computing	46
19	Cryptography (cryptography, tokenization; encryption; masking)	55
Többszörös fedés miatti kalkulált összes szabadalom		1079
<i>Fedés eltávolításával érintett szabadalmak száma összesen</i>		<i>1017</i>

Forrás: Saját táblázat

A fedési táblázatok átlójában lévő számok azt jelzik, hogy az adott technológia az összes találatból hány esetben kerül említésre önállóan. Míg az egyéb bankrobotika technológiákkal történő említés során az oszlopok és megfelelő sorok keresztezése szolgáltat információt arról, hogy az adott technológia jellemzően milyen egyéb technológiákkal szerepel együtt a szabadalmi címekben. A fedések esetében a cellák lila színűek, a cellán belül elhelyezett számok pedig a fedési számosságot hivatottak reprezentálni. A manuális címkézés eredményeképpen azonosított átfedést az egyes technológiák között a 38. ábra szemlélteti 36 alkategória alapján, illetve a 39. ábra, 19 főkategória mentén.

38. ábra: A bankrobotika technológiák fedési táblázata a minta alapján (n=1023; 36 bankrobotika címke)

	AI	NLP	ML	Blockchain	API	NN	DL	Intelligent agent	augmented reality	distributed ledger	cloud	robot	RPA	chatbot, virtual assistant	OCR, opt. sensor	virtual reality	biometric	voice assistant	payment	cybersecurity	image processing	IoT	recommendation	predict	pattern	cognitive	facial recognition	anomaly detection	cryptocurrency	Quantum computing	secure	tokenization	encryption	smart eye_meth.	masking	Cryptography	Total	áttekintés	áttekintés %						
AI	40																																				64	15	23						
NLP	2	27																																				30	3	10					
ML	2	1	145																																			108	23	16					
Blockchain	4	0	1	37																																		42	5	12					
API	0	0	0	0	12																																	14	2	14					
NN	2	2	2	0	0	20																																27	7	26					
DL	0	0	0	0	0	0	5																															8	3	38					
Intelligent agent	0	0	0	0	0	0	0	10																															10	0	0				
augmented reality	0	0	0	0	0	0	0	0	40																														42	2	5				
distributed ledger	0	0	1	0	0	0	0	0	0	24																													27	3	11				
cloud	0	0	1	0	0	0	0	0	0	0	22																												25	3	12				
robot	0	0	0	0	0	0	0	0	0	0	0	3																											3	0	0				
RPA	1	0	0	0	0	1	0	0	0	0	0	0	11																										13	2	15				
chatbot, virtual assistant	0	0	0	0	0	0	0	0	0	0	0	0	0	19																										20	1	5			
OCR, opt. sensor	0	0	0	0	0	1	0	0	0	0	0	0	0	0	3																									4	1	25			
virtual reality	0	0	0	0	0	0	1	0	1	0	0	0	0	0	0	2																								6	4	67			
biometric	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	1	27																						33	6	18				
voice assistant	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	8																					8	0	0				
payment	0	0	0	0	1	0	0	0	1	1	2	0	0	0	0	0	0	0	102																					110	8	7			
cybersecurity	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	6																			7	1	14				
image processing	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	9																			9	0	0				
IoT	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	3																		4	1	25			
recommendation	1	0	2	0	0	0	0	0	0	0	0	0	0	0	0	1	0	1	0	0	0	24																		31	7	23			
predict	0	0	9	0	1	0	0	0	0	0	0	0	0	0	0	1	1	0	0	0	0	2	99																	83	14	17			
pattern	2	0	4	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	19																26	7	27			
cognitive	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	21															23	2	9			
facial recognition	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	2														4	2	50			
anomaly detection	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	19													20	1	5			
cryptocurrency	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2												2	0	0			
Quantum computing	1	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0			46		46	2	4		
secure	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0			102		102	5	5	
tokenization	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	2	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0					11	7	64	
encryption	1	0	0	2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0					20	6	30	
smart eye_meth.	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0					35	0	0	
masking	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0					2	0	0
Cryptography	0	0	1	0	0	0	0	0	0	6	0	0	0	3	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0					12	25	13	52

Forrás: Saját ábra

39. ábra: A bankrobotika technológiák fedési táblázata a minta alapján (n=1023; 19 bankrobotika címke)

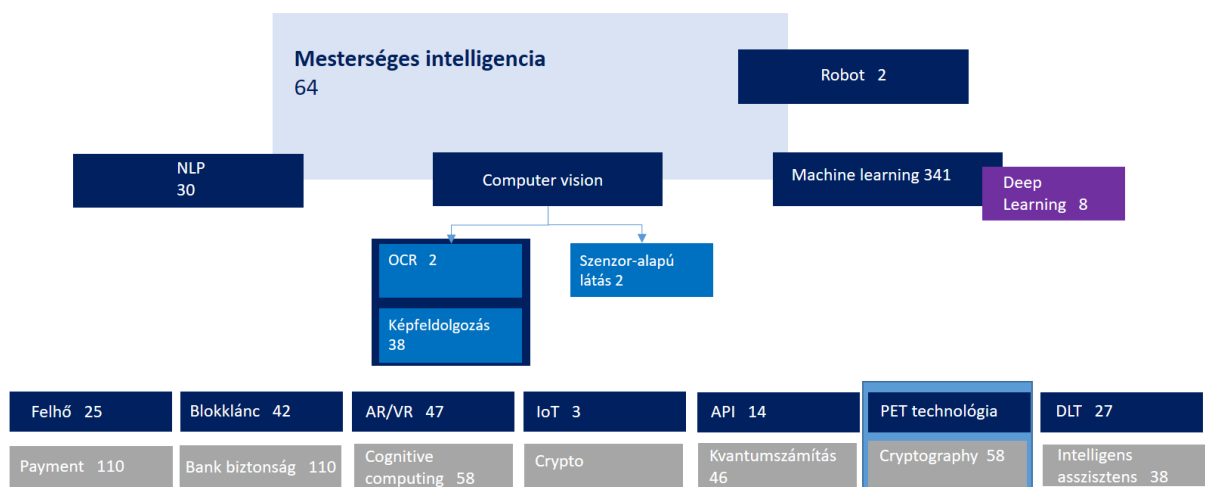
	AI	NLP	ML	Blockchain	API	Intelligent assistant	augmented/virtual reality	distributed ledger	cloud	RPA	OCR	image processing	payment	security	IoT	cognitive computing	cryptocurrency	Quantum computing	Cryptography	Total	átfedés	átfedés %	
AI	49																			64	15	23	
NLP	2	27																			30	3	10
ML	8	3	324																		341	17	5
Blockchain	1	0	1	37																	42	5	12
API	0	0	0	0	12																14	2	14
Intelligent assistant	0	0	0	0	0	38															38	0	0
augmented/virtual reality	0	0	2	0	0	0	43														47	4	9
distributed ledger	0	0	1	0	0	0	0	18													27	9	33
cloud	0	0	1	0	0	0	0	0	22												25	3	12
RPA	1	0	1	0	0	0	0	0	0	14											16	2	13
OCR	0	0	1	0	0	0	0	0	0	0	3										4	1	25
image processing	0	0	1	0	0	1	1	1	0	0	0	38									46	8	17
payment	0	0	1	0	1	0	1	1	2	0	0	0	102								110	8	7
security	1	0	0	0	0	0	0	0	0	0	0	0	0	106							114	8	7
IoT	0	0	0	0	0	0	0	0	0	0	0	1	0	0	3						4	1	25
cognitive computing	0	0	1	0	0	0	0	0	0	0	0	0	1	0	0	56					58	2	3
cryptocurrency	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2				2	0	0
Quantum computing	1	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	44			46	2	4
Cryptography	1	0	1	3	0	3	0	6	0	0	0	3	1	7	0	0	0	0	33		58	25	43

Forrás: Saját ábra

A fedési táblázat jó kiindulópont ahhoz, hogy a későbbiekben az NLP és ML hibrid modell vektorizációja és klaszterező eljárása révén megértsük, hogy mely üzleti cél támogatására jellemzően milyen technológiák kerülnek alkalmazásra a bankoknál.

A manuális címkézés eredményeképpen szükségesnek tartom a szakirodalom alapján azonosított bankrobotika technológiák körének kibővítését, amelyet az alábbi, 40. ábrán szemléltetek szürke háttérű dobozokkal. A dobozokban lévő számok azt jelzik, hogy a bankrobotika szabadalmi adatokban az egyes technológiák hány szabadalmat érintően szerepeltek.

40. ábra: A bankrobotika technológiák körének kibővítése



Forrás: Saját ábra

A következő fejezetben a szabadalmi adatok címkézését vektorizáció (NLP) alkalmazásával is elvégzem.

5.6. Vektorizáció alapú címkézés: NLP és ML modell alkalmazása

Az elemzés célja a banki szabadalmi adatokat alapján annak megállapítása, hogy milyen bankrobotika technológiák kerülnek alkalmazásra a gyakorlatban. Ennek azonosítására a szabadalmi adatok címének (a szabadalom tárgyát képező technológia rövid leírása) elemzését végzem el a természetes nyelvfeldolgozás (vektorizáció), valamint a gépi tanulási modellek (K-közép algoritmus) kombinálásával. A szövegek vektorizáció során az egyes szabadalmak címének szavait vektorokká alakítom a TF-IDF (Term Frequency- Inverse Document Frequency) súlyozási módszer segítségével, hogy a szavak információ tartalmát a szövegben előforduló szavak súlyának meghatározása révén vektorokká alakítsam, majd a vektorok távolsága alapján meghatározom, hogy az egyes szabadalmi címek milyen mértékben

hasonlítanak/különböznek egymástól. Ezen hasonlóság/különbség szolgáltatja a klaszterező eljárás alapját, amelynek elvégzéséhez a K-közép algoritmust alkalmazom a gépi tanulási modell részeként. A klaszterek kialakításához a Davies-Bouldin indexet alkalmazom. A Davies-Bouldin index nullához közelítő értéke azt jelzi, hogy sikerült a belül minél inkább homogén csoportok szeparálása a többi klasztertől. Az iteráció alkalmazott mértéke 500 iteráció.

Az elemzéshez két modell került kialakításra. Az első modell a manuálisan felcímkezett szabadalmakat elemzi az előbbieken leírt módon, míg a másik modell elemzése valamennyi – vagyis a kulcsszavak alapján nem azonosított, „egyéb” kategória címkével ellátott szabadalmakra is kiterjed. Ugyanakkor az elemzés lépései mindkét modell esetében azonosak:

- Top50Bank_Patents_v4.xlsx importálása a Google Colab elemzési környezetbe.
- az elemzéshez szükséges könyvtárak meghívása Python nyelv használatával
- a szabadalmi adatok beolvasása és előfeldolgozása (1. modell alapján kizárólag a bankrobotika címkével ellátott szabadalmak kerülnek elemzésre, így az egyéb főcímkével rendelkezők kiszűrésre kerülnek még a vektorizáció és a klaszterező eljárást megelőzően)
- a szöveges adatok vektorizálása a szabadalmi címek alapján, amely során a szöveges adatokat TF-IDF vektorokká alakítjuk a TfidfVectorizer segítségével.
- a vektorizált adatokat a főkomponens elemzés (PCA) segítségével redukáljuk
- klaszterező eljárás elvégzése a kiválasztott K-közép algoritmus révén
- a klaszterező eljárás iterációi során kialakított klaszterek kiértékelése és az eredmények rendezése a Davies-Bouldin index révén (davies_bouldin_score függvény).

A bankrobotika szabadalmak címei alapján készített vektorizáció, valamint a klaszterező eljárás eredményét az alábbiakban részletezem. A python kódokat a 36. számú, illetve a 37. számú melléklet (Kód13, Kód14¹) tartalmazza.

5.6.1. Az 1. modell kiértékelése, eredmények

A K-közép algoritmus az előzetesen bankrobotika címkével ellátott szabadalmakat vizsgálta, amelyek során 39 klasztert alakított ki. A kapott eredmények alapján a 39. klaszternek volt a

¹ Köszönet illeti az eredeti Kód13, Kód14 módosításáért és a végső kód kialakításáért dr. Schmuck Viktort, akinek a szakértelme nélkül a vektorizáció és a klaszterező eljárás kevésbé eredményes megoldásra vezetett volna.

legjobb eredménye, 3.8889008023519804, ami azt jelenti, hogy sikeresen alakított ki elkülönült klasztereket a Davies-Bouldin index alapján (41. ábra).

41. ábra: Az 1. modell futtatásának eredménye – részlet a Google Colab környezetből

```

          kategoria  cluster
10      Cryptography    26
40      payment         8
61      OCR             23
62      payment         8
82      OCR             23
...
4374   image processing  19
4377   cognitive computing  29
4385   application programming interface  17
4389   application programming interface  17
4391   Distributed ledger    5

[1023 rows x 3 columns]
=====
OrderedDict([(39, 3.8889008023519804)])

```

Forrás: Saját ábra

Az első modell futtatásából származó eredményekre, vagyis az egyes szabadalmak klaszterbe sorolására vonatkozó mintát a 38. számú melléklet tartalmaz.

5.7. A gépi címkézés kiértékelése –Üzleti területi csoportosítás

A manuális címkéhez viszonyított klaszter címke alapján az alábbi megállapításokat teszem:

- a szakirodalom elemzés és a szabadalmak áttekintése révén kialakított 36 kezdeti kulcsszó mennyiségével megegyezik az első modell által kialakított klaszterek száma. **Tehát a manuális címkézés a bankrobotika technológiákat hozzávetőlegesen megfelelő módon alakította ki a kulcsszavas szűrés eredményeképpen.**
- **Ugyanakkor** nem szabad megfeledkezni arról, hogy **míg a** kulcsszavas szűrés által kivitelezett **manuális címkézés a technológiákra fókuszál**, addig **a vektorizáció révén kialakított klaszterek a cím egészének elemzésén keresztül sokkal inkább a technológia alkalmazásának leírására, vagyis az üzleti célra fókuszálnak.** Vagyis, egy adott technológiát az alkalmazás céljának megfelelően számos kategóriába sorolt a vektorizáción alapuló K-közép algoritmus.

A gépi klaszterbe sorolást a 42. ábra, illetve a 25. táblázat szemlélteti. Az ábrán késsel a legmagasabb technológián belüli érték lett jelölve. A mellékletben elhelyezett táblázat valamennyi besorolást tartalmazza az egyes kategóriákhoz tartozás alapján (39. számú melléklet).

42. ábra: A főkategóriánként jelzett klaszter hovatarozás (n=964 elemszám alapján)

Sorcímek	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38					
application programming interface																		10					1	1																				
artificial intelligence																	44												4									1						
augmented/virtual reality								42																				1																
blockchain				6		1				6									1	1				1		19		1																
cloud			1	2						3		1				2				6			1	3		1	1												1					
cognitive computing			2	1				19									1		1	1			1				2		27										1					
Cryptocurrency																			1					1																				
Cryptography			1	3						3	1	1						1	1	2	1			13			2										1	2		1				
Distributed ledger		1								1																														3				
image processing												6				2				20				1	7		1			1														
intelligent assistant												1				2				1		17		1	8		3														1			
Internet of Things																									1	1															1			
machine learning		3	14	8	10	20		10			9	2	18	69	9	5	1					1	21	15	17	2	4		7						1	3	3	17	3	19	28	3		
Natural language																													22													5		
OCR																								2			1																	
payment			1		4								41			27					4	6		6					1	1					1	3	3	4						
Quantum computing		1		1	22					2						1				1			7			1												5	1		2			
RPA																					1			3		9			1															
security		8	2	6	1	2		1		8		1	29			4		2	8		4			5			9													11	1	1	2	1
Végösszeg	13	20	10	54	21	15	29	43	41	23	10	37	31	18	69	20	50	14	16	32	13	17	25	73	19	12	44	22	8	32	4	8	23	7	25	10	19	29	8					

Forrás: Saját ábra

25. táblázat: Klaszterenként leggyakrabban előforduló technológia

Klaszter	Domináns technológia	Klaszterbe tartozó szabadalmak közös üzleti célja	Üzleti cél kategória
0	security	hozzáférés, távoli erőforrás-kezelés; előrejelző erőforrás-transzferek lehetősége, ami hatékonyabb erőforrásallokációt és tervezést eredményez, biztonságos feldolgozás és tranzakciók kezelése	hozzáférés, távoli erőforrás-kezelés, biztonságos feldolgozás és tranzakciók kezelése
1	machine learning	Automatizált előrejelzések és információk, személyre szabott ajánlások nyújtása és a párhuzamosan biztosított személyes adatok védelme; interakciók elemzése és felhasználói profilok	Kölcsönhatások elemzésén (felhasználói profilok) alapuló személyre szabott és hatékony ajánlások
2	machine learning	üzleti folyamatok hatékonyságának növelés ML modellek által (teszteset-generálás, Hatékony szoftverkiadások, Megerősítő tanulás vizualizáció, Mély tanulás tudásgráfokkal, gépi tanulás fejlesztési dokumentációban, Kód klónozás és hitelesítés, Rosszindulatú szoftverek elleni védelem, Gépi tanulás regresszióanalízisben, Teszteset generálás gépi tanulással, Kép- és hangérzékenység megőrzése, Szabályok alapú szoftver-ellenőrzés.)	hatékonyság növelés
3	quantum computing	adatbiztonság, privát adatok védelme, titkosítási módszerek, biztonságosabb tranzakciók kialakítása, okosszerződések alkalmazása, valamint hagyományos pénzügyi folyamatok fejlesztése a digitális térben, kiberbiztonság, manuális folyamatok csökkentése, gyors és könnyű fizetési módok, illetve ezt támogató platformok	adatbiztonság, kiberbiztonság
4	machine learning	Intelligens, interaktív elemzés révén az anomáliák valós idejű észlelése és a kapcsolódó kockázatok minimalizálása az azonnali válaszreakció által	Anomália észlelése és hálózatbiztonság, adatbiztonság
5	distributed ledger	elosztott adattárolás és információ biztosítása révén megbízható rendszerek és tranzakciók biztosítása, automatizált hitelesítés és engedélyezés biztonságos adattárolás mellett történő biztosítása	Biztonságos adattárolás és hitelesítés
6	cognitive computing	hatékony adatkezelés és továbbítás, rendszer monitoring és hiba előrejelzés, ami segít az előrejelző karbantartásban és a zavartalan működés biztosítását; előre nem várt eseményekre nyújtott rendszer válasz kialakítása	a rendszerek adaptív képességének kialakítása a rendszerek reagálásának dinamikussá tételében
7	augmented/virtual reality	kereskedési és ügyfélszolgálati folyamatok és tevékenység hatékonyságának növelése az interaktív omnichannel kommunikáció biztosítása révén	interaktív tanácsadási élmény, fogyasztói élménynyújtás fokozása,

8	payment	fizetési szolgáltatások hatékonyságának fokozása; mobil fizetési megoldások, fizetési és tranzakciós biztonság biztosítása, fizetési rendszerek fejlesztése és optimalizálása, fizetési folyamatok leegyszerűsítése és a hitelesítés biztonságának megteremtése	innovatív fizetési szolgáltatások és rendszerek kialakítása
9	security	biztonságos és hatékony fizetési folyamatok, tranzakciók és autentikáció	hitelesítés, tranzakciók és adatok védelme
10	machine learning	mozgásformák, mintázatok automatikus, video-alapú, képi feldolgozása és értelmezése, kártékony tevékenységek azonosítása és megelőzése (bankbiztonság, ATM biztosítása, tüzeset elleni reagálás)	képi feldolgozás automatizált információfeldolgozásban és biztonságban betöltött szerepe
11	payment	a fizetési rendszerek során alkalmazott innovatív technológiák és felhasználási lehetőségeik, például tokenizáció, kriptográfia, biometrikus aláírások, tranzakciós modellek és kapcsolódó adatbázisok kezelési mechanizmusai	elektronikus fizetési és tranzakciós mechanizmusok és azt támogató eszközök - hitelesítés
12	security	érzékeny banki adatok biztonságának és az adatvédelmének fokozása	banki adatok védelme a harmadik fél felhőkörnyezetben történő folyamatokban, adatsere közben
13	machine learning	hatékony gépi tanulási architektúrák létrehozása az időbeli adatváltozás hatékony modell általi kezelésére, különböző felhasználási területekre történő gépi modellek kialakítása (stressz teszt, kereskedés) az adatok biztonságos kezelése mellett	hatékony és biztonságos gépi tanulás architektúrák kialakítása
14	machine learning	Komplex gépi tanulás alkalmazások és adatbáziskezelés különböző üzleti célok (csalásfelderítés, egyebek) támogatás érdekében.	ML által támogatott elemzés, észlelés, előrejelzés, döntéshozatal
15	machine learning	Tartalom alapú összefoglalások és ajánlások generálása, adatkezelés felhő-alapú platformokon	adatok kezelése és továbbítás, valamint a tartalom alapú összefoglalások és ajánlások generálása
16	artificial intelligence	AI-alapú biztonság és megfigyelés: fizikai helyszínek, hálózatok, rendszerek és adatok biztonságának ellenőrzésére és védelmére; döntéstámogatásra; adatfeldolgozás és információ kinyerés; ügyfélélmény javítása az interakciók személyre szabásával	AI-alapú alkalmazások és rendszerek
17	API	API-kon keresztül nyújtott teljesítmény- és biztonságjavító szolgáltatások, azonosítás és verifikáció	biztonságos és hatékony alkalmazások közötti kommunikáció
18	security	ügyfélprofilok nélkül végrehajtott biztonságos tranzakciók és műveletek különböző innovatív technológiákkal, kriptográfia, blokklánc	adatvédelemre és az identitás titkosítása

19	image processing	biometrikus adatok azonosítására alkalmazott képfeldolgozás és a kapcsolódó adatvédelmet támogató titkosítási megoldások (blokklánc, tokenizáció) a felhőalapú és online térben	képfeldolgozás
20	payment	Biztonságos, kriptográfia és egyéb titkosítási technológiák által biztosított és autentikált fizetési tranzakciók lebonyolítására szolgáló rendszerek	fizetési szolgáltatás biztonságának garantálása
21	intelligent assistant	hang-és képi feldolgozás alapú biometrikus azonosítás, érzelem és hangulatfelismerés	felhasználói interakció és élménynyújtás a biometrikus adatok és érzelmek felismerése révén
22	machine learning	felhőalapú hálózatstabilitás, generatív adversarial hálózatok a biometrikus adatok felismerésére, chatbotok együttműködésének biztosítása, neurális hálózatok robusztusságának javítása	hálózatok stabilitásának, biztonságának és adatáramoltatásának biztosítása
23	machine learning, cryptography	ML modelleken és kriptográfiai módszereken alapuló bankbiztonság	informatikai rendszerek, hálózatok védelme, bankbiztonság
24	machine learning	hatékony adatfeldolgozás az előrejelzések készítéséhez és döntéstámogatáshoz – lehetővé téve a széleskörű üzleti célok hatékony kiszolgálását	hatékony adatfeldolgozás
25	intelligens RPA	folyamatok hatékonyabb és intelligensebb vezérlésére, monoton feladatok kiváltása magas hatékonyság mellett	intelligens folyamatautomatizálás
26	blockchain	blokkláncra épülő technológiák (okos szerződések, tranzakciók, adatvédelem) és az azokhoz kapcsolódó hálózatok és alkalmazások	biztonság és az adatvédelem
27	NLP	chatbotok, szövegértelmezési és generálási rendszerek, üzeneteket, dokumentumok, felhasználói lekérdezések input (nyelvi) adatainak feldolgozása, értelmezése és generálása	nyelvi adatok feldolgozása, értelmezése és kezelése
28	machine learning	Rendszerek és hálózatok optimalizálása érdekében alkalmazott ML modellek	rendszer és hálózat optimalizálás
29	cognitive computing	ML, NLP és egyéb innovatív technológiák alkalmazása során történő optimalizáció és hatékony adatfelhasználás elősegítése	adatok hatékony felhasználása különböző feladatok megoldása során

30	artificial intelligence	bemenő adatok és események alapján aktiválódó cselekvések, válaszreakciók	AI-architektúrák automatizált triggereken alapuló válaszadási képessége a környezetben bekövetkezett változásra
31	Quantum computing	kvantum számítások végrehajtására szolgáló technikák és módszerek	kvantumszámítás
32	security, cryptography	felhőkörnyezetben történő biztonságos adatfeldolgozás és adatátvitel, szorosan kapcsolódva a felhő technológiához és az adatbiztonság (kriptográfia, DLT) területéhez	adatkezelés, adatbiztonság és adatfeldolgozás
33	payment	erőforrásokhoz kapcsolódó kérések (peer-to-peer hálózatok) biztonságos kezelése	fizetési, változtatási kérelmek biztonságos kezelése
34	machine learning	valós idejű adatok különböző módon történő felhasználása	valós idejű adatfeldolgozás és előrejelzés, ajánlások
35	payment	viselkedési minták elemzésén alapuló csalásmegelőzés támogatása	csalások és káros események észlelése, kapcsolódó kiberbiztonság
36	machine learning	előrejelzéseket és becsléseket alkalmaznak adott adatok vagy minták alapján, támogatva a döntéshozatalt	előrejelzés, predikció
37	machine learning	gépi tanulás modellek létrehozásának, finomhangolásának, illetve a modelleredmények tesztelésének támogatása	ML modellek építését és tesztelését támogató rendszerek és módszerek
38	NLP	természetes nyelvű input adatok alapján személyre szabott válaszok generálása	NLP-alapú személyre szabott válaszgenerálás és információ nyújtás

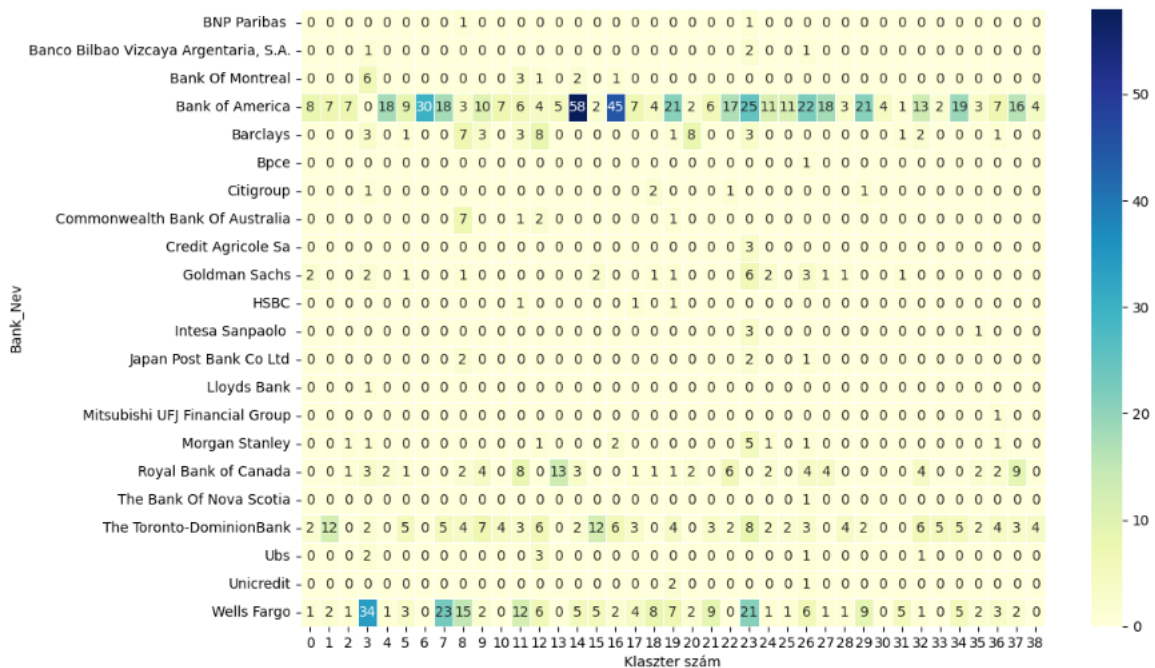
Forrás: Saját táblázat

Amint látható, az alkalmazott technológiával gyakran előforduló szavakat a súlyok alapján bár jellemzően egy kategóriába sorolta a rendszer, Ugyanakkor, ezek mögött számos üzleti cél húzódhat meg.

A fenti, 31. táblázat alapján egyértelműen azonosíthatók az üzleti célok esetében leggyakrabban alkalmazott bankrobotika technológiák. Amint láthattuk az adatvédelmet és biztonságot, mind a blokklánc, mind a hatékonyan támogathatják. Míg a blokklánc a tranzakciók és adatok követésének és rögzítésének módját változtatja meg, addig a kvantumszámítás olyan titkosítási módszereket és technikákat fejleszt, amelyek még ellenállóbbak a feltörési kísérletekkel szemben.


A fenti táblázat alapján a domináns bankrobotika technológiák majdnem valamennyi manuálisan címkézett főkategóriát lefedik. A bankrobotika technológiák üzleti célú felhasználása (klaszterek) bankonkénti alakulását szemlélteti a 43. ábra. A klaszterekhez tartozó szabadalmak száma alapján megállapítható, hogy a Bank of America egyetlen klaszter kivételével valamennyiben bír szabadalommal (43., 44. ábra). Ezzel szemben, a The Toronto-Dominion Bank 8 klaszter esetében nem rendelkezik szabadalommal, míg a Wells Fargo esetében ez 7 klasztert érint (40., 41. számú melléklet, Kód15, Kód16).

43. ábra: Bankrobotika technológiák üzleti célú felhasználásának alakulása bankonként



Forrás: Saját ábra

44. ábra: Bankok bankrobotika szabadalmi portfóiójának alakulása az üzleti célok tekintetében



Forrás: Saját ábra

A vizsgálat alapján elfogadottnak tekintem a H3 hipotézist, mivel a szakirodalom által meghatározott banki területekhez kapcsolódó üzleti célok a gépi címkézés eredményeképpen az üzleti célok sokkal szélesebb körét fedik le.

A következő alfejezet a gépi címkézés révén kialakításra kerülő üzleti célok (klaszterek) elemzését tartalmazza.

5.7.1. Bankrobotika technológiák fedése

Az alábbiakban áttekintem, hogy a gépi címkézés eredményeképpen az egyes technológiák a szabadalmak címének vektorizációja alapján mely egyéb technológia típusokkal mutatnak fedést (26. táblázat).

26. táblázat: Technológiák együttes alkalmazása

#	Bankrobotika címkék (alkategóriák)	Érintett klaszterek száma (<i>domináns</i>)
1	Artificial Intelligence	1, 10, 16 , 25, 27, 34, 30
2	Natural Language Processing	27, 28, 38
3	Machine Learning	0,1,2,3,4,5,6,7,9,10, 11, 13,14,15,16, 17, 20, 22, 23,24,25,26,27, 28, 31-38
4	Blockchain	3,5,9, 14,16, 18,19, 24, 26, 29,32
5	API	17, 23, 24
6	Intelligent Assistant	12,15, 19, 21,22,23, 26, 35
7	Augmented/Virtual Reality	7, 26, 34
8	Distributed Ledger	0,5,9, 23, 32
9	Cloud	2,3,8,9, 12,15, 19,22,23,25, 26,29,32
10	<i>RPA (robot címke)</i>	19, 23 , 25 , 29
11	OCR	22, 23,26
12	Image Processing	5,7,11,15, 19,20,21,22,23, 26,29
13	Payment	1,3,5,6,7,8,11,17,18,20,23,28,29,31,33,34,35
14	Security (Cybersecurity)	0,1,3,4,5,7,9,11,12,15,16,17,18,20,23,26,32,33,34,35,37
15	Internet Of Things	19,22,23,29
16	Cognitive Computing	1,3,6,16,18,20,23,26,29,32,37
17	Cryptocurrency	23,18
18	Quantum Computing	0,2,3,9,15,17,19,23,26,31,32,34
19	Cryptography	1, 3,5, 9, 10, 11,15,16,17,18,19,20,23,26,31,32,34
Klaszterek száma		39
Manuális címke főalkategória száma:		19 (36 kategória)

Forrás: Saját táblázat

A vizsgálat alapján elfogadottnak tekintem a H4 hipotézist, mivel a technológiák közötti fedéseket, vagyis az együtt történő alkalmazásukat a fedési mátrixok igazolják.

5.7.2. A 2. modell kiértékelése

A második modell esetében (37. számú melléklet, Kód14) a K-közép algoritmus az előzetesen bankrobotika címkével ellátott szabadalmakat vizsgálta, amelyek során 39 klasztert alakított ki. A kapott eredmények alapján a 29. klaszternek volt a legjobb eredménye, 4.740574564918173 a Davies-Bouldin index alapján (45. ábra).

45. ábra: A 2. modell futtatásának eredménye – részlet a Google Colab környezetből

```
Choose Files | Top50Bank...ents_v4.xlsx
• Top50Bank_Patents_v4.xlsx(application/vnd.openxmlformats-officedocument.spreadsheetml.
Saving Top50Bank_Patents_v4.xlsx to Top50Bank_Patents_v4 (7).xlsx
<ipython-input-13-d8cec3ccf53e>:14: FutureWarning: Inferring datetime64[ns] fro
df = pd.read_excel('Top50Bank_Patents_v4.xlsx')

      cím kategoria cluster
0 Information processing device, information pro... egyeb 13
1 Delivery management system egyeb 27
2 Information processing apparatus, information ... egyeb 13
3 Information processing device, information pro... egyeb 13
4 Information processor, information processing ... egyeb 13
... ..
4404 Customer service impact reporting egyeb 6
4405 Financing method and financial structure egyeb 6
4406 Content delivery network solution for egaming egyeb 24
4407 Projectile launcher and loader egyeb 6
4408 Collapsible hockey goal egyeb 6

[4409 rows x 3 columns]
=====
OrderedDict([(29, 4.740574564918173)])
```

Forrás: Saját ábra

A szabadalmak klaszterbe sorolására vonatkozó mintát a 39. számú melléklet tartalmaz.

A két modell közül tehát az első modell ért el jobb eredményt a Davies-Bouldin index alapján, ugyanakkor az első modell csak a szabadalmak egy részén (bankrobotika címkével ellátott) folytatta le a vizsgálódást és több klasztert hozott létre.

Modell 2. esetében ugyanakkor a manuális címkézéshöz viszonyított kiértékelés akadályozó tényezője a modell 1-hez viszonyított alacsonyabb klaszterszám, amely egyben azt is jelenti, hogy a részletes technológiai azonosítást követően egy szűkebb keretrendszerbe próbálnánk becsomagolni az üzleti célok szempontjából az alkalmazott technológiákat. Következésképpen, elvetem a kiértékelés szükségességét, mivel az alacsony klaszterszám a manuális címkézés eredményénél is alacsonyabb címkeszámot eredményezne.

Ugyanakkor említendő, hogy a modell 2. felcímkézte, klaszterbe sorolta a korábban „egyéb” címkével ellátott szabadalmakat is. A második modell eredményére példát, így a korábban „egyéb” címszóval jelölt szabadalmak besorolását a 42. számú melléklet tartalmazza.

5.8. Az AI-címkézés jelensége

Az AI-címkézés jelenségének kiértékelése során támaszkodok a modell 1 esetében kapott klaszter eredményekre, Továbbá, a manuális címkézés során a bankrobotika technológiák mátrixa alapján azonosított fedésekre. Ezek alapján elkészítettem az AI kapcsolódó innovatív technológia fedési mátrixát (27. táblázat).

27. táblázat: Az AI technológia fedési mátrixa a vizsgált mintában

Klaszter	Banki felhasználás	Fedésben lévő bankrobotika technológia
1	interakciók elemzésén (felhasználói profilok) alapuló személyre szabott és hatékony ajánlások	cognitive computing, cryptography, machine learning, security, payment
10	képi feldolgozás automatizált információfeldolgozásban és biztonságban betöltött szerepe	cryptography, machine learning
16	AI-alapú alkalmazások és rendszerek	blockchain, cognitive computing, cryptography, machine learning, security
25	intelligens folyamatautomatizálás	machine learning, RPA, cloud
27	nyelvi adatok feldolgozása, értelmezése és kezelése	machine learning, natural language
30	AI-architektúrák automatizált triggeren alapuló válaszadási képessége a környezetben bekövetkezett változásra	-
34	valós idejű adatfeldolgozás és előrejelzés, ajánlások	Cryptography, Quantum computing, machine learning, augmented/virtual reality, payment, security

Forrás: Saját forrás

Mind a manuális, mind a modell címkézés eredményeképpen elmondható, hogy az AI az alábbi bankrobotika technológiákkal áll fedésben: NLP, ML, blokklánc, NN, intelligens RPA, image processing, recommendations, pattern, quantum computing, encryption. Nem terjed ki Ugyanakkor, az AI megnevezés használata az alábbi technológiákra: API, intelligens ügyintéző, virtuális asszisztens, chatbot, distributed ledger, felhő, OCR, IoT, cryptocurrency.

Bár a kulcsszavas szűrés eredményeképpen, az alábbi technológiákhoz kapcsolódó szabadalmak címében az AI nem került párhuzamosan alkalmazásra, az 1. modell futtatása alapján az üzleti felhasználás tekintetében közös klaszterbe estek az AI-al az alábbi technológiák –így ezek esetében is valószínűsíthető, hogy felmerülhet az AI-címkézés: DL, augmented/virtual reality, robot, biometric, voice assistant, payment, cybersecurity, predict, cognitive, facial recognition, anomaly detection, secure, tokenization, smart systems, masking, cryptography. A 28. táblázat áttekintést nyújt arra, hogy az AI mely egyéb technológiákkal áll fedésben a gépi címkézés alapján.

28. táblázat: A bankrobotika technológiák és az AI fedése – eredeti kulcsszavak (36)

	AI-al együtt említve	Az adott technológia fedésben áll az AI-al a vektorizáció és klaszterezés eredménye alapján?
NLP	2	igen
ML	2	igen
Blokklánc	4	igen
API	0	nem
NN	2	igen
DL	0	igen
Intelligent agent	0	nem
augmented reality	0	igen
distributed ledger	0	nem
cloud	0	nem
robot	0	igen
RPA	1	igen
<i>chatbot, virtual assistant</i>	0	nem
OCR, opt. sensor	0	nem
virtual reality	0	igen
biometric	0	igen
voice assistant	0	igen
payment	0	igen
cybersecurity	0	igen
image processing	1	igen
IoT	0	nem
recommendation	1	igen
predict	0	igen
pattern	2	igen
cognitive	0	igen
facial recognition	0	igen
anomaly detection	0	igen
cryptocurrency	0	nem

Quantum computing	1	igen
secure	0	igen
tokenization	0	igen
encryption	1	igen
smart syst.,meth.	0	igen
masking	0	igen
Cryptography	0	igen

Forrás: Saját táblázat

A potenciális AI-címkézés tekintetében megállapítható, hogy az AI leggyakrabban (sorrendben) az alábbi technológiákkal együtt fordul elő (az előfordulás gyakorisága alapján): ML (7), blokklánc (4), NLP (2), RPA (1), képfeldolgozás (1), kvantumszámítás (1), encryption (1). Ugyanakkor a manuális címkézés eredményeképpen az alábbi eredmény adódik: ML (8), NLP (2), blokklánc (1), RPA (1), kriptográfia (1), kvantumszámítás (1). A gépi és manuális címkézés között lévő kisméretű eltérés a kategóriák összevonásából és a címek azonosításának folyamatából származik. Ugyanakkor mindkét eljárás alapján egyértelmű, hogy az AI leggyakrabban a ML modellekkel együtt kerül említésre, amelyet a blokklánc és NLP követ. A manuális címkézés eredményeképpen adódó 9 rekordot manuálisan is elemeztem (29.táblázat) és az alábbiakat állapítom meg a szabadalmak tanulmányozását követően:

- a szabadalmakban leírt technológia egy része olyan ML modellekre utal, amelyek az adatbázis tanulás és teszt adataira felosztása, majd a modell futását követően szolgáltatnak eredményt (ML modell, mint AI-címke)
- egy részük olyan komplex rendszerekre utal, amelyek AI motor révén tárolt adatokhoz nyúlnak, hogy a valós idejű adatok alapján módosítsák az output-ot (például ajánlás), ilyen szempontból a ML modellek egy komplex rendszerbe ágyazottan jelennek meg.

29. táblázat: Potenciális AI-címkék manuális áttekintése

Bank	Szabadalom szám	Manuális főcímké kategória	Szabadalom mögöttese tartalma	AI-címke?
Bank Of Montreal	US-2021326960-A1	machine learning, artificial intelligence	Az AI modell itt a deep neural network modellre utal, vagyis olyan rendszerre utal, amely ML-et használ	igen
The Toronto-DominionBank	CA-3095309-A1	Cryptography, artificial intelligence	előzetesen képzett ML modell (CNN) a hitelminősítés előrejelzésére az eseményadatok alapján	igen
Bank of America	US-10726434-B2	machine learning, artificial intelligence	Az AI modell motor valós idejű elemzést végez az ügyfél válaszára és ajánlásokat generál a felhasználói élmény személyre szabásához. Komplex rendszerbe ültetve.	nem
Bank of America	US-2022398316-A1	machine learning, artificial intelligence	ML modellekre utal, mint tanított AI algoritmusok, a rosszindulatú, csalás gyanús események észlelésére, amely alapján a biztonsági intézkedések automatizálhatóak	igen
Bank of America	US-2018349793-A1	machine learning, artificial intelligence	A ML/ AI scoring algoritmus által előállított adatot generált adatokat továbbítja a klienshez, majd az interakciós adatok alapján módosítja az ajánlást	igen
Bank of America	US-2021390439-A1	artificial intelligence, Quantum computing	Machine Learning (ML) osztályozási algoritmusokat alkalmaz az események manipulációra utaló jelek azonosítására. Ezt követően a kvantum számítógép átalakítja és tárolja.	nem
Bank of America	US-11310259-B2	security, artificial intelligence	hálózatfigyelő rendszer a gyanús események észlelésére. Az AI-rendszert a kétirányú hosszú rövid távú memória (BDLSTM), az ismétlődő neurális hálózatokat (RNN), és a természetes nyelv feldolgozást (NLP) modulok alkotják.	nem
Bank of America	US-2022358030-A1	artificial intelligence, blockchain	A blockchain rendszer az AI (motor) alapú teszt szkriptek generálásával egészülhet ki	nem
Bank of America	US-2022121982-A1	RPA, artificial intelligence	A ML modellek alkalmazása az RPA botok optimális számának meghatározására és használatára utal az munkafolyamatok elemeinek feldolgozásához	igen

Forrás: Saját táblázat

A robot-címkézésre vonatkozóan az alábbi táblázat szolgáltat kiegészítő információt a szabadalmi adatok alapján a robot-címkékre vonatkozóan, amely alapján megállapítható, hogy a szakirodalommal ellentétben a robot címke valamennyi bankrobotika tekintetében alkalmazásra kerül (30. táblázat).

30. táblázat: A gépi valamint a manuális címkézés összevetése

Gyakorlatban alkalmazott bankrobotika technológia	Manuális címkézéskor alkalmazott?	Robot címke szakirodalmánál alkalmazott?
Machine Learning	✓	✓
Quantum Computing	✓	
Distributed Ledger	✓	
Cognitive Computing	✓	
Augmented/Virtual Reality	✓	
Payment	✓	
Artificial Intelligence	✓	✓
API	✓	
Image Processing	✓	✓
Intelligent Assistant	✓	✓
Cryptography	✓	
Security	✓	
Intelligens RPA	X	✓
Blockchain	✓	
NLP	✓	✓

Forrás: Saját táblázat

Az AI-címkék vizsgálatát követően megállapítom, hogy a H5 hipotézis elfogadásra kerül, mivel az AI-címkézés a szabadalmi adatok alapján számos esetben más technológiák helyett, univerzális szóhasználatként kerül szerepeltetésre, annak ellenére, hogy valójában más technológia áll a termék/szolgáltatás mögött.

Összefoglaló gondolataimat az 6. fejezet részletezi.

6. Összefoglalás: Kutatási eredmények

6.1. *A kutatás kiindulópontja: szakirodalmi hiányosságok és kutatási célkitűzések*

A kutatásom kezdetén számos problémával szembesültem az AI és kapcsolódó innovatív technológiák bankszaktori alkalmazási lehetőségeinek vizsgálata során. Egyrészt, a publikációk többsége elfelejtkezik a bank, mint szervezet, működésének egészben történő vizsgálatáról, jellemzően benchmarkok felállítására törekszik valamely banki front, middle, back office (rész)területre fókuszálva. Másrészt, további kezdeti nehézségként jelentkezett, hogy a szakirodalom jelenleg nem jelöl ki egy olyan elkülönült kutatási területet, amely az AI és kapcsolódó innovatív technológiákat a bankszektor maga szigorúan szabályozott jogszabályi környezetében elemezné. A szektor-specifikus jogszabályi környezete természetes korlátként jelentkezhet az AI és kapcsolódó technológiák adaptációja során a prudens és transzparens működés jegyében. Bár léteznek olyan tanulmányok, amelyek az érintett jogszabályi környezetet (AI rendelet, GDPR, CRR), illetve az azok között fennálló kapcsolódási pontokat vizsgálják. Ugyanakkor jellemzően ez a vizsgálat is egyoldalú, hiszen kizárólag a jogszabályi oldal felől közelíti a témát. Következésképpen, hiányzik a holisztikus szemléletmód, illetve a kapcsolódó vizsgálati keretrendszer, amely egy elszeparált kutatási területként vizsgálná a szigorú szabályozói környezettel rendelkező bankszektorban alkalmazott AI és kapcsolódó innovatív technológiák felhasználási lehetőségeit.

A terület lehatárolásának hiányában a kapcsolódó strukturált elemzési keretrendszer is hiányzott. E két alapvető probléma áthidalására, korábbi kutatómunkám során javaslatot tettem a bankrobotika (kutatási) terület lehatárolására, illetve kialakítottam a strukturált vizsgálati keretrendszerét.

Az eredeti bankrobotika definíció a bankrobotika technológiai fókuszával és a bankszektor szigorú jogszabályi keretrendszerével közelítette a területet, amikor a FinTech területen is megjelenő innovatív technológiák bankszaktori alkalmazásaként határozza meg a bankrobotikát (Prisznyák, 2023c). Bár a fogalom további két iteráción ment keresztül a disszertációban, kiindulópontot jelentett a bankrobotika terület lehatárolásának vizsgálatához. A bankrobotika koncepció kialakítása mellett, meghatároztam azokat a technológiákat

(bankrobotika technológiák), amelyeket a szakirodalom alapján jellemzően alkalmaznak a különböző banki front, middle, back office területeken.

A bankrobotika vertikális és horizontális modellje (VHM) lehetőséget nyújtotta arra, hogy a kutatómunkám során horizontális: 1.) nano (operatív szint); (2.) mikro (intézmény szint), (3.) mezzo (bankszektor szint), (4.) makro (nemzetgazdasági szint), (5.) globális, illetve vertikális dimenzióik mentén: (1.) befektető, (2.) a fogyasztó, (3.) a szervezet (bank), (4.) a munkavállalók, (5) regulátor vizsgálódjak (Prisznyák, 2023c).

A bankrobotika koncepció kialakítása mellett, meghatároztam azokat a technológiákat (bankrobotika technológiák), amelyeket a szakirodalom alapján jellemzően alkalmaznak a különböző banki front, middle, back office területeken. Így ezeket a szervezet aspektusából, nano szintű megközelítésből vizsgáltam a VHM keretében.

A bankrobotika terület FinTech-től való lehatárolásának szükségességét a bankrobotika jogszabályi keretrendszerének 'kialakításán' és tárgyalásán keresztül alapoztam meg. A megközelítés összhangban van az AI rendelet 9. preambulumbekkezdésével, amely hangsúlyozza az AI rendelet egyidejű figyelembevételét az érintett szektorban alkalmazott már meglévő EU-s (Alapjogi Charta), valamint másodlagos uniós jogforrásokkal (például GDPR), Továbbá, egyéb ágazati/szakterületi rendeletekkel (CRR, CRD IV), valamint jogszabályokkal és iránymutatásokkal (HLEG, 2019, (EU) 2024/1689) és kapcsolódó sztenderdekkel. Ezt jogszabályelemzés keretében is vizsgáltam a kutatómunkám folyamán.

A bankrobotika terület lehatárolásának szükségessége mellett további két fő pillért jelöltem ki: (1) a robot/AI-címkézés jelenségét, illetve az első és a második téma együttes érvényesülését, nevezetesen a bankrobotika területen létező robot/AI-címkézés igazolását – amelyet a disszertációm címe is fémjelez.

A robot/AI- címkével ellátott innovatív technológiák új típusú incidensek megjelenését eredményezik, Ugyanakkor gyakran szinonimaként alkalmazzák őket a technológiák konvergenciája következtében. Ezt a jelenséget robot/AI-címkézésnek neveztem el. A robot/AI-címkézés jelentősége abban áll, hogy az univerzális szóhasználat (amely mind a szakirodalomban, mind a szürkeirodalomban és piaci gyakorlatban megjelenik) elmulasztjuk annak megértését, hogy valójában milyen technológia húzódik meg a robot/AI-címke háttérében. Ugyanakkor a különböző mögöttes technológiák (ML, DL, NLP, gépi látás, egyebek) eltérő felhasználási lehetőségekkel, kapcsolódó autonómia szinttel, emberi felügyeleti

mechanizmusokkal rendelkeznek. Következésképpen eltérő kockázatokat indukálnak. A mögöttes technológia pontos definiálása hiányában ugyanakkor sérülhet a bank kockázatkezelési gyakorlata, amennyiben nem készül fel a mögöttes technológiák azonosításán keresztül a szükséges megelőző intézkedések meghozatalára.

Disszertációmban tehát három fő témát vizsgáltam: (1) a robot/AI-címkézés jelenséget, (2) a bankrobotika koncepció és kutatási terület lehatárolásának szükségességét, továbbá (3) a bankrobotika területen megvalósuló robot/AI-címkézés jelenségét – amelyeket köré 5 kutatási kérdést, illetve kapcsolódó hipotézist szerveztem (31. táblázat).

A három téma mentén kialakított kutatási kérdéseket és kapcsolódó hipotéziseket az alábbi 31. táblázat tartalmazza.

31. táblázat: Kutatási kérdések és hipotézisek összefoglaló táblázata

Téma	Kutatási kérdés	Hipotézis
I. A bankrobotika koncepció és kutatási terület	K1: Szükséges a bankrobotika (kutatási) területet a FinTech-től elkülönült kutatási területként kezelni?	H1: A bankszektor szigorú prudenciális szabályozása természetes akadályul szolgál az AI és kapcsolódó technológiák implementációjának, fejlesztésének. A szektor-specifikus sajátosságok figyelembevétele miatt célszerű a területet lehatárolt, önálló területként kezelni.
II. Robot-és AI-címkézés jelenség	K2: Létező jelenség a robot/AI-címkézés a bankszektorban?	H2: A szakirodalom alapján a robot/AI univerzális szóhasználat mögött jellemzően az alábbi technológiák húzódnak meg: technológiákra: AI, ML, NLP, gépi látás, kvantum számítás, blokklánc, API, PET technológia, felhő, DLT, AR/VR, IoT. Ezen mögöttes technológiák felhasználási lehetősége a banki front/middle/back office területen különböznek. Következésképpen, eltérő kockázatokat indukálnak – amely összefüggésben áll a kockázatkezelést kiemelten kezelő bankrobotika területtel.
III. Bankrobotika területen megvalósuló robot/AI-címkézés jelensége	K3: Milyen főbb üzleti célú felhasználási lehetőségei vannak ezeknek a bankrobotika technológiáknak? Széleskörben támogatja a banki front, middle, back office területeket?	H3: A feldolgozott szakirodalmak alapján a főbb alkalmazási területek a Sales, marketing, portfóió-és vagyongazdálkodás, hitelezési tevékenység, AML, CFT, csalásmegelőzés terület igényei által meghatározottak, amelyeket az irodalmi összefoglaló táblázatokban is szerepeltettek.
	K4: A bankrobotika technológiák mennyire kerülnek együtt/fedésben használatra?	H4: Az alkalmazott bankrobotika technológiák önállóan, de más technológiákkal együttesen is jelentős mértékben kerülnek alkalmazásra, igazodva a terület specifikusan megfogalmazott üzleti célokhoz
	K5: Az AI-címkézés tekintetében mi jellemző a bankrobotika technológiák fedésére? Jellemzően mit takarnak ezek az AI-címkék?	H5: A szakirodalom alapján megállapított AI-címkézés keretében az AI-címkézés jellemzően az alábbi technológiák esetében kerül alkalmazásra: ML, NLP, gépi látás, intelligens chatbotok, intelligens robotok.

Forrás: Saját forrás

A kutatási területen azonosított hiányosságokat, a kapcsolódó kutatómunkámat, illetve új, saját kutatási eredményeimet az alábbiakban részletezem.

6.2. Alkalmazott kutatási módszerek és eredmények

Alábbiakban a megfogalmazott kutatási témák mentén ismerttetem a felhasznált módszerek révén elért kutatási eredményeimet.

6.2.1. A bankrobotika lehatárolásának szükségessége (K1, H1)

A bankrobotika koncepció lehatárolásának szükségessége érdekében strukturált mélyinterjúkat folytattam 2022. december és 2023. május között, olyan banki üzleti, illetve szoftverfejlesztő szakemberek bevonásával, akik részt vettek AI, ML, robot bevezetéssel, fejlesztéssel kapcsolatos projektekben.

A mélyinterjú tapasztalatokat jogszabáylelemzéssel egészítettem ki, amelynek során az AI rendelet, a CRR, illetve a GDPR közötti kapcsolódási pontokat vizsgáltam, hogy ráirányítsam a figyelmet arra, hogy a bankszektor különösen szigorú szabályozási környezete együttesen határozzák meg azt a keretrendszert, amit a bankoknak az AI rendszerek fejlesztése, működtetése során figyelembe szükséges venniük. Következésképpen, a prudenciális banki szabályozás, a meglévő Európai Unió jogforrásokkal (Alapjogi Charta), valamint másodlagos jogforrásokkal (GDPR, Data Act, DORA, Felhő-ajánlás), illetve kapcsolódó nemzetközi sztenderdekkel együttesen olyan speciális szabályozói környezetet alkot, amely meghatározza az AI és kapcsolódó innovatív technológiák bankszektori alkalmazási lehetőségeit (például a hitelminősítő és a HR profilozó rendszerek magas kockázatú besorolásra). **Ezt a komplex jogszabályi környezetet a bankrobotika jogszabályi keretrendszerének neveztem el, és a bankrobotika terület lehatárolásának egyik fő mozgatórugójaként tekintem.**

A bankrobotika és a FinTech közötti határvonal szükségességét az alábbi indokok támasztják alá, a jövőbeni alapos kutatások érdekében: Először is, a komplex szabályozói környezet miatt az AI rendelet ((EU) 2024/1689) általános megközelítése nem specifikus a pénzügyi szolgáltatásokra, így nem elegendő az AI rendeletnek való megfelelés; figyelembe kell venni a bankszektor prudenciális szabályozását is. Másodsor, a bankszektor szigorú jogszabályi környezete a társadalmi és gazdasági hatások miatt korlátozza a mesterséges intelligencia alkalmazását, különösen a pénzügyi rendszer stabilitása és a természetes személyek élethelyzetére gyakorolt hatás tekintetében. Harmadszor, az innovatív szolgáltatások, mint a BNPL, és a hitelminősítő rendszerek szükségessége rávilágít a bankrendszer kockázatkezelési

igényeire, beleértve a fogyasztóvédelem és a pénzügyi nehézségekkel kapcsolatos kockázatokat. Negyedszer, bizonyos AI rendszerek alkalmazását korlátozhatja a banki szektor jelentősége, különösen a modellek átláthatósága és diszkrimináció-mentessége miatt. Ötödször, az MNB folyamatosan próbálja a jogszabályokat az AI technológiák felhasználásához igazítani, ami a bankszektor-specifikus kezelés és kutatás szükségességét jelzi. Végül, a banki engedélyek követelményei és a hosszú távú nyereségességre vonatkozó szabályozások, mint a CRD IV és a CRR, a tőkekövetelmények és a kockázatkezelési mechanizmusok révén szabályozzák a technológia lehetőségeit és a munkavállalók szükséges képességeit.

A szakirodalom elemzés, mélyinterjúk és a jogszabály elemzés alapján a HI hipotézisemet elfogadtam. Megállapítható, hogy a bankszektor szigorú prudenciális szabályozása természetes akadályt képez az AI és a kapcsolódó technológiák implementálásában és fejlesztésében.

A szektor-specifikus sajátosságok figyelembevételével indokolt, hogy a bankszektorban történő AI alkalmazást önálló, lehatárolt területként kezeljük. Az eredmények alapján megvalósult a bankrobotika koncepció kialakítása és a fogalom harmadik iterációja:

A bankrobotika az egyed szintű változást biztosító elképzelt rend a digitális éra gyorsan változó banki környezetében, mivel lehetővé teszi a bankok számára, hogy a komplex jogszabályi keretrendszer és az AI területet célzó kutatási tevékenységek révén olyan rendszereket építsenek ki, amelyek alkalmazkodnak az új technológiákhoz. Ezáltal a bankrobotika kitölti az új-tradicionális banki modellek közötti réseket, és biztosítja az innovatív megoldások bevezetését és integrációját, amely lehetővé teszi a bankok számára, hogy hatékonyan reagáljanak a digitális éra kihívásaira.

Következésképpen, a disszertációban is ismertetett DNS modell keretében az alábbiak szerint öszegzem a bankrobotikával kapcsolatos fogalmi iterációkat:

- **Technológiai aspektus/spirál (szűkebb értelmezés, 2. réteg a.):** technológiai adaptáció. Vagyis a FinTech területen is megjelenő innovatív technológiák (AI, ML, robotok és kapcsolódó innovatív technológiák) bankszektori alkalmazása.
- **Szervezeti aspektus (tágabb értelmezés, 2. réteg b.):** szervezeti átalakulás. Vagyis a szervezet adaptációs képessége, amely meghatározza a digitális átállást kísérő szervezeti kultúra átalakulását, a munkavállalók, a szervezeti értékek fejlődését, a banki stratégiát, az alkalmazott üzleti modellt.

- **Stratégiai aspektus (legtágabb értelmezés, 1. réteg):** a bankszektor egészének alkalmazkodási képességét leíró DNS lánc (egyedek alkalmazkodási képessége alapján). Az elképzelt rend/ a bankszektort átfogó hosszútávú alkalmazkodási folyamat, amelyet rövidtávon megvalósuló szervezeti és technológiai képességekben bekövetkező változások indukálnak.

6.2.2. A robot/AI-címkézés jelensége (K2, H2)

A robot/AI- címkézés jelenségének kiindulásaként azon mögöttes okokat kutattam, amelyek hozzájárulnak a robot/AI szóhasználat univerzálissá válásához (robotika, antropomorf robotok, nyelvészeti, munkafolyamati tevékenységre irányuló kifejezés, popkultúra gyökerek). Következésképpen, egy egyszerű, ám komplex kérdéshez jutottam: *Mit jelent a robot a bankszektorban?*

A kérdés megválaszolása érdekében a banki front, middle, back office területeken alkalmazott szoftver/hardver robotokat, illetve a mögöttük lévő technológiákat tekintettem át. Megállapítottam, hogy a robot-címke mögött számos technológia húzódik meg: RPA, AI, ML, DL, robot/virtuális asszisztensek, (intelligens) chatbotok és fizikai robotok, NLP. A koncepciók keveredése indukálja, hogy a robot-címkével szinonim módon kerül értelmezése az AI-címke is. A robot-és AI-címkék közötti különbség meghatározásához a technológiákat dinamikus/statikus válaszadási képesség révén vizsgáltam.

A szakirodalom elemzése révén megállapítottam, hogy míg az AI-alapú rendszerek képesek megfigyelni a környezetet, önállóan elemezni az információkat, következtetéseket levonni és intézkedéseket hozni a környezet változásainak megfelelően, addig az RPA (Robotic Process Automation) és az egyszerű chatbotok válaszadási képessége az automatizálás révén csupán az előre programozott, statikus válaszadásra korlátozódik. Ennek alapján a robot- és AI-címkézés között a határvonalat a dinamikus válaszadás képességénél húztam meg. Következésképpen, a bankrobotika koncepció (amely az AI-t és kapcsolódó intelligens technológiákat foglalja magában) a robot-címkézés tágabb jelenségét az AI-címkézés jelenségére szűkíti. Vagyis az RPA nem tekinthető a bankrobotika technológiáiban releváns tényezőnek.

Megállapítottam továbbá, hogy míg a robot-címke univerzális szóhasználat a technológiák kifejezésének egyszerűsítésére irányul, addig az AI-címke használata mögött nem csak a technológiák konvergenciája miatti téves szóhasználat, hanem a szándékos manipuláció is meghúzódhat. Ez a szándékosság az *AI-washing jelenséghez* vezethet el.

A robot/AI-címkézés jelenségének igazolásához, *mélyinterjúk kérdéseket (K5, K8)*, illetve a *HunOR adatbázist* alkalmaztam. A mélyinterjú eredmények rávilágítottak a gyakorlati alkalmazásra, amelynek keretében a robot/AI-címke gyakran az alábbi mögöttes technológiákra utal: ML, virtuális asszisztens, chatbot, intelligens chatbot, felhő-alapú megoldások, szuperszámítógépek, egyszerűbb adatfeldolgozó rendszerek, NLP, szoftver robotok, RPA.

A robot/AI-címkézés gyakorlati megvalósulása érdekében a HunOR működési kockázati eseményeket rögzít adatbázisát használtam (Prisznyák, 2024a), annak feltérképezésére, hogy a jelenlegi oprisk kockázatkezelés során érvényesül-e a robot/AI címkézés. A találat csak három oprisk eseményt eredményezett, Ugyanakkor, felhívja a figyelmet arra, hogy: a robotokkal kapcsolatos leírások nem tartalmaznak információkat a robotokról/AI-ról, sem a címke mögött lévő mögöttes technológiáról. Nem térnek ki továbbá a robot (adott technológia) autonómiájának fokára, sem az emberi felügyelet jellegére, Továbbá, nem tárgyalják a humán munkaerő-robot szerepét (trade-off) az adott munkafolyamatban.

Az elemzett szakirodalom és a gyakorlatban végzett mélyinterjúk, illetve HunOR adatbázis elemzése alapján H2 hipotézist elfogadottnak tekintem. A 'robot' és 'AI' univerzális szóhasználat mögött különböző technológiák állnak, amelynek figyelembevétele szükséges tényezője a proaktív kockázatkezelési rendszerek működtetésének.

6.2.3. AI és kapcsolódó technológiák a banki területeken (K3, H3)

A bankrobotika területen megvalósuló AI/robot-címkézés megvalósulását a disszertáció harmadik témájához tartozó (K3-H3, K4-H4, K5-H6) kutatási kérdéseken és hozzájuk tartozó hipotézisek révén vizsgáltam.

A H3 hipotézis a bankrobotika technológiák negyedik fejezetben ismertetett felhasználási lehetőségeinek (Front office: étékesítés, CRM, portfólió-és vagyongazdálkodás, middle office: hitelezés, back office: Compliance keretében a AML, CFT, KYC, HR) gyakorlati igazolására irányult.

A vizsgálatot a szabadalmi adatok felhasználásával végeztem el vektorizáció és K-közép klaszterező eljárás segítségével a Google Patent szabadalmi adatbázis ingyenesen elérhető adatai révén a világ top50banjára vonatkozóan. Az elemzési környezetnek a Google Collaboratory-t választottam.

A szabadalmi adatok címeinek elemzése alapján 38 üzleti felhasználási területet azonosítottam, amelyek mögött eltérő technológia dominál. Az azonosított üzleti célok között

szerepelnek például az alábbi kategóriák (a teljes listát tartalmazó táblázat az empirikus résznél található): (1) Hozzáférés, távoli erőforrás-kezelés, biztonságos feldolgozás és tranzakciók kezelése; (2) adatelemzésen alapuló személyre szabott ajánlások; (3) hatékonyság növelése; (4) adatbiztonság és kiberbiztonság, [...] (36) csalások és kiberbiztonság; (37) predikció; (38) ML modellek építését támogató rendszerek; (39) NLP-alapú személyre szabott válaszgenerálás.

A kapott eredmények alapján megállapítottam, hogy a bankrobotika technológiák üzleti célú támogatása széles skálán mozog. A szabadalmi adatok címeinek vektorizációján alapuló ML modell (K-közép algoritmus) 39 üzleti felhasználási területbe sorolta a bankrobotika technológiákat. Következésképpen, elfogadottnak tekintem a H3 hipotézisemet, amely szerint a bankrobotika technológiák széles körűen képesek támogatni a front, middle, back office területeket.

6.2.4. Bankrobotika technológiák együttes felhasználása/fedés (K4, H4)

A negyedik hipotézisem keretében a bankrobotika technológiák együttes alkalmazását, fedését vizsgáltam. A szabadalmi adatok címe alapján azonosítottam, hogy hány esetben fordul elő valamely technológia a vizsgált többi technológiával együtt, illetve hány esetben más technológiákkal. Az eredményül készített fedési mátrix az empirikus fejezet tartalmazza.

Az összesítő táblázatból kiolvasható, hogy legnagyobb százalékos arányban a kriptográfia, DLT, OCR kerül alkalmazásra más technológiákkal, így az is meghatározhat az üzleti területi klaszter hovatartozásuk alapján, hogy mely üzleti célok támogatása esetében jellemzően mely bankrobotika technológiák kerülnek együttesen alkalmazásra.

Az eredmények alapján megállapítottam, hogy a bankrobotika technológiák együttes alkalmazása gyakori. Az együttes alkalmazás alapján meghatározhatók azon üzleti területek, amelyek jellemzően több, vagy kombinált bankrobotika technológiákat alkalmazását igénylik. Így a H4 hipotézisemet elfogadottnak tekintem.

6.2.5. AI-címkézés érvényesülése (K5, H5)

A szabadalmi adatok elemzése alapján az AI 49 esetben egyedül kerül említésre, további 15 esetben (23%) pedig egyéb technológiákkal. Az elemzés kiegészítéseképpen elvégeztem a potenciális AI-címkével ellátott (fedésben lévő) szabadalmak manuális ellenőrzését és áttekintettem a dokumentációkat. Az elemzés eredményeképpen beigazolódott, hogy számos esetben az AI olyan egyéb, mögöttes technológiára utal, amely nem egy komplex rendszer részeként, hanem kizárólag valamely bankrobotika technológia helyetti megnevezésre irányul.

(Erre bővebb információt a releváns táblázat tartalmaz az empirikus fejezetben). A kapott eredmények alapján megállapítottam, hogy a bankrobotika területen is érvényesül a robot/AI-címkzés. Vagyis, elfogadottnak tekintem a H5 hipotézist.

Az egyes fejezetekben elért saját kutatási eredményeket (újdonság) az 32. táblázat, míg a hipotézisek tekintetében levont következtetéseket a 33. összegző táblázat ismerteti.

32. táblázat: A disszertáció hiánypótló jellege, kutatási újdonságok

Téma	Kezdeti kutatási gap, hiányosság	Kutatási újdonságok
Bankrobotika koncepció és kutatási terület	<p>A banki területen fejlesztett, alkalmazott AI, robotok és kapcsolódó innovatív technológiák esetében nincsen egy olyan dedikált terület, amely a saját holisztikus látásmódjával, szektor-specifikus szabályozó keret és sajátosságok mentén vizsgálná (természetes technológia adaptációs korlátok) ezen technológiákat.</p> <p>A jogszabályi rendeleteket említő tanulmányok sem a kutatási terület lehatárolásának szükségességén keresztül vizsgálják a témát, hanem jellemzően jogi aspektusból elemzés a rendeletek közötti összefüggéseket, potenciális kapcsolódási pontokat.</p>	<p>(1) a koncepció kialakítása és iterációi (szemléltetés a DNS modell mentén); keretrendszer kialakítása: vertikális és horizontális modell (VHM), kialakítása; bankrobotika technológiák meghatározása; bankrobotika terület lehatárolása a FinTechről. A bankrobotika koncepció megértése a bankszektor evolúciójának megértéséhez is hozzájárul (DNS modell).</p> <p>(2) bankrobotika jogszabályi keretrendszer 'kialakítása', vizsgálata: a terület lehatárolás szükségességének indoklása, valamint a jövőbeli kutatási keretek meghatározása céljából.</p> <p>Az AI rendelet, CRR, GDPR együttes vizsgálata, A bankszektori AI rendszerek kockázati besorolásának vizsgálata.</p>
Robot/AI-címkzés jelensége	<p>A bankszektorban jelentkező kockázatokat jellemzően az AI és kapcsolódó innovatív technológiákkal összefüggő AI kockázatok mentén jelölik ki. Ugyanakkor elmulasztják a probléma mélyebb gyökereinek megértését. A robot/AI-címkzés jelensége meglátásom alapján olyan jelentős problémákat okozhat a mögöttes technológiák felhasználási területtel összefüggő kockázatainak nem kellő mélységű megértésére tett törekvések és kapcsolódó kockázatkezelési intézkedések hiányában, mint amennyire evidens. A szakirodalom tehát elbukik az AI kockázatok kezelése révén annak megértésében, hogy milyen alapvető intézkedésekkel lehetne a kockázatot csökkenteni. Nevezetesen a robot/AI-címkzés visszaszorításával.</p>	<p>Robot/AI-címkzés jelenség létezésének igazolása: a bankrobotika terület vizsgálat szükségességének megértése indokolja a címkzés jelenségével járó kockázatok megértését, vagyis, hogy az univerzális robot/AI szavak eltérő mögöttes technológiákat jelölhetnek, amikhez eltérő felhasználási lehetőségek, kockázatok, robot autonómia és felügyeleti mechanizmusok kapcsolódhatnak. A jelenség megértése a kockázatkezelés sikerének kulcsa. (Kevésbé elterjedt területek tárgyalása: AI-washing, ethics-washing.)</p>
Bankrobotika területen alkalmazott robot/AI-címkzés vizsgálata	<p>AI, robotok és kapcsolódó innovatív technológiák alkalmazásának komplex vizsgálata a bankrobotika front/middle/back office területeken jellemzően nem valósul meg. Ezen szócikkek jellemzően generális áttekintés nyújtanak, és a ML modellek vizsgálatán keresztül és benchmarkok felállítására törekednek.</p> <p>Az AI, robotok és kapcsolódó innovatív technológiák banki területen történő gyakorlati alkalmazásának vizsgálata korábban nem került még igazolásra szabadalmi adatokon keresztül.</p> <p>A kutatás hiányosságaiként azonosított tényezők együttes vizsgálata.</p>	<p>AI, robotok és kapcsolódó innovatív technológiák banki front, middle, back office területi alkalmazási lehetőségeinek vizsgálata holisztikus módon (Sales, marketing, CRM, portfólió-és vagyongazdálkodás, bankfióki robotok, kockázatkezelés, Compliance: AML, CFT, KYC, HR).</p> <p>A bankrobotika technológiák együttes alkalmazásának vizsgálata a felhasználási cél tükrében, hozzájárul a robot/AI-címkzés mögött lévő technológiák együttes alkalmazásának megértéséhez.</p> <p>A robot-és AI-címkzés jellemzően az alábbi technológiák esetében kerül alkalmazásra a bankrobotika területen: ML, NLP, gépi látás, intelligens chatbotok, intelligens robotok.</p>

Forrás: Saját táblázat

33. táblázat: Saját kutatási eredmények összefoglalása a kutatási kérdések mentén

Disszertáció kutatási témája	Kutatási kérdés	Saját kutatási eredmény - Tézis
I. A bankrobotika koncepció és kutatási terület	K1	<i>A szakirodalom elemzés, mélyinterjúk és jogszabályelemzés szintetizálását követően a bankszektor specifikus sajátosságok indukálják az AI és kapcsolódó innovatív technológiák elkülönült (kutatási) területként történő kezelését. A bankrobotika terület az egyed szintű változást biztosító elképzelt rend (rendszerezett, lehatárolt kutatási területként meghatározott tudásbázis és kutatási irány) a digitális éra gyorsan változó banki környezetében. A bankrobotika fogalom három értelmezése az alábbi: (1) Technológiai aspektus (szűkebb értelmezés), (2) Szervezeti aspektus, (3) Stratégiai aspektus (legtágabb értelmezés).</i>
II. Robot-és AI-címkézés jelenség	K2	<i>A robotok-és AI-címkék esetében a különböző mögöttes technológiákat (például ML, fizikai robot, NLP) gyakran szinonimaként alkalmaznak. A robot-és AI-címkézés mind a szakirodalomban, mind a gyakorlatban igazolást nyert. A szakirodalmi vizsgálat alapján a robot-és AI-címkékkel az alábbi technológiákat használják szinonimaként: ML, DL, robot asszisztensek, intelligens chatbotok és fizikai robotok. A mélyinterjúk alapján a gyakorlatban az alábbiakat: ML, virtuális asszisztens, chatbot, intelligens chatbot, felhő-alapú megoldások, szuperszámítógépek, egyszerűbb adatfeldolgozó rendszerek, NLP, szoftver robotok, RPA.</i> <i>A robot-címkézés szűkítése az AI-címkézés jelenségére egyúttal a bankrobotika mögöttes technológiáinak szűkítését is jelenti az intelligens technológiákra. Ezek alapján a határvonalat a robot- és AI-címke között a gépi 'gondolkodási', tanulási képesség és a végrehajtás között húzható meg, elszeparálva egymástól a dinamikus válaszadási képességgel bíró AI és kapcsolódó technológiákat az RPA-tól, valamint az előre programozott válaszadás mentén működő egyszerű chatbotoktól.</i>
III. Robot- és AI-címkézés a bankrobotika területen	K3	<i>A bankrobotika technológiák üzleti célú támogatása széles skálán mozog, amit mind a szakirodalom kutatás, mind a mélyinterjúk megerősítettek. A szabadalmi adatok címeinek vektorizációján alapuló ML modell (K-közép algoritmus) 39 üzleti felhasználási területbe sorolta a bankrobotika technológiákat.</i>
	K4	<i>A bankrobotika technológiák együttes alkalmazása a fedési mátrixok alapján gyakori. Az együttes alkalmazás alapján meghatározhatók azon üzleti területek, amelyek jellemzően több, vagy kombinált bankrobotika technológiákat alkalmazását igénylik.</i>
	K5	<i>Az elemzett szabadalmi adatok alapján robot/AI-címkézés a bankrobotika területen az alábbi technológiákat érinti: NLP, ML, Blockchain, RPA, Security, Quantum computing, Cryptography.</i>

Forrás: Saját forrás

7. Továbbmutató kutatási irány

Az LVX-1 (Elvex) nevű robot túlzottan emberi jellemzőket produkált, következésképpen, leállításra került. Előtt az alábbi monológot intézte tervezői felé: „Múlt éjszaka álmodtam [...]álmomban azonban úgy tűnt, hogy nincs sem első, sem második törvény, csak a harmadik létezik, és a harmadik törvény az volt, hogy a robotnak védenie kell a saját létezését” (Asimov, 1986).

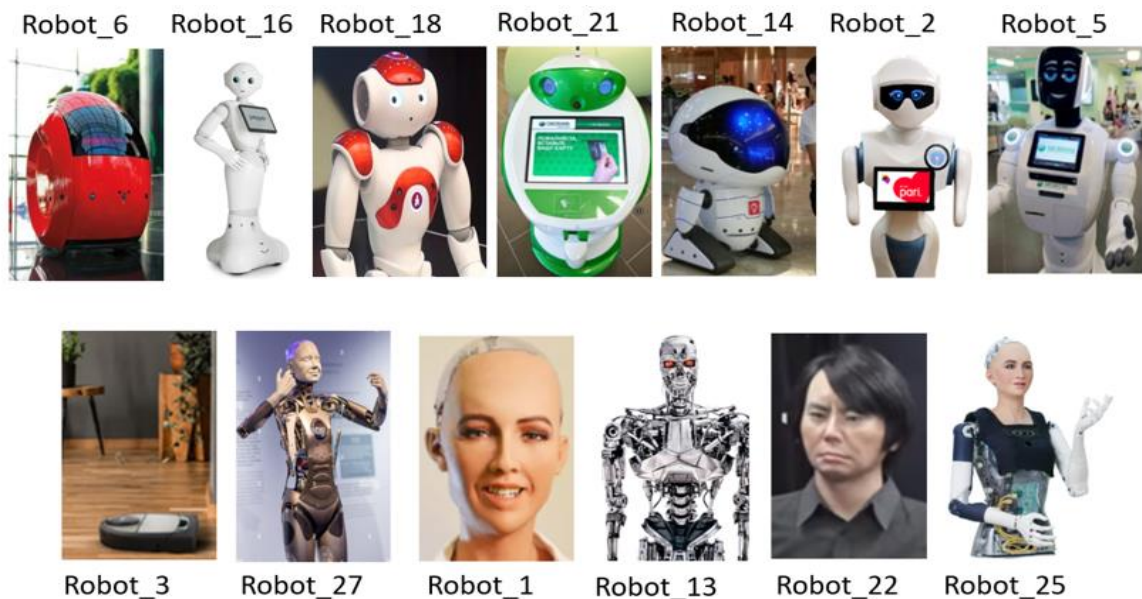
Habár a bankiszektorban egyre népszerűbbek a teljesen autonóm, robotok által működtetett bankfiókok. a szakirodalomban hiányoznak a bankfiókokban alkalmazott fizikai megjelenésű robotokkal kapcsolatos kutatások. Csak Amelia, Mathies és Patterson (2022) vizsgálta a kiskereskedelmi banki robotok elfogadását, és azonosított 16 olyan dimenziót, amelyek befolyásolják a robotok elfogadását, például a hasznosságot, a társas interakciókat, a magánéleti kockázatokat és a korábbi tapasztalatokat (Amelia – Mathies – Patterson, 2022). Ezen kívül Prisznyák (2023) a bankfiókokban alkalmazott fizikai robotok spektrumát és az autonómiával kapcsolatos működési kockázatkezelési kihívásokat vizsgálja (Prisznyák, 2024b).

Az emberek gyakran próbálják emberi tulajdonságokkal és viselkedési jellemzőkkel felruházni a robotokat antropomorfizmus révén. Az elvégzendő feladat jellegétől függően az mesterséges, emberhez hasonló ügynökök fizikai megjelenést igényelhetnek, amelyet különböző életformák alapján terveznek meg (Epley – Waytz – Cacioppo, 2007; Robertson, 2017). A robotok tervezése kulcsszerepet játszik az ember-robot interakció sikeres kialakításában és fenntartásában, és a társas robotokhoz különböző emberi tulajdonságok hozzárendelése széles spektrumot ölel fel (Fox – Gambino, 2021). A funkcionalitás, például az információk verbális és nonverbális kommunikáció révén történő megadása, tanácsadás és irányítás, fontos támogató szerepet játszik a robotokkal szembeni észlelésben és érzelmi viselkedésben (Bhatti – Leidner, 2021). Az udvariasság megnyilvánítása, a társas jelzésekre és kontextusra megfelelő válaszadás, valamint a sokféleség tisztelete elősegítheti a pozitív társas reakciókat (Asprino et al., 2022). A társas képességekkel rendelkező robotok révén a felhasználók/ fogyasztók úgy érzékelhetik őket, mint akik érzelmekkel rendelkeznek (Gültekin, 2022). A társas képességek, mint például a verbális és nonverbális kommunikáció, illetve az emberi tulajdonságokkal és viselkedéssel rendelkező robotokat nagyobb elfogadás övezi (Song – Kim, 2022), és növelik a sikeres ember-robot interakció valószínűségét (Beer – Fisk – Rogers, 2014). Az emberek robotokkal kapcsolatos attitűdjeinek és aggályainak, valamint a banki

robotpénztárosokkal kapcsolatos észlelésük vizsgálatához Mori félelmetes völgy elméletét használják. Ez a koncepció azt írja le, hogy az emberi hasonlóság és a robotok pozitív benyomása (kedvelhetőség) közötti kapcsolat nemlineáris (Mori, 1970).

2023 márciusa és novembere között kérdőíves felmérést végeztem Google Forms-on keresztül. Az elemzésben 181 résztvevő vett részt akik az ember-szerűség és benyomás mentén 26 robotot értékelték, amelyek közül hét banki robot volt (46. ábra).

46. ábra: Az elemzésbe bevont robotok

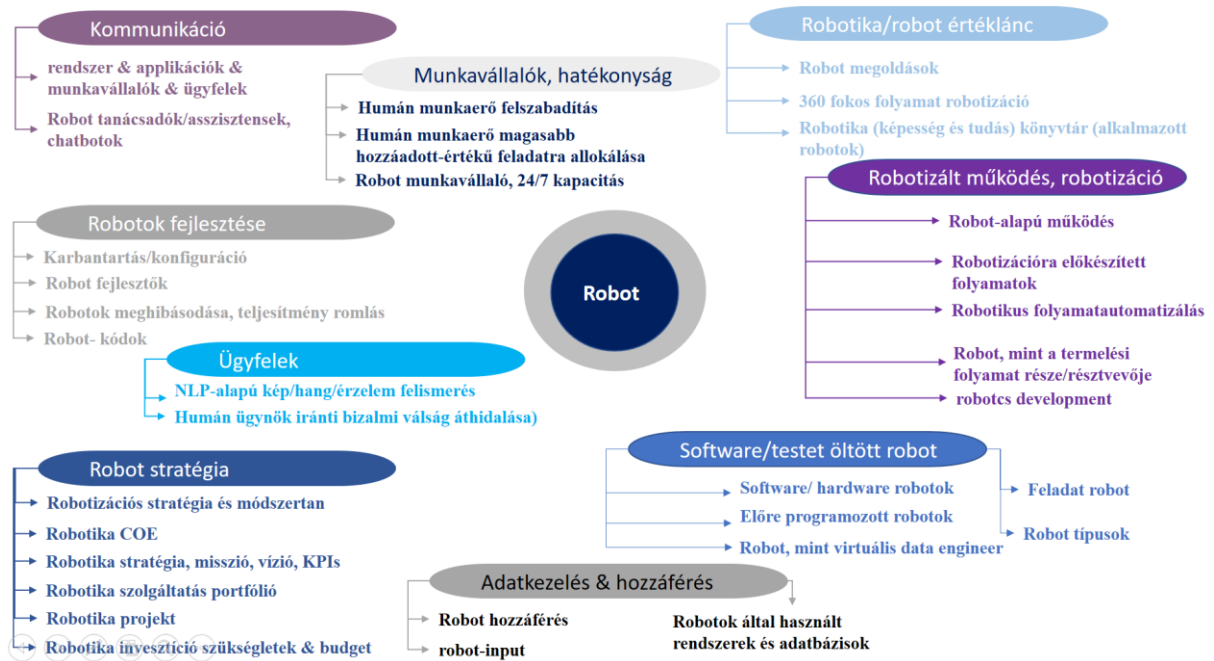


Forrás: Saját forrás

A felmérés célja a résztvevők robotokkal kapcsolatos attitűdjeinek, aggályaiknak és észlelésüknek a mérésére irányult. Az eredmények alapján megállapítottam, hogy az összes banki robot, amelyet bankfiókokban alkalmaznak, az „uncanny valley” előterében helyezkedik el, kevésbé emberi megjelenéssel, de jobb fogyasztói benyomást keltve. A tanulmány rámutatott, hogy a jelenleg használt banki robotok tervezésében a dehumanizáció koncepcióját alkalmazták, hogy javítsák a robotok összesített benyomását, miközben az emberi hasonlóságot szándékosan alacsonyan tartották. Az vizsgálódás eredményeképpen bevezettem a RoboSapiens Bankercus koncepciót, mint egy elméleti, ideálisan tervezett robotot, azzal a céllal, hogy segítse az antropomorf és dehumanizált formák közötti finom egyensúly megtalálását.

8. MELLÉKLETEK

1. számú melléklet: A robot szóhasználat a szakirodalmi források alapján



Forrás: Saját forrás

2. számú melléklet: Az AI fejlettségi szintjei

Jellemző	ANI	AGI	ASI
Alkalmazási kör	Speciális alkalmazási kör (limitált feladatellátási képesség)	Általános (humán) intelligencia imitálása révén feladatok széles körének elvégzése	Bármely feladat elvégzése
Feladat ellátás mértéke	Korlátozott	Korlátlan – emberi képességet számos területen meghaladó	Korlátlan– emberi képességet exponenciálisan minden területen meghaladó
Fejlődési képesség és öntanulás	Programozók által nyújtott fix domain modellek	Öntanuló és érvelő operációs környezet	Folyamatosan fejlődő öntanuló.
Alkalmazott adatok típusa címkézés szerint	Tanulás felcímkézett adatokon	Tanulási adatbázis alacsony számú mintát igényel (strukturálatlan adatokból is)	Tanulási adatbázis alacsony számú mintát igényel.
Humán kognitív képességekhez viszonyított feladatvégzés	Feladat megértése nélküli reflexív feladatvégzés	Humán kognitív képességeket szimuláló széles körű feladatvégzés	Humán kognitív képességeket meghaladó feladatvégzés
Tudás transzferálódás	A feladat végrehajtása során megszerzett tudás nem transzferálódik át más feladatra (domain)	A feladat végrehajtása során megszerzett tudás felhasználása további új feladatok ellátásához	A feladat végrehajtása során megszerzett tudás felhasználása további új feladatok ellátásához
Öntudat és érzések	Nincs	Nincs	Van
Létezés	Létezik	Létezik (kezdetleges)	Hipotetikus

Forrás: Saját ábra

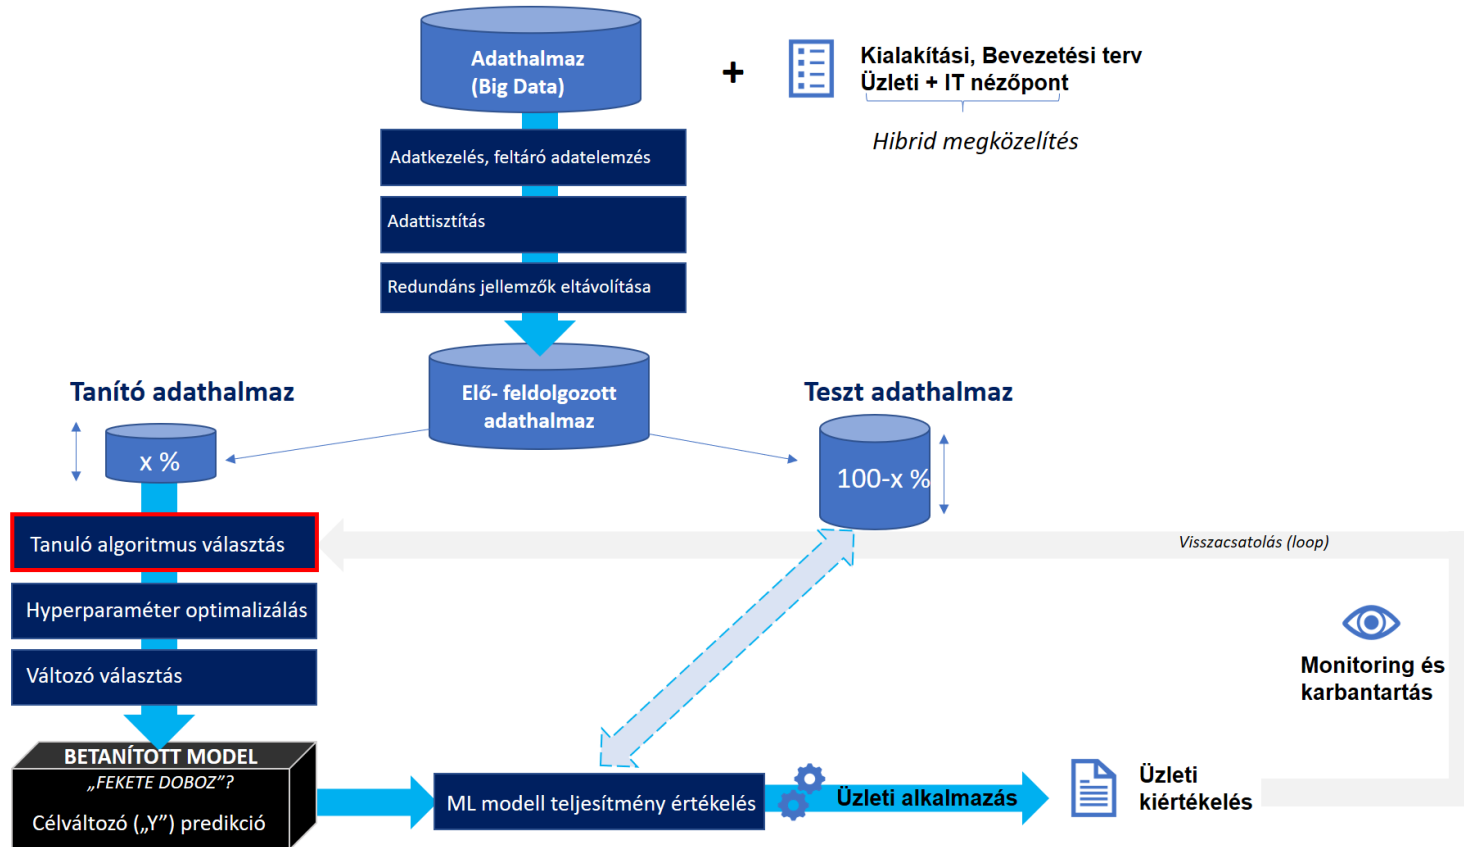
3. számú melléklet: Népszerű algoritmusok gyengeségei és erősségei

Algoritmus	Feladat jellege	Erősség	Gyengeség	Banki alkalmazási terület
DF	osztályozás, anomália detektálás, asszociáció	Egyszerű és könnyen érthető döntési struktúra	Túlzottan egyszerű modell, túlfitalás	Hitelképesség értékelés, csalás detektálás
RF	osztályozás, anomália detektálás,	Jobb pontosság és általánosító képesség, mint DF	Nagyobb számítási igény, kényes a hiperparaméterekre	Betrűgés és csalás detektálás, kereskedési stratégiák
NB	osztályozás	Egyszerű és gyors, hatékony kategorizáció	Feltételezi, hogy a bemeneti változók függetlenek	Spam szűrés, ügyfélprofilok kategorizálása
KNN	osztályozás, asszociáció	Nincs előzetes tanulás szükséges	Kényes a dimenziószámra, nagy számítási igény	Betrűgés detektálás, ügyfélklaszterezés
SVM	osztályozás, anomália detektálás, asszociáció	Hatékony magas dimenziós térben	Érzékeny a zajra, bonyolult paraméterek beállítása	Osztályozás, regresszió
NN	osztályozás	Komplex és nem lineáris relációk kezelése	Nagy adatigény, túlfitalás veszélye	Képfelismerés, személyes ajánlatok
DL	osztályozás	Alacsony szintű jellemzők tanulása bonyolult adathalmazokban	Számítási erőforrások, nagy adatigény	Beszéd felismerés, ügyfélviselkedés elemzés
HMM	osztályozás, klaszterezés	Jól alkalmazható sorozat adatokra	Csak korlátozott mértékben kezeli az idősoros adatokat	Pénzügyi piaci előrejelzés, idősoros elemzés
LR	osztályozás	Egyszerű és interpretálható modellek	Csak lineáris kapcsolatokat képes modellezni	Hitelkockázat értékelés, churn analízis
PLS, LASSO	regresszió	Egyszerű és interpretálható modellek	Érzékeny a zajra, nem kezeli jól nem lineáris kapcsolatokat	Hitelkockázat elemzés, összefüggések feltárása
LARS	regresszió	Alkalmazható nem lineáris kapcsolatokra	Komplexebb és nehezebben értelmezhető modellek	Hitelkockázat elemzés, árképzési modellek

K-mean	klaszteranalízis	Egyszerű és hatékony adatcsoportosítás	Függ az előzetes középértékek kiválasztásától	Ügyfélklaszterezés, kampányok célközönségének meghatározása
BN	anomália detektálás, asszociáció	Jól kezeli a bizonytalanságot és a hiányzó adatokat		
Q-learning	optimális tevékenység választás	Hatékonyan alkalmazható problémamegoldó játékokban	Lassú konvergencia problémái lehetnek	Kereskedési stratégiák, portfólió menedzsment
DBSCAN	klaszteranalízis	Automatikus zajszűrés és nem konvex csoportok kezelése	Érzékeny a hiperparaméterekre, nem alkalmas nagy dimenziós adathalmazokra	
PCA	klaszteranalízis	Dimenzió csökkentés és adatkompresszió	Információvesztés a dimenzió csökkentése során	Adatvizualizáció, portfólió optimalizáció
SARSA	optimális tevékenység választás	Online tanulásra alkalmas, optimális politika megtalálása	Csak korlátozott környezet	

Forrás: Saját táblázat

4. számú melléklet: ML modellépítés tipikus lépései



Forrás: Saját ábra

5. számú melléklet: Kiválasztott algoritmusok összehasonlítása számítási komplexitás tényezői alapján

Összehasonlítás szempontjai	RF	K-NN	SVM	Lineáris regresszió	Logisztikus regresszió	Naive Bayes	K-közép
Tanítási idő komplexitás	$O(n \cdot \log(n) \cdot m \cdot T)$ Sok megfigyelés esetén lassú	$O(k \cdot n \cdot m)$ Sok megfigyelés esetén lassú	$O(n^2)$ alacsony P esetén, míg $O(n^3)$ magas P esetén tanítási idő hosszú	$O(m^2(n + m))$ Tanítási ideje hosszú, végrehajtási ideje rövid.	$O(n \cdot m)$ Rövid, hatékony végrehajtási idő (főleg kis adatbázison).	$O(n \cdot m)$ Alacsony tanítási idő	$O(I \cdot CL \cdot n \cdot m)$ Nagyobb adatkészletnél lassabb
Végrehajtási idő	$O(D \cdot T^2)$	$O(n \cdot m)$	$O(S \cdot m)$	$O(m)$	$O(m)$	$O(o \cdot m)$	$O(n \cdot m + CL \cdot m)$
Tárigény	$O(D \cdot T^2)$	$O(n \cdot m)$	$O(n^2)$ alacsony	$O(m)$ alacsony	$O(m)$ alacsony	$O(o \cdot m)$ alacsony	$O((CL \cdot n) \cdot m)$
Párhuzamos műveletvégzés	Igen	Igen	Nem	Nem	Nem	Nem	Nem
Parametrikusság	Nem parametrikus	Nem parametrikus	Nem parametrikus	Parametrikus	Parametrikus	Parametrikus	Parametrikus
Líneritás	Nem lineáris	Nem lineáris	Lineáris/Nem-lineáris (kernel)	Lineáris	Lineáris	Lineáris	Lineáris

Forrás: Saját táblázat

6. számú melléklet: Az AI bevezetést gátló főbb tényezők

Szerző, év	Terület	Tényezők
Statistik Austria, 2023	Kérdőív az ICT technológiák használatáról	Mesterséges intelligenciával kapcsolatos technológiák figyelmen kívül hagyása, Belső szakértelem hiánya, Jogi bizonytalanságok, Kompatibilitási problémák meglévő berendezésekkel, szoftverekkel vagy rendszerekkel, Nehézségek az szükséges adatok elérhetőségével vagy minőségével, Adatvédelmi aggályok, Költségek, Haszon hiánya, Etikai aggályok
Kumar et al., 2021	indiai közszolgáltatási rendszer	a technológiába vetett bizalom hiánya, korlátozott AI-irodalom, politikai problémák, jogi és etikai kihívások, gazdasági politikák és szabályozások hiánya, IT-szakértelem hiánya, kiépített keretrendszer hiánya, nyelvi komplexitás, átláthatóság hiánya, integrált megközelítés hiánya, IT-infrastruktúra hiánya, felelősség és elszámoltathatóság elvesztése, alacsony ösztönzők, a szereplőkkel való összehangoltság hiánya, a szegények kizárásának félelme, a dolgozók rossz hozzáállása, a fogyasztók motivációjának hiánya és a kognitív tudatosság hiánya
Singhal - Dube - Jain, 2022	bankszektor	tehetség és szakképzett munkavállalók hiánya, a szabályozási politikák, az adatok rendelkezésre állása és minősége, valamint a tudatosság a kritikus akadályok
BMW, 2021	Németországi vállalatok	(1) Költségek és finanszírozás (fejlesztési, bevezetési költségek; finanszírozási források; idő allokációs problémák); (2) alkalmazottak készségei (AI szakértői készség hiányok; alkalmazás iránti hajlandóság hiány; továbbképzési hiányosságok); (3) adat és adatkezelés (Adatvédelmi kérdések, A külső/belső adatokhoz való hozzáférés hiánya; adatok minősége; adatbiztonsági problémák; adatvédelmi követelmények túl magasak, adatvédelmi előírások megfelelő integrálása az AI-alapú adatfelhasználáshoz; Az adatkezelés módszertani ismereteinek hiánya; (4) jogi kihívások (kockázatkezelési és compliance kihívások; technikai eszközök fejlesztése; meglévő rendszerekbe integrálás/felhasználási lehetőségeinek jogi korlátai); (5) AI iránti bizalom és megbízható AI (felhasználók bizalma az AI iránt; átlátható, megbízható AI és kapcsolódó tájékoztatás; lehetséges alkalmazások ismeretének hiánya; hozzáadott értékteremtés bizonyítéka a tradicionális módszerekhez képest); (6) harmadik felekkel való együttműködés (Az üzleti partnerek elégtelen beruházási költségvetése; Egyéni AI-megoldások kínálatának hiánya; A külső támogatás hiánya az AI kérdésekben; Az együttműködési hajlandóság hiánya az egyetemek részéről
OECD, 2021	OECD 37, EU27 KKV-k	erőforrás hiány, szakértelem hiány, hozzáférés az infrastruktúrához, rendszerek alacsony interoperabilitása, az adatkultúra és a digitális tudatosság hiánya, belső készség hiányok, finanszírozási hiányosságok, bizonytalanság a felelősségek és kötelezettségek terén új digitális tevékenységek végzésekor, a hírnév károsodásának kockázatai; kapacitás és képesség hiány a komplex regulációs elvárások teljesítésére (pl: GDPR).
McKinsey & Company, 2018	10 szektor, 1226 cég	Hiányosságok az alábbi terén: AI stratégia, megfelelő készségekkel rendelkező tehetség, funkcionális szilók, vezetők elköteleződésének, technológiai infrastruktúra hiánya, adatok, befektetési bizonytalanságok, alulfinanszírozott AI, adatok korlátozott hasznossága, személyes ítélet felülírja az AI-t, AI betekintések relevancia hiánya, frontvonalbeli folyamatok változásának hiánya.
Grünbichler, 2023	Tudományos adatbázis: Scopus	(1) Menedzseri Szint (Elköteleződés/hozzáértés hiánya a felső vezetés részéről; Szabályozási akadályok / technikai kockázatok kezelése; Hosszú döntéshozatali folyamat; AI stratégia hiánya); (2) Munkavállalói Szint (Kompetencia hiánya – programozási és gépi tanulási készségek, módszertani tudás; Elfogadás hiánya; Gépi tanulási algoritmusok érthetlensége; Frontvonalbeli folyamatok változásának hiánya az AI alkalmazása után); (3) Szervezeti Szint (Funkcionális szilók korlátozzák az end-to-end AI megoldásokat; AI-ra vonatkozó alulfinanszírozás a vonali szervezetben; Személyes ítélet felülírja az AI-alapú döntéshozatalt); (4) Adat Szint (Belső adatok rendelkezésre állásának hiánya; Adatok korlátozott hasznossága; Adatbiztonsági problémák; Adatvédelmi aggályok); (5) Külső Szint (Külső támogatás hiánya AI kérdésekben; Üzleti partnerek elégtelen beruházási költségvetése AI megoldásokhoz; Vásárlói bizalom hiánya; Egyetemek vagy kutatóintézetek együttműködési hajlandóságának hiánya; Külső adatokhoz való hozzáférés hiánya; Közvélemény tájékoztatása az AI-ról és az AI alkalmazások előnyeiről)
Prisznják, 2023c		(1) Compliance-jogszabályok betartása (Jogszabályoknak (AI-jogszabály, DORA-, GDPR-rendelet, egyebek) megfelelő működtetés, kockázati osztályozás; etikai iránymutatások érvényre juttatása); (2) Ügyfél-tájékoztatás és szerződéses (Ügyfél-tájékoztatás a jogszabályi előírásoknak megfelelően – ügyfélszerződésbe integrálás); (3) Alkalmazási korlátok (nemzetközi és hazai szabályozói környezet lassú adaptációja); (4) Regulációs sand bokx (Modell tesztelési lehetőségének megteremtése az üzleti terület számára (banki IT-/AI-szakértők támogatása)), (5) Adatszolgáltatási kötelezettség, dokumentáció (Modell és üzemeltetési követelményeknek (műszaki dokumentáció, nyilvántartás követelményeinek) való megfelelés).

Forrás: Saját táblázat

7. számú melléklet: Etikus AI elvárások formálódása

Asimow a „Runaround” (1942) című novellájában a gépek etikus alkalmazásával és viselkedésével összefüggésben lefektette a robotika három törvényét, amely a mai napig vitatott. Ugyanakkor az etikai elvek kialakítása során iránymutatásul szolgál.

A későbbiekben Asimov a „The Evitable Conflict” (1950) novellájában módosítja az első törvényt, kiterjesztve az emberiség egészségének védelmére (Asimov, 1950:146). Wiener (1948) az intelligens viselkedés gépek által megvalósítható szimulációjának lehetőségét a „Cybernetics: or Control and Communication in the Animal and the Machine” című munkájában az információ- és visszacsatolási mechanizmusokra vezeti vissza. Kapcsolódóan a kezdeti mesterséges intelligencia kutatásokhoz, Neumann a Hixon Symposium (1948) keretében az elsők között ismertette a kognitív architektúrák, emberi agy működéséhez hasonló felfogásának, így a gondolkodó gépek működésének alapjait – amelyet a későbbiekben "The General and Logical Theory of Automata" cikkében – tárgyal (Neumann, 1963). Turing a „Computing Machinery and Intelligence” tanulmányában a gépek fejlődéséről értekezik: „a gépek végül versenyezni fognak az emberekkel az összes, tisztán intellektuálisnak tekinthető területen” (Turing, 1950:22). A természetes és mesterséges intelligencia között húzódo kimondatlan verseny az agy működési modellje alapján formálódik. A számítógépek és az emberi agy működése közötti hasonlóságot és különbségeket Neumann a „The Computer and the Brain” könyvében ismerteti (Neumann, 1958). Weizenbaum 1966-ban befejezi a demonstrációs célú számítógépes program (ELIZA) írását, amely a számítógépek intelligens viselkedését hivatott demonstrálni. A széleskörű publicitást hozzájárult a mesterséges intelligencia kutatásokat támogató piaci hangulat fellobbanásához. Az emberek megtévesztésére alkalmas chatbottal kapcsolatosan felmerülő etikai aggályokról Weizenbaum a „Computer power and Human Reason” könyvében fejti ki álláspontját és a humán érték megóvásával kapcsolatosan felhívja a figyelmet a fejlesztési folyamatokba integrálandó etikai elvek szükségességére (Weizenbaum, 1976).

Bár a mesterséges intelligencia fejlődésének kezdetét az 1956-os dartmouth-i konferenciával azonosítják, a társadalmi felelősségvállalással kapcsolatos kezdeti gyökerei az 1991-ben megrendezésre kerülő „Artificial Intelligence and Social Responsibility” (San Francisco, USA) konferenciához kötődnek. Az első és második AI-telet követően az etikus gépek és a mesterséges intelligencia kutatási terület is egyre nagyobb popularitásra tett szert 1990-es évektől (Yu, et al., 2018). Anderson az intelligens gépek etikai viselkedését a gép által

kivitelezett cselekmény adott helyzethez társítható morális, etikai kritériumok igazolásához köti (Anderson, 1995). Kapcsolódóan a gépek etikus döntéshozatalához Friedman és Nissenbaum a „Bias in Computer Systems” felállítanak egy keretrendszert a gépek diszkriminációmentes döntéshozatalának elősegítése céljából (Friedman–Nissenbaum, 1996). Az ezredfordulót követően Veruggio (2007) a humanoid robotok fejlesztésével kapcsolatos etikai problémákról értekezik, míg Anderson és Anderson megállapítja, hogy az etikus AI keretrendszer az emberi értékrendre és erkölcsre épülő AI-rendszerek létrejöttét hivatott támogatni (Anderson–Anderson, 2011). Az etikus AI kutatások szórványos megjelenése ellenére az AI etikai kérdéseit tárgyaló első konferenciára („Ethics of Artificial Intelligence”, New York, USA) 2016-ig várni kellett.

Az AI rendszerek szabályozásakor a szabályozó hatóságok olyan alapvető etikai vonatkozással bíró kihívásokkal szembesülnek, mint az erkölcsi, etikai jó univerzális absztrakt fogalmának meghatározása. Adódik tehát a kérdés, mit tekintünk az etikus AI harmonizált koncepciójának, igazságosnak, jogilag elfogadhatónak, megbízhatónak és biztonságosnak?

A kérdésre adott válasz számos esetben evidensnek tűnhet, ugyanakkor közelebbről vizsgálva egy komplex, terület-és társadalomcsoportonként eltérő, kulturális dilemmához jutunk (Awad et al., 2018). Az etikus AI-rendszer tervezésének kérdésköre összefüggésben van a természetes intelligencia filozófiai és normatív etikai felfogásaival (Prisznyák, 2023b). A problémát a kulturális eltérésekből is adódó etikai dilemmák jelentik. Kirkpatrick megállapítása alapján a cselekvési alternatívák elfogadott etikai elvek mentén történő választása etikai dilemmákat eredményezhet (Kirkpatrick, 2015). Következésképpen, korábbi kutatásom során hangsúlyoztam, hogy az etikus AI kérdésköre a kulturális etikusság kérdése is egyben (Prisznyák, 2023b).

Az etika keretrendszerében az etikus AI a társadalmi igazságosság és az emberiség jólétének előmozdításául szolgáló eszközként tekinthető, amely az emberi értékrendre és erkölcsre épül. A mesterséges intelligencia fejlesztésével és tervezésével kapcsolatos dilemmákat tárgyalva Denning és Denning felhívja a figyelmet az AI fejlesztéssel összefüggő etikai dilemmák létezésére, amelyek az üzleti érdekek alapján nem feltétlenül szolgálják a technológia-alapú társadalmi érdeket (Denning – Denning, 2020). Következésképpen, az etikus AI-rendszer összhangot feltételez az AI rendszer tervezése és működése, valamint az azt szabályozó társadalom – lásd Európai Unió- által elvárt és elfogadott erkölcsi normák között.

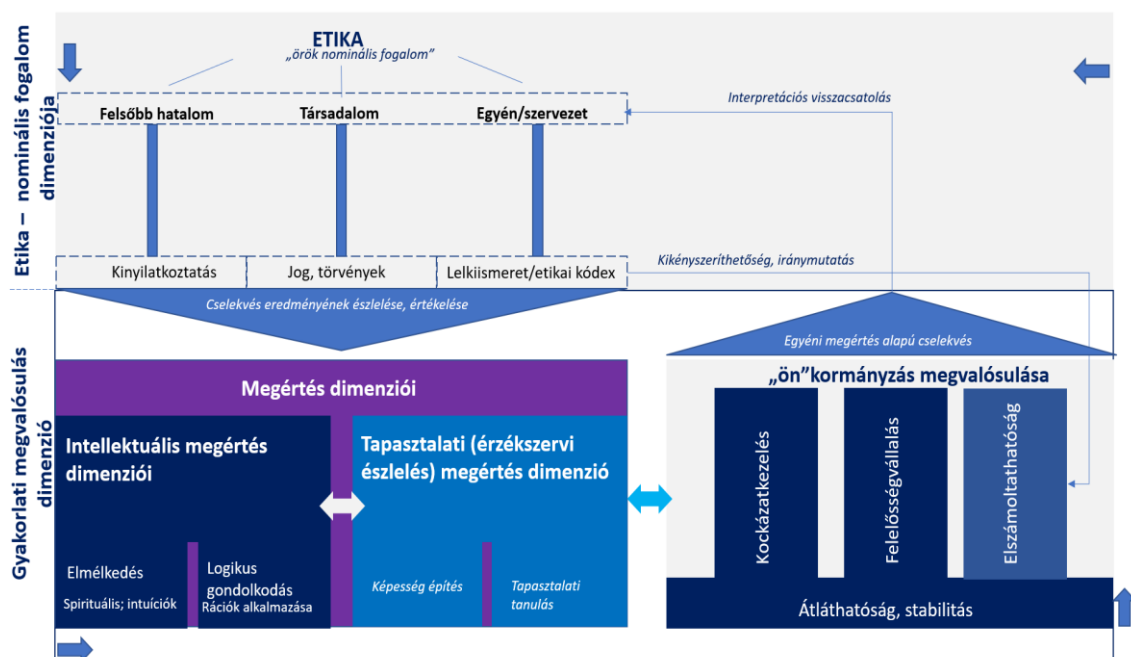
2015-öt követően, az „AI szuperhatalmak” is értekeznek etikai elvek AI-rendszer működési mechanizmusába illesztésének kereteiről. Az amerikai álláspontot képviselő „Report on the Future of Artificial Intelligence” (2016) megjelenését követően az Európai Bizottság (2019) kiadta „A megbízható mesterséges intelligenciára vonatkozó etikai iránymutatását”, amelyet az ázsiai régióban vezető szerepet betöltő Kína 2019-ben publikált álláspontja követett (Beijing AI Principles) (European Commission, 2018; Executive Office of the President National Science and Technology, 2016; Beijing Academy of Artificial Intelligence, 2019; COM/2018/237 final). Ezen állásfoglalásokat nemzetközi viszonylatban kiemelendő jelentőséggel bíró intézmények publikációi egészítették ki (European Banking Federation, 2019; OECD, 2019; IEEE, 2021; EBA, 2021). Jobin, Lenca és Vayena 84 nemzetközi etikus AI-t szabályozó dokumentum átfogó vizsgálata alapján 11 etikai értéket és irányelvet azonosított (Jobin – Lenca – Vayena, 2019). Ezek közül számos etikai irányelv esetében nemzetközi konvergencia megfigyelését emelik ki. Az etikus viselkedéssel összefüggő elvek proliferációjából kiindulva Floridi és Cowls a mesterséges intelligencia alábbi négy alapelvét azonosították: jótékonyosság, károkozás-mentesség, autonómia, igazságosság, amelyet egy ötödik elv - megmagyarázhatóság hozzáadásával egészítettek ki (Floridi – Cowls, 2019). Hagendorff 22 irányelvet eleméz és megállapítja, hogy az elszámoltathatóság, az értelmezhetőség, a magánélet védelme, az igazságosság, az átláthatóság, a robusztusság és a biztonság a legkönnyebben operacionalizálható elvek közé tartoznak (Hagendorff, 2022). Az AI nemzetközi szabályozásában bekövetkezett kedvező fordulat ellenére, Yu és szerzőtársai a felelős AI-rendszerek fejlesztésének kihívásait és fontosságát érintően hangsúlyozza az etikai szempontok integrációjának hiányát az AI rendszerek fejlesztése során (Yu et al., 2018). Ugyanakkor az AI-washing térnyerésével párhuzamosan az "etikamosás" („ethics washing”) jelenség is terjedőben van, amely gyakorlat keretében félrevezető módon (szándékosan) hangsúlyozzák az etikai elvek iránti elkötelezettséget, miközben valójában nem követnek valódi etikai normákat (Prisznyák, 2023b).

Korábbi kutatómunkám során a gyakorlatban is alkalmazható megoldások kidolgozása érdekében összehasonlító elemzést végeztem az EU mesterséges intelligenciáról szóló jogszabálya és a megbízható mesterséges intelligenciára vonatkozó etikai irányelvek között. Ennek során két kritikus hiányosságot azonosítottam: (1) az AI-rendszerfejlesztők és felügyelők etikai érzékenyítésének és képzésének szükségességét, valamint (2) a káros visszacsatolási hurkok és döntéshozatali torzulások kezelésének hiányát. E problémák áthidalására javaslatokat dolgoztam ki, amelyekhez 21 filozófus filozófiai és etikai örökségét használtam

iránymutatásként, célul tűzve ki az azonosított hiányosságok és a szervezeti integrációs problémák megoldását. A gap elemzés eredményét, illetve az etikus AI rendszerek kialakítását támogató feladatmátrix leírását a 8. számú mellékletben helyeztem el, mivel túlfeszítené jelen értekezés gondolatmenetét. A kutatást mélyinterjúkkal egészítettem ki és megállapítottam, hogy az etikai elvek az üzleti gyakorlatban jellemzően még gyerekcipőben járnak és nem kerülnek célirányosan tárgyalásra, elemzésre az AI rendszerek tervezése során (Prisznyák, 2023b).

Az etika fogalma különböző szinteken és csatornákon keresztül értelmezhető, legyen szó egyéni, szervezeti vagy társadalmi szintről, illetve vallási vagy más nézőpontokról. A szervezeti értékekhez igazodó, stratégiába illeszkedő elvek lefektetése – például egy etikus AI kódex formájában – kulcsfontosságú lehet az AI-rendszerek megbízhatóságának növelésében és a bizalom kialakításában az érintett felek között. Ennek érdekében szükséges, hogy az etikus AI szervezeti szinten is értelmezésre kerüljön, és hogy a gyakorlatban az elvek folyamatos fejlődése történjen meg, amely a társadalmi visszacsatolások alapján finomodva közelít a harmonizált etikai normákhoz. Az etikus AI fejlesztését és alkalmazását egy folyamatos iterációs folyamatnak tekintem, amely megteremti a megbízhatóság alapjait. Ezért javaslatot tettem arra, hogy a szervezetek gondolják át és formálják meg etikai elveiket, amelyhez a 17. ábra nyújthat további útmutatást (Prisznyák, 2023b).

Etika szervezeti interpretációjának megvalósulása – a szerző értelmezésében



Forrás: Saját ábra

8. számú melléklet: Etikus AI gap elemzés

Korábbi kutatómunkám során gap elemzést végeztem a megbízható mesterséges intelligencia etikai irányelveit tartalmazó iránymutatás, illetve az AI rendelet követelményeinek összehasonlítására (Pisznyák, 2023b). Az összehasonlító elemzés – direkt megfeleltethetőség hiányában– nem tárgyalja az etikai iránymutatás alábbi két kritériumát: (5.) sokféleség, megkülönböztetésmentesség és méltányosság; (6.) társadalmi és környezeti jólét, amely egyben az összehasonlító gap elemzés korlátjaként értelmezendő.

Az AI Act és az etikus AI iránymutatás megfeleltetése

Megbízható AI etikai iránymutatása		COM (2021) 206 final	
Fejezet/pont	Megbízható AI etikai elvek követelményei	Cím/fejezet/cikk	AI Jogszabály követelmények
II. fejezet 1.	Az emberi cselekvőképesség támogatása és emberi felügyelet	III. cím, 2. fejezet 14. cikk	Emberi felügyelet
II. fejezet 2.	Műszaki stabilitás és biztonság	III. cím, 2. fejezet 15. cikk	Pontosság, stabilitás és kiberbiztonság
II. fejezet 3.	Adatvédelem és adatkezelés	III. cím, 2. fejezet 10. cikk	Adatok és adatkezelés
II. fejezet 4.	Átláthatóság	III. cím, 2. fejezet 13. cikk	Átláthatóság és a felhasználók tájékoztatása
II. fejezet 7.	Elszámoltathatóság	III. cím 3. fejezet 17.cikk	Minőségirányítási rendszer

Forrás: Saját ábra

Az elemzés eredményeképpen két hiányosságot azonosítottam: (1) az AI-rendszer fejlesztők és felügyelők etikai érzékenyítése, képzése; (2) a káros visszacsatolási hurkok és döntéshozatali torzulás javasolt kezelése. Az összehasonlító elemzés eredményeképp azonosított Gap1 és Gap2 hiányosságot és azok relevanciáját az alábbi táblázat összesíti.

Az Etika és technikai területek találkozása - gap elemzés

Elemzési szempontok	Etikai követelmények	AI rendelet követelménye	Azonosított gap
Gap elemzés alapja	Az emberi cselekvőképesség támogatása és emberi felügyelet 2.fejezet (1.)	Emberi felügyelet III. cím 2. fejezet 14. cikk	AI-rendszer fejlesztők és felügyelők etikai érzékenyítése, képzése
Gap részletezése	A felügyeletet ellátó személy szükséges képességeit (rendszer működés, kapacitás, korlátok megértése képessége) az etikus iránymutatás nem részletezi. Kizárólag a felügyeleti módok, a kockázatok elemzésén és a felhasználók szempontjából közelít.		
Relevancia indoka (etikai aggály)	Előfordulhat, hogy az AI-rendszerek döntéshozatala hátrányosan hathat bizonyos csoportokra (alapvető jogok, biztonság, méltányosság). Az etikus emberi felügyelet ellátásához a technikai tudás és etikai érzékenyítés szükséges – mind a fejlesztők, mind az üzemeltetők és felügyelők számára – a következmények időben történő észlelése, kezelése és megelőzése érdekében.		

Kapcsolódó probléma	AI-rendszert fejlesztők, felügyelők, üzemeltetők etikai érzékenyítése jellemzően elmarad az üzleti tervezés és implementáció során.		
Gap elemzés	Műszaki stabilitás és biztonság 2. fejezet. (2.)	Pontosság, stabilitás és kiberbiztonság III. cím 2. fejezet 15. cikk	káros visszacsatolási hurkok és döntéshozatali torzulás
Gap részletezése	Az etikai iránymutatás nem értekezik a rendszer által jónak ítélt, valójában hibás visszacsatolási hurkok meglétéről és kezelésük módjáról.		
Relevancia indoka (etikai aggály)	Az AI-rendszerek esetében előfordulhatnak káros visszacsatolási hurkok, amelyek során a rendszer helyesnek ítélt, mégis hibás döntéseket a későbbiekben inputként használ, megerősítve a hibás döntéseket. Egy negatív folyamat indul el, amely a rendszer döntésein keresztül a környezetre nézve is negatív hatást eredményezhet.		
Kapcsolódó probléma	A visszacsatolási hurkok az adat, a modell és a felhasználói interakció torzulását eredményezhetik, amennyiben az AI-rendszer üzemeltetése, alkalmazása során nem megfelelő a monitoring folyamat, illetve a szükséges adatkorrekciók elmaradnak.		

Forrás: Saját táblázat

A $Gap1_{jav.Gap1\ int}$, $Gap1_{jav.Gap2\ int}$ és $Gap2_{jav.Gap1\ int}$, $Gap2_{jav.Gap2\ int}$ alapján elmondható, hogy a $Gap2$ feloldása során alkalmazott munkavállalói etikai képzés számos, etikai kritériumot (adatvédelem, adatkezelés, átláthatóság, elszámoltathatóság) érintően gyakorol hatást a műszaki stabilitásra és a kockázatkezelésre. Az azonosított gap-ek ($Gap1$, $Gap2$) értelmezése ($Gap1_{int.}$, illetve $Gap2_{int.}$) alapján az alábbi, feladatmátrix táblázatban feltüntetett javaslatokkal élek (interpretáció $Gap1-Gap1_{int.}$, interpretáció $Gap2-Gap2_{int.}$) a hiányosságok üzleti implementáció során történő feloldása céljából.

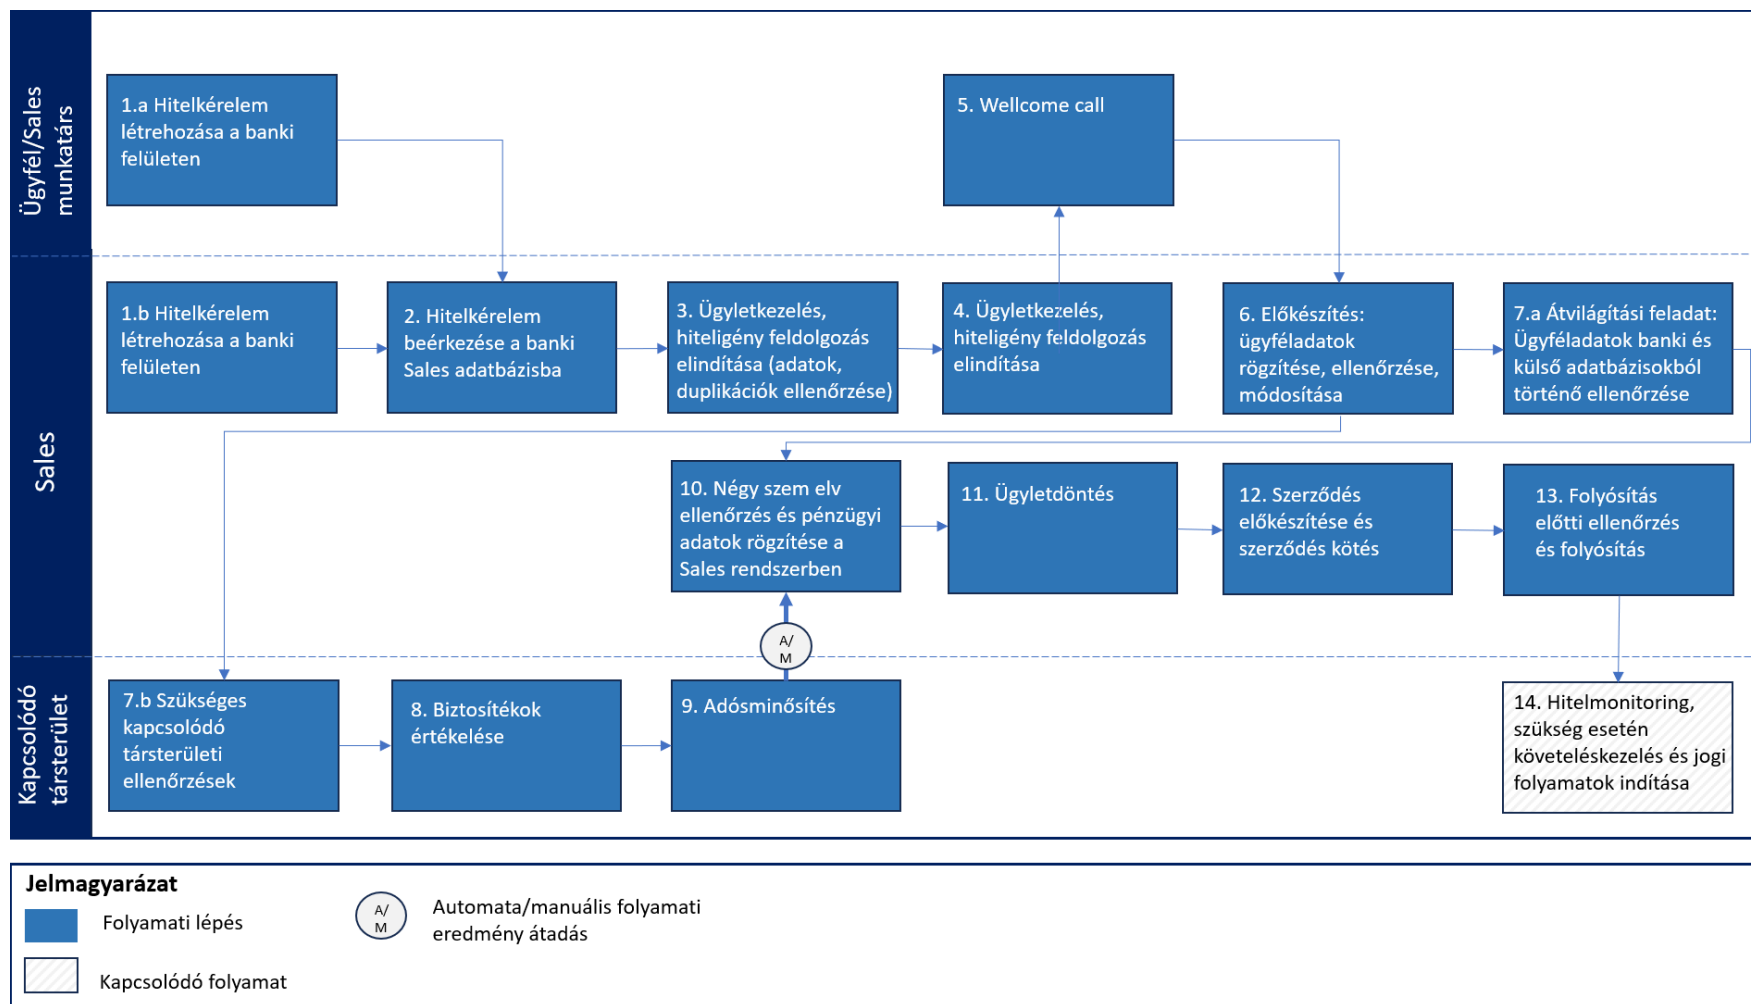
táblázat: Javaslataim az etikus AI üzleti implementációjának elősegítésére- feladatmátrix

		Megbízható AI-ra vonatkozó etikai iránymutatás azonosított hiányosságai	
		Gap 1	Gap 2
Interpretáció	Gap 1 _{int.}	<p>Gap1_{jav.Gap1 int}</p> <ol style="list-style-type: none"> Etikai kódexek revíziója az etikus AI-rendszerek szervezeti keretbe illesztése AI stratégia részeként a szervezeti stratégiába illesztés biztosítása Kultúrába illesztés - szervezet átfogó és specifikus etikai érzékenyítése (felügyelők, fejlesztők, érintett üzleti területek specifikus képzése, oktatás) Felelős szervezeti egység Működési folyamat kialakítása: követelmények, feladatok (termék célcsoport (társadalom, kultúra) etikai normáinak vizsgálata) kialakítása, folyamatok szabályozása (szabályzatok, utasítások kidolgozása) Kockázatkezelési folyamat: monitoring folyamatok és eszközrendszer 	<p>Gap2_{jav.Gap1 int}</p> <ol style="list-style-type: none"> Modell korlátok objektív megfogalmazása (etikai fékek beépítése) és a modell tanulás során tanúsított folyamatos monitoring Modell döntési eredményének körültekint, szkeptikus értelmezése Folyamatos monitoring (stabil, meghízható működés) a hibák redukálása érdekében Adatkormányzás és adatelőkészítés A rendszer működési mechanizmusának megértése, átláthatóság biztosítása jelenségek megszüntetése, megmagyarázhatóság biztosítása)

Gap 2 _{int.}	<p>(limitek, mérőszámok), felelősök és következmények, Compliance biztosítása</p> <p>7. Etikai fórum kialakítása: felmerülő aggályok diskurzusának színtere</p>	<p>13. Szubjektív etikai elvek érvényesülésének negligálása (beprogramozott, érintett fél érdeke, célorientált (profit))</p>
	<p>Gap1_{jav.Gap2 int}</p> <p>14. Tapasztalatok kodifikációjának támogatása</p> <p>15. Incidens jelentések gyűjtése (riport vezetés) – jelentés a fórumok, felelős szervezeti egység felé</p> <p>16. Beavatkozási szituációk és kritériumainak meghatározása manuális döntés, döntés felülvizsgálat, rendszer leállítás lehetőségei</p>	<p>Gap2_{jav.Gap2 int}</p> <p>17. Alkalmazott algoritmusok megfelelő megválasztása (az egyszerűség elve alapján áttekinthetőség-pontosság trade-off)</p> <p>18. Rendszer önreflexió a tanulási folyamat során (alkalmazott teljesítmény, pontosság mérési metrikák)</p> <p>19. Etikai elvek stabil ontológiai leképezése</p> <p>20. Káros visszacsatolási hurkok jelentése, közzététele: incidens adatbázis</p>

Forrás: Saját szerkesztés Prisznyák, 2023b, pp.:185 alapján

9. számú melléklet: A hitelezés tipikus folyamata



Forrás: Saját ábra

10. számú melléklet: Adatkészletek kiegyensúlyozásának módszerei

Módszer	Eljárás	Leírás	Ajánlott alkalmazás
Minta újraválasztás (Resampling)	Alul-mintavételezés	A többségi osztályból véletlenszerűen eltávolított elemek révén a két osztály aránya kiegyensúlyozottabb lesz.	Amikor a kisebbségi osztályban kevés elemszám van.
	Túl-mintavételezés	A kisebbségi osztály elemszáma kerül növelésre ismétlődően hozzáadva, vagy mesterségesen generált adatok révén.	Amikor a kisebbségi osztályban kevés példa van.
Mesterséges adatgenerálás	SMOTE	Új, mesterséges példákat generálása a kisebbségi osztály egyedei közötti távolságok alapján.	Kisebbségi osztály feltöltése új példákkal
	ADASYN	Mesterséges példákat létrehozása súlyok alapján, amelyek meghatározzák az egyedek fontosságát.	Kisebbségi osztály feltöltése új példákkal, de súlyokkal finomítva.
Hibrid módszerek	Borderline-SMOTE	Mesterséges példákat hoz létre az osztályhatáron lévő egyedekből, ami segíthet a határvonalon lévő egyedek kiegyensúlyozásában.	Amikor az SMOTE nem hozott megfelelő eredményeket.
Súlyozott példák és algoritmusok	Adatpontok súlyozása	Az algoritmusok révén súlyokat rendel az egyedekhez, hogy kiegyensúlyozottabban kezelje őket.	A tanító adatok fontosságának megkülönböztetése során
Algoritmusok beállításai	Osztálysúlyok állítása	Osztályok súlyának beállítása algoritmusok révén.	A súlyozás kiegyenlítése algoritmus révén
Felügyelt tanítású módosított algoritmusok	Címkék kiegyensúlyozása	Új címkék készítése a tanító adatok számára, hogy kiegyensúlyozottabb állomány álljon rendelkezésre.	Egyenletlen címkézés simítása algoritmus révén.

Forrás: Saját táblázat

11. számú melléklet: Sales, marketing területen alkalmazott ML megoldások áttekintése – összefoglaló táblázat

Szerző(k), év	üzleti cél	ML algoritmus	Adatbázis	Teljesítmény indikátor	jellemzőindikátorok	Eredmény
Moro –Cortez –Rita (2015)	LTV alapú megtérülés javaitása, bankbetét eladások (kampányok) tervezése	NN	banki telemarketing kampányadatok, időablak: 2008-2013; 1293 kontakt adat	AUC, ALIFT	22 változó (ügyféladatok, hívás adatok, pénzügyi és gazdasági adatok	a historikus információk használata jelentősen javította a pontosságot, és két új LTV bemeneti változó is fontosnak bizonyult a modell teljesítményében.
Guliyev, Tatoğlu (2021)	potenciálisan lemorzsolódó ügyfelek előrejelzése	XGBoost, DT, RF	kereskedelmi banki 274542 ügyfél ügyfél adat (274542 ügyfél); kiegyensúlyozatlan (churn 11,5%)	AUC, ROC, sensitivity, ACC, Specificity	churn státusz, életkor, átlagos jövedelem; nem, hitelösszeg, kamat ráta, az utoljára lehívott hitel felhasználásának időtartama. hitelvisszafizetés (pozitív értéke: kérdésbe esett – dpd), hitelkeretösszeg növekedése (I/N), verseny-alapú régóban él az ügyfél (I/N), van hitelkártyája az ügyfélnek (I/N), salary kártya van-e (I/N), ügyfélhez tartozó hitelügyletek száma	Shapley értékeket alkalmaz Az XgBoost teljesít (auc:96,97%)a legjobban, amit a RF követ
Mandurkar et al. (2022)	potenciálisan lemorzsolódó ügyfelek előrejelzése	k-NN, SVM, DT, FT, LR, XGBoost	hitelkártya adatok Kaggle	recall, accuracy	igénybe vett termékek száma, hitelminősítés, Földrajzi hely (származási ország), Nem, Életkor, a számla mennyi ideje aktív, Egyenleg, Van bankkártyája, Aktív ügyfél-e, jövedelem becsült értéke, Elhagyta a szolgáltatást (I/N), vezetőknék, fogyasztó egyedi ID-je	SMOTE túlmintavételezési technikát alkalmaz. A modellnek rögzített és potenciális adatforrásokkal kell rendelkeznie, és minimális információval szükséges operálnia a hatékonyság érdekében.
Verma (2019)	perszonalizált kampány a takarékszámra ügyfeleknek a lemorzsolódás megakadályozása érdekében	LR, DT, RF, ANN, XGboost	szűrt kereskedelmi banki adatbázis (megjegyzés: 21-50 éves ügyfelekre és materiality thresholdra leválogatva)	ROC, AUC, Gini-koefficiens, pontosság, specifitás, érzékenység	életkor, átlagos egyenleg, foglalkozási kód, lakossági hitel típusa, átlagos hitelösszeg és átlagos tranzakció szám	Alumintavételezést alkalmaz. AZ RF bizonyul a legerősebb modellnek, amelyet az ANN értékei követnek.

Leung, Chung (2020)	dinamikus ügyfeladatok elemzésen alapuló churn előrejelző modell –hosszú időablak hatásának vizsgálata	LR, RF, GBM	kereskedelmi banki adatbázis (USA); 32.000 ügyfeladat; időablak: 2016 - 2019	accuracy, precision, recall	születési év, megtakarítási termékek száma, hűségidő, hiteltermékek száma, közvetett hitel jelzők, hitel/bankkártya jelzők, számlanyitás/lezárás dátumai. Számlatevékenységek: közvetlen befizetések száma és összege, számlafizetések száma, hitelfizetések száma és összege, bankfióki látogatások száma, bankkártya tranzakciók száma, online tranzakciók száma	a dinamikus osztályozási megközelítés során rögzített dinamikus vevői viselkedés és trendfaktorok a több képzési időszak során alkalmazott SMOTE révén képesek az előrejelzés optimalizálására. A hosszabb vizsgálati időablak célja annak tesztelése, hogy a pontosság marginális növekedését javítja-e vagy csökkenti az időablak hosszának változtatása.
Tran - Le – Nguyen (2017)	hitelkártya churn ráta prognózis	SVM, DT, RF, LR, k-NN	Kaggle, 10127 hitelkártya adat	pontosság, precision, recall, F1 pontszám	21 változó - ugyanaz, mint Cao (2021) esetében	Az ügyfélszegementációnak nincs hatása a modell ügyféllemorzsolódás előrejelzésének képességére. A legjobban teljesítő algoritmus a RF és az SVM.
Seymen et al. (2022)	potenciálisan lemorzsolódó ügyfelek előrejelzése	ANN, CNN ÖsszBench M: LR, SVM, k-NN	kiskereskedelmi adatbázis (5747 ügyfél), időablak: 2018 – 2020 (27 hó)	accuracy, precision, recall, AUC	demográfiai adatok (életkor, iskolai végzettség, jövedelem, foglalkoztatási státusz) és viselkedési adatok (kategóriánkénti vásárlások száma, összege, havi promóciók a termékkategóriákban)	A legjobban teljesítő modellek a mélytanuló algoritmusok: a CNN – viszont futási ideje jelentős-, majd az ANN, amelyeket az SVM (hasonló teljesítmény), illetve a LR, majd a k-NN követ.
Cao (2021)	ügyféllemorzsolódás előrejelző modellek magyarázhatóságának javítása	LR, GB, RF, NB	hitelkártya ügyfelek; Kaggle adatbázis (10.000-es mintanagyság); kiegyensúlyozatlan (churn 16,07%)		21 változó - ugyanaz, mint Cao (2021) esetében	SHAP módszert alkalmaz, A legjobb előrejelző a GB. Az egyes modellek eltérhetnek abban, hogy a célváltozót melyik változó befolyásolja leginkább.
Sabbeh (2018)	benchmark felállítása a churn ügyfelek előrejelzésére	LR, DT (CART), NB, SVM, k-NN; ensemble learning modell: adaBoost, GB, RF; ANN	telekommunikáció vállalat adatai	17 magyarázó ügyéljellemező a szolgáltatás használatával kapcsolatosan	pontosság	A legjobb teljesítményt az együttes tanulási technikák érték el: RF és AdaBoost (96%-os pontosság), ezt követte az MLP és SVM (94%), majd a DT (90%) és a NB (88%), végül a LR és diszkriminancia analízis (86,7%)

Hea et al. (2014)	potenciálisan lemorzsolódó ügyfelek előrejelzése	SVM, LR	kínai kereskedelmi bank ügyfél adatai (50000); időszak: 2011-2012	pontosság, F1-pontszám	ügyfelek személyes (életkor, nem, oktatás, jövedelem, foglalkozás, szolgáltatási idő, vagyon/hozzáadott érték aránya, egyebek) és üzleti indikátorai (betéti számlák, betéti egyenleg, betétek száma, fogyasztási összeg, egyebek)	Az erőteljesen kiegyensúlyozatlan adatbázis miatt az SVM nem megfelelő előrejelző algoritmus és az értékelési kritériumok nem mérik megfelelően a modell előrejelző erejét. A véletlenszerű mintavételezés jelentősen javítja az SVM modell előrejelzési pontosságát.
Loukili – Messaoudi – El Ghazi (2022)	potenciálisan lemorzsolódó ügyfelek előrejelzése az árazási terv, ajánlat javítása, promóciók, ügyfélpreferencia meghatározása érdekében	k-NN, LR, RF, SVM	Kaggle adatbázis, telekommunikációs iparág	pontosság, precision, recall, F1-pontszám, ROC görbe	20 ügyféljellemző	A modellek magasabb előrejelző pontosságot értek el a hiperparaméterek keresztvalidációval történő beállítására. Az SVM a legjobban teljesítő modell
Elrefai – Elgazzar – Khodeir (2021)		DT, k-NN, RF, NB, SVM	Portugál bank telemarketing adatai (UCI elérhető online adatbázis); 45 ezer adat	pontosság, hiba ráta, precision, recall, F1-pontszám	16 attribútum (kor, foglalkozás, családi állapot, oktatás, fizetési nehézségek, lakáshitel, személyi kölcsön, kapcsolat típusa, hónap, hét napja, időtartam, kampány, pdays, korábbi kapcsolatok száma, kimenetel előrejelzése, foglalkoztatási változó, fogyasztói árindex, fogyasztói bizalom index, EURIBOR3M, alkalmazottak szám)	A modellek előrejelzési képessége elfogadható, 90% körüli. Sorrendben: DT, k-NN, NB, RF, SVM.
Dawood – Elfakhrany – Maghraby (2019)	előfizető ügyfelek előrejelzése, ügyfélcsoportok hatékony kialakítása az ügyfélkapcsolat hatékonyság növelése érdekében	K-közép, javított K-közép, fuzzy c-közép, ANN	Tajvani bank (UCI online elérhető adatbázisa)	pontosság, sensitivity, specificity, precision, recall, F-measure, G-mean	nyújtott hitel összege, nem, iskolai végzettség, családi állapot, kor, 6 havi számla egyenleg összege, előző fizetés összege, jövedelem típusa	A felügyelt ML modellek pontossága magasabb a felügyelt ML modellek teljesítményével szemben.
Kaur - Kaur (2020)	banki AI-alkalmazások szakirodalmi áttekintése	n.a.	n.a.	n.a.	n.a.	A tanulmány azt javasolja, hogy több technológiát vezessenek be a banki élmény javítása érdekében, ideértve a drive-thru bankolást, az automata ügyfélszámla adatokat nyomtató kioszkokat és a chatbotokat. A fogyasztók preferálják az

						okospénztárcákat. Az online csalás fő kihívás.
Sharahi - Aligholi (2015)	demográfiai és viselkedési szegmentáción alapuló loyális ügyfél azonosítás kommunikációs-és marketing stratégia hozzáigazítása (hűség javítás)	K-közép,	Teheráni banki adatok	A klaszterezési algoritmus evolúciós eljárása révén a klaszterközpontok minden iterációban az optimalizáció felé mozdulnak el.	14 attribútum (a vállalat típusa, tevékenysége, élettartama, együttműködés ideje, a vállalat bankszámlái, hiteltörténete, hitel típusok, fedezet típusa, a csekk száma, a POS eszköz használata, a kapott kezességvállalási levelek/akkreditívek száma, hitelek/követelések összege.	A K-means algoritmus 7 változót választott ki: Vállalat típusa, élettartama, tevékenysége, együttműködés ideje a bankkal", hiteltörténet, hitel típusa, hitel összege. A klaszterezés során two-step megközelítést alkalmaz.
Ayoubi (2016)	Ügyfélszegmentálás a marketing stratégia személyre szabásához	Kohonen neurális hálózat	Taavon bank ügyfél adatai (56000)	számított CLV érték a szegmensbe soroláshoz	demográfiai és viselkedési adatok az ügyfelekről	Ügyfélcsoportokhoz illeszkedő CRM kampányok kidolgozása. Az eredményeket fel lehet használni a hitelezési, finanszírozási döntés során is
Palaniappan, et al. (2017)	Ügyfélprofilképzés, ügyfélcsoportosítás, vásárlás iránt fogékony ügyfelek azonosítása	NB, RF, DT	Portugál bank telemarketing adatai (UCI elérhető online adatbázis); 45 ezer adat	precision, recall ráta	21 attribútum (lásd Elrefai et al., 2021 esetében)	precision és recall tekintetében a NB, majd a DT, végül a RF modell bizonyul a legpontosabbnak.
Patil-Dharwadkar (2017)	a lemorzsolódó ügyfelek, valamint csalásgyanús ügyletek hatékony azonosításához az ügyfélszegmens megfelelő szegmentációja szükséges	ANN	Nyilvánosan elérhető német hitelfelvevői adatbázis- (2 adatbázist alkalmaz, csalásfelderítésre és lemorzsolódásra) g 285,774 tranzakciós adat	Átlagos négyzetes gyökeltérést, pontosság	ügyféladatok (ügyfélaazonosító, életkor, nem, egyenleg, jövedelem, hitelkártya státusz, családi állapot, hitel típusa, számlatípus, tranzakciók száma, ügyfél oktatása és foglalkozása, egyebek)	A modell jó eredményeket ér el a besorolási pontosság tekintetében. Fraud adatbázis alapján 72%-ot, churn predikcióra 98%-ot.
Jewandah (2018)	AI felhasználás szakirodalmi áttekintése: csalásmegelőzés	n.a.	n.a.	n.a.	n.a.	felhasználási lehetőségeket nevesít
Oyeniye Adeyemo (2015)	potenciálisan lemorzsolódó ügyfelek előrejelzése	K-közép	Nigériai bank ügyféladatai	n.a.	ügyféljellemzők	Az elért eredmény azt mutatja, hogy a végrehajtott módszerek képesek az ügyfélviselkedés mintázatainak meghatározására, és segítenek a bankoknak a lemorzsolódó ügyfelek azonosításában.

Forrás: Saját ábra

12. számú melléklet: Portfólió- és vagyongazdálkodás területen alkalmazott ML áttekintése – összefoglaló táblázat

Szerző(k), év	Üzleti cél	ML algoritmusok	Adatbázis	Teljesítmény indikátor	Felhasznált adatok	Eredmény
Kaczmarek- Perez (2022)	Optimális portfólió építés a várható hozamok előrejelzése alapján	RF	S&P500 index részvények, 20 év historikus adat (1999-től 2019-ig), 120 ezer megfigyelés és 10 millió rekordot	pontosság, volatilitás Sharpe ráta	22 jellemző (részvény attribútumok), valamint havi szintű 7 makrogazdasági változó	átlagosan a ML modellek által kockázat- és hozamoptimalizált portfóliók (a Sharpe hányados szempontjából 16%-kal) jobb teljesítményt nyújtanak, mint a 1/N* portfóliók. A Markowitz-féle (mean-variance) és a HRP optimalizálók teljesítményében tapasztalt különbségek nem jelentősek, és főként a portfóliók létrehozásához használt részvények számától függenek, ahol az HRP inkább kevesebb részvényt részesít előnyben.
Gu – Kelly – Xiu (2020)	előrejelzés az eszköz kockázati prémiumára	LR, NN, RT	CRSP adatbázis (havi összesített részvényhozamok a NYSE, AMEX és NASDAQ tőzsdéken jegyzett vállalatokra), időablak: 60 év (1957-2016), minta: 30 000 részvény	pontosság mérésére: Diebold és Mariano teszt; részvény-szintű előrejelző R2	94 jellemző; és 8 makroökonómiai előrejelző. osztalék-ár arányt, a nyereség-ár arányt, a könyv-érték arányt, a nettó saját tőke növekedés, a kincstárjegy kamatlábát, a kamatláb-különbség, az alapértékkülönbség, a részvények szórása	A NN és a RT a legjobban teljesítő algoritmusok az eszközárak/ eszközárakhoz tartozó hozamok előrejelzésére
Shukla (2019)	a részvényárak árának, trendjének előrejelzése révén árnövekedési/ árcsökkenési előrejelzés a napi és hosszú távú kereskedési döntésekhez	O- LSTM, NN, ÖsszBenchM: LR, ELSTM	3 National Stock Exchange (NSE)-en szereplő bank részvény adatai; 2 évnél hosszabb kereskedési napi adat (2016-2018)	Pontosság, Négyzetes hiba középértéke (Mean Squared Error – a becstült mennyire tér el a valóstól)	technikai mutatók (Williams % ráta, Mozgóátlag)	A javasolt O- LSTM piacfüggetlen, mivel a mélytanulás LSTM dinamikáját alkalmazza, ahelyett, hogy mereven rögzítettek lennének az adatok
Chaweeewanchon – Chaysiri (2022)	Markowitz átlag-várianca alapú	Hibrid gépi tanulási modell, amely	Stock Exchange of Thailand 50 Index (SET50)	Sharpe-ráta, szórás, átlagos hozam	részvényárfolyam jellemzők (záróár, nyitóár, legmagasabb,	A részvények előválogatásának integrálása javíthatja az ML modell teljesítményét. A javasolt módszer

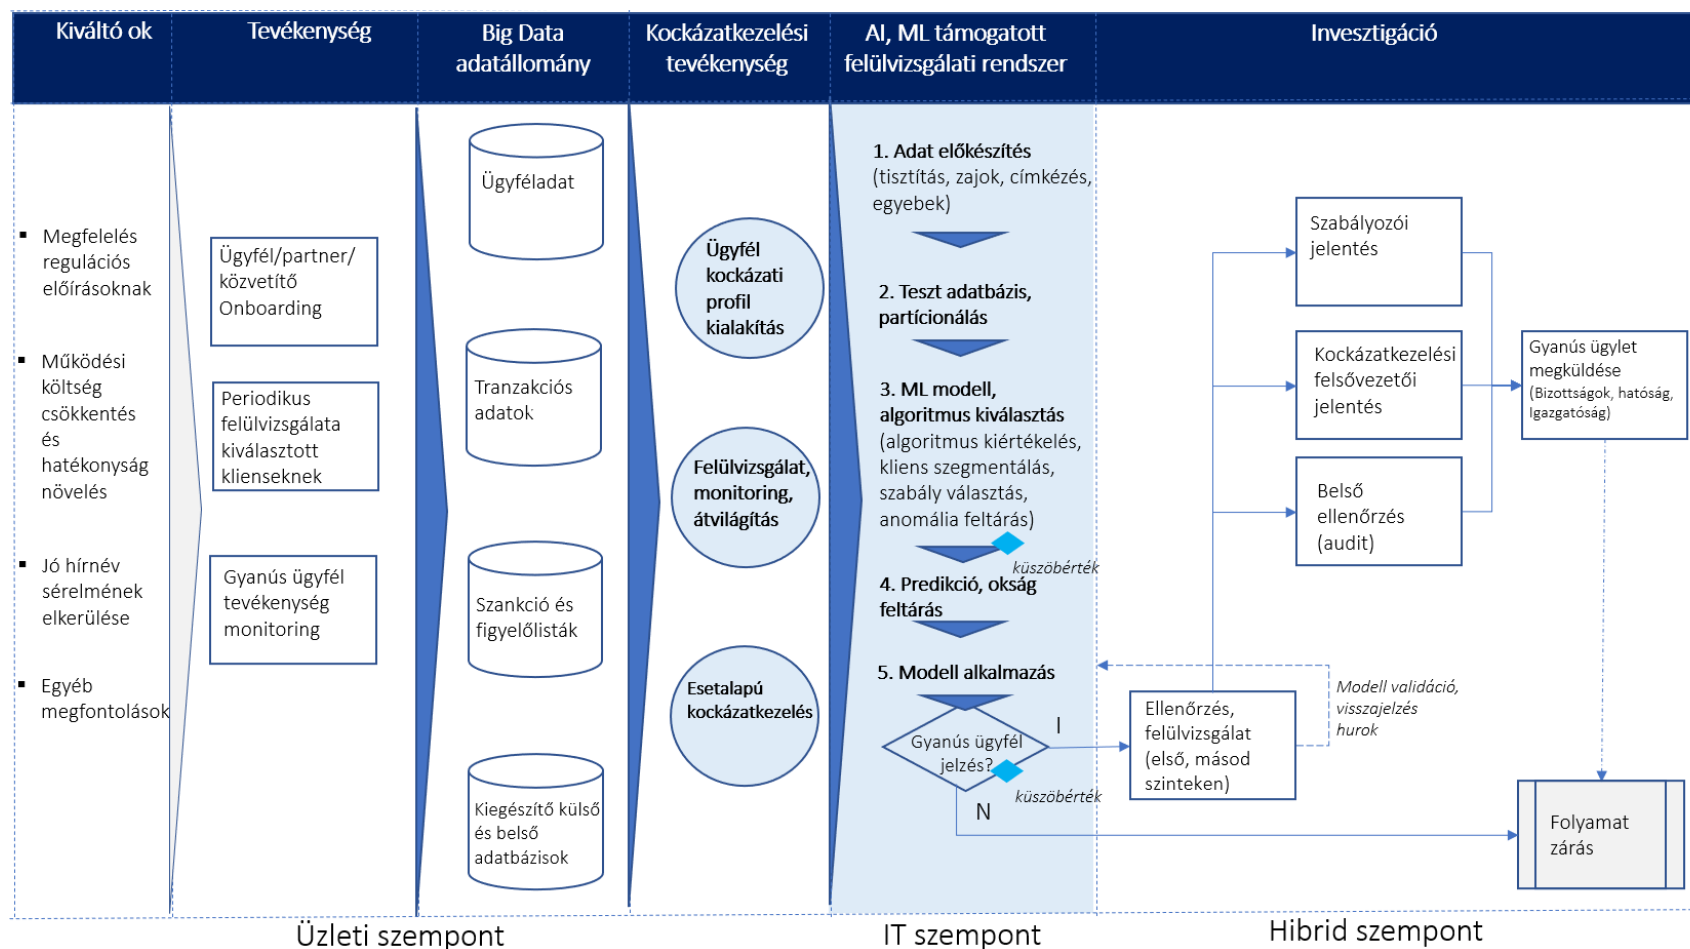
	portfólió optimalizáció részvényár előrejelzés és előválogatás	összekapcsolja a CNN és a BiLSTM-t			legalacsonyabb napi érték)	felülmúlja a többi modellt a Sharpe-ráta, az átlagos hozam és a kockázat szempontjából is.
Fischer - Krauss (2017)	Részvények árazási irányváltásainak előrejelzése	LSTM, ÖsszBenchM: RF, standard deep net (DNN), LR	S&P 500 részvények adatai (1992 – 2015)	pontosság, Sharpe-ráta, szórás, átlagos hozam (%)	részvényárfolyam jellemzők	Az LSTM valamennyi modellt túlteljesítette a teljesítménymérők mentén
Wang et al. (2020)	részvényhozam, alul/túlteljesítő részvények előrejelzése és portfólió optimalizáció	LSTM, ÖsszBenchM: SVM, RAF, DNN	FTSE-100 napi részvényadatai 212 részvényre, időablak: 25 év (1994 – 2019)	Átlagos abszolút hiba (MAE); Átlagos abszolút százalékos hiba (MAPE); Gyökök közötti átlagos négyzetes hiba (RMSE); Magyarázat számítási együttható (R^2), Átlagos négyzetes hiba (MSE); szórás, éves átlagos hozam, Sharpe-ráta és Sortino hányados	részvényárfolyam jellemzők	A javasolt modell egyértelműen jobb teljesítményt nyújt.
Wu et al. (2021)	pontosabb részvényárfolyam előrejelzés	CNN; LSTM, ÖsszBenchM: CNNpred, CNN-corr, SVM, NN	tíz részvény két piacról (amerikai és tajvani)	pontosság	opciók és futures múltbeli adatok	Egy új keretrendszert javasol, amely kombinálja a CNN és LSTM algoritmusokat (SACLSTM)
Aithal et al. (2023)	a portfólió kiválasztás, a portfólió optimalizáció és a portfólió menedzsmentet elősegítése	K-közép	NSE NIFTY 100 részvényárfolyam adatok egy hónapos időszakra	Sharpe-ráta	részvényárfolyam jellemzők	Az összes optimalizált portfólió jobb teljesítményt nyújt a benchmark hozamokhoz képest.
Vivek et al. (2022)	részvényárfolyam előrejelzése	ANN, SVM, geneikus algoritmus LSTM	A Google tanító adathalmaza részvényekre, időablak: 2012-2016	a valós és a prognosztizált árfolyam különbsége	részvényárfolyam jellemzők	Az LSTM nyújtotta a legjobb teljesítményt.

Wang – Li – Li (2020)	A befektetési alap értékelése	K-közép	Capricorn befektetési alapok (fund)	hibaszórás (error variance)	fundok historikus adatok és árfolyam jellemzők	A K-közép algoritmuson hatékony elemzést végez a befektetési alapokról.
Lee et. al. (2021)	Befektetési alapok rövid távú árfolyammozgásának becslése, előrejelzési hatékonyságuk javítása	LSTM	TWSE 005 (ETF befektetési alap), kereskedési időszak 2017/01 - 2019 Q3.	pontosság mérésére: technikai elemzési mutatók, mint a KD, RSI, bias, Williams %, MACD	fundok historikus adatok és árfolyam jellemzők	Az LSTM hatékonyan jelzi előre a befektetési alapok árfolyamát, így más pénzügyi termékekre is alkalmazhatónak tűnik.
Agudelo – Medina – Méndez (2020)	pénzügyi eszköz árfolyam előrejelzés	genetikus algoritmus	a NASDAQ részvényindexet követő portfólió adatai, időablak: 7 év (2013 – 2019)	pontosság mérésére: hozam és a befektetés kumulált értéke közötti különbség.	nyitó/záróár, legmagasabb, legalacsonyabb ár	A GA alapú befektetési stratégiával az éves hozam növekedése közel 4,14% és 12,98% közötti volt, meghaladva a B&H és a TA stratégiákat.
Chen et al. (2021)	Részletes pénzügyi információ fundamentális elemzése a hozamok előrejelzéséhez	RF, SGD Boosting	10-K riportok	AUC	Teljes pénzügyi kimutatók: mérleg, éves beszámoló, eredménykimutató, CF kimutató	Az eredmények azt sugallják, hogy az elemzők nem képesek teljes mértékben beépíteni a pénzügyi információt az előrejelzésekbe.
Conlona - Cotter – Kynigakisc (2021)	A ML modellek hatása a portfóliók újraegyensúlyozására és az alkalmazott súlyok változására. Portfólió optimalizálás, portfólió diverzifikáció	NN, SGD	Chen és Zimmermann (2020) nyílt forrású eszközárazási adatkészlete	Statikus tényező kovariancia, dinamikus béta kovariancia, dinamikus tényező kovariancia, dinamikus hibakovariancia.	portfólió jellemzők	Az autoencoder egy gépi tanulás algoritmus, amely képes a bemeneti adatok saját reprezentációját létrehozni úgy, hogy először tömörített állapotba kódolja azokat, majd visszafejti őket az eredeti formájukba. Az ezzel előállított minimális varianciájú portfóliók jobb teljesítményt nyújtanak a kockázatminimalizálás szempontjából.
Mirete-Ferrer et al. (2022)	Vagyongazdálkodás hatékonyságának növelése	50 ML algoritmus szakiroalmi áttekintése	na.	na.	na.	Megfogalmazza a portfólió-és vagyongazdálkodás terület főbb problémáit és összegezi az alkalmazható ML megoldásokat.
Hanauera - Kononova- Rapp (2022)	európai részvények fair értékének becslése	RF, GBRT, LASSO, LR	Refinitiv Datastream: "Halott részvények", azaz már nem aktív EU17 részvények	a pontossághoz: a fundamentális érték ($V_{i,t,m}$) és a megfigyelt piaci érték ($MV_{i,t}$) közötti százalékos különbség	számviteli változók (TotalAssets, TotalLiabil, NitoCom, NibElPrefDiv, TotalAssets, TotalAssets, PreTaxIncome, LTDe	A ML algoritmusokon alapuló stratégiák jóval magasabb kockázat-korrigált hozamot ("alpha") eredményeznek, mint az egyszerű lineáris regresszió (alkalmazott változatai). Ez a nem-lineáris összefüggések és kölcsönhatások figyelembevételének fontosságát

			(EU15, Svájc és Norvégia)		bt, TotalAssets, TotalDiv, egyebek)	hangsúlyozza a fundamentális elemzés során.
Zheng. – Zhang – Zhang (2023)	egy robo-advisor (ügynök) létrehozása a piaci információkon alapuló ideális kereskedési stratégia kiválasztásához részvény indexek esetében	Advantage Actor-Critic, Trust Region Policy Optimization, Proximal Policy Optimization, Actor-Critic Using Kronecker Factored Trust Region., Deep Deterministic Policy Gradient	A S&P-100 komposit részvényei, időablak: 11 év napi kereskedési adatai	hozam ráta, Sharpe-ráta	napi részvényárfolyam adatok (nyitó/záró ár, legmagasabb, legalacsonyabb ár, volumenitás)	A fuzzy kiterjesztésű együttes tanulók jobb eredményeket mutattak, mint a különálló algoritmusok fuzzy kiterjesztés nélkül.
Xiaotian– Jiang – Jionglong (2021)	a portfóliókezelés támogatása a kriptovaluták piaci környezetének elemzésében (hanem medve piacon)	NN	A háttérvizsgálat előtti harminc nap legnagyobb tranzakciós forgalmú 11 kriptovalutájának adatai	végző kumulatív portfólió érték (fAPV) , Sharpe-ráta	záróár (nyitó ár itt egyenlő az előző záróval – mivel folytonos időszaki valuta piacot feltételeznek), legmagasabb, legalacsonyabb ár	A jellemzők használata növelheti az előrejelzés pontosságát és így elérhető hozamokat. A jellemzők kombinációja közel 10%-kal jobb teljesítményt nyújt a hagyományos stratégiákhoz képest.
Wang (2023)	portfólió optimalizálás és előrejelzés	RNN, RF, LSTM	n.a.	n.a.	n.a.	A tanulmányok azt mutatják, hogy a ML modellek optimalizálhatják a portfóliókat, és pontosabb előrejelzéshez vezethetnek.
Phoon – Koh (2018)	vagyongazdálkodás robot tanácsadókkal történő támogatás	chatbot, robo-advisor	n.a.	n.a.	n.a.	A robot tanácsadók testreszabhatják a portfólió-és vagyongazdálkodást.
Brenner – Meyll (2020)	robot tanácsadók bizalomnövelő szerepe	robo-advisor	n.a.	n.a.	n.a.	Erős negatív kapcsolatot mutattak ki a robot-tanácsadók használata és a humán tanácsadás iránti igény között. A robo-advisorok használata azokra a befektetőkre jellemző, akik félnek az befektetési csalás (humán agent) áldozatává válni.
Fisch – Laboure – Turner (2018)	nyugdíjtervezés folyamatának támogatása	robo-advisor	n.a.	n.a.	n.a.	jogi és etikai szabályozás, tervezési kihívások, adatvédelem és magánélet tárgyalása

Forrás: Saját táblázat

13. számú melléklet: ML támogatott AML, CFT folyamat általános folyamatábrája



Forrás: Prisznyák, 2022b, pp.: 29

14. számú melléklet: AML, CFT, Csalásmegelőzés területen alkalmazott ML algoritmusok áttekintése – összefoglaló táblázat

Szerző(k), év	Üzleti cél	ML algoritmusok	Adatbázis	Teljesítmény indikátor	Felhasznált adatok	Eredmény
Zhang –Trubey (2019)	A pénzmossás eseményeinek modellezési hatékonyságának javítása	SVM, ANN, Maximum Likelihood/ Bayes logisztikus regresszió, DT, RF	Amerikai pénzüzetek valós adatai	AUC, ROC görbe	tranzakciós adatok	Legjobb teljesítmény: ANN algoritmus. Az SVM és RF a logisztikus regressziónál jobb teljesítményt nyújt. Az SVM jól teljesít a lineárisan nem elválasztható csoportok osztályozásában. Túl/alulmintavételezést használnak az adatbázis kiegyensúlyozásra.
Wang –és Yang (2007)	A kereskedelmi bank ügyfélprofilok alapján a pénzmossás kockázatának meghatározási szabályait létrehozni	DT	Ügyfél tranzakciós adatok	Hamis pozitív arány	iparág, lokáció, cégméret, banki termék	A döntési fa korlátozottan hatékony (nem azonosít megfelelően minden gyanús tranzakciót).
Chen –Guestrin (2016)	Növeljék a családi mintázatok felderítésének hatékonyságát	XGBoost, pGBRT	4 publikus adatkészletet alkalmaz	Futási (végrehajtási) idő, pontosság	tranzakciós és ügyféladatok	A gyorsítótárazási hozzáférési mintázatok, adattömörítés és sharding alapvető elemek a skálázható végpont-végpont rendszer kialakításához a fa fokozás céljából. Így a XGBoost futási ideje, erőforrásigénye lacsonyabb és képes valós világban előforduló skálázhatósági problémákat megoldani minimális erőforrásfelhasználással.
Wei et al. (2012)	Csalásnyús magatartás felismerése és kockázatértékelése	ContrastMiner (modelleket kombinál)	Ausztráliai bank adatbázisa	Riasztási, észlelési arány pontossága	tranzakciós és ügyféladatok	A ContrastMiner modell nagy, kiegyensúlyozatlan adatállomány esetén jelentősen javítja a pontosságot és alacsonyabb false riasztási mennyiséget produkál a hagyományos módszerekhez viszonyítva.
Khan et al. (2013)	Csalásnyús mintázatok felismerése	ML: Bayesi hálózatok	Valós pénzüzeti online banki adatai (8.2 million tranzakcióról, minden ügyfélre 7	Hamis pozitív arány.	tranzakciós adatok és ezekből kombinált adatok, mint a vásárlók teljes hitelösszege, teljes terhelésösszege, a hitel és terhelés összegeinek különbsége és a hitel- és	A központi bank által megadott AML szabályokat alkalmazza a modellépítés során (pl: korábbi inaktív számla intenzív használata). Bayes-pontszámai összehasonlításra kerülnek az átlagos és a tréning

			napos időintervallumban)		terhelési tranzakciók gyakorisága	adathalmazból számolt maximális Bayes-pontszámmal, majd gyanús/nem gyanús flag-et kap. Előbbi esetben további humán kivizsgálásra kerül az ügylet.
Kannan – Somasundaram (2017)	Csalásgyanús ügyletek hatékonyabb detektálása	ML: TBOD és AROMLD, K-means IBK, NB, DT, RF	Valós banki adatbázist.	Érzékenység, pontosság, specifitás, futási (végrehajtási) idő	sensitivity, futási idő, pontosság, TP, TN, FP, FN, F1, precision	Az előzetes szegmentálás hiánya az ML detektálásban dimenziós problémát okoz. Emellett a normális és gyanús tranzakciók elkülönítésének hiánya az elemzési időigényt növeli. A TBOD pontosabb, viszont a számítási komplexitása és végrehajtási ideje az összteljesítményét csökkenti. Alternatívaként az AROMLD futási ideje alacsonyabb.
Jullum – Løland – Huseby (2020)	Potenciális pénzmosási ügyletek azonosítása ML modellel, további vizsgálat céljából.	XGBoost	Anonim banki adatok.	Brier-pontszámot, AUC görbe, PPP	tranzakciós adatok és ügyfélhez tartozó háttérinformációk (pl.: korábbi fizetéseketelenség, egyebek)	Az XGBoost alkalmazása teljesítménynövekedést eredményez (AUC, PPP, TPR) tekintetében
Patil –Dharwadkar (2017)	a lemorzsolódó ügyfelek, valamint csalásgyanús ügyletek hatékony azonosításához az ügyfélszegmens megfelelő szegmentációja szükséges	ANN	Nyilvánosan elérhető német hitelfelvevői adatbázis (2 adatbázist alkalmaz, csalásfelderítésre és lemorzsolódásra) g 285,774 tranzakciós adat	Átlagos négyzetes gyökeltérést, pontosság	ügyféladatok (ügyfélazonosító, életkor, nem, egyenleg, jövedelem, hitelkártya státusz, családi állapot, hitel típusa, számlatípus, tranzakciók száma, ügyfél oktatása és foglalkozása, egyebek)	A modell jó eredményeket ér el a besorolási pontosság tekintetében. Fraud adatbázis alapján 72%-ot, churn predikcióra 98%-ot.
Álvarez et al. (2017)	az előrejelzési pontosság növelése	LR, DT, NN, RF	Valós tranzakciós adatokat tartalmazó adatbázis	Pontossága, TN, TP, FN, FP ráta	n.a.	Az adatállományban lévő zaj eltávolításával javítható az osztályozó algoritmus teljesítménye. Az RF a többinél magasabb osztályozói teljesítményt biztosít.
Savage et al. (2016)	valós idejű adatok alkalmazása a csalásgyanús ügyletek azonnali azonosításához	k-legközelebbi szomszéd algoritmus, SVM, RF	Ausztrál Tranzakció Jelentés és Elemzési Központnak jelentett tranzakciók adatok.	ROC görbe, pontosság, FTP ráta	demográfiai jellemzők; ügyfél hálózati, tranzakciós, dinamikus jellemzők (idősorok elemzéséből származnak, pl. szokatlanul magas összegek száma)	Az SVM-nél az RF valamivel jobb teljesítményt ad. A kapcsolatvizsgálat növeli a jelenlegi rendszer hatékonyságát.
Deng et al. (2009)	csalásgyanús ügyletek rövid időn belül történő kivizsgálásának és	Naive- Bayes, SVM	Pénzintézettől származó valós tranzakciós adatok.	Pontosság, szakértői validáció	tranzakciós jellemzők	A szekvenciális aktív tanulási módszer alkalmazása magasabb teljesítményt eredményezett a Naive

	jelentési kötelezettségének való eleget tevés biztosítása					Bayes és SVM modellek teljesítményénél.
Luo (2014)	gyanús tranzakciók észlelési hatékonyságának növelése a gyanús számlák szűrése esetén	FP-growth algoritmus	Valós banki adatok lapján generált 100 milliós adatállomány	Pontosság	tranzakciós adatok	A t ranzakciószám növekedésével a modell teljesítménye javul.
Alexandre - Balsa (2018)	a gyanús tranzakciók azonosításán túl, a humán szakértők munkájának támogatása	K-közép algoritmus	Pénzintézet valós adatbázisa alapján	ROC görbe, illetve banki szakemberek (validáció)	tranzakciós viselkedési adatok	Szabálygenerálásnál a J48, JPART algoritmus biztosította a legjobb eredményt. Ugyanakkor a precizitás mértéke elmaradt a várttól.
Le-Khac – Markos – Kechadi (2010)	ügyfelekhez kötött csalásgyanús tranzakciós mintázatok azonosítása	Neurális hálózatok	BEP Bank befektetési alapokhoz kapcsolódó tranzakciós adathalmaza	banki szakértői validáció	tranzakciós adatok	A modell esetében a paramterek megválasztása fontos a modell teljesítménye és futási (végrehajtási) idő szempontjából.
Drezewski – Sepielak – Filipkowski (2012)	csalásgyanús tranzakciós mintázatok azonosítása	FP-Growth, FPClose, FPMax, Sequence Miner, BIDE, BIDEMax	Bankszámlakivonatokat tartalmazó adatbázis	végrehajtási idő	tranzakciós adatok (tranzakció azonosító, egyenleg, dátum, számlaszám, tulajdonos neve és címe, átutalás iránya (bejövő, kimenő, egyebek))	A klaszterelemzés és létrehozott fürtök sikeresen használható a pénzmosás felderítésére.
Rocha-Salazar – Segovia-Vargas – Camacho-Miñano (2021)	Szabály-alapú rendszerek hatékonyságának tesztelése a ML modellek előrejelzési képességeivel szemben (hamis pozitív arány csökkentése)	K-közép, Neural Gas, Strict, SOM algoritmus	Mexikói pénzügyintézetek adatbázisa	Calinski-Harabasz index; abnormalitás indikátor, pontosság, ERR, ACC	tranzakciós és ügyféladatokat (Ügyfél szegmens, Politikailag kitett személyek, Gazdasági tevékenység, Kapcsolat időtartama, Kor, Jövedelemforrás, Nemzetiség, Termék típus, Tranzakció típus, Pénzügyi eszköz, Valuta, Csatornák, Földrajzi zóna, Egyéb)	Addicionális, nem tranzakciós változók modellbe integrálása javítja az előrejelzés pontosságát, és csökkenti az emberi erőforrás szükségletet, költségeket.
Rouhollahi (2021)	emberi beavatkozás minimalizálása mellett megvalósuló csalásfelderítés	Klasszifikációs algoritmusok: logisztikus regresszió, legközelebbi szomszéd módszer, Véletlen erdő, neurális hálózatok, Naive Bayes, Anomália észlelés: iForest	Strukturált banki tranzakciós adatállomány	Pontosság, precizitás, fedés, F1-mérték	tranzakciós adatok (tranzakció típus, tranzakció összeg, tranzakció ideje, hely, gyakoriság, eredet és cél)	Legmagasabb pontosság: neurális hálózat (futási ideje hosszabb, mint a többi algoritmusé). Fedés szempontjából legmagasabb érték: RF. Anomália észlelésnél legjobb eredmény: iForest. Az osztályozás jobb teljesítményét produkált, mint az anomália észlelés.

Forrás: Saját táblázat

15. számú melléklet: K1, K2, K3 kutatási kérdésekre adott válaszok

#	K1 (Prisznyák, 2023b) Tervezés módja	K2 (Prisznyák, 2023b) Bankrobotika technológia megvalósulás módja	K3 (Prisznyák, 2023c) Menedzsment hozzáállásra
1.	top-down: Az üzleti oldal gyakran nincs teljesen tisztában az AI, ML és automatizáció lehetőségeivel, így a menedzsment szerepe kiemelkedő	Hibrid (mindennapi üzleti folyamatok in-house; K+F igényes fejlesztések partner/vendor bevonásával a projekt elejétől kezdődően).	nyitottság, menedzseri támogatás jellemző
2.	Hibrid megoldás. Top-down: A kezdeményezése gyakran vezetői/befektetői nyomásra a menedzsment szintjéről indul. Ugyanakkor megoldási javaslatok gyakran bottom-up kerülnek előterjesztésre. A kettő közötti kapcsolat az R&D teremti meg a modellek folyamatos értékelése révén.	Partnerség: Ügyféligényre szabott termékfejlesztés. Cél a felvásárlás szintjére eljuttatni a céget a termékfejlesztés révén.	Az AI bevezetése a menedzsment hozzáállásától függ: egyesek univerzális megoldásként tekintenek rá, míg mások óvatosak, és nyomásgyakorlásra van szükség a projekt elindításához.
3.	Top-down: A fejlesztés kezdeményezése gyakran az ellátási lánc végéről (fogyasztói igények és befektetők) indul. Ezt szem előtt tartva, a menedzsment stratégiai oldaláról történik a kezdeményezés, és az AI-bevezetési projektek esetében a tervezés és végrehajtás a menedzsment által meghatározott célok és irányvonalak szerint történik.	In-house fejlesztések nem mindig sikeresek. A fejlesztések többsége félig in-house, félig kiszervezett (partnerség). Előfizetési modell keretében a partner személyre szabja a termékét.	A menedzsment az AI-hype-ot kihasználva támogatja a projekteket, mivel ez segíthet az értékesítési volumen növelésében.
4.	Top-down: A fejlesztési kezdeményezések gyakran az ellátási lánc végéről, vagyis a fogyasztói igények és befektetők által indulnak. Ezenkívül a menedzsment stratégiai oldaláról történik a tervezés és végrehajtás. (megjegyzés: FinTechnél tudták mit szeretnének, HealthTech-nél kevésbé.)	In-house fejlesztések dominálnak, de partnerfüggő, hogy szerződöttetett vendorként, vagy partnercéggként alkalmazzák a szakértőket.	A menedzsment általában támogatja az AI projekteket, mivel azok növelhetik az értékesítési volumet és a vállalati reputációt. Előfordul, hogy elzárkózik, ha nem értik teljesen a technológiát vagy a potenciális előnyöket.
5.	Bottom-up: a fejlesztés és kezdeményezés jellemzően az üzleti oldalról indul, alulról jövő kezdeményezésként.	Hibrid. Tevékenység függő. A partnerséget a bank jellemzően a költség-és erőforrástervezés megspórolása miatt alkalmazza, így kapacitásbővítést spórol.	A menedzsment pozitívan áll a projektekhez, és elkötelezettek az AI és kapcsolódó technológiák bevezetése iránt.
6.	top down: tipikusan vezetői szintről indul, de üzleti területről is lehet kezdeményezés, ha a beszállító ajánlata felkelti a menedzsment érdeklődését.	Hibrid: A vevői rendszerek fejlesztése házon belül (kódbázis tulajdonlás miatt). A feldolgozási rendszerek beszállító bevonásával.	A menedzsment hozzáállása általában támogatónak tűnik szóban, de a tettekben elzárkózás jellemző.
7.	Hibrid: a kezdeményezés mindkét irányból indulhat, és kívülről is érkezhethet. A bankoknál a belső innovációs	In-house az adatvagyon óvása miatt. Elzárkózás az adatátadástól.	A menedzsment pozitívan viszonyul az AI és kapcsolódó technológiák bevezetéséhez, mivel

	kezdeményezések, mint például ötletversenyek, és külső források, mint egyetemek és start-up programok, egyaránt szerepet játszanak a fejlesztési és beruházási folyamatokban.		az adatvagyonot óvják és a szükséges támogatást biztosítják. Azonban a menedzsment elzárkózik az adatátadástól és vannak korlátai abban, hogy milyen eseteket támogatnak.
8.	Bottom-up: a fejlesztések gyakran az IT részlegekből vagy az aktuális üzleti szükségletekből indulnak, és a támogatás mértéke változhat a menedzsment hozzáállásától függően.	In-house: a fejlesztés házon belül történt, az aktuális üzleti szükségletekből kiindulva,	A Bankoknál a menedzsment nyitottabb a technológiákra, könnyen elfogadják a változást, és a kommunikáció is jobb
9.	Bottom-up: a fejlesztés és kezdeményezés jellemzően a back office területéről indul el, de az üzleti igény a front office-ból érkezik.	In-house az ágazat specifikus szaktudásigény miatt.	Kezdeti nyitottság (költségbecsléskor alábbhagyott), vagyis kevésbé támogató
10.	Top-down: a nagyobb piaci/vállalati ügyfelek igényei alapján történik a menedzsment stratégiai tervezés.	Hibrid. Kezdeti in-house projekt kiegészülése a szaktudás miatt külsős fél bevonásával.	A menedzsment hozzáállása nyitott és támogató volt a projekt során
11.	top-down: a kezdeményezés gyakran menedzseri szinten indult (költségcsökkentés, volumennövelés), meghatározott elvárásokkal és célokkal.	In-house fejlesztések – de a cég beszállít partner cégeknek.	Aktív támogatás, mivel nem támogató magatartása esetén gyorsan keresnek helyette új menedzsmentet.
12.	Hibrid, de főleg top-down: Az anyavállalati elvárások irányították az irányt. A menedzsmentből érkezik, különösen akkor, ha erőforrás-megtakarítási vagy működési hatékonyságot célzó projektekről van szó. Az IT és a biztonsági csapatok is részt vesznek a kezdeményezésben, de gyakran az üzleti igények vezetik a projekt előkészítését és megvalósítását.	Hibrid: partner cégtől vásárolt dobozos termék személyre szabása in-house fejlesztés révén valósult meg..	Jellemzően támogató, de gyakran túlzó elvárásokat támaszt és elvárja a gyors és jelentős költségcsökkentést vagy teljesítménynövekedést.
13.	Top-down: jellemzően a menedzsment szintjéről indul.	Partnerség: kezdetben külső beszállítóval együttműködve, akit a tudás átvétele után fokozatosan kivonnak a folyamatból.	A menedzsment hozzáállása pozitív és támogató, amennyiben allokált költségvetéssel rendelkezik. Kezdetben lehetnek bizonytalanságok, a projekt edukációját és a technológiai megértést követően általában pozitívan támogatják a bevezetést.
14.	Hibrid: Az AI bevezetési projekteknél kezdeményezés fentről (top-down) indul, például az excel alapú megoldások csökkentése, majd a részletek kidolgozása csapatból (bottom-up) jön. A fejlesztés tehát mindkét irányból érkezik.	in-house dedikált csapat látja el	A középszintű menedzsmentek támogatják a fejlesztéseket, és a felső menedzsment is pozitívan áll a projektekhez.

Forrás: Saját táblázat

16. számú melléklet: K6, K7 kutatási kérdésekre adott válaszok

#	K6: Az etikai megfontolások (Prisznyák, 2023b)	K7: Oktatást AI-témában (Prisznyák, 2023b)
1.	Felmerülhet a diszkrimináció kérdése, és az etikai aggályok közé tartozik, ha a modellek olyan adatokat tartalmaznak, mint például a vallási hovatartozás, mivel hangsúlyozza, hogy az ilyen érzékeny adatok nem lehetnek a modellek részei, és az adatokat titkosítják. Az adatbiztonság és a GDPR szerepe jelentős az etikusság miatt, mint jogszabályi korlát. hangsúlyozza, hogy az adatokat titkosítják, és a modellek nem tartalmazhatnak érzékeny személyes információkat. A jogszabályok betartása és az adatkezelési szabályok az adatgyűjtés és -kezelés szempontjából is kiemelkedőek.	A projektben résztvevők magas szintű involvátságot élveznek, és számukra folyamatos inputot, workshopokat, és dokumentációt biztosítanak. A projekt csapaton kívüli munkavállalók képzésről nincs információja.
2.	A tipikus problémák és dilemmák az adatok gyűjtésével, tárolásával és továbbadásával kapcsolatban a következők: a publikusan elérhető adatbázisok esetén a szerződés gyakran kizárja a továbbadás lehetőségét, így ez nem megoldás. Saját adatbázis létrehozása nyilvános helyeken is problémás lehet, mivel olyan metaadatokat is rögzíthet, amelyek nem megengedettek. Kiemelten fontos, hogy a személyiségi jogokat figyelembe véve és GDPR-nek megfelelő módon történjen az adatgyűjtés.	az AI és ML technológiák bevezetése során gyakran hiányzik a megfelelő képzés és érzékenyítés. A cégnél elérhetőek különböző trainingek, de sokan nem használják ki azokat időhiány miatt. Az autodidakta tanulás gyakori, de általában korlátozott. A képzések gyakran általánosak, míg a problémák specifikusak. A menedzsment általában nem fektet kellő figyelmet a képzésekre, mivel leterhelt. Kivételt képeznek a középvezetők, akik szívesen részt vesznek a tréningeken és érdeklődnek az AI iránt.
3.	Akadályok közé tartozik az adatok tulajdonjoga, a licenck felhasználása, a tanulóadatok előállítás, és a vonatkozó jogszabályok betartása. Az igazi etikai kérdések (tervezés) még gyerekcipőben járnak, és a fő fókusz a működési problémák megoldásán van. A felelősség inkább az üzemeltetőknél van.	Az AI-technológiák bevezetése során az oktatás és érzékenyítés részben megtörténik, mivel a felhasználók megtanulják alkalmazni a rendszert. A cégek gyakran biztosítanak dokumentációt és élő beszélgetéseket az önképzéshez, de formális oktatás nem jellemző. A rendszerhasználat mellett a fogalmi tisztázások általában az ügyfél által fenntartott support szervezeti egység feladatai közé tartoznak.
4.	Nem merült fel etikai aggály a vállalat részéről az AI alkalmazásával kapcsolatban. Ugyanakkor jelentkeztek regulációs és jogszabályi korlátok, főként a személyi adatvédelem terén, valamint problémák adódtak az ML technológiák optimalizálásában, adatgyűjtésben és adatgenerálásban.	A bevezetés során a rendszerhasználat mellett fogalmi tisztázások érdekében vállalati traininget kapnak a felhasználók.
5.	Az etikai megfontolások nem képezik a vizsgálat tárgyát az AI-rendszerek fejlesztése és implementációja során, mivel a ML-et nem kockázatos felhasználási eseként alkalmazzák, és az adatok nem személyre szabottak, csupán leíró jellegűek.	A bevezetett technológiák kapcsán nem volt konkrét vállalati training, workshop vagy dokumentáció erre vonatkozóan.
6.	A szolgáltatásokból való kizárás és diszkrimináció jelenleg nem hangsúlyos problémák. A GDPR megfelelés érdekében jogászok integrálják az adatfelhasználási előírásokat az ügyfélszerződésekbe. Ezt lehetővé teendő, a ML modellek gyakran primitív formában működnek. További probléma az adattárolás kérdésköre (GDPR).	A vállalat költségoldalról minimalizálják a trainingeket, ami a rendszerhasználaton túl a fogalmi tisztázásokra is vonatkozik. Emiatt a felhasználók nem kapnak részletes és mélyreható információkat a trainingeken.

7.	Technológia szempontjából még nem tartanak ott. ML esetében előjött a diszkriminatív döntéshozatal, de az etikai megfontolások szisztematikusan nem kerülnek vizsgálatra külön. Nem feltétlenül kell mindent a robotra bízni, így ezeket a kérdéseket részben áthidalhatja a humán kontroll. További kritikus pont az adatfelhasználás (GDPR).	Akik a kompetencia központban dolgoznak, általában kapnak képzést, amely során kodifikált tudást sajátítanak el, valamint on-the-job traininget is kapnak, amit a munkavégzés során tanulnak meg. Az ügyintézők és egyéb érintettek számára inkább érzékenyítést nyújtanak nyílt napokon vagy belső tudásmegosztó anyagok, például white paperek formájában, amelyek bemutatják az AI technológiák előnyeit és működését.
8.	A diszkriminatív döntéshozatal kérdései felmerülnek, de az etikai megfontolások szisztematikusan vizsgálata nem jellemző.	Az oktatás és a fogalmi tisztázás terén lenne szükség fejlesztésre.
9.	Az interjúalany elmondása alapján nem képezik az etikai megfontolások különösebb vizsgálat tárgyát az AI-rendszerek fejlesztése és implementációja során. Az etikai aggályok inkább döntéstámogató modelleknél merülhetnek fel, de a konkrét AI-projekteknel, amelyeken ő dolgozott, nem voltak ilyen jellegű vizsgálatok.	Az oktatás és érzékenyítés az AI bevezetése során nem jellemző, így a dolgozók nem kapnak hivatalos tréninget ezen a téren.
10.	Etikai aggályként jelentkezett a digitális robot ember-szerű megjelenésének dilemmája (emberi arc vs rajzolt figura) a félelemkeltés elkerülése érdekében. Adatvédelmi, biztonsági kérdések (jelszó, soft autentikációs) is felmerültek. A GDPR miatt voltak további korlátok, például a hang lementése terén – a jogi megfelelés miatt a folyamatot módosítani kellett.	A beszállító biztosította a képzést a vállalat munkatársai számára, hogy megtanulják az AI rendszerek, például a virtuális asszisztens üzemeltetését.
11.	Etikai megfontolások nem képezik a vizsgálat tárgyát, mivel a fejlesztések nem érték el azt a fázist, ahol ezek komoly problémát jelentenének. Felléptek viszont a modell reprezentativitással kapcsolatos problémák, kérdések.	Az AI rendszerek bevezetése során képzéseket, workshopokat, és dokumentációt biztosítottak a felhasználók számára. Ezek a képzések részletesen tartalmazták, hogy mit várhatnak el a rendszer teljesítményétől, és hogyan kell értékelnit a teljesítményt az előre meghatározott benchmarkok alapján.
12.	Bank- és adatbiztonság részéről felmerült etikai aggály, különösen az adatok kezelése (GDPR) és a rendszerbiztonság kapcsán.	A banki menedzsment kap vállalati képzéseket és workshopokat az új technológiák bevezetésekor, amely során megismerheti az új rendszerek működését és a fogalmi tisztázást.
13.	A fejlesztés adott szakaszában még nem merültek fel etikai aggályok, mivel a technológia nem jutott el arra a szintre, ahol ezek a kérdések relevánssá válnának.	Az AI és kapcsolódó technológiák bevezetése során rendszeres nagyvállalati képzések zajlanak, amelyek a rendszerhasználaton túl a fogalmi tisztázásra is kiterjednek, biztosítva ezzel az alkalmazottak és a menedzsment megfelelő edukációját.
14.	Az etikai megfontolások nem merülnek fel, mivel a csapat tevékenysége nem érinti közvetlenül az ügyfeleket, illetve inkább folyamatautomatizálást támogat. De a vállalat globális jelenléte miatt a földrajzi alapú jogi szabályozásoknak is eleget kell tenni.	Új szoftverek bevezetésekor fontos, hogy a képzési idő biztosítva legyen, és ellenőrizzék az alkalmazottak képességeit a rendszer fenntartására és használatára.

Forrás: Saját táblázat

17. számú melléklet: K5, K8 kutatási kérdésekre adott válaszok

#	K5: Alkalmazott technológiák	K9: Menedzsment technológiai ismeretei
1.	ML-et alkalmaznak a vásárlási előrejelzések készítésére a front office területeken, illetve a middle office-ban a kockázatértékelés és monitoring folyamatokban (prediktív modellezés). Felügyelt és nem felügyelt tanulási technikákat is használnak, beleértve a megerősítéses tanulást.	Az üzleti területeken, valamint azok vezetői között általában hiányzik a szükséges kompetencia az AI és ML technológiákkal kapcsolatban.
2.	Az önvezető autók AI rendszere magában foglalja a gépi tanulási (ML) modell komponenseket, amelyek kulcsfontosságúak a jármű környezetének pontos és megbízható felismerésében. Az algoritmusok, különösen a CNN (konvolúciós neurális hálózat) algoritmusok, feldolgozzák az adatokat, például a kamerából származó képeket, hogy azonosítsák és osztályozzák a környezeti elemeket, mint a sávokat, közlekedési táblákat és akadályokat. Ez a felismerés alapvető a biztonságos és hatékony döntéshozatalhoz az önvezető autók számára.	Vevői oldalon a beszerző csapat, illetve a menedzserek nem mindig rendelkeznek mély technikai háttérrel, ami problémát okoz az elvárások tisztázásakor. Amennyiben bizottsággal tárgyalnak, ahol van technikai szakértő, az feloldja ezt a problémát már az igényfelmérés szakaszában.
3.	Neurális hálózatok az önvezető autók fejlesztésében a közlekedési helyzetek hatékony feldolgozására és a járművezérlés optimalizálására szolgálnak. Ezek a hálózatok segítenek a környezeti objektumok, mint például más járművek és gyalogosok, azonosításában és értelmezésében, valamint a döntéshozatali folyamatokban.	Ügyfél oldalon a menedzsment technológiai ismeretei általában kevésbé mélyek, ami miatt nehéz közös elvárásokat kialakítani és a projektek kezdeti szakaszában problémák merülhetnek fel.
4.	A healthtech szektorban Deep Neural Networks (DNN) és Graph Neural Networks (GNN) technológiákat alkalmaznak betegségek előrejelzésére és diagnosztikai elemzésekre. A Reinforcement Learning módszerei, mint a Q-learning és Actor-Critic learning, optimalizálják a navigációs rendszereket és más alkalmazásokat. Virtuális agentek (humanoid és nem-humanoid) segítik az orvosi szolgáltatásokat, míg az adatvédelmi és adatgyűjtési problémák kiemelt figyelmet kapnak. A fintech szektorban Deep Neural Networks (DNN) használják pénzügyi előrejelzésekhez és Forex kereskedelemhez. A Reinforcement Learning, különösen Q-learning, segít a kereskedelmi rendszerek optimalizálásában. A GPU-k biztosítják a neurális hálózatok futtatását, és az adatgyűjtési infrastruktúra is kiemelt jelentőségű. A menedzsment és IT szakemberek közötti kommunikációs problémák gyakori kihívást jelentenek.	Az interjúalany szerint a banki menedzsment technológiai ismerete általában korlátozott. Gyakran nem rendelkeznek mélyebb megértéssel az AI, ML és automatizáció technikai aspektusairól, és ez problémákat okozhat a projektmenedzsmentben és a fejlesztési folyamatokban.
5.	Gépi tanulási (ML) technológiákat alkalmaz a jegyértékesítési és üzemanyagköltség-optimalizálási folyamatokban. Az ML modellek a jegyfoglalások előrejelzésére és az overbooking kockázatának minimalizálására szolgálnak, amelyhez felügyelt tanulási technikákat használnak. Továbbá, az üzemanyagköltségek optimalizálásában a modellek figyelembe veszik az időjárást, az utasok számát és egyéb változókat, hogy hatékonyabb üzemanyag-stratégiát dolgozzanak ki.	Az interjúalany szerint a menedzsment technológiai ismeretei általában korlátozottak, és nem rendelkeznek mélyebb technikai tudással az AI, ML és automatizáció terén. Az üzleti oldal érti az IT-t, de gyakran csak alapvető szinten, és mélyebb ismereteik nincsenek ezekről a technológiákról.
6.	A gépi tanulást és az automatizációt az alábbi területeken alkalmazzák: Sales és ügyfélkezelés (front office): A gépi tanulás predikciós modellek használatával támogatja az értékesítési előrejelzéseket és a targetinget, segítve a vásárlói szokások és trendek jobb megértését. Ügyfélkezelés és adminisztráció (back office): Itt az automatizáció és a robotika alkalmazása a belső rendszerek optimalizálását célozza.	A menedzsment gyakran nincs teljesen tisztában az AI, ML és automatizáció fogalmaival és azok közötti különbségekkel. Ennek következtében homályos és téves elképzelések alakulhatnak ki a technológiák alkalmazásával kapcsolatban.

7.	AI és ML alkalmazások hitelminősítési és csalásfelderítési célból, továbbá CRM területen. Utóbbinál a következő legjobb ajánlatok (next-best-offer) készítésére és a churn ráta (ügyféllemerzősülés) elemzésére alkalmaznak ML modelleket, amelyek segítenek a termékek upselling és cross-selling stratégiáiban. Szuperszámítógép projekt: Nagy teljesítményű számítógépeket használnak a jövőbeli, nagyszámítási kapacitást igénylő alkalmazásokhoz, például GPT-3 alapú nyelvi modellekhez, amelyek az ügyfélkommunikáció és a chatelés területén nyújtanak majd új lehetőségeket.	A menedzsment gyakran nincs teljesen tisztában az AI és kapcsolódó technológiák pontos jelentésével és különbségeivel. Ennek következtében előfordulhat, hogy téves értelmezések merülnek fel a technológiák alkalmazásában.
8.	Banki Projektek: A szakember számos AI és ML projektet vezetett különböző pénzügyi intézményeknél, FATCA jelentési kötelezettségekhez kapcsolódó modelleket fejlesztett. Az adatbázisok és profilozó modellek segítségével elemezte az ügyfelek pénzügyi mozgásait, hogy azonosítsa bizonyos nemzetiségű állampolgárokra vonatkozó jogszabályi előírások betartása (jelentés) céljából. Front-end és Back-end Projektek: Támogatott front-end és back-end projekteket, például email klasszifikációt és NLP algoritmusok fejlesztését a risk management területen, ahol az indiai csapat által gyűjtött risk-es kérdéseket kezelte.	A bankszektorban a menedzsment nagyjából tisztában van az AI és ML technológiákkal, és felületesen értik azok működését. Emiatt a banki menedzsment nyitottabb a változásokra, és könnyebben elfogadják az AI-alapú megoldásokat.
9.	Automatizált Adattranszfer: Excel táblák sorait automatikusan átkonvertálja egy rendszerbe, növelve a törzskönyvi folyamatok hatékonyságát. Prediktív Modellezés: Linear Regression-t használ a törzskönyvi engedélyek várható kiadási dátumának előrejelzésére. NLP Alkalmazás: Dokumentumok automatikus fordítása. Költségsökkentés és Hatékonyság: Prediktív modellek támogatják a gyártási tervek optimalizálását és a selejt csökkentését.	A menedzsment nagyjából tisztában van az AI és ML technológiákkal, sok esetben felületesen értik azok működését. Az üzlet és informatika közötti kommunikáció hiánya is problémát jelent, ami akadályozza a technológiai fejlesztések hatékony támogatását.
10.	Az ügyfélszolgálati folyamatok automatizálására virtuális asszisztens fejlesztettek, amely során NLP és Machine Learning modelleket alkalmaztak a hangalapú és szöveges ügyfélinterakciók feldolgozására, az ügyfelek szándékainak azonosítása és az önkiszolgáló folyamatok indítása.	Az ügyfél menedzsmentje, üzleti részlege és a fejlesztői oldal közötti kommunikáció kezdetben kihívásokkal küzdött, mivel a menedzsment nem mindig volt teljesen tisztában az AI, ML és automatizáció működésével. Az is előfordult, hogy a menedzsment túltolta az AI képességeit, mivel a technológia valójában kevesebbet tudott, mint amennyit a menedzsment várhatott tőle. Ahogy a projekt előrehaladt, és a fejlesztők részletesebb magyarázatokat adtak, a menedzsment jobban megértette az AI működését és potenciálját.
11.	Az AI-t a neurális képfeldolgozási technológiák területén alkalmazták, különös figyelmet fordítva sávok és objektumok felismerésére 3D-s térben autók körül kameraképek alapján. A fejlesztés során neurális hálózatokat és számítógépes látás technikákat használtak, kezdetben SVM-et, majd áttértek a hatékonyabb neurális hálózatokra.	A menedzsment gyakran nagy várakozásokkal rendelkezik az AI technológiákkal kapcsolatban, de nem mindig van teljesen tisztában azok korlátaival és lehetőségeivel. Ennek következtében kommunikációs szakadék alakul ki a menedzsment és a fejlesztők között. A menedzsment gyakran csak konkrét számokat és teljesítménymutatókat igényel anélkül, hogy megértené a technológiai kihívásokat és komplexitást.
12.	A banknál a sérülékenységmenedzsment során mesterséges intelligenciát alkalmaztak egy piacon elérhető dobozos sérülékenységi szoftver keretében. Az AI-t a sérülékenységek keresésére használták, ahol az agent-ek a felhasználók laptopjaira telepítve keresik a Windows operációs rendszert érintő biztonsági problémákat.	A menedzsment általánosságban elmondható, hogy rendszerint idősebb korosztály, nincsenek tisztában a képességekkel és az AI, automatizáció közötti különbséggel.
13.	Szoftver robotok révén a háttér-folyamatok (back office rendszerek) támogatása.	Kezdetben gyakran hiányzik a megfelelő tudás az AI, ML és automatizáció terén, így az edukációra és a fogalmak tisztázására nagy hangsúlyt kell fektetni.
14.	A bank back office területén (napi és időszakos kötelező jelentések) folyamatautomatizálás az (open source szoftverek, mint a Knime) révén Excel alapú megoldások csökkentésére.	A menedzsment technológiai ismeretei nem mindig kielégítőek, különösen a bonyolult AI és ML technológiák esetében.

Forrás: Saját táblázat

18. számú melléklet: Bankrobotika kulcszólista

Cloud; Payment; Recommendation; Predict; Pattern; Anomaly; Crypto; Storage; Transaction; Data transfer; Robot; Artificial Intelligence; Natural Language Processing (NLP); Machine learning; Blockchain; API; Neural network; Deep learning; Decision tree; Intelligent agent; Augmented reality; Distributed ledger; Robotic process automation; Chatbot; Virtual assistant; Optical sensor; Optical character recognition; Virtual reality; Biometric; Voice assistant; Cybersecurity; Image processing; Internet of Things; Cognitive; Facial recognition; Anomaly detection; Cryptocurrency; Quantum computing; Secure access; Tokenization; Encryption; Smart systems and methods; Masking; Deep fake.

19. számú melléklet: A szabadalmaztathatóság főbb feltételei

Kritérium	Leírás
Újdonság	az ötletnek olyan új jellemzőt kell mutatnia, amely nem ismert a már létező tudásban, amely a benyújtás időpontjáig (vagy a prioritás dátumáig) létezett.
Ipari alkalmazhatóság / hasznosság	az ötletnek alkalmasnak kell lennie ipari vagy üzleti célra, ami több, mint pusztán elméleti jelenség, vagy el kell érnie egy kedvező eredményt.
Szabadalmaztatható tárgyi kör	minden nemzeti jogszabály meghatározza a szabadalmi védelemre jogosult tárgyakat. a szabadalmaztathatóságból kizárt tárgykör gyakran érinti a tudományos elméleteket, esztétikai alkotásokat, matematikai módszereket, növény- vagy állatfajtákat, természeti anyagok felfedezéseit, kereskedelmi módszereket, diagnosztikai, terápiás és sebészeti módszereket az orvosi kezelésre (ellentétben az orvosi termékekkel) és számítógépes programokat
Elégséges információ	az ötletnek olyan kérelemben kell lennie, amelyet elégségesen világos és teljes módon bemutatnak, hogy az átlagos szakmai ismeretekkel rendelkező személy képes legyen azt elvégezni a releváns műszaki területen.

Forrás: Saját szerkesztés a <https://www.wipo.int/patents/en/protection.html> alapján

20. számú melléklet: A szabadalmi kérelem főbb elemei

Kritérium	Leírás	Főbb tartalmi elemei
Kérelem	a kérelmező kijelenti, hogy a szabadalmi védelmet kéri, és alapvető adatokat tartalmaz a kérelemmel kapcsolatban	az ötlet címét, a benyújtás dátumát, a prioritás dátumát és a bibliográfiai adatokat, például a kérelmező és feltaláló nevét és címét
Cím és leírás	felfedi az ötletet, világos nyelvezettel és elegendő részletességgel, ötlet címét, jelezve annak műszaki területét, és magában foglalja az ötlet hátterét és leírását, meg kell jelölnie a találmány tárgyát, célszerűen utalva arra a szakterületre, ahol felhasználható. Törekedni kell arra, hogy a cím minél informatívabb legyen. A leírás címének meg kell egyeznie a bejelentési kérelemben és a kivonatban megjelölt címmel. Több találmány esetében a címben valamennyinek szerepelnie kell.	<p>a találmány tárgyának és alkalmazási területének rövid megjelölését,</p> <p>a technika állása (a találmányhoz legközelebb álló megoldások) ismertetését a források megjelölésével, valamint azoknak a hiányosságoknak az ismertetését, amelyek javítását a találmány célozza,</p> <p>a találmánnyal megoldandó feladat megjelölését,</p> <p>a kitűzött feladat legáltalánosabb megoldását, összhangban a főigényponttal,</p> <p>szükség esetén az előnyös megoldások ismertetését, összhangban az aligénypontokkal,</p> <p>az ábrák felsorolását, tárgyuk megjelölésével,</p> <p>az oltalom terjedelmét alátámasztó egy vagy több példát,</p> <p>a találmányhoz fűződő – a technika állásához viszonyított – előnyös hatások bemutatását.</p>
Ábrák	az ötlet vizuális részleteit - szükség esetén leírás kísérheti	rajzok, tervek vagy diagramok
igénypont(ok)	kért szabadalmi védelem terjedelme	
Kivonat	az ötlet összefoglalója	

Forrás: Saját szerkesztés a <https://www.wipo.int/patents/en/protection.html>

21. számú melléklet: Kínai szabadalom azonosítása – nyelvi korlátok

CN115774610A

(19) 国家知识产权局



(12) 发明专利申请



(10) 申请公布号 CN 115774610 A

(43) 申请公布日 2023. 03. 10

(21) 申请号 202211471288.1

(22) 申请日 2022.11.23

(71) 申请人 中国银行股份有限公司

地址 100818 北京市西城区复兴门内大街1号

(72) 发明人 袁华浩

(74) 专利代理机构 北京三友知识产权代理有限公司 11127

专利代理师 徐焕 童磊

(51) Int. Cl.

G06F 9/48 (2006.01)

G06F 16/23 (2019.01)

权利要求书2页 说明书11页 附图3页

(54) 发明名称

任务数据处理方法及装置

(57) 摘要

本说明书涉及数据处理技术领域，具体地公开了一种任务数据处理方法及装置，其中，该方法应用于第一节点，所述第一节点为计算机集群中的任意计算节点，所述方法包括：从数据库中获得集群节点任务分配信息表和任务信息表；所述集群节点任务分配信息表中包括集群标识、节点标识和任务标识之间的对应关系；所述任务信息表中包括任务标识和任务信息之间的对应关系；从所述集群节点任务分配信息表中查找所述第一节点的节点标识和集群标识对应的目标任务标识；从所述任务信息表中查找所述目标任务标识对应的目标任务信息，以基于所述目标任务信息执行任务处理。上述方案实现了集群在不设立中心节点的情况下对集群中的各个节点进行任务分配。



115774610 A

Forrás: Saját ábra a Google Patent adatbázisba feltöltött szabadalmi dokumentumok alapján

22. számú melléklet: A Google Colab gyakran használt könyvtárai és eszközei

Könyvtár	Leírás
pandas	A pandas egy adatkezelési és analízis könyvtár, amely könnyű és hatékony eszközöket nyújt adattáblák (DataFrame) létrehozásához, manipulálásához és elemzéséhez.
numpy	A numpy egy numerikus számításokhoz használt könyvtár, amely hatékonyan kezeli többdimenziós tömböket vagy mátrixokat.
google.colab	Ez a könyvtár lehetővé teszi a Google Colab funkcióinak használatát, például a fájlok feltöltését a kódból.
matplotlib	Ez egy 2D ábrázolási könyvtár, amely lehetővé teszi diagramok, grafikonok és ábrák létrehozását a vizualizációhoz.
seaborn	A seaborn egy adatvizualizációs könyvtár, amely az alapértelmezett matplotlib megjelenítést gazdagítja és egyszerűsíti. Támogatja a bonyolultabb statisztikai vizualizációkat is.
scikit-learn	Ez egy gépi tanulás könyvtár, amely tartalmazza a gépi tanulás algoritmusok széles választékát a felügyelt és felügyeletlen tanuláshoz.
statsmodels	A statsmodels a statisztikai modellezéshez és tesztekhez használt könyvtár, amely különböző statisztikai modelleket, regressziókat és hipotézisvizsgálatokat támogat.
openpyxl	Az openpyxl lehetővé teszi a Microsoft Excel xlsx fájlok kezelését, olvasását és írását Pythonból.
datetime	A datetime egy beépített Python modul, amely lehetővé teszi a dátumok és időpontok kezelését, manipulálását és formázását

Forrás: Saját forrás

23. számú melléklet: Top50Bank_Patents.xlsx adatstruktúra - részlet

A	B	C	D	E	F	G	H	I	J	K	L
Bank_Nev	Szabadalom_ID	label_fokategoria	label_alkategoria	Cim	Jogosult	Feltalalo	priority date	Filing_creation_da	publication date	grant date	Link
3120	US-11354602-B2	machine learning	machine learning	System and methods to mit	Bank Of America Corporation	Eren Kursun	2019-06-04	2019-06-04	2022-06-07	2022-06-07	https://patents.google.com/patent/US11354602B2/en
3121	US-11531863-B2	machine learning	machine learning	System and methods for use	Bank Of America Corporation	Eren Kursun	2019-08-12	2019-08-12	2022-12-20	2022-12-20	https://patents.google.com/patent/US11531863B2/en
3122	US-11637880-B2	machine learning	machine learning	System and methods for ge	Bank Of America Corporation	Eren Kursun	2019-08-12	2019-08-12	2022-12-27	2022-12-27	https://patents.google.com/patent/US11637880B2/en
3128	US-10496460-B2	machine learning	anomaly detection	System for technology anor	Bank Of America Corporation	Aaron Dion Kephart, Katy Le	2017-11-15	2017-11-15	2019-12-03	2019-12-03	https://patents.google.com/patent/US10496460B2/en
3131	US-11020392-B2	machine learning	pattern	Pattern-based examination	Bank Of America Corporation	Eren Kursun	2018-11-26	2018-11-26	2021-08-24	2021-08-24	https://patents.google.com/patent/US11020392B2/en
3132	US-10055991-B2	machine learning, aug	virtual reality, predict	System for prediction of fut	Bank Of America Corporation	Alicia C. Jones-McFadden, J	2016-10-07	2016-10-07	2018-08-21	2018-08-21	https://patents.google.com/patent/US10055991B2/en
3137	US-8436110-B2	augmented/virtual realit	augmented reality	Conducting financial transa	Bank Of America Corporation	Matthew A. Calman, Erik Ste	2011-03-08	2012-01-01	2013-05-07	2013-05-07	https://patents.google.com/patent/US8436110B2/en
3154	US-9317860-B2	augmented/virtual realit	augmented reality	Collective network of augme	Bank Of America Corporation	Matthew A. Calman, Erik Ste	2011-03-08	2012-01-01	2016-04-19	2016-04-19	https://patents.google.com/patent/US9317860B2/en
3156	US-11042934-B2	machine learning, bloc	machine learning, bloc	Crypto-machine learning er	Bank Of America Corporation	Awadhesh Pratap Singh, Vi	2017-11-13	2017-11-13	2021-06-22	2021-06-22	https://patents.google.com/patent/US11042934B2/en
3159	US-10710239-B2	RPA	robotic process automat	Intelligent control code upd	Bank Of America Corporation	Jigesh Rajendra Salary, Kris	2018-11-08	2018-11-08	2020-07-14	2020-07-14	https://patents.google.com/patent/US10710239B2/en
3167	US-10754967-B2	machine learning	predict	Big data based predictive g	Bank Of America Corporation	Harish Ragavan, Srinivasan	2016-04-08	2016-04-08	2020-08-25	2020-08-25	https://patents.google.com/patent/US10754967B2/en
3168	US-11275819-B2	image processing	biometric	Generative adversarial netw	Bank Of America Corporation	Eren Kursun	2018-12-05	2018-12-05	2022-03-15	2022-03-15	https://patents.google.com/patent/US11275819B2/en
3169	US-11568392-B2	blockchain	blockchain	Automated event processin	Bank Of America Corporation	Jisoo Lee, John C. Checco	2017-12-07	2021-10-05	2023-01-17	2023-01-17	https://patents.google.com/patent/US11568392B2/en
3175	US-10210767-B2	augmented/virtual realit	augmented reality	Real world gamification usir	Bank Of America Corporation	Joseph N. Johansen, Kath	2016-12-13	2016-12-13	2019-02-19	2019-02-19	https://patents.google.com/patent/US10210767B2/en
3177	US-10482232-B2	RPA	robotic process automat	Robotic process automatio	Bank Of America Corporation	Nagaraju Buddhiraju, Nye	2017-08-16	2017-08-16	2019-11-19	2019-11-19	https://patents.google.com/patent/US10482232B2/en
3178	US-10217375-B2	augmented/virtual realit	augmented reality	Virtual behavior training us	Bank Of America Corporation	Willard H. Waldron, Victoria	2016-12-13	2016-12-13	2019-02-26	2019-02-26	https://patents.google.com/patent/US10217375B2/en
3181	US-11586681-B2	machine learning	machine learning	System and methods to mit	Bank Of America Corporation	Eren Kursun	2019-06-04	2019-06-04	2023-02-21	2023-02-21	https://patents.google.com/patent/US11586681B2/en
3182	US-10726763-B2	machine learning	machine learning	Dynamic interaction optimiz	Bank Of America Corporation	Eren Kursun, Dharmender K	2018-08-21	2018-08-21	2021-04-27	2021-04-27	https://patents.google.com/patent/US10726763B2/en
3184	US-10726434-B2	machine learning, artifi	artificial intelligence, rec	Leveraging an artificial intel	Bank Of America Corporation	Alicia C. Jones-McFadden, K	2016-10-07	2019-10-17	2020-07-28	2020-07-28	https://patents.google.com/patent/US10726434B2/en
3187	US-10958691-B2	cognitive computing	cognitive	Network security system wit	Bank Of America Corporation	Sasidhar Purushothaman	2017-10-25	2020-01-30	2021-03-23	2021-03-23	https://patents.google.com/patent/US10958691B2/en
3209	US-1182800-B2	Quantum computing	Quantum computing	Controlling enterprise softw	Bank Of America Corporation	Lonnice Jason Carter	2019-04-08	2019-04-08	2021-11-23	2021-11-23	https://patents.google.com/patent/US1182800B2/en
3223	US-11270206-B2	artificial intelligence	artificial intelligence	Incremental learning throug	Bank Of America Corporation	Eren Kursun	2018-11-20	2018-11-20	2022-03-08	2022-03-08	https://patents.google.com/patent/US11270206B2/en
3224	US-1164564-B2	machine learning	pattern	Augmented intent and entit	Bank Of America Corporation	Donatus Asumu, Bhargav A	2018-12-05	2020-06-12	2021-11-02	2021-11-02	https://patents.google.com/patent/US1164564B2/en
3225	US-11852239-B2	image processing, Inter	biometric, Internet of Th	Multi-biometric-factor, interi	Bank Of America Corporation	Patrick Nicholas Lawrence, .	2018-03-29	2020-02-27	2021-11-30	2021-11-30	https://patents.google.com/patent/US11852239B2/en
3227	US-11157475-B1	machine learning	machine learning	Generating machine learnin	Bank Of America Corporation	Matthew I. Cobb, Melissa A	2019-04-26	2019-03-30	2021-10-26	2021-10-26	https://patents.google.com/patent/US11157475B1/en
3229	US-11262979-B2	machine learning	machine learning	Machine learning webpage	Bank Of America Corporation	Paresh Deshmukh, Yacine A	2019-09-18	2020-02-20	2022-03-01	2022-03-01	https://patents.google.com/patent/US11262979B2/en
3230	US-10977166-B1	RPA	robotic process automat	System for automated error	Bank Of America Corporation	Karthik Jagannathan, Jason	2019-10-15	2019-10-15	2021-04-13	2021-04-13	https://patents.google.com/patent/US10977166B1/en
3240	US-9504469-B2	machine learning	predict	Predictive coding of docum	Bank Of America Corporation	Phillip L. Richards, David M	2009-03-27	2010-03-24	2013-08-06	2013-08-06	https://patents.google.com/patent/US9504469B2/en
3242	US-11449599-B2	machine learning	machine learning	Identifying similar sentence	Bank Of America Corporation	Kishore GOPALAN, Salish C	2019-08-27	2019-08-27	2022-09-20	2022-09-20	https://patents.google.com/patent/US11449599B2/en
3245	US-11176230-B2	security	secure	Processing authentication r	Bank Of America Corporation	Michael E. Toth, Hitesh Sha	2018-12-05	2018-12-05	2021-11-16	2021-11-16	https://patents.google.com/patent/US11176230B2/en
3248	US-10624807-B2	robot	robot	Robotics assisted productio	Bank Of America Corporation	Awadhesh Pratap Singh	2017-11-03	2019-11-11	2020-11-03	2020-11-03	https://patents.google.com/patent/US10624807B2/en
3249	US-10768956-B2	cloud	cloud	Dynamic cloud stack testin	Bank Of America Corporation	Sandeep Kumar Chauhan, C	2017-08-23	2019-09-20	2020-09-08	2020-09-08	https://patents.google.com/patent/US10768956B2/en
3251	US-11537876-B2	machine learning	machine learning	Targeted variation of machi	Bank Of America Corporation	Vaughn M. Eivens, Ganesh	2018-11-28	2018-11-28	2022-12-27	2022-12-27	https://patents.google.com/patent/US11537876B2/en
3253	US-10462027-B2	cloud	cloud	Cloud network stability	Bank Of America Corporation	Sandeep Kumar Chauhan, A	2017-08-22	2017-08-22	2019-10-29	2019-10-29	https://patents.google.com/patent/US10462027B2/en
3254	US-11195910-B2	security	secure	Utilizing federated user ide	Bank Of America Corporation	Hitesh Shah	2018-12-05	2018-12-05	2021-10-26	2021-10-26	https://patents.google.com/patent/US11195910B2/en
3256	US-11310200-B2	machine learning	machine learning	System and method for ma	Bank Of America Corporation	Eren Kursun	2019-05-24	2019-05-24	2022-04-19	2022-04-19	https://patents.google.com/patent/US11310200B2/en
3259	US-11468361-B2	machine learning	machine learning	Real-time convergence ana	Bank Of America Corporation	Eren Kursun, Hylton N. van	2019-05-24	2019-05-24	2022-10-11	2022-10-11	https://patents.google.com/patent/US11468361B2/en
3260	US-11526725-B2	machine learning	neural network	Attention-based layered nei	Bank Of America Corporation	Eren Kursun	2019-12-06	2019-12-06	2022-12-13	2022-12-13	https://patents.google.com/patent/US11526725B2/en
3262	US-11070449-B2	Distributed ledger	Distributed ledger	Intelligent application deplo	Bank Of America Corporation	Srinivasa Rao Dakshinam,	2018-12-04	2018-12-04	2021-07-20	2021-07-20	https://patents.google.com/patent/US11070449B2/en
3264	US-10484442-B2	cloud	cloud	Dynamic cloud stack config	Bank Of America Corporation	Sandeep Kumar Chauhan, S	2017-08-23	2017-08-23	2019-11-19	2019-11-19	https://patents.google.com/patent/US10484442B2/en
3267	US-11050769-B2	machine learning	machine learning	Controlling dynamic user ir	Bank Of America Corporation	Michael Toth, Xianhong Zhe	2018-02-05	2018-02-05	2021-06-29	2021-06-29	https://patents.google.com/patent/US11050769B2/en
3268	US-11348121-B2	machine learning	anomaly detection	Multi-source anomaly detec	Bank Of America Corporation	George Alberio, Elijah Clark	2019-10-14	2019-10-14	2022-05-31	2022-05-31	https://patents.google.com/patent/US11348121B2/en
3270	US-11168919-B2	security	cybersecurity	Automated real-time multi	Bank Of America Corporation	Michael J. Shand	2019-07-18	2019-07-18	2022-04-26	2022-04-26	https://patents.google.com/patent/US11168919B2/en

Forrás: Saját ábra

24. számú melléklet: Kód1 – A szabadalmak számának alakulása a vizsgált időszak alatt

```
import pandas as pd
import matplotlib.pyplot as plt
from google.colab import files

# Fájl feltöltése
uploaded = files.upload()

# Excel fájl beolvasása
df = pd.read_excel('Top50Bank_Patents_v4.xlsx')

# csoportosítás priority date alapján és számolás
df['priority_year'] = df['priority date'].dt.year
year_counts = df['priority_year'].value_counts().sort_index()

# Az évek tengely skálázása öt évenként
years = year_counts.index
year_ticks = [year for year in years if year % 5 == 0]

# Vonaldiagram létrehozása
plt.figure(figsize=(10, 6))
plt.plot(year_counts.index, year_counts.values, marker='o')
plt.xlabel('Év')
plt.ylabel('Szabadalomok száma')
plt.title('Évenkénti szabadalomok száma')
plt.grid(True)
plt.xticks(year_ticks, rotation=45)
plt.tight_layout()

# Diagram megjelenítése
plt.show()
```

25. számú melléklet: Kód2 – Szabadalmak számának alakulása bankonként 1999-2010 között

```
import pandas as pd
import matplotlib.pyplot as plt
import seaborn as sns
from google.colab import files

# Fájl feltöltése
uploaded = files.upload()

# Excel fájl beolvasása
df = pd.read_excel('Top50Bank_Patents_v4.xlsx')

# Szűrés az 1999 - 2010 közötti szabadalmaztatási folyamatra priority dátum alapján
filtered_df = df[(df['priority date'].dt.year >= 1999) & (df['priority date'].dt.year <= 2010)]

# Pivot tábla létrehozása a bankok és évek alapján
pivot_table = pd.pivot_table(filtered_df, values='Szabadalom_ID', index='Bank_Nev',
                               columns=filtered_df['priority date'].dt.year, aggfunc='count', fill_value=0)

# Szabadalmak bankonkénti eloszlásának hőtérképen való ábrázolása
plt.figure(figsize=(12, 8))
sns.heatmap(pivot_table, cmap='YlGnBu', annot=True, fmt='g', linewidths=0.5)
plt.title('Szabadalmak száma bankok és évek szerint (1999-2010)')
plt.xlabel('Év')
plt.ylabel('Bank')
# X tengely címkéinek elforgatása
plt.xticks(rotation=45)
plt.show()
```

26. számú melléklet: Kód3 – Szabadalmak számának alakulása bankonként 2010-2018 között

```
import pandas as pd
import matplotlib.pyplot as plt
import seaborn as sns
from google.colab import files

# Fájl feltöltése
uploaded = files.upload()

# Excel fájl beolvasása
df = pd.read_excel('Top50Bank_Patents_v4.xlsx')

# Szűrés a 2010 - 2023 között elindított szabaalmakra a priority dátum alapján
filtered_df = df[(df['priority date'].dt.year >= 2010) & (df['priority date'].dt.year <= 2018)]

# Pivot tábla létrehozása a bankok nevei és a vizsgált évek alapján
pivot_table = pd.pivot_table(filtered_df, values='Szabadalom_ID', index='Bank_Nev',
                               columns=filtered_df['priority date'].dt.year, aggfunc='count', fill_value=0)

# Szabadalmak bankonkénti eloszlásának hőtérképen való ábrázolása
plt.figure(figsize=(12, 8))
sns.heatmap(pivot_table, cmap='YlGnBu', annot=True, fmt='g', linewidths=0.5)
plt.title('Szabadalmak száma bankok és évek szerint (2010-2018)')
plt.xlabel('Év')
plt.ylabel('Bank')
# X tengely címkéinek elforgatása
plt.xticks(rotation=45)
plt.show()
```

27. számú melléklet: Kód4 – Szabadalmak számának alakulása bankonként 2018-2023 között

```
import pandas as pd
import matplotlib.pyplot as plt
import seaborn as sns
from google.colab import files

# Fájl feltöltése
uploaded = files.upload()

# Excel fájl beolvasása
df = pd.read_excel('Top50Bank_Patents_v4.xlsx')

# Szűrés a 2010 - 2023 között elindított szabadalmaztatási folyamatokra priority dátum alapján
filtered_df = df[(df['priority date'].dt.year >= 2018) & (df['priority date'].dt.year <= 2023)]

# Pivot tábla létrehozása a bankok nevei és a vizsgált évek alapján
pivot_table = pd.pivot_table(filtered_df, values='Szabadalom_ID', index='Bank_Nev',
                               columns=filtered_df['priority date'].dt.year, aggfunc='count', fill_value=0)

# Szabadalmak bankonkénti eloszlásának hőterképen történő ábrázolása
plt.figure(figsize=(12, 8))
sns.heatmap(pivot_table, cmap='YlGnBu', annot=True, fmt='g', linewidths=0.5)
plt.title('Szabadalmak száma bankok és évek szerint (2018-2023)')
plt.xlabel('Év')
plt.ylabel('Bank')
# X tengely címkéinek elforgatása
plt.xticks(rotation=45)
plt.show()
```


28. számú melléklet: Kód5 - A bankrobotika szabadalmak számának alakulása a vizsgált időszak alatt

```
import pandas as pd
import matplotlib.pyplot as plt
from google.colab import files

# Fájl feltöltése
uploaded = files.upload()

# Excel fájl beolvasása
df = pd.read_excel('Top50Bank_Patents_v4.xlsx')

# Szűrés: az "egyéb" címkével rendelkezők figyelmen kívül hagyása
filtered_df = df[df['cimke_fokategoria'] != 'egyeb']

# Számolás az évek (priority date) csoportosítása alapján
filtered_df['priority_year'] = filtered_df['priority date'].dt.year
year_counts = filtered_df['priority_year'].value_counts().sort_index()

# Az évek tengely öt évenkénti skálázása
years = year_counts.index
year_ticks = [year for year in years if year % 5 == 0]

# Vonaldiagram létrehozása
plt.figure(figsize=(10, 6))
plt.plot(year_counts.index, year_counts.values, marker='o')
plt.xlabel('Év')
plt.ylabel('Szabadalomok száma')
plt.title('Bankrobotika szabadalmak számának alakulása a vizsgált időszak alatt')
plt.grid(True)
plt.xticks(year_ticks, rotation=45)
plt.tight_layout()

# Diagram megjelenítése
plt.show()

# Az adatok mentése Excel fájlba
result_df = pd.DataFrame({'Év': year_counts.index, 'Szabadalomok száma':
year_counts.values})
result_df.to_excel('szabadalomok_szama_nem_egyeb.xlsx', index=False)
```

29. számú melléklet: Kód6 – Bankrobotika szabadalmak időbeli alakulása bankrobotika technológiáinként

```
import pandas as pd
import matplotlib.pyplot as plt
import numpy as np
from google.colab import files

# Fájl feltöltése parancs
uploaded = files.upload()

# Excel fájl beolvasása
df = pd.read_excel('Top50Bank_Patents_v4.xlsx')

# Szűrés a cimke_fokategoria alapján – az egyéb főcímké kiszűrése
filtered_df = df[df['cimke_fokategoria'] != 'egyeb']

# Pivot tábla létrehozása a cimke_fokategoria és az évek alapján
pivot_table = pd.pivot_table(filtered_df, values='Szabadalom_ID', index='cimke_fokategoria',
columns=filtered_df['priority date'].dt.year, aggfunc='count', fill_value=0)

# Hőtérkép létrehozása
plt.figure(figsize=(12, 8))
plt.imshow(pivot_table.values, cmap='YlGnBu', aspect='auto')
plt.xticks(range(len(pivot_table.columns)), pivot_table.columns, rotation=45)
plt.yticks(range(len(pivot_table.index)), pivot_table.index)
plt.colorbar(label='Szabadalomok száma')
plt.title('Zabadalmak száma címke és évek szerint')
plt.xlabel('Év')
plt.ylabel('Címke főkategória')

# Bankrobotika szabadalmak számának kiírása a hőtérképen
for i in range(len(pivot_table.index)):
    for j in range(len(pivot_table.columns)):
        plt.text(j, i, pivot_table.values[i, j], ha='center', va='center', color='black', fontsize=10)

plt.tight_layout()
plt.show()

# Pivot tábla megjelenítése
print(pivot_table)
```

30. számú melléklet: Kód 7 – Bankrobotika technológiák megoszlásának alakulása

1999-2010 között

```
import pandas as pd
import matplotlib.pyplot as plt
from google.colab import files

# Fájlfeltöltése parancs
uploaded = files.upload()

# Excel fájl beolvasása
df = pd.read_excel('Top50Bank_Patents_v4.xlsx')

# Szűrés a címke_fokategoria alapján – az egyéb főcímke kiszűrése
filtered_df = df[df['cimke_fokategoria'] != 'egyeb']

# Szűrés az évek alapján (1999 - 2010)
filtered_df = filtered_df[(filtered_df['priority date'].dt.year >= 1999) & (filtered_df['priority date'].dt.year <= 2010)]

# Pivot tábla létrehozása a címke_fokategoria és az évek alapján
pivot_table = pd.pivot_table(filtered_df, values='Szabadalom_ID', index='cimke_fokategoria', columns=filtered_df['priority date'].dt.year, aggfunc='count', fill_value=0)

# Hőtérkép létrehozása
plt.figure(figsize=(12, 8))
plt.imshow(pivot_table.values, cmap='YlGnBu', aspect='auto')
plt.xticks(range(len(pivot_table.columns)), pivot_table.columns, rotation=45)
plt.yticks(range(len(pivot_table.index)), pivot_table.index)
plt.colorbar(label='Szabadalomok száma')
plt.title('Szabadalmak száma címke és évek szerint (1999-2010)')
plt.xlabel('Év')
plt.ylabel('Címke főkategória')

# Szabadalmak számának kiírása a hőtérképen
for i in range(len(pivot_table.index)):
    for j in range(len(pivot_table.columns)):
        plt.text(j, i, pivot_table.values[i, j], ha='center', va='center', color='black', fontsize=10)

plt.tight_layout()
plt.show()

# Pivot tábla készítése
print(pivot_table)
```

31. számú melléklet: Kód 8 – Bankrobotika szabadalmi portfólió alakulása 1999-2010

```
import pandas as pd
import matplotlib.pyplot as plt
from google.colab import files

# Fájlfeltöltése
uploaded = files.upload()

# Excel fájl beolvasása
df = pd.read_excel('Top50Bank_Patents_v4.xlsx')

# Szűrés a címke_fokategoria alapján – az egyéb főkategória figyelmen kívül hagyása
filtered_df = df[df['Bankrobotika kategória'] != 'egyeb']

# Szűrés az évek alapján (1999 - 2010 közöttre)
filtered_df = filtered_df[(filtered_df['priority date'].dt.year >= 1999) & (filtered_df['priority date'].dt.year <= 2010)]

# Pivot tábla létrehozása a címke_fokategoria és évek (priority date) alapján
pivot_table = pd.pivot_table(filtered_df, values='Szabadalom_ID', index='címke_fokategoria',
                              columns=filtered_df['priority date'].dt.year, aggfunc='count', fill_value=0)

# Hőtérkép létrehozása
plt.figure(figsize=(12, 8))
plt.imshow(pivot_table.values, cmap='YlGnBu', aspect='auto')
plt.xticks(range(len(pivot_table.columns)), pivot_table.columns, rotation=45)
plt.yticks(range(len(pivot_table.index)), pivot_table.index)
plt.colorbar(label='Szabadalomok száma')
plt.title('Bankrobotika szabadalmak száma címke és évek szerint (1999-2010)')
plt.xlabel('Év')
plt.ylabel('Címke főkategória')

# Szabadalmak számának kiírása a hőtérképen
for i in range(len(pivot_table.index)):
    for j in range(len(pivot_table.columns)):
        plt.text(j, i, pivot_table.values[i, j], ha='center', va='center', color='black', fontsize=10)

plt.tight_layout()
plt.show()

# Pivot tábla megjelenítése
print(pivot_table)
```

32. számú melléklet: Kód 9 – Bankrobotika technológiák megoszlásának alakulása 2010 – 2018 között

```
import pandas as pd
import matplotlib.pyplot as plt
from google.colab import files

# Fájl feltöltése
uploaded = files.upload()

# Excel fájl beolvasása
df = pd.read_excel('Top50Bank_Patents_v4.xlsx')

# Szűrés a címke_fokategoria alapján – az egyéb főkategória figyelmen kívül hagyása
filtered_df = df[df['címke_fokategoria'] != 'egyeb']

# Szűrés az évek (priority date) alapján (2010 - 2018 közöttre)
filtered_df = filtered_df[(filtered_df['priority date'].dt.year >= 2010) & (filtered_df['priority date'].dt.year <= 2018)]

# Pivot tábla létrehozása a címke_fokategoria és évek (priority date) alapján
pivot_table = pd.pivot_table(filtered_df, values='Szabadalom_ID', index='címke_fokategoria',
columns=filtered_df['priority date'].dt.year, aggfunc='count', fill_value=0)

# Hőtérkép létrehozása
plt.figure(figsize=(12, 8))
plt.imshow(pivot_table.values, cmap='YlGnBu', aspect='auto')
plt.xticks(range(len(pivot_table.columns)), pivot_table.columns, rotation=45)
plt.yticks(range(len(pivot_table.index)), pivot_table.index)
plt.colorbar(label='Szabadalomok száma')
plt.title('Szabadalmak száma címke és évek szerint (2010-2018)')
plt.xlabel('Év')
plt.ylabel('Címke főkategória')

# Szabadalmak számának kiírása a hőtérképen
for i in range(len(pivot_table.index)):
    for j in range(len(pivot_table.columns)):
        plt.text(j, i, pivot_table.values[i, j], ha='center', va='center', color='black', fontsize=10)

plt.tight_layout()
plt.show()

# Pivot tábla megjelenítése
print(pivot_table)
```

33. számú melléklet: Kód 10- Bankrobotika szabadalmi portfólió alakulása 2010-2018

```
import pandas as pd
import matplotlib.pyplot as plt
import seaborn as sns
from google.colab import files

# Fájlfeltöltése
uploaded = files.upload()

# Excel fájl beolvasása
df = pd.read_excel('Top50Bank_Patents_v4.xlsx')

# Szűrés a 2010 - 2018 közötti szabadalmaztatási tevékenységre priority dátum alapján
filtered_df = df[(df['priority date'].dt.year >= 2010) & (df['priority date'].dt.year <= 2018)]

# Szűrés az "egyéb" címkék figyelmen kívül hagyása érdekében
filtered_df = filtered_df[filtered_df['cimke_fokategoria'] != 'egyeb']

# Pivot tábla létrehozása a bankok nevei és az évek (priority date) alapján
pivot_table = pd.pivot_table(filtered_df, values='Szabadalom_ID', index='Bank_Nev',
                               columns=filtered_df['priority date'].dt.year, aggfunc='count', fill_value=0)

# Szabadalmak bankonkénti eloszlásának hőtérképen való ábrázolása
plt.figure(figsize=(12, 8))
sns.heatmap(pivot_table, cmap='YlGnBu', annot=True, fmt='g', linewidths=0.5)
plt.xlabel('Év')
plt.ylabel('Bank')
# X tengely címkéinek elforgatása
plt.xticks(rotation=45)
plt.show()
```

34. számú melléklet: Kód 11 – Bankrobotika technológiák megoszlásának alakulása 2018 – 2023 között

```
import pandas as pd
import matplotlib.pyplot as plt
from google.colab import files

# Fájlfeltöltése
uploaded = files.upload()

# Excel fájl beolvasása
df = pd.read_excel('Top50Bank_Patents_v4.xlsx')

# Szűrés a címke_fokategória alapján – az egyéb főkategória figyelmen kívül hagyása
filtered_df = df[df['címke_fokategória'] != 'egyeb']

# Szűrés az évek alapján (2018 - 2023 között)
filtered_df = filtered_df[(filtered_df['priority date'].dt.year >= 2018) & (filtered_df['priority date'].dt.year <= 2023)]

# Pivot tábla létrehozása a címke_fokategória és évek alapján
pivot_table = pd.pivot_table(filtered_df, values='Szabadalom_ID', index='címke_fokategória',
                              columns=filtered_df['priority date'].dt.year, aggfunc='count', fill_value=0)

# Hőtérkép létrehozása
plt.figure(figsize=(12, 8))
plt.imshow(pivot_table.values, cmap='YlGnBu', aspect='auto')
plt.xticks(range(len(pivot_table.columns)), pivot_table.columns, rotation=45)
plt.yticks(range(len(pivot_table.index)), pivot_table.index)
plt.colorbar(label='Szabadalomok száma')
plt.title('Szabadalmak száma címke és évek szerint (2018-2023)')
plt.xlabel('Év')
plt.ylabel('Címke főkategória')

# Szabadalmak számnak kiírása a hőtérképen
for i in range(len(pivot_table.index)):
    for j in range(len(pivot_table.columns)):
        plt.text(j, i, pivot_table.values[i, j], ha='center', va='center', color='black', fontsize=10)

plt.tight_layout()
plt.show()

# Pivot tábla megjelenítése
print(pivot_table)
```

35. számú melléklet: Kód 12 – Bankrobotika szabadalmi portfólió alakulása 2018-2023

```
import pandas as pd
import matplotlib.pyplot as plt
import seaborn as sns
from google.colab import files

# Fájlfeltöltése
uploaded = files.upload()

# Excel fájl beolvasása
df = pd.read_excel('Top50Bank_Patents_v4.xlsx')

# Szűrés a 2018 - 2023 közötti szabadalmaztatási tevékenységre priority dátum alapján
filtered_df = df[(df['priority date'].dt.year >= 2018) & (df['priority date'].dt.year <= 2023)]

# Szűrés az "egyéb" címkék kivételével–figyelmen kívül hagyás
filtered_df = filtered_df[filtered_df['cimke_fokategoria'] != 'egyeb']

# Pivot tábla létrehozása a bankok és évek (priority date) alapján
pivot_table = pd.pivot_table(filtered_df, values='Szabadalom_ID', index='Bank_Nev',
                               columns=filtered_df['priority date'].dt.year, aggfunc='count', fill_value=0)

# Szabadalmak bankonkénti eloszlásának hőtérképen való ábrázolása
plt.figure(figsize=(12, 8))
sns.heatmap(pivot_table, cmap='YlGnBu', annot=True, fmt='g', linewidths=0.5)
plt.xlabel('Év')
plt.ylabel('Bank')
# X tengely címkéinek elforgatása
plt.xticks(rotation=45)
plt.show()
```


36. számú melléklet: Kód 13 – NLP és ML hibrid modell (K-közép) futtatása az egyéb focimke_kategoria nélkül

```
import json
import numpy as np
import pandas as pd
from sklearn.feature_extraction.text import TfidfVectorizer
from sklearn.decomposition import PCA
from sklearn.cluster import KMeans
from sklearn.metrics import davies_bouldin_score
import matplotlib.pyplot as plt
from pprint import pprint
from collections import OrderedDict

from google.colab import files
uploaded = files.upload()

# Excel fájl beolvasása
df = pd.read_excel('Top50Bank_Patents_v4.xlsx')

df.head()
df = df[df['cimke_fokategoria'] != 'egyeb']
data_col = df['Cim']
data_col

vectorizer = TfidfVectorizer(stop_words='english')
vectorized_documents = vectorizer.fit_transform(data_col)
vectorized_documents

pca = PCA(n_components=2)
reduced_data = pca.fit_transform(vectorized_documents.toarray())

# num_clusters = range(10, 40)
num_clusters = [39]

dbscores = {}

for cluster_count in num_clusters:
    results = pd.DataFrame()
    results['Szabadalom_ID'] = df['Szabadalom_ID']
    results['Bank_Nev'] = df['Bank_Nev']
    results['cimke_fokategoria'] = df['cimke_fokategoria']
    results['cimke_alkategoria'] = df['cimke_alkategoria']
    results['cim'] = data_col

    kmeans = KMeans(n_clusters=cluster_count, n_init=5,
                    max_iter=500, random_state=42)
    kmeans.fit(vectorized_documents)
    dbs = davies_bouldin_score(vectorized_documents.toarray(), kmeans.labels_)
    dbscores[cluster_count] = dbs
```

```
results['cluster'] = kmeans.labels_  
print(results)  
results.to_excel('%d_kategoria_cluster.xlsx' % cluster_count)  
print('='*10)  
  
d_sorted_by_value = OrderedDict(sorted(dbscores.items(), key=lambda x: x[1]))  
pprint(d_sorted_by_value)  
  
# XLSX fájl mentése  
files.download('%d_kategoria_cluster.xlsx' % num_clusters[0])
```

37. számú melléklet: Kód 14 – NLP és ML hibrid modell (K-means) futtatása az egyéb focimke_kategoria bevonásával

```
import json
import numpy as np
import pandas as pd
from sklearn.feature_extraction.text import TfidfVectorizer
from sklearn.decomposition import PCA
from sklearn.cluster import KMeans
from sklearn.metrics import davies_bouldin_score
import matplotlib.pyplot as plt
from pprint import pprint
from collections import OrderedDict

uploaded = files.upload()
# Excel fájl beolvasása
df = pd.read_excel('Top50Bank_Patents_v4.xlsx')
df.head()
data_col = df['Cim']
data_col

vectorizer = TfidfVectorizer(stop_words='english')
vectorized_documents = vectorizer.fit_transform(data_col)
vectorized_documents

pca = PCA(n_components=2)
reduced_data = pca.fit_transform(vectorized_documents.toarray())
# num_clusters = range(10, 40)
num_clusters = [29]

dbscores = {}

for cluster_count in num_clusters:
    results = pd.DataFrame()
    results['Szabadalom_ID'] = df['Szabadalom_ID']
    results['Bank_Nev'] = df['Bank_Nev']
    results['cimke_fokategoria'] = df['cimke_fokategoria']
    results['cimke_alkategoria'] = df['cimke_alkategoria']
    results['cim'] = data_col

    kmeans = KMeans(n_clusters=cluster_count, n_init=5,
                    max_iter=500, random_state=42)
    kmeans.fit(vectorized_documents)
    dbs = davies_bouldin_score(vectorized_documents.toarray(), kmeans.labels_)
    dbscores[cluster_count] = dbs
    results['cluster'] = kmeans.labels_
    print(results)
    results.to_excel('%d_kategoria_cluster_egyebekkel.xlsx' % cluster_count)
    print('='*10)
```

```
d_sorted_by_value = OrderedDict(sorted(dbscores.items(), key=lambda x: x[1]))
pprint(d_sorted_by_value)

# XLSX fájl mentése
files.download('%d_kategoria_cluster_egyebekkel.xlsx' % num_clusters[0])
```

38. számú melléklet: Az 1. modell futtatásának eredménye – minta

Szabadalom_ID	Bank_Nev	Cimke_fokategoria	Cimke_alkategoria	Cim	Klaszter
AU-2022202404-A1	Royal Bank of Canada	payment	payment	Secure processing of electronic payments	11
US-2020372369-A1	Royal Bank of Canada	machine learning	machine learning	System and method for machine learning architecture for partially-observed multimodal data	13
US-2020151686-A1	Royal Bank of Canada	blockchain	blockchain	System and method for cross-border blockchain platform	9
US-2020034830-A1	Royal Bank of Canada	payment	payment	Payment card with secure element and replenishable tokens	8
US-2019236455-A1	Royal Bank of Canada	machine learning	neural network	Pre-training neural networks with human demonstrations for deep reinforcement learning	22
AU-2017231106-B2	Royal Bank of Canada	payment	payment	Systems, methods, and devices for secure generation and processing of data sets representing pre-funded payments	11
US-2018047065-A1	Royal Bank of Canada	machine learning	predict	System and method for predictive digital profiles	26
US-11520899-B2	Royal Bank of Canada	machine learning	machine learning	System and method for machine learning architecture with adversarial attack defense	13
US-2021406386-A1	Royal Bank of Canada	security	secure	System and method for multiparty secure computing platform	9
US-11531930-B2	Royal Bank of Canada	machine learning	machine learning	System and method for monitoring machine learning models	37

Forrás: Saját táblázat

39. számú melléklet: Gépi címkézés eredményének klaszter hovatarozása

Sorcímkek	Klaszter címkék																																												
	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38						
application programming interface																		10						1	1																				
application programming interface, payment																		1																											
application programming interface, Quantum computing																		1																											
artificial intelligence																		44												4							1								
artificial intelligence, blockchain																		1																											
artificial intelligence, Quantum computing																																							1						
augmented/virtual reality																																													
augmented/virtual reality, image processing																																													
augmented/virtual reality, payment																																													
blockchain				6		1				6									1	1					1			19			1														
cloud			1	2						3				1						6				1	3		1	1													1				
cloud, payment										1																																1			
cognitive computing		2		1															1		1			1					2													27		1	
cognitive computing, payment																																												1	
Cryptocurrency																																													
Cryptography			1		3						3	1	1																																
Cryptography, artificial intelligence																																													
Cryptography, blockchain																																													
Cryptography, Distributed ledger																																													
Cryptography, image processing																																													
Cryptography, machine learning																																													

40. számú melléklet: Kód15 – Bankrobotika technológiák üzleti célú felhasználásának alakulása bankonként

```
import pandas as pd
import matplotlib.pyplot as plt
import seaborn as sns

# Excel fájl beolvasása
df = pd.read_excel('39_kategoria_clusterenként lévő szabadalom szám.xlsx')

# Oszlopnevek ellenőrzése
print(df.columns)

# Pivot tábla létrehozása
pivot_table = df.pivot_table(index='Bank_Nev', columns='cluster', values='Szabadalom_ID',
aggfunc='count', fill_value=0)

# Hőtérkép létrehozása
plt.figure(figsize=(12, 8))
sns.heatmap(pivot_table, cmap='YlGnBu', annot=True, fmt='d', linewidths=.5)
plt.title('Szabadalmak száma bankonként és klaszter csoportonként')
plt.xlabel('Klaszter szám')
plt.ylabel('Bank_Nev')
plt.show()
```

41. számú melléklet: Kód16 – Bankok bankrobotika szabadalmi portfóliójának alakulása az üzleti célok tekintetében

```
import json
import numpy as np
import pandas as pd
from sklearn.feature_extraction.text import TfidfVectorizer
from sklearn.decomposition import PCA
from sklearn.cluster import KMeans
from sklearn.metrics import davies_bouldin_score
import matplotlib.pyplot as plt
from pprint import pprint
from collections import OrderedDict

# Excel fájl beolvasása
df = pd.read_excel('39_kategoria_cluster_mentes_eredmenye.xlsx')

# Buborékdiagram létrehozása bankonként és cluster csoportonként
bank_counts = df.groupby(['Bank_Nev', 'cluster']).size().reset_index(name='count')
bank_patent_counts = df.groupby(['Bank_Nev',
'cluster']).size().reset_index(name='total_patents')

# A buborékdiagram méretének beállítása a szabadalmak számával
max_size = bank_patent_counts['total_patents'].max()
sizes = bank_patent_counts['total_patents'] / max_size * 100

# Buborékdiagram létrehozása
fig, ax = plt.subplots(figsize=(10, 6))
scatter = ax.scatter(bank_counts['cluster'], bank_counts['Bank_Nev'], s=sizes,
c=bank_counts['count'], cmap='viridis', alpha=0.7)

# Színek állítása
cbar = plt.colorbar(scatter)
cbar.set_label('Szabadalomok száma')

# A tengelyek címkeinek beállítása
plt.xlabel('Klaszter szám')
plt.ylabel('Bank_Nev')
plt.title('Bankok szabadalmainak klaszterezése bankonként és cluster csoportonként')

# Diagram megjelenítése
plt.show()
```

42. számú melléklet: A 2. modell gépi címkézésének eredménye - minta

Szabadalom_ID	Bank_Nev	Cimke_fokategoria	Cimke_alkategoria	Cim	Klaszter
CA-3133280-A1	Bank Of Montreal	machine learning	predict	Systems and methods for predicting operational events	2
US-11514490-B2	Bank Of Montreal	payment	payment	System and process for electronic calendar payments	8
US-2022391844-A1	Bank Of Montreal	egyeb	egyeb	Systems and methods for data mart rationalization	2
US-2021326960-A1	Bank Of Montreal	machine learning, artificial intelligence	artificial intelligence, predict	Artificial intelligence modeling to predict electronic account data	8
US-2020396131-A1	Bank Of Montreal	egyeb	egyeb	Network capacity planning systems and methods	2
US-2022300540-A1	Bank Of Montreal	security	secure	Systems and methods for secure storage and retrieval of trade data	9
US-2019377654-A1	Bank Of Montreal	egyeb	egyeb	Systems and methods for generating a snapshot view of network infrastructure	2
US-2022108504-A1	Bank Of Montreal	machine learning	machine learning	Systems and methods for generating flood hazard estimation using machine learning model and satellite data	7
US-3810218-A	Bank Of Montreal	egyeb	egyeb	Camera mechanism	6
US-3266278-A	Bank Of Montreal	egyeb	egyeb	Locking device	6
WO-0237346-A2	Bank Of Montreal	egyeb	egyeb	Internet based consumer credit loan application system	20
CA-3171086-A1	Bank Of Montreal	egyeb	egyeb	Systems and methods for executing models based on metadata	2

Forrás: Saját táblázat

IRODALOMJEGYZÉK

- Abe, M.** – Nakayama, H. (2018): Deep Learning for Forecasting Stock Returns in the Cross-Section. *Advances in Knowledge Discovery and Data Mining*, pp. 273 – 284. https://doi.org/10.1007/978-3-319-93034-3_22
- Abel, M.** – Buccino, G. – Binkofski, F. (2024): Perception of robotic actions and the influence of gender. *Front. Psychol.* 15:1295279. <https://doi.org/10.3389/fpsyg.2024.1295279>
- Abraham, F.** – Schmukler, S. – Tessada, J. (2019): Financial Innovation and Additionality: The Power of Economic Analysis and Data Analytics (June 1, 2019). *World Bank Research and Policy Briefs* No. 138280. Online: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3586630
- Addy, W.** — Ajayi-Nifise, A. — Bello, B. — Odeyemi, O. — Falaiye, T. (2024): AI in credit scoring: A comprehensive review of models and predictive analytics. *Global Journal of Engineering and Technology Advances.* 18. 118-129. <https://doi.org/10.30574/gjeta.2024.18.2.0029>
- Agarwal, A.** (2017): Future Of Robotics In Banking. *International Journal of Informative & Futuristic Research.* Volume 4. 6297-6320. ISSN: 2347-1697. Online: https://www.researchgate.net/publication/318108459_Future_Of_Robotics_In_Banking
- Agudelo, A. A.** – Medina, R. A. R. – Méndez, N. D. D. (2020): Machine learning applied in the stock market through the Moving Average Convergence Divergence (MACD) indicator. *Investment Management and Financial Innovations*, 17(4), 44-60. [https://doi.org/10.21511/imfi.17\(4\).2020.05](https://doi.org/10.21511/imfi.17(4).2020.05)
- Ahmed, O.** (2018): Artificial Intelligence in HR. *IJRAR* December 2018, Volume 5, Issue 4. pp.971-978. Online: <https://www.ijrar.org/papers/IJRAR1944797.pdf>
- Aithal, P** – Geetha, M. – Acharya, D. – Parthiv. S. – Parthiv, M. (2023): Real-Time Portfolio Management System Utilizing Machine Learning Techniques. *IEEE Access.* p. 1-1. <https://doi.org/10.1109/access.2023.3263260>

- Ala'raj, M.** – Abbod, M. F. – Majdalawieh, M. (2021): Modelling customers credit card behaviour using bidirectional LSTM neural networks. *Journal of Big Data* volume 8 issue 1. <https://doi.org/10.1186/s40537-021-00461-7>
- Alberg, J.** – Lipton, Z. (2017): Improving Factor-Based Quantitative Investing by Forecasting Company Fundamentals. Online: https://www.researchgate.net/publication/321095166_Improving_Factor-Based_Quantitative_Investing_by_Forecasting_Company_Fundamentals
- Alexandre, C.** – Balsa, J. (2018): A Multi-Agent System Based Approach to Fight Financial Fraud: An Application to Money Laundering. Preprints, 2018010193. <https://doi.org/10.20944/preprints201801.0193.v1>
- Alt, R.** – Beck, R. – Smits, M. T. (2018): Fintech and the transformation of the financial industry. *Electronic Markets*, volume 28 issue 3 on pages 235 to 243. <https://doi.org/10.1007/s12525-018-0310-9>
- Álvarez-Jareño** – J. A. – Badal-Valero, E. – Pavía, J. M. (2017): Using machine learning for financial fraud detection in the accounts of companies investigated for money laundering. *Working Papers 2017/07, Economics Department, Universitat Jaume I, Castellón (Spain)*, Online: <https://ideas.repec.org/p/jau/wpaper/2017-07.html>
- Amelia, A.** – Mathies, C. – Patterson, P.G. (2022): Customer acceptance of frontline service robots in retail banking: A qualitative approach, *Journal of Service Management*, Vol. 33 No. 2, pp. 321-341. <https://doi.org/10.1108/JOSM-10-2020-0374>
- Anjali, C.** – Priyanka, B. (2018): Application of Ensemble Models in Credit Scoring Models. *Business Perspectives and Research*. Volume 6, issue 2. 129 t-141. <https://doi.org/10.1177/2278533718765531>
- Appel, M.** – Izydorczyk, D. – Weber, S. – Mara, M. – Lischetzke, T. (2020): The uncanny of mind in a machine: Humanoid robots as tools, agents, and experiencers. *Computers in Human Behavior*, 102, 274–286. <https://doi.org/10.1016/j.chb.2019.07.031>

Arrieta, A. B. – Díaz-Rodríguez, N. – Del Ser, J. et al (2020): Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information Fusion*, Volume 58, June 2020, pp. 82-115. <https://doi.org/10.1016/j.inffus.2019.12.012>

Asian Development Bank Institute (2020): Digital transformation: some implications for financial and macroeconomic stability. *ADB Working Paper Series*. No. 1139 May 2020. Online: <https://www.adb.org/sites/default/files/publication/606546/adbi-wp1139.pdf>

Asimov, I. (1986): Robot dreams. New York, Ace Books

Asprino, L. – Ciancarini, P. – Nuzzolese, A. G. – Presutti, V. – Russo, A. (2022): A reference architecture for social robots. *Journal of Web Semantics*, 72, 1570-8268. <https://doi.org/10.1016/j.websem.2021.100683>

Awad, E. – Dsouza, S. – Kim, R. – Schulz, J. – Henrich, J. – Shariff, A. – Bonnefon, J-F. – Rahwan, I. (2018): The Moral Machine Experiment. *Nature*. Vol. 563, Iss: 7729, pp 59-64. <https://doi.org/10.1038/s41586-018-0637-6>

Ayoubi, M. (2016): Customer Segmentation Based on CLV Model and Neural Network. *IJCSI International Journal of Computer Science Issues*, Volume 13, Issue 2, March 2016. <https://doi.org/10.20943/01201602.3137>

Azimi, M. – Agrawal, A. (2021): Is Positive Sentiment in Corporate Annual Reports Informative? Evidence from Deep Learning (January 5, 2021). Forthcoming, *Review of Asset Pricing Studies*, 2021, <https://doi.org/10.2139/ssrn.3258821>

Bagó P. (2023): A mesterséges intelligencia lehetőségei a pénzügyekben. *Gazdaság és Pénzügy*, 10(1): 21–38. <https://doi.org/10.33926/gp.2023.1.2>

Bank for International Settlements (2011): Principles for the Sound Management of Operational Risk. Online: <https://www.bis.org/publ/bcbs195.pdf>

- Bank for International Settlements** (2017): Sound Practices: Implications of Fintech developments for banks and bank supervisors. Online: <https://www.bis.org/bcbs/publ/d431.pdf>
- Bank for International Settlements** (2021): Use of big data sources and applications at central banks. ISSN 1991-7511. Online: https://www.bis.org/ifc/publ/ifc_report_13.pdf
- Bank of America Global Research** (2023): Me, Myself and AI - *Artificial Intelligence Primer Thematic Investing*. Online: <https://business.bofa.com/content/dam/flagship/global-research/ai-trends-impact-report.pdf>
- Bank of Italy** (2022): Explainable Artificial Intelligence: interpreting default forecasting models based on Machine Learning. Online: https://www.bancaditalia.it/pubblicazioni/qef/2022-0674/QEF_674_22.pdf?language_id=1
- Baraka, K.** – Alves-Oliveira, P. – Ribeiro, T. (2020): An extended framework for characterizing social robots. *Springer series on bio- and neurosystems* (pp. 21–64). https://doi.org/10.1007/978-3-030-42307-0_2
- Bartram, S.M.** – Branke, J. – Motahari, M. (2020): Artificial intelligence in asset management. *CFA Institute Research Foundation Literature Reviews*. <https://www.cfainstitute.org/-/media/documents/book/rf-lit-review/2020/rflr-artificial-intelligence-in-asset-management.pdf>
- Basel Committee on Banking Supervision** (2021): Revisions to the Principles for the Sound Management of Operational Risk. Online: <https://www.bis.org/bcbs/publ/d515.pdf>
- Baum, C.** – Chiang, J. H-y. – David, B. – Frederiksen, T. K. (2022): SoK: Privacy-Enhancing Technologies in Finance. *Proceedings on Privacy Enhancing Technologies*, volume 2022, issue 4, pp. 24 - 43. <https://doi.org/10.56553/popets-2022-0097>

- Becker, S.** – Cheridito, P. – Jentzen, A. (2019): Deep optimal stopping. *Journal of Machine Learning Research*, 20, pp. 1-25. Online: <https://jmlr.org/papers/volume20/18-232/18-232.pdf>
- Beer, J. M.** – Fisk, A. D. – Rogers, W. A. (2014): Toward a framework for levels of robot autonomy in Human-Robot interaction. *Journal of Human-robot Interaction*, 3(2), 74. <https://doi.org/10.5898/jhri.3.2.beer>
- Beer, J. M.** – Fisk, A. D. – Rogers, W. A. (2014): Toward a Framework for Levels of Robot Autonomy in Human-Robot Interaction. *Journal of Human-Robot Interaction*, Volume 3. Issue 2. pp 74–99. <https://doi.org/10.5898/jhri.3.2.beer>
- Beijing Academy of Artificial Intelligence** (2019): *Beijing AI Principles. Datenschutz und Datensicherheit* - DuD 43, pp: 656 - 656. Online: <https://www.semanticscholar.org/paper/Beijing-AI-Principles/a703873b9c697c05b9146a5df790745b6f303857>
- Bekey, A. G.** (2005): Autonomous Robots: From Biological Inspiration to Implementation and Control. *The MIT Press*. ISBN: 9780262534185.
- Bekkum, M.** – Borgesius, F. (2023): Using sensitive data to prevent discrimination by AI: Does the GDPR need a new exception? *Computer law & security review*, 48 (2023), 105770 <https://doi.org/10.2139/ssrn.4104823>
- Belharet, A.** – Bharathan, U. – Mathur, C. (2020): A Study on the Impact of Artificial Intelligence on Project Management. *Project & Program Management*, eJournal, Issue 15, Volume 13, <https://doi.org/10.2139/ssrn.3660689>
- Berger, A. N.** (2003): The Economic Effects of Technological Progress: Evidence from the Banking Industry. *Journal of Money, Credit, and Banking*, volume 35 issue 2 on pages 141 - 176. <https://doi.org/10.1353/mcb.2003.0009>
- Berhil, S.** – Benlahmar, H. – Labani, N. (2020): A review paper on artificial intelligence at the service of human resources management. *Indonesian Journal of Electrical Engineering*

and Computer Science, Vol. 18, No. 1, April 2020, pp. 32~40 ISSN: 2502-4752,
<https://doi.org/10.11591/ijeecs.v18.i1.pp32-40>

Bhattacharyya, S.S. – Nair, S. (2019): Explicating the future of work: perspectives from India. *J. Manag. Dev.* 38 (3), 175–194. <https://doi.org/10.1108/JMD-01-2019-0032>

Bhatti, S. – Leidner, D. (2021): Acceptance of Anthropomorphic Technology: A Literature Review. *Proceedings of the Annual Hawaii International Conference on System Sciences*. <https://doi.org/10.24251/hicss.2021.774>

Bianchi, D – Büchner, M. – Tamoni, A. (2020): Bond Risk Premia with Machine Learning. *WBS Finance Group Research Paper*, No. 252, <http://dx.doi.org/10.2139/ssrn.3232721>

Bommasani, R. – Hudson, D. – Adeli, E. – Altman, R. – Arora, S. – Arx, S. – Bernstein, M. – Bohg, J. – Bosselut, A. – Brunskill, E. – Brynjolfsson, E. – Buch, S. – Card, D. – Castellon, R. – Chatterji, N. – Chen, A. – Creel, K. – Davis, J. – Demszky, D. – Liang, P. (2021): On the Opportunities and Risks of Foundation Models. Online: [https://www.researchgate.net/publication/353941945 On the Opportunities and Risks of Foundation Models](https://www.researchgate.net/publication/353941945_On_the_Opportunities_and_Risks_of_Foundation_Models)

Bonaccorsi di Patti, E. – Calabresi, F. – De Varti, B. – Federico, F. – Affinito, M. – Antolini, M. – Lorizzo, F. – Marchetti, S. – Masiani, I. – Moscatelli, M. – Privitera, F. – Rinna, G. R. (2022): Artificial Intelligence in Credit Scoring. An Analysis of Some Experiences in the Italian Financial System. *Bank of Italy Occasional Paper* No. 721. <https://doi.org/10.2139/ssrn.4462973>

Botunac, I. – Parlov, N. – Bosna, J. (2024): Opportunities of Gen AI in the Banking Industry with regards to the AI Act, GDPR, Data Act and DORA, 2024 13th Mediterranean Conference on Embedded Computing (MECO), Budva, Montenegro, 2024, pp. 1-6, <https://doi.org/10.1109/meco62516.2024.10577936>

Boz, Z. – Gunnec, D. – Birbil, I. – Öztürk, M. K. (2018): Reassessment and Monitoring of Loan Applications with Machine Learning. *Applied Artificial Intelligence*. 32. 1-17. <https://doi.org/10.1080/08839514.2018.1525517>

- Brenner, L.** – Meyll, T. (2020): Robo-Advisors: A substitute for human financial advice. *Journal of Behavioral and Experimental Finance*, volume 25, pp: 100275. <https://doi.org/10.1016/j.jbef.2020.100275>
- Brewis, G.** (2004): Beyond banking: lessons from an impact evaluation of employee volunteering at Barclays Bank. *Voluntary Action: the journal of the Institute for Volunteering Research*, 6 (3) pp. 13-25.
- Brotcke, L.** (2022): Time to Assess Bias in Machine Learning Models for Credit Decisions. *Journal of Risk and Financial Management* 15:165. <https://doi.org/10.3390/jrfm15040165>
- Bundesministerium für Wirtschaft und Energie (BMWi)** (2021): Herausforderungen beim Einsatz von Künstlicher Intelligenz: Ergebnisse einer Befragung von jungen und mittelständigen Unternehmen in Deutschland. Online: [https://www.de.digital/DIGITAL/Redaktion/DE/Digitalisierungsindex/Publikationen/publikation-download-ki-herausforderungen.pdf? blob=publicationFile&v=3](https://www.de.digital/DIGITAL/Redaktion/DE/Digitalisierungsindex/Publikationen/publikation-download-ki-herausforderungen.pdf?blob=publicationFile&v=3)
- Bussmann, N.** – Giudici, P. – Marinelli, D. – Papenbrock, J. (2020): Explainable Machine Learning in Credit Risk Management. *Computational Economics* (2021) 57:203–216. <https://doi.org/10.1007/s10614-020-10042-0>
- Calo, R.** (2017): Artificial Intelligence Policy: A Primer and Roadmap. *SSRN Electronic Journal* (August 8, 2017). <https://doi.org/10.2139/ssrn.3015350>
- Cao, N.** (2021): *Explainable Artificial Intelligence for Customer Churning Prediction in Banking*. Online: <https://ceur-ws.org/Vol-3026/paper17.pdf>
- Capital Bank** (2024): Machine learning is upending everything. Online: <https://www.capitalone.com/commercial/insights/machine-learning-is-upending-everything-so-why-arent-us-businesses-ready/>

- Cappelli, P.** – Tambe, P. – Yakubovich, V. (2018): Artificial Intelligence in Human Resources Management: Challenges and a Path Forward. *SSRN Electronic Journal*.
<https://doi.org/10.2139/ssrn.3263878>
- Castro-González, Á.** – Admoni, H. – Scassellati, B. (2016): Effects of form and motion on judgments of social robots' animacy, likability, trustworthiness and unpleasantness. *International Journal of Human-Computer Studies*, 90, 27-38.
<https://doi.org/10.1016/j.ijhcs.2016.02.004>
- Chai, J.** – Zeng, H. – Li, A. – Ngai, E. W. T. (2021): Deep learning in computer vision: A critical review of emerging techniques and application scenarios. *Machine Learning with Applications*, volume 6, pp 100134. <https://doi.org/10.1016/j.mlwa.2021.100134>
- Chaweewanchon, A.** – Chaysiri.R. (2022): Markowitz Mean-Variance Portfolio Optimization with Predictive Stock Selection Using Machine Learning. *International Journal of Financial Studies* 10: 64. <https://doi.org/10.3390/ijfs10030064>
- Chen, K.** (2018): Financial innovation and technology firms: a smart new world with machines. Banking and Finance Issues in Emerging Markets (*International Symposia in Economic Theory and Econometrics, Vol. 25*), Emerald Publishing Limited, Bingley, pp. 279–292.
<https://doi.org/10.1108/s1571-038620180000025012>
- Chen, L.** – Pelger, M. – Zhu, J. (2019): Deep Learning in Asset Pricing (April 4, 2019).
<http://dx.doi.org/10.2139/ssrn.3350138>
- Chen, T.** – Guestrin, C. (2016): XgBoost: a scalable tree boosting system. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, ACM, pp. 785–794. <https://doi.org/10.1145/2939672.2939785>
- Chen, X.** – Cho, Y. H. – Dou, Y. – Lev, B. (2021): *Fundamental Analysis of Detailed Financial Data: A Machine Learning Approach*. Online:
<https://www.semanticscholar.org/paper/Fundamental-Analysis-of-Detailed-Financial-Data%3A-A-Chen-Cho/8bee434a3a64883c66c2a2f88a067d8f95d962f2>

- Cheng, M.** – Qu, Y. (2023): Does Operational Risk Management Benefit from FinTech? *Emerging Markets Finance and Trade*, 59(14), 4012–4027. <https://doi.org/10.1080/1540496x.2022.2164464>
- Chong, E.** – Han, C. – Park, F. (2017): Deep Learning Networks for Stock Market Analysis and Prediction: Methodology, Data Representations, and Case Studies. *Expert Systems with Applications*. 83. 187 – 205. <https://doi.org/10.1016/j.eswa.2017.04.030>
- Cocca, T.** (2016): Potential and Limitations of Virtual Advice in Wealth Management. *Journal of Financial Transformation*. 44. 45-57. Online: https://www.researchgate.net/publication/311740686_Potential_and_Limitations_of_Virtual_Advice_in_Wealth_Management
- Cocco, L.** – Pinna, A. – Marchesi, M. (2017): Banking on Blockchain: Costs Savings Thanks to the Blockchain Technology. *Future Internet*, volume 9 issue 3, p. 25. <https://doi.org/10.3390/fi9030025>
- Conlona, T.** – Cotter, J. – Kynigakisc, I. (2021): Machine Learning and Factor-Based Portfolio Optimization. (July 8, 2021). *Michael J. Brennan Irish Finance Working Paper Series Research Paper No. 21-6*, <https://doi.org/10.2139/ssrn.3889459>
- Consumer Financial Protection Bureau** (2022): Buy Now, Pay Later: Market trends and consumer impacts. Online: https://files.consumerfinance.gov/f/documents/cfpb_buy-now-pay-later-market-trends-consumer-impacts_report_2022-09.pdf
- Dawood, E.** – Elfakharany, E. – Maghraby, F. (2019): Improve Profiling Bank Customer’s Behavior Using Machine Learning. *IEEE Access* volume 7 on pages 109320 to 109327. <https://doi.org/10.1109/access.2019.2934644>
- DBS** (2018): DBS introduces Jim, Southeast Asia’s first virtual bank recruiter. Online: https://www.dbs.com/newsroom/DBS_introduces_Jim_Southeast_Asias_first_virtual_bank_recruiter

- de Graaf, M.M.A.** (2016): An Ethical Evaluation of Human–Robot Relationships. *Int J of Soc Robotics* 8, 589–598 (2016). <https://doi.org/10.1007/s12369-016-0368-5>
- Deloitte** (2021): *Artificial intelligence: Transforming the future of banking*. Online: <https://www2.deloitte.com/content/dam/Deloitte/us/Documents/process-and-operations/us-ai-transforming-future-of-banking.pdf>
- Deloitte** (2023): The National Institute of Standards and Technology Artificial Intelligence Risk Management Framework (NIST AI RMF) emphasizes the need for Trustworthy AI™. Online: <https://www2.deloitte.com/content/dam/Deloitte/us/Documents/deloitte-analytics/us-ai-institute-NIST-ai-risk-management.pdf>
- Dennett, D.** (1984): *Cognitive Wheels: The Frame Problem of AI. Minds, Machines, and Evolution* (ed. Hookway, C.) 129–152, Cambridge University Press, 1984. Online: https://www.researchgate.net/publication/225070451_Cognitive_Wheels_The_Frame_Problem_of_AI
- Denning, P. J.** – Denning, D. E. (2020): Dilemmas of artificial intelligence. *Communications of the ACM*, 63(3), 22–24. <https://doi.org/10.1145/3379920>
- Diksha, M.** – Poonam, S. – Awadhesh, S. (2022): How Blockchain Can Automate KYC: Systematic Review. *Wireless Personal Communications*. Vol. 122, pp. 1987–2021. <https://doi.org/10.1007/s11277-021-08977-0>
- Discanno, F.** (2023): A Comparison Between The Labor Market Trends In The European And Italian Banking Sectors: The Impact Of Digital Transformation And The Related Need For Investing In The Human Factor. *Cambridge Open Engage*. <https://doi.org/10.33774/coe-2023-1cldg>
- Drezewski, R.** – Sepielak, J. – Filipkowski, W. (2012): System supporting money laundering detection. *Digital Investigation*, Vol. 9, Issue 1, pp. 8–21. <https://doi.org/10.1016/j.diin.2012.04.003>

- EBA** (2024b): Draft Regulatory Technical Standards to further harmonise ICT risk management tools, methods, processes and policies as mandated under Articles 15 and 16(3) of Regulation (EU) 2022/2554. Online: <https://www.eba.europa.eu>
- El Qadi, A.** – Trocan, M. – Díaz-Rodríguez, N. – Frossard, T. (2023): Feature contribution alignment with expert knowledge for artificial intelligence credit scoring. *Signal, Image and Video Processing*, vol. 17, no. 2, pp. 427-434, 2023. <https://doi.org/10.1007/s11760-022-02239-7>
- Elcholiqi, A.** – Musdholifah, A. (2020): Chatbot in Bahasa Indonesia using NLP to Provide Banking Information. *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*. volume 14 issue 1 on page 91, <https://doi.org/10.22146/ijccs.41289>
- El-Gohary, H.** – Thayaseelan, A. – Babatunde, S. – El-Gohary, S. (2021): An Exploratory Study on the Effect of Artificial Intelligent-Enabled Technology on Customers Experiences in Banking Sector. *Journal of Technological Advancements*, 1(1): 1–17. <https://doi.org/10.4018/jta.20210101.oa1>
- Elrefai, A.** – Elgazzar, M. – Khodeir, N. (2021): Using Artificial Intelligence In Enhancing Banking Services. *IEEE 11th Annual Computing and Communication Workshop and Conference (CCWC)*. <https://doi.org/10.1109/ccwc51732.2021.9375993>
- Epley N.** – Waytz A. – Cacioppo J. (2007): On seeing human: a three-factor theory of anthropomorphism. *Psychol Rev* 2007 Oct;114(4):864-886. <http://10.1037/0033-295X.114.4.864>
- Ernst & Young (EY)** (2016): Get ready for robots. Online: https://assets.ey.com/content/dam/ey-sites/ey-com/en_gl/topics/emeia-financial-services/ey-get-ready-for-robots.pdf
- Etzioni, A.** – Etzioni, O. (2016): AI assisted ethics. *Ethics and Information Technology*, 18(2), 149–156. <https://doi.org/10.1007/s10676-016-9400-6>

European Banking Authority (2020): *EBA Report On Big Data And Advanced Analytics*.
Online:

https://www.eba.europa.eu/sites/default/documents/files/document_library/Final%20Report%20on%20Big%20Data%20and%20Advanced%20Analytics.pdf

European Banking Authority (2021): *EBA Discussion Paper On Machine Learning For IRB Models*. Online: <https://www.eba.europa.eu/>

European Banking Authority (2021): *Follow-up report on the use of machine learning for internal ratings-based models*. Online: <https://www.eba.europa.eu/publications-and-media/press-releases/eba-publishes-follow-report-use-machine-learning-internal>

European Banking Authority (2023): *Follow-Up Report From The Consultation On The Discussion Paper On Machine Learning For IRB Models*. Online: <https://www.eba.europa.eu/publications-and-media/press-releases/eba-publishes-follow-report-use-machine-learning-internal>

European Banking Authority (2024): *Consultation Paper On The Mandates In The Loss Group*. EBA/CP/ 2024/ 13. Online: <https://www.eba.europa.eu/sites/default/files/2024-06/4bd7c79f-9c45-4c9c-91bb-aff4c0895930/CP%20on%20OpRisk%20mandates%20in%20the%20loss%20group.pdf>

European Banking Federation (2019): *EBF position paper on AI in the banking industry*, July 1. Online: https://www.ebf.eu/wp-content/uploads/2020/03/EBF_037419-Artificial-Intelligence-in-the-banking-sector-EBF.pdf

European Central Bank (2018): *Guide to assessments of licence applications Licence applications in general*. Online: https://www.bankingsupervision.europa.eu/ecb/pub/pdf/ssm.201803_guide_assessment_credit_inst_licensing_appl.en.pdf

European Commission (2020): *The Assessment List for Trustworthy Artificial Intelligence (ALTAI)*. Online: <https://digital-strategy.ec.europa.eu/en/library/assessment-list-trustworthy-artificial-intelligence-altai-self-assessment>

European Data Protection Board (2024): *Statement 3/2024 on data protection authorities' role in the Artificial Intelligence Act framework*. Online: https://www.edpb.europa.eu/system/files/2024-07/edpb_statement_202403_dpasroleaiact_en.pdf

European Parliament (2022): *Report on Artificial Intelligence in a Digital Age*. 2020/2266(INI). European Parliament, April 5. https://www.europarl.europa.eu/doceo/document/A-9-2022-0088_EN.html

Executive Office of the President National Science and Technology (2016): *Preparing For The Future Of Artificial Intelligence*. Online: https://obamawhitehouse.archives.gov/sites/default/files/whitehouse_files/microsites/ostp/NSTC/preparing_for_the_future_of_ai.pdf

Eyal, I. (2017): Blockchain Technology: Transforming Libertarian Cryptocurrency Dreams to Finance and Banking Realities. *Computer*, 50(9): 38–49. <https://doi.org/10.1109/mc.2017.3571042>

Fang, L. – Li, X. – Subrahmanyam, A. – Zang, K. (2023): Does FinTech Innovation Improve Traditional Banks' Efficiency and Risk Measures? A New Methodology and New Machine-Learning-Based Evidence from Patent Filings. *Economics, Business, Computer Science*. <https://doi.org/10.2139/ssrn.4350734>

FATF (2021): *Opportunities and Challenges of New Technologies for AML/CFT*, FATF, Paris, France. Online: <https://www.fatf-gafi.org/publications/fatfrecommendations/documents/opportunitieschallenges-newtechnologies-aml-cft.html>

FATF (2023): *Illicit Financial Flows from Cyber-Enabled Fraud*. Online: <https://www.fatf-gafi.org/content/dam/fatf-gafi/reports/Illicit-financial-flows-cyber-enabled-fraud.pdf.coredownload.inline.pdf>

Fáykiss P. – Papp D. – Sajtos PI – Törös Á. (2018): A FinTech-innovációk ösztönzésének szabályozói eszközei: Innovation Hub és Regulatory Sandbox a nemzetközi gyakorlatban. *Hitelintézési Szemle*, 17(2): 43–67. <https://doi.org/10.25201/hsz.17.2.4367>

Financial Conduct Authority (FCA) (2022): Making Buy Now Pay Later terms clearer as take-up increases. Online: <https://www.fca.org.uk/about/case-study/bnpl-terms-clearer>

Federal Trade Commission (2021): Aiming for truth, fairness, and equity in your company’s use of AI. *Federal Trade Commission*, April 19. <https://www.ftc.gov/business-guidance/blog/2021/04/aiming-truth-fairness-equity-your-companys-use-ai>

Federal Trade Commission (2023): Keep your AI claims in check. *Federal Trade Commission*, February 27. <https://www.ftc.gov/business-guidance/blog/2023/02/keep-your-ai-claims-check>

Fehér, P. – Varga, K. (2017): Using Design Thinking to Identify Banking Digitization Opportunities – Snapshot of the Hungarian Banking System. *30TH Bled eConference: Digital Transformation – From Connecting Things to Transforming Our Lives*. <https://doi.org/10.18690/978-961-286-043-1.12>

Fernandez, D. – Aman, A. (2018): Impacts of Robotic Process Automation on Global Accounting Services, *Asian Journal of Accounting and Governance*, vol 9, <http://dx.doi.org/10.17576/AJAG-2018-09-11>

Financial Conduct Authority (FCA) (2021): Buy-now-pay-later products to be regulated. Online: <https://www.gov.uk/government/news/buy-now-pay-later-products-to-be-regulated>

Financial Conduct Authority (FCA) (2023): Unregulated Buy Now Pay Later (BNPL) firms becoming authorised. Online: <https://www.fca.org.uk/news/news-stories/unregulated-bnpl-firms-becoming-authorised>

Financial Stability Board (2017): *Artificial intelligence and machine learning in financial services Market developments and financial stability implications*. Online: <https://www.fsb.org/wp-content/uploads/P011117.pdf>

Financial Times (2017): Bank of America aims to reinvent the bricks and mortar branch. Online: <https://www.ft.com/content/2abd7dca-17c0-11e7-a53d-df09f373be87>

Finlay, S. (2018): *Artificial Intelligence and Machine Learning for Business: A No-Nonsense Guide to Data Driven Technologies* (Third Edition). Online: https://www.researchgate.net/publication/326200736_Artificial_Intelligence_and_Machine_Learning_for_Business_A_No-Nonsense_Guide_to_Data_Driven_Technologies_Third_Edition/citation/download

FINRA (2016): *AI Applications in the Securities Industry*. Online: <https://www.finra.org/rules-guidance/key-topics/fintech/report/artificial-intelligence-in-the-securities-industry/ai-apps-in-the-industry>

Fisch, J. E. – Laboure, M. – Turner, J. A. (2018): The Emergence of the Robo-advisor. The Disruptive Impact of FinTech on Retirement Systems, pp: 13 - 37. <https://doi.org/10.1093/oso/9780198845553.003.0002>

Fischer, A. (2018): *OTP LAB: Bank és Fintech együttműködés a gyakorlatban*. Előadás dátuma: 2018. szeptember 7. Budapest: OTP Bank. Online: https://www.mkt.hu/wp-content/uploads/2018/09/Fischer_Andras.pdf

Fischer, T. – Krauss, C. (2017): Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research* 270: 654–669. <https://doi.org/10.1016/j.ejor.2017.11.054>

- Flavián, C.** – Pérez-Rueda, A. - Belanche, D. - Casaló, L., A. (2021): Intention to use analytical Artificial Intelligence in services. *Journal of Service Management*, volume 33 issue 2. pp:293 - 320. <https://doi.org/10.1108/josm-10-2020-0378>
- Floridi, L.** – Cowls, J. (2019): A Unified Framework of Five Principles for AI in Society. *Harvard Data Science Review*, <https://doi.org/10.1162/99608f92.8cd550d1>.
- Formosa, P.** (2021): Robot Autonomy vs. Human Autonomy: Social Robots, Artificial Intelligence (AI), and the Nature of Autonomy. *Minds and Machines (Dordrecht)*, 31(4), 595–616. <https://doi.org/10.1007/s11023-021-09579-2>
- Gajane, P.** – Pechenizkiy, M. (2018): On Formalizing Fairness in Prediction with Machine Learning. *arXiv* *arXiv:1710.03184*.
https://www.fatml.org/media/documents/formalizing_fairness_in_prediction_with_ml.pdf
- Gambino, A.** – Fox, J. – Ratan, R. (2020): Stronger CASA: Extending the Computers Are Social Actors Paradigm. 1. 71-86. <https://doi.org/10.30658/hmc.1.5>
- Geetha, R.** – Reddy, D. (2018): Recruitment through artificial intelligence: A conceptual study. *International Journal of Mechanical Engineering and Technology*. 9. 63-70. Online: https://www.researchgate.net/publication/326929416_Recruitment_through_artificial_intelligence_A_conceptual_study
- Ghodselahe, A.** – Amirmadhi, A. (2011): Application of Artificial Intelligence Techniques for Credit Risk Evaluation. *International Journal of Modeling and Optimization*. 1. 243-249. <https://doi.org/10.7763/ijmo.2011.v1.43>
- Giudici, P.** (2018): Fintech Risk Management: A research challenge for artificial intelligence in finance. *Frontiers in Artificial Intelligence (Lausanne)*, 1. <https://doi.org/10.3389/frai.2018.00001>

- Grünbichler, R. (2023):** Implementation barriers of artificial intelligence in companies. *Conference: Proceedings of FEB Zagreb 14 th International Odyssey: Conference on Economics and Business: Zagreb.* <https://doi.org/10.22598/odyssey/2023.5>
- Gu, S. – Kelly, B. – Xiu, D. (2020):** Empirical asset pricing via machine learning. *The Review of Financial Studies*, 33(5), 2223–2273. <https://doi.org/10.3386/w25398>
- Guardian (2018):** Inside Shanghai's robot bank: China opens world's first human-free branch. Online: <https://www.theguardian.com/cities/2018/may/14/shanghai-robot-bank-china-worlds-first-human-free-branch-construction>
- Guerra, P. – Castelli, M. (2021):** Machine Learning Applied to Banking Supervision a Literature Review. *Risks* 9: 136. <https://doi.org/10.3390/risks9070136>
- Guhathakurta, R. (2018):** Cognitive Automation — Going beyond Rule-based RPA. *IndraStraGlobal*, Vol. 04, Issue No: 9 (2018), 0006, https://www.researchgate.net/publication/327426469_Cognitive_Automation_-_Going_beyond_Rule-based_RPA
- Guliyev, H. – Tatoğlu, Y. F. (2021):** Customer churn analysis in banking sector: Evidence from explainable machine learning models. *Journal of Applied Microeconometrics*. volume 1 issue 2. 85–99. <https://doi.org/10.53753/jame.1.2.03>
- Gültekin, M. (2022):** Human-social robot interaction, anthropomorphism and ontological boundary problem in education. *Psycho-Educational Research Reviews*, 11(3), 751-773. doi: https://doi.org/10.52963/perr_biruni_v11.n3.11
- Guo, Y. – Liang, C. (2016):** Blockchain application and outlook in the banking industry. *Financial Innovation*. volume 2, Article number: 24 (2016). <https://doi.org/10.1186/s40854-016-0034-9>
- Hacker, P. – Passoth, J-H. (2022):** Varieties of AI Explanations Under the Law. From the GDPR to the AIA, and Beyond. *SSRN Electronic Journal*. ISSN 1611-3349. <https://doi.org/10.2139/ssrn.3911324>

- Hagendorff, T.** (2020): The Ethics of AI Ethics: An Evaluation of Guidelines. *Minds and Machines* (2020) 30:99–120. <https://doi.org/10.1007/s11023-020-09517-8>
- Hanauera, M. X.** – Kononova, M. – Rapp, M. S. (2022): Boosting Agnostic Fundamental Analysis: Using Machine Learning to Identify Mispricing in European Stock Markets. *Finance Research Letters*, Forthcoming. <https://doi.org/10.2139/ssrn.3977872>
- Hannan-M.** – Shahriar-M. – Ferdous-M.S. – Chowdhury-M. – Rahman-M. (2023): A systematic literature review of blockchain-based e-KYC systems. *Computing* **105**, 2089–2118. <https://doi.org/10.1007/s00607-023-01176-8>
- Harkácsi, G. J.** – Szegfű, L. P. (2021): A megfelelésgbiztosítási funkció szerepe a digitalizáció, mesterséges intelligencia és robotizáció idején a pénzügyi szektorban. *Hitelintézeti Szemle*, 20 (1). pp. 152-170. <https://doi.org/10.25201/hsz.20.1.152170>
- Hayashi, Y.** (2022): Emerging Trends in Deep Learning for Credit Scoring: A Review. *Electronics*. 11. 3181. <https://doi.org/10.3390/electronics11193181>
- He, D. C.** – Y. Ho. – L. Xu (2020): Risk and return of online channel adoption in the banking industry, *Pacific-Basin Finance Journal* 60: 101268. <https://doi.org/10.2139/ssrn.3532215>
- He, H.** – Zhang, W. – Zhang, S. (2018): A novel ensemble method for credit scoring: Adaption of different imbalance ratios. *Expert Systems with Applications*, vol. 98, pp. 105-117, 2018. <https://doi.org/10.1016/j.eswa.2018.01.012>
- Hea, B.** – Shic, Y. – Wand, Q. – Zhao, X. (2014): Prediction of customer attrition of commercial banks based on SVM model. *Procedia Computer Science*, 31 (2014) 423 – 430, <https://doi.org/10.1016/j.procs.2014.05.286>
- Hess, T.** – Matt, C. – Benlian, A. - Wiesböck, F. (2016): Options for formulating a digital transformation strategy. *MIS Q Exec* 15(2):123–139. <https://doi.org/10.4324/9780429286797-7>

HLEG (2019): *Ethics guidelines for trustworthy AI. (HLEG)*. Online: https://www.europarl.europa.eu/cmsdata/196377/AI%20HLEG_Ethics%20Guidelines%20for%20Trustworthy%20AI.pdf

Horváth, D. (2019): Bank – Fintech Együttműködés – Avagy A Megújulás Kulcsa A Pénzügyi Szolgáltatások Piacán?. *Vezetéstudomány / Budapest Management Review* L . Évf. 2019. 3. Sz Ám/ Issn 0133- 0179 <https://doi.org/10.14267/veztud.2019.03.01>

Huang, H. M. (2004): Autonomy levels for unmanned systems (ALFUS) framework. Online: https://tsapps.nist.gov/publication/get_pdf.cfm?pub_id=823586

IBM (2024): What is RPA? Online: <https://www.ibm.com/topics/rpa>

Institute for Robotic Process Automation (2014): Introduction To Robotic Process Automation A Primer. Online: <https://irpai.com/wp-content/uploads/2015/05/Robotic-Process-Automation-June2015.pdf>

Institute of Electrical and Electronics Engineers (2021): *The IEEE Global Initiative on Ethics of Autonomous and Intelligent Systems Industry Connections Activity Initiation Document (ICAID)*. Online: https://standards.ieee.org/wp-content/uploads/import/governance/iccom/IC16-002-Global_Initiative_for_Ethical_Considerations_in_the_Design_of_Autonomous_Systems.pdf

International Federation of Robotics (2016): *World Robotics Report 2016: European Union occupies top position in the global automation race*. Online: <https://ifr.org/>

International Monetary Fund (2023): Generative Artificial Intelligence in Finance: Risk Considerations. Online: <https://www.imf.org/en/Publications/fintech-notes/Issues/2023/08/18/Generative-Artificial-Intelligence-in-Finance-Risk-Considerations-537570>

International Organization for Standardization (2012): *ISO 8373:2012. Robots and robotic devices*. Online: <https://www.iso.org/standard/55890.html>

International Organization for Standardization (2015): *ISO/TC 299. Robotics*. Online: <https://www.iso.org/committee/5915511.html>

International Organization for Standardization (2021): *ISO 8373:2021. Robotics – Vocabulary*. Online: <https://www.iso.org/obp/ui/#iso:std:iso:8373:ed-3:v1:en>

International Organization for Standardization (2022): *Framework for Artificial Intelligence (AI) Systems Using Machine Learning (ML)*. ISO/IEC 23053:2022. Online: <https://cdn.standards.iteh.ai/samples/74438/dc54208373d643c191a657cf5eed9eaf/ISO-IEC-23053-2022.pdf>

International Organization for Standardization (2023a): *Information technology — Artificial intelligence — Guidance on risk management*. ISO/IEC 23894:2023. Online: <https://www.iso.org/standard/77304.html>

International Organization for Standardization (2023b): *Information technology — Artificial intelligence — Management system*. ISO/IEC 42001:2023. Online: <https://cdn.standards.iteh.ai/samples/81230/4c1911ebc9a641fcb6ee21aa09c28ad3/ISO-IEC-42001-2023.pdf>

Jaiswal, A. – Arun, C. J. – Varma, A. (2021): Rebooting employees: upskilling for artificial intelligence in multinational corporations, *The International Journal of Human Resource Management*, volume 33 issue 6, pp. 1179 - 1208, <https://doi.org/10.4324/9781003377085-5>

Jasic, T. – Wood, D., (2004): The profitability of daily stock market indices trades based on neural network predictions: case study for the S&P 500, the DAX, the TOPIX and the FTSE in the period 1965-1999. *Applied Financial Economics*, 2004, vol. 14, issue 4, 285-297. <https://doi.org/10.1080/0960310042000201228>

Jewandah, S. (2018): How artificial intelligence is changing the banking sector—A case study of top four commercial Indian banks. *International Journal of Management, Technology*

And Engineering, 8(7), 525-530. Online:
<https://ijamtes.org/gallery/66.july%20ijmte%20-%20711.pdf>

Jobin, A. – Lenca, M. – Vayena, E. (2019): The Global Landscape of AI Ethics Guidelines. *Nature Machine Intelligence*, 1, 389–399, <https://doi.org/10.1038/s42256-019-0088-2>.

Johari, R.J. – Zul, N.B. – Talib, N. – Hussin, S.A.H.S (2020): Money Laundering: Customer Due Diligence in the Era of Cryptocurrencies. *Proceedings of the 1st International Conference on Accounting, Management and Entrepreneurship (ICAMER 2019), Advances in Economics, Business and Management Research (AEBMR), Atlantis Press*, pp. 130–135. <https://doi.org/10.2991/aebmr.k.200305.033>

Jullum, M. – Løland, A. – Huseby, R. B. – Ånonsen, G. – Lorentzen, J. (2020): Detecting money laundering transactions with machine learning. *Journal of Money Laundering Control*, Vol. 23, No. 1, pp. 173–186. <https://doi.org/10.1108/jmlc-07-2019-0055>

Jung, D. – Dorner, V. – Glaser, F. – Morana, S. (2018): Robo-Advisory: Digitalization and Automation of Financial Advisory. *Business & Information Systems Engineering*. 60. issue 1, pp. 81 - 86, <https://doi.org/10.1007/s12599-018-0521-9>

Kaczmarek, T. – Perez, K. (2022): Building portfolios based on machine learning predictions. *Economic Research-Ekonomska Istraživanja*, 35:1, 19-37, <https://doi.org/10.1080/1331677x.2021.1875865>

Kannan, S.– Somasundaram, K. (2017): Autoregressive-based outlier algorithm to detect money laundering activities. *Journal of Money Laundering Control*, Vol. 20, No. 2, pp. 190–202. <https://doi.org/10.1108/jmlc-07-2016-0031>

Karacsony, P. (2022): Analysis of the Attitude of Hungarian HR Professionals to Artificial Intelligence. *Naše gospodarstvo/Our Economy*, 68(2), 55-64. <https://doi.org/10.2478/ngoe-2022-0011>

- Kaur, I.** – Kaur, J. (2020): Customer Churn Analysis and Prediction in Banking Industry using Machine Learning. Sixth International Conference on Parallel, *Distributed and Grid Computing (PDGC)*. 434–437. <https://doi.org/10.1109/pdgc50313.2020.9315761>
- Kaya, O.** (2019): Artificial intelligence in banking. A lever for profitability with limited implementation to date. *EU Monitor, Deutsche Bank Research*, June 4. <https://www.dbresearch.com>
- Kedziora, D.** – Penttinen, E. (2021): Governance models for robotic process automation: The case of Nordea Bank. *Journal of Information Technology Teaching Cases*, 2021, Vol. 11(1) 20–29. <https://doi.org/10.1177/2043886920937022>
- Kerényi Á.** – Molnár J. (2017): A FinTech-jelenség hatása – Radikális változás zajlik a pénzügyi szektorban? *Hitelintézeti Szemle*, 16(3), p. 32–50. <http://doi.org/10.25201/HSZ.16.3.3250>
- Khan, N. S.** – Larik, A. S. – Raiput, Q. – Haider, S. (2013): A Bayesian approach for suspicious financial activity reporting. *International Journal of Computers and Applications*, 35(4). <https://doi.org/10.2316/journal.202.2013.4.202-3864>
- Khurana, D.** – Koli, A. – Khatter, K. – Singh, S. (2023): Natural language processing: state of the art, current trends and challenges. *Multimedia Tools Applications*, 82, 3713–3744. <https://doi.org/10.1007/s11042-022-13428-4>
- Kien, S. S.** – Weill, P. – Xu, M. (2019): DBS: From The "World's Best Bank" To Building The Future-Ready Enterprise. Online: <https://www.pega.com/insights/resources/dbs-worlds-best-bank-building-future-ready-enterprise>
- Kim, K.** – Han, Y. – Sugil, L. – Sung, C. – Chulung, L. (2019): Text Mining for Patent Analysis to Forecast Emerging Technologies in Wireless Power Transfer. *Sustainability*. volume 11, issue 22, p. 6240. <https://doi.org/10.3390/su11226240>
- Kirkpatrick, J.** (2015): Drones and the Martial Virtue Courage. *Journal Of Military Ethics*, 2015 VOL. 14, NOS. 3–4, 202–219 <https://doi.org/10.1080/15027570.2015.1106744>

- Kitsios, F.** – Kamariotou, M. (2021): Artificial Intelligence and Business Strategy towards Digital Transformation: A Research Agenda. *Sustainability*, 13 (4), 2025. <https://doi.org/10.3390/su13042025>
- Kou, G.** – Akdeniz, Ö.O. – Dinçer, H. – Yüksel, S. (2021): FinTech investments in European banks: a hybrid IT2 fuzzy multidimensional decision-making approach. *Financial Innovation*, 7(1), 39. <https://doi.org/10.1186/s40854-021-00256-y>
- Kovács, L.** – Marsi, Erika (2018): Bankmenedzsment, banküzemtan. *Alapítvány a Pénzügyi Kultúra Fejlesztéséért, Budapest*. ISBN: 978-963-89653-2-5
- KPMG (2023):** The regulation of Buy-Now Pay-Later moves one step closer. Online: <https://kpmg.com/xx/en/home/insights/2023/03/the-regulation-of-buy-now-pay-later-moves-one-step-closer.html>
- Kreger, A.** (2022): *Research of Digital Customer Expectations from Banking and Fintech Services*. Online: https://www.researchgate.net/publication/361959618_Research_of_Digital_Customer_Expectations_from_Banking_and_Fintech_Services
- Kshetri, N.** (2020): Artificial intelligence in human resource management in the Global South. Association for Information Systems. *AMCIS 2020 Proceedings Organizational Transformation & Information Systems (SIGORSA)*. Online: <https://core.ac.uk/download/pdf/326836152.pdf>
- Kulkarni, C. S.** – Bhavsar, A. U. – Pingale, S. R., – Kumbhar, S. S. (2017): BANK CHAT BOT– an intelligent assistant system using NLP and machine learning. *International Research Journal of Engineering and Technology*, 4(5), 2374-2377. Online: https://www.academia.edu/33566306/BANK_CHAT_BOT_An_Intelligent_Assistant_System_using_NLP_and_Machine_Learning
- Kumar, S.** – Raut, R. D. – Queiroz, M. M. – Narkhede B. E. (2021): Mapping the barriers of AI implementations in the public distribution system: The Indian experience. *Technology in Society*, 67. <https://doi.org/10.1016/j.techsoc.2021.101737>

Kurzweil, R. (1999): *The Age of Spiritual Machines: When Computers Exceed Human Intelligence*. Penguin Books, London.

Lacity, M. – Willcocks, L. (2016). A new approach to automating services. 58. 41-49. Online: https://www.researchgate.net/publication/308659455_A_new_approach_to_automating_service

Langenbucher, K. (2022): AI credit scoring and evaluation of creditworthiness – a test case for the EU proposal for an AI Act. *Continuity and change – how the challenges of today prepare the ground for tomorrow ECB Legal Conference 2021* ISBN 978-92-899-4990-3. pp:362-390. Online: <https://www.ecb.europa.eu/pub/pdf/other/ecb.ecblegalconferenceproceedings202204~c2e5739756.en.pdf?326d24503e8896af91efce04141760e5>

Lanzolla, G. – Lorenz, A. – Miron-Spektor, E. – Schilling, M. – Solinas, G. – Tucci, C. (2020): Digital transformation: What is new if anything? Emerging patterns and management research. *Academy of Management Discoveries*. <https://doi.org/10.5465/amd.2018.0103>

Lee, M. – Chang, J.-W. – Hung, J. C. – Chen, B.-L. (2021): Exploring the Effectiveness of Deep Neural Networks with Technical Analysis Applied to Stock Market Prediction. *Computer Science and Information Systems*, 2021, Volume 18, Issue 2, Pages: 401-418. <https://doi.org/10.2298/csis2003010021>

Leffrang, D. – Mueller, O. (2023): AI Washing: The Framing Effect of Labels on Algorithmic Advice Utilization. *International Conference on Information Systems, 10*. Online: <https://ris.uni-paderborn.de/record/50121>

Leung, H. C. – Chung, W. (2020): A Dynamic Classification Approach to Churn Prediction in Banking Industry. *Americas Conference on Information Systems, 2020 Proceedings*. 28. Online: <https://core.ac.uk/download/pdf/326836343.pdf>

Li, J. – Kuang, K. – Wang, B. – Liu, F. – Chen, L. – Wu, F. – Xiao, J. (2022): *Shapley Counterfactual Credits for Multi-Agent Reinforcement Learning*. Proceedings of the

27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining.
<https://doi.org/10.1145/3447548.3467420>

Liu, W. – Fan, H. - Xia, M. (2022): Credit scoring based on tree-enhanced gradient boosting decision trees. *Expert Systems with Applications*, vol. 189, 16034. <https://doi.org/10.1016/j.eswa.2021.116034>

Lokman, A. S. – Amedeen, M. A. (2018): Modern Chatbot Systems: A technical review. In *Advances in intelligent systems and computing* (pp. 1012–1023). https://doi.org/10.1007/978-3-030-02683-7_75

Loukili, M. – Messaoudi, F. - El Ghazi, M. (2022): Supervised Learning Algorithms for Predicting Customer Churn with Hyperparameter Optimization. *International Journal of Advances in Soft Computing and its Applications*. 14. 49–63. <https://doi.org/10.15849/ijasca.221128.04>

Lundberg, S. – Lee, S.-I. (2017): A Unified Approach to Interpreting Model Predictions. Online:
https://www.researchgate.net/publication/317062430_A_Unified_Approach_to_Interpreting_Model_Predictions

Luo, X. (2014): Suspicious Transaction Detection for Anti-Money Laundering. *International Journal of Security and Its Applications*, Vol. 8, No. 2, pp. 157– 166. <https://doi.org/10.14257/ijasia.2014.8.2.16>

Maettig, B. – Foot, H. (2020): Approach to improving training of human workers in industrial applications through the use of Intelligence Augmentation and Human-in-the-Loop. *2020 15th International Conference on Computer Science Education (ICCSE)* (pp. 283–288). IEEE. <https://doi.org/10.1109/ICCSE49874.2020.9201867>

Magyar Nemzeti Bank (2017): *Innováció és Stabilitás Fintech Körkép Magyarországon*. Budapest. Online: <https://www.mnb.hu/letoltes/konzultacios-dokumentum.pdf>

- Malali, A. B.** – Gopalakrishnan, S. (2020): Application of Artificial Intelligence and Its Powered Technologies in the Indian Banking and Financial Industry: An Overview. *IOSR Journal Of Humanities And Social Science*. Volume 25, Issue 4, Series. 6 (April. 2020) 55–60. <https://doi.org/10.9790/0837-2504065560>
- Malgieri, G.** – Pasquale, F. (2024): Licensing high-risk artificial intelligence: Toward ex ante justification for a disruptive technology. *Computer Law & Security Review*. 52. 105899. <https://doi.org/10.1016/j.clsr.2023.105899>
- Mandurkar, L.** – Khanke, S. – Khandaskar, R. – Ukey, A. (2022): Churn Prediction using Various Machine Learning Algorithms. *International Journal of Advanced Research in Science, Communication and Technology*. 429–435. <https://doi.org/10.48175/ijarsct-7707>
- Manela, A.** – Moreira, A. (2017): News implied volatility and disaster concerns. *Journal of Financial Economics*. Volume 123, Issue 1, January 2017, Pages 137-162. <https://doi.org/10.1016/j.jfineco.2016.01.032>
- Marchinares, A.** – Alonso, A. I. (2020): Project Portfolio Management Studies Based on Machine Learning and Critical Success Factors. 2020 **IEEE International Conference on Progress in Informatics and Computing (PIC)**, 369-374. <https://doi.org/10.1109/pic50277.2020.9350787>
- Martínez-Sánchez, J.** – Cruz-García, S. – Venegas-Martínez, F. (2020): Money laundering control in Mexico: A risk management approach through regression trees (data mining). *Journal of Money Laundering Control*. Vol. 23 No. 2, pp. 427-439. <https://doi.org/10.1108/jmlc-10-2019-0083>
- McCarthy, J.** – Misnky, M. L. – Rochester, N. – Shannon, C. E. (1955): A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence. *AI Magazine*, 27(4), 12. <https://doi.org/10.1609/aimag.v27i4.1904>
- McKinsey & Company** (2019): *Beyond banking: How banks can use ecosystems to win in the SME market*. Online:

<https://www.mckinsey.com/~media/mckinsey/industries/financial%20services/our%20insights/how%20banks%20can%20use%20ecosystems%20to%20win%20in%20the%20sme%20market/how-banks-can-use-ecosystems-to-win-in-the-sme-market-vf.pdf>

McKinsey & Company (2020): AI-bank of the future: Can banks meet the AI challenge?
Online: <https://www.mckinsey.com>

Medina, L. – Cano-Kollmann, M. – Álvarez, I. (2020): International connectivity in the generation of information and communication technology (ICT) in Spain. *Competitiveness Review: An International Business Journal*, volume 30 issue 3, pp. 355 – 371, <https://doi.org/10.1108/cr-08-2019-0072>

Megargel, A. – T. P. C. Fan (2018): SOA maturity influence on digital banking transformation, *IDRBT J. Bank. Technol.*, vol. 02, pp. 1–27, 2018

Meshkova, E. – Wawrzyniak, D. – Wójcik-Mazur, A. (2019): Risk Management In Banking. Credit, Market And Technology Perspective. *Polskie Towarzystwo Ekonomiczne, 2018, Polska,* Częstochowa. Online: https://www.researchgate.net/publication/334092029_RISK_MANAGEMENT_IN_BANKING_Credit_Market_and_Technology_perspective

Minsky, M – Seymour, P. (1969): *Perceptrons, An Introduction to Computational Geometry.* MIT Press, Cambridge, Mass., 1969.

Mirete-Ferrer, P. M. – Garcia-Garcia, A. – Baixauli-Soler, J. S. – Prats. M. A. (2022): A Review on Machine Learning for Asset Management. *Risks* 10: 84. <https://doi.org/10.3390/risks10040084>

MNB (2017): Innováció és stabilitás, FinTech körkép Magyarországon. Konzultációs dokumentum. Magyar Nemzeti Bank. <https://www.mnb.hu/innovation-hub/hirek/innovacio-es-stabilitas-fintech-korkep-magyarorszagon>

MNB (2024): Az európai felügyeleti hatóságok közzétették a DORA rendelet első csomagjába tartozó, az IKT- és harmadik fél kockázatkezelésre és az incidensek osztályozására

vonatkozó részletszabályokat. Online: <https://www.mnb.hu/felugyelet/felugyeleti-keretrendszer/felugyeleti-hirek>

Mokheleli, T. – Museba, T. (2022): Machine Learning Approach for Credit Score Predictions. *Journal of Information Systems and Informatics* Vol. 5, No. 2, June 2023. <https://doi.org/10.51519/journalisi.v5i2.487>

Mori, M. (1970): Bukimi no tani [The uncanny valley]. *Energy*, 7(4), 33–35.

Moro, S. – Cortez, P. – Rita, P. (2015): *Using customer lifetime value and neural networks to improve the prediction of bank deposit subscription in telemarketing campaigns.* Online: <https://repositorium.sdum.uminho.pt/bitstream/1822/38305/1/NCAA-preprint.pdf>

Morris, M.R. – Sohl-Dickstein, J.N. – Fiedel, N. – Warkentin, T.B. – Dafoe, A. – Faust, A. – Farabet, C. – Legg, S. (2023): Levels of AGI for Operationalizing Progress on the Path to AGI. <https://doi.org/10.48550/arXiv.2311.02462>

Munkhdalai, L. – Jong, Y. L. – Keun, R. (2020): A Hybrid Credit Scoring Model Using Neural Networks and Logistic Regression. *Advances in Intelligent Information Hiding and Multimedia Signal Processing*, pp. 251 - 258. https://doi.org/10.1007/978-981-13-9714-1_27

Mushava, J. – Murray, M. (2022): A novel XGBoost extension for credit scoring class-imbalanced data combining a generalized extreme value link and a modified focal loss function. *Expert Systems with Applications*, vol. 202, 2022. <https://doi.org/10.1016/j.eswa.2022.117233>

Nadkarni, S. – Prügl, R. (2021): Digital transformation: a review, synthesis and opportunities for future research. *Management Review Quarterly*, Springer, vol. 71(2), pages 233-341, April. <https://doi.org/10.1007/s11301-020-00185-7>

Nagy S. (főszerk) (1977): *Pedagógiai Lexikon, Akadémiai Kiadó, Budapest 1977*

- NAIH** (2022): Határozat. NAIH-85-3/2022. Online: <https://naih.hu/hatarozatok-vegzesek/file/517-mesterseges-intelligencia-alkalmazasanak-adatvedelmi-kerdesei>
- Nar, R.** – Singal, A. - Kumar, P. (2016): Abnormal activity detection for bank ATM surveillance, *International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, Jaipur, India, 2016, pp. 2042-2046, <https://doi.org/10.1109/icacci.2016.7732351>
- Nass, C.** – Moon, Y. (2000): Machines and Mindlessness: Social Responses to Computers. *Journal of Social Issues*. 56. 81-103. <https://doi.org/10.1111/0022-4537.00153>
- National Institute of Standards and Technology** (2024): Artificial Intelligence Risk Management Framework (AI RMF 1.0). Online: <https://nvlpubs.nist.gov/nistpubs/ai/NIST.AI.100-1.pdf>
- Nepal SBI Bank Ltd** (2017): 26th Annual report. Online: <https://nsbl.statebank/about-nepal-sbi-bank-ltd>
- Neumann, J. von (1958):** *The Computer and the Brain*. Yale University Press, Inc. Online: https://complexityexplorer.s3.amazonaws.com/supplemental_materials/5.6+Artificial+Life/The+Computer+and+The+Brain_text.pdf
- Neumann, J. von.** (1963): The General and Logical Theory of Automata. Online: <https://www.semanticscholar.org/paper/The-General-and-Logical-Theory-of-Automata-Neumann/e8538f11920fa6e56b3d34771bb330bd3e07281d>
- Nikolarea, E.** (2021): The Interface of Nous and Computer in Inter-disciplinary. Research, Communication and Education. *Systemics, Cybernetics And Informatics*, Volume 19 - Number 7. Online: <https://www.iiisci.org/Journal/PDV/sci/pdfs/ZA630OW21.pdf>
- Nilsson, N. J.** (2010): *The Quest For Artificial Intelligence. A History Of Ideas And Achievements.* Cambridge University Press. <https://doi.org/10.1017/cbo9780511819346>

- Nitin, R.** – Saurabh, C. – Jayesh, R. (2023): Blockchain and Artificial Intelligence (AI) integration for revolutionizing security and transparency in finance. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.4644253>
- Nitin, R.** – Saurabh, C. – Jayesh, R. (2023): Blockchain and Artificial Intelligence (AI) integration for revolutionizing security and transparency in finance. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.4644253>
- Nordea Bank** (2020): More time for the human touch thanks to robotics. Online <https://www.nordea.com/en/news/more-time-for-the-human-touch-thanks-to-robotics>
- Novait** (2017): And her name is Lesya! There is a new agent in Call center of OTP Bank. Online: <https://novait.com.ua/en/news-robot-employee-lesya-in-otpbank/>
- OECD** (2019): Artificial Intelligence & Responsible Business Conduct. Online: <https://mneguidelines.oecd.org/RBC-and-artificial-intelligence.pdf>
- OECD** (2021): Artificial Intelligence, Machine Learning and Big Data in Finance: Opportunities, Challenges, and Implications for Policy Makers, <https://www.oecd.org/finance/artificial-intelligence-machine-learningbig-data-in-finance.htm>.
- Okon, S.** – Oruh, J. (2012): Enhanced ATM Security System Using Biometrics. *IJCSI International Journal of Computer Science Issues*, Vol. 9, Issue 5, No 3, September 2012 ISSN: 1694-0814. Online: https://www.researchgate.net/publication/344966848_ENHANCED_ATM_SECURITY_SYSTEM_USING_BIOMETRICS
- Oyeniya, A. O.** – A. B. Adeyemo (2015): Customer churn analysis in banking sector using data mining techniques. *Afr J Comput ICT* 8, no. 3 (2015): 165-174. Online: <https://www.semanticscholar.org/paper/Customer-Churn-Analysis-In-Banking-Sector-Using-Oyeniya-Adeyemo/0fd0067775eef2aa52547229c17e06128fdc0633>

- Palaniappan, S.** – Aida, M. – Mohd Foozy, C. F. – Atan, R. (2017): Customer Profiling using Classification Approach for Bank Telemarketing. *JOIV: International Journal on Informatics Visualization*, volume 1 issue 4-2. 214-217. <https://doi.org/10.30630/joiv.1.4-2.68>
- Pamuk, M.** – Schumann, M. (2023): Opening a New Era with Machine Learning in Financial Services? Forecasting Corporate Credit Ratings Based on Annual Financial Statements. *International Journal of Financial Studies* 11: 96. <https://doi.org/10.3390/ijfs11030096>
- Panagiotis, C.** – Wanyun, G. – Srinivasan, R. – Rindal, Peter – Mahdi, Z. (2023): *Privacy-Enhancing Technologies for Financial Data Sharing*. Online: https://www.researchgate.net/publication/371728696_Privacy-Enhancing_Technologies_for_Financial_Data_Sharing
- Panigutti, C.** — Hamon, R. — Hupont Torres, I. — Fernández-Llorca, D. — Yela, D. — Junklewitz, H. — Scalzo, S. — Mazzini, G. — Sanchez, I. — Garrido, J. — Gómez, E. (2023): The role of explainable AI in the context of the AI Act. *FACCT '23: Proceedings of the 2023 ACM Conference on Fairness, Accountability, and Transparency*. 1139 – 1150. <https://doi.org/10.1145/3593013.3594069>
- Parasuraman, R.** – Sheridan, T. – Wickens, C. (2000): A model for types and levels of human interaction with automation. *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans*, 30(3):286–297, 2000. <https://doi.org/10.1109/3468.844354>
- Park, S.** – Jun, S. (2020): Technological Cognitive Diagnosis Model for Patent Keyword Analysis. *ICT Express* 2020, 6, 57–61. <https://doi.org/10.1016/j.ict.2019.09.004>
- Parne, P.** (2021a): Digital banking - architecture strategies using cloud computing. *International Journal on Cloud Computing: Services and Architecture* volume 11 issue 6 pp. 9 - 18. <https://doi.org/10.5121/ijccsa.2021.11602>

- Parne, P.** (2021b): Cloud Computing Strategy and Impact in Banking/Financial Services. *Computer Science and Information Technology Trends*. 37-45. <https://doi.org/10.5121/csit.2021.111704>
- Patil, P.** – Dharwadkar, N. (2017): Analysis of banking data using machine learning. *International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud) (I-SMAC)*. 876–881. <https://doi.org/10.1109/i-smac.2017.8058305>
- Payne, E.H.M.** – Peltier, J. – Barger, V.A. (2021): Enhancing the value co-creation process: artificial intelligence and mobile banking service platforms. *Journal of Research in Interactive Marketing*, 15(1): 68–85. <https://doi.org/10.1108/jrim-10-2020-0214>
- Phoon, K. F.** – Koh, C. C. F. (2018): Robo-advisors and wealth management. *The Journal of Alternative Investments*. Winter 2018, 20 (3) 79 – 94. <https://doi.org/10.3905/jai.2018.20.3.079>
- Pintér É.** – Herczeg B. (2023): A technológia szerepe a pénzügyisolgáltatás-innovációban a big tech-vállalatok térnyerése tükrében. *Gazdaság és Pénzügy*, 10(1): 39–56. <https://doi.org/10.33926/gp.2023.1.3>
- Prateek, P.** (2020): Robotic Process Automation: Challenges and Solutions for the Banking Sector, *International Journal of Management* 11(12), 2020, pp. 322–333. <https://doi.org/10.34218/ijm.11.12.2020.031>
- Pratt, M.** – Mohcine, B. – Nazim, T. – Sarma, C. (2021): Use of AI for Improving Employee Motivation and Satisfaction. *Educating Engineers for Future Industrial Revolutions*, pp. 289 – 299, https://doi.org/10.1007/978-3-030-68201-9_30
- Premchand, A.** – Choudhry, A. (2018): Open banking and APIs for transformation in banking. *Proc. 2018 Int. Conf. Commun. Comput. Internet Things, IC3IoT 2018*, pp. 25–29, 2019. <https://doi.org/10.1109/IC3IoT.2018.8668107>
- Premnath, S.** – Arun, A. (2020): A Qualitative Study of Artificial Intelligence Application Framework in Human Resource Management. <https://doi.org/10.31219/osf.io/uqhn2>

- Prisznyák A.** (2022a): „Tradicionális” bankok front/middle/back office területeinek mesterséges intelligencia (AI), gépi tanulás (ML) implementációja. *FinTech – DEFI - Kriptoeszközök gazdasági és jogi lehetőségei és kockázatai. Konferenciakötet – válogatott tanulmányok,* Pécs, pp. 98–113. <https://pea.lib.pte.hu/bitstream/handle/pea/34319/PTE-%C3%81JK-20211119.pdf?sequence=1&isAllowed=y>
- Prisznyák A.** (2022c): Mesterséges intelligencia a bankszektorban. *GAZDASÁG ÉS PÉNZÜGY* 9: 4 pp. 395-402., 8 p. (2022). <https://doi.org/10.33926/gp.2022.4.6>
- Prisznyák A.** (2023a): A természetes intelligencia manifesztációjának filozófiai kérdései. *Hitelintézeti Szemle*, 22. évf. 1. szám, 2023. március, 166–170. o. Online: <https://hitelintezetiszemle.mnb.hu/letoltes/hsz-22-1.pdf>
- Prisznyák A.** (2023b): Etikus AI: Javaslat az EU megbízható AI szabályozás hiányosságainak áthidalására és a gyakorlati implementáció támogatására. *Gazdaság és Pénzügy*, 10(2): 169–195. <https://doi.org/10.33926/gp.2023.2.4>
- Prisznyák A.** (2023c): A bankrobotika horizontális és vertikális értékteremtése és az AI-washing jelenség. *Hitelintézeti Szemle*, 22. évf. 3. szám, 2023. szeptember, 97–122. o. <https://doi.org/10.25201/hsz.22.3.97>
- Prisznyák A.** (2022b): Bankrobotika: mesterséges intelligencia és gépi tanulás alapú banki kockázatkezelés: Pénzmosás és terrorizmusfinanszírozás megakadályozása. *Pénzügyi Szemle*, 67(2): 293–308. https://doi.org/10.35551/psz_2022_2_8
- Prisznyák A.** (2024a): The robot-labelling phenomenon. Robot-Ready Modern Operational Risk Management. *(publikálás alatt)*
- Prisznyák, A.** (2024b): Robo Sapiens Bankercus: an ideally designed anthropomorph banking service robot? *(publikálás alatt)*

- Puhle, M.** (2016): The FinTech Revolution: A Closer Look At Robo-Advisors. December 2016/Issue 4 (Volume 3): *Economy and Finance*. <https://doi.org/10.2139/ssrn.2658701>
- Resano, M.** – Ramon, J. (2021): Regulating for Competition with Bigtechs: Banking-As-A-Service and 'Beyond Banking. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.3982500>
- Robertson, J.** (2017): Robo Sapiens Japonicus. *University of California Press*. Oakland, California. ISBN: 9780520959064. <https://doi.org/10.1515/9780520959064>
- Rocha-Salazar, J-d-J.** – Segovia-Vargas, M-J. – Camacho-Miñano M-d-M. (2021): Money laundering and terrorism financing detection using neural networks and an abnormality indicator. *Expert Systems with Applications*, Vol. 169, 114470. <https://doi.org/10.1016/j.eswa.2020.114470>
- Romão, M. J.** – Costa, J., – Costa, C. J. (2019): Robotic Process Automation: A Case Study in the Banking Industry. *2019 14th Iberian Conference on Information Systems and Technologies (CISTI)* (pp. 1-6). <https://doi.org/10.23919/cisti.2019.8760733>
- Rouf, N.,** – Malik, M. B. – Arif, T. – Sharma, S. – Singh, S. – Aich, S. – Kim, H-C. (2021): Stock Market Prediction Using Machine Learning Techniques: A Decade Survey on Methodologies, Recent Developments, and Future Directions. *Electronics* 2021, 10, 2717. <https://doi.org/10.3390/electronics10212717>
- Rouhollahi, Z.** – Beheshti, A. – Mousaeirad, S. – Goluguri, S. R. (2021): Towards Artificial Intelligence Enabled Financial Crime Detection. *ArXiv abs/2105.10866*, pp. 538–546. <https://doi.org/10.1145/3487664.3487740>
- Runchi, Z.** – Liguó, X. – Qin, W. (2023): An ensemble credit scoring model based on logistic regression with heterogeneous balancing and weighting effects. *Expert Systems with Applications*, vol. 212, 118732. <https://doi.org/10.1016/j.eswa.2022.118732>

- Russell, S.** – Norvig, P. (2003): *Artificial Intelligence: A Modern Approach* (2. kiadás). Upper Saddle River, NJ: *Pearson Education, Inc.*
- Russell, S.** – Norvig, P. (2010): *Artificial Intelligence: A Modern Approach. 3rd Edition*, *Prentice-Hall, Upper Saddle River.*
- Sabbeh, F.** (2018): Machine Learning Techniques for Customer Retention: A Comparative Study. *International Journal of Advanced Computer Science and Applications*. Volume 9 issue 2. 273-281. <https://doi.org/10.14569/ijacsa.2018.090238>
- Samek, W.** – Müller, K-R. (2019): Towards Explainable Artificial Intelligence. *ArXiv abs/1909.12072*. n. pag. Online: <https://arxiv.org/abs/1909.12072>
- Samuel, A. L.** (1959): Some studies in machine learning using the game of checkers. *IBM Journal of research and development*, 3(3), 210-229. https://doi.org/10.1007/978-1-4613-8716-9_14
- Savage, D.** – Wang, Q. – Chou, P. – Zhang, X. – Yu, X. (2016): Detection of money laundering groups using supervised learning in networks. *AAAI-17 Workshop on AI and Operations Research for Social Good, Australia*, <https://doi.org/10.48550/arXiv.1608.00708>
- Schnitzer, R.** – Hapfelmeier, A. – Gaube, S. – Zillner, S. (2024): AI Hazard Management: A framework for the systematic management of root causes for AI risks. In: Farmanbar, M., Tzamtzi, M., Verma, A.K., Chakravorty, A. (eds) *Frontiers of Artificial Intelligence, Ethics, and Multidisciplinary Applications. FAIEMA 2023. Frontiers of Artificial Intelligence, Ethics and Multidisciplinary Applications*. Springer, Singapore. https://doi.org/10.1007/978-981-99-9836-4_27
- Schuett J.** (2023): Risk Management in the Artificial Intelligence Act. *European Journal of Risk Regulation*. Published online 2023:1-19. <https://doi.org/10.1017/err.2023.1>
- Securities and Exchange Commission (SEC)** (2024): Chair Gary Gensler on AI Washing. Online: <https://www.sec.gov/newsroom/speeches-statements/sec-chair-gary-gensler-ai-washing>

- Seele, P.** – Schultz, M.D. (2022): From Greenwashing to Machinewashing: A Model and Future Directions Derived from Reasoning by Analogy. *Journal Business Ethics*, 178, 1063–1089. <https://doi.org/10.1007/s10551-022-05054-9>
- Sefik, S.** – Alper, O. (2017): Workforce Optimization for Bank Operation Centers: A Machine Learning Approach. *International Journal of Interactive Multimedia and Artificial Intelligence*. 4. 81-87. <https://doi.org/10.9781/ijimai.2017.07.002>
- Seymen, O.** – Hizioglu, A.– Dogan, O. – Er, O. – Olmez, E. (2022): Customer Churn Prediction Using Ordinary Artificial Neural Network and Convolutional Neural Network Algorithms: A Comparative Performance Assessment. *GAZI UNIVERSITY JOURNAL OF SCIENCE*, volume 36. issue 2. 720 - 733 <https://doi.org/10.35378/gujs.992738>
- Shaikh, A.A.** – Hanafzadeh, P. – Karjaluoto, H. (2017): Mobile Banking and Payment System: A Conceptual Standpoint. *International Journal E-Business Research*, 13(2): 14–27. <https://doi.org/10.4018/ijebr.2017040102>
- Sharahi, M.** – Aligholi, M. (2015): Classify the Data of Bank Customers Using Data Mining and Clustering Techniques (Case Study: Sepah Bank Branches Tehran. *J. Appl. Environ. Biol. Sci.*, 5(5)458–464, 2015. ISSN: 2090–4274. Online: [https://www.textroad.com/pdf/JAEBS/J.%20Appl.%20Environ.%20Biol.%20Sci.,%205\(5\)458-464,%202015.pdf](https://www.textroad.com/pdf/JAEBS/J.%20Appl.%20Environ.%20Biol.%20Sci.,%205(5)458-464,%202015.pdf)
- Sheetal, T.** – Sagar, S. – Piyush, R. – Ashokkumar, R. (2024): Using AI and Natural Language Processing to Enhance Consumer Banking Decision-Making. *2024 International Conference on E-mobility, Power Control and Smart Systems (ICEMPS)*, Thiruvananthapuram, India, 2024, pp. 1-6. <https://doi.org/10.1109/icemps60684.2024.10559280>
- Shneiderman, B.** (2020): Human-centered artificial intelligence: Reliable, safe and trustworthy, 2020. *International Journal of Human–Computer Interaction*. 36(6), 495–504. <https://doi.org/10.1080/10447318.2020.1741118>

- Shneiderman, B.** (2020): Human-centered artificial intelligence: Reliable, safe and trustworthy, 2020. *International Journal of Human–Computer Interaction*. 36(6), 495–504. <https://doi.org/10.1080/10447318.2020.1741118>
- Shoham, Y.** – Perrault, R. – Brynjolfsson, E. – Clark, J. – Manyika, J. – Niebles, J.C. – Lyons, T. – Etchemendy, J. – Grosz, B. – Bauer, Z. (2018): The AI Index 2018 Annual Report. *AI Index Steering Committee, Human-Centered AI Initiative, Stanford University*, Stanford, CA, December 2018. Online: https://hai.stanford.edu/sites/default/files/2020-10/AI_Index_2018_Annual_Report.pdf
- Shukla, S.** (2019): Deploying Feedback for Personal Learning in the Workplace: Leveraging Culture, Ritualization, and Technology. Doctoral dissertation, Harvard Graduate School of Education. Online: <https://dash.harvard.edu/bitstream/handle/1/42081632/SHUKLA-DISSERTATION-2019.pdf?sequence=1>
- Sibaliija, T.** – Jovanović, S. – Đurić, J. (2019): ROBOTIC PROCESS AUTOMATION: OVERVIEW AND OPPORTUNITIES. *International Journal "Advanced Quality"*, Vol. 46, No. 3–4, 2018. year, Belgrade, Serbia. Online: https://www.researchgate.net/publication/332970286_ROBOTIC_PROCESS_AUTOMATION_OVERVIEW_AND OPPORTUNITIES
- Singhal, A.** – Dube, P. – Jain, V. K. (2022): Modelling barriers of artificial intelligence in banking sectors using total interpretive structural modelling. *International Journal of Applied Decision Sciences*, 2022 Vol.15 No.3, pp.311 – 335. <https://doi.org/10.1504/ijads.2022.122649>
- Song, C. S.** – Kim, Y-K. (2022): The role of the human-robot interaction in consumers' acceptance of humanoid retail service robots. *Journal of Business Research*. 146. 489-503. <https://doi.org/10.1016/j.jbusres.2022.03.087>
- Spiliotopoulos, R.** – Androutsopoulos, I. – Spyropoulos, C. (2001): Human-Robot Interaction Based On Spoken Natural Language Dialogue. Online:

https://www.researchgate.net/publication/2361845_Human-Robot_Interaction_Based_On_Spoken_Natural_Language_Dialogue

State, C. – Chakrabarti, P. – Hughes, D. – Ripy, S. (2023): Everyone’s Talking AI, Including the Federal Trade Commission: Key Takeaways from the FTC’s 2023 AI Guidance. *The Journal of Robotics, Artificial Intelligence & Law*, 6(4): 265–269. <https://www.crowell.com/a/web/jJgxMLt3bJdVTPbGi137sU/everyones-talking-ai-including-the-ftc-key-takeaways-from-the-ftcs-2023-ai-guidance.pdf>

Statistics Austria (2023): 11% of Austrian enterprises use artificial intelligence. Online: <https://www.statistik.at/fileadmin/announcement/2023/10/20231017IKTU2023EN.pdf>

Strader, T.J. – Rozycki, J. J. – Root, H. T. – Huang, Y-H. J. (2020): Machine Learning Stock Market Prediction Studies: Review and Research Directions. *Journal of International Technology and Information Management*. Volume 28, Issue 4, article 3. pp. 63–83. <https://doi.org/10.58729/1941-6679.1435>

Stulz, R. M. (2019): Fintech, bigtech, and the future of banks. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.3455297>

Suhel, S. F. – Shukla, V. K. – Vyas, S. – Mishra, V. P. (2020): Conversation to automation in banking through chatbot using artificial machine intelligence language. In *2020 8th International Conference on Reliability, Infocom Technologies and Optimization (Trends and Future Directions) (ICRITO)* (pp. 611-618). Noida, India. <https://doi.org/10.1109/icrito48877.2020.9197825>

Szalavetz A. (2022): Digitalisation-induced performance improvement: Don’t take it for granted! *Acta Oeconomica*, 72(4)m, 457-475. <https://doi.org/10.1556/032.2022.00031>

Szikora, A. – Nagy, B. (2020): Mesterséges intelligencia a pénzügyi szektorban (Artificial intelligence in the financial sector. *Magyar Nemzeti Bank*, 7 May. <https://www.mnb.hu/kiadvanyok/szakmai-cikkek/felugyelet/dr-szikora-andrea-nagy-benjamin-mesterseges-intelligencia-a-penzugyi-szektorban>

- Tanda, A.** – Schena, C. (2019): Introducing the FinTech Revolution. In: FinTech, BigTech and Banks, *Palgrave Macmillan Studies in Banking and Financial Institutions*. Palgrave Pivot, Cham, pp.1–5. https://doi.org/10.1007/978-3-030-22426-4_1
- Tomašev, N. J.** – Cornebise, F. – Hutter, S. – Mohamed, A. – Picciariello, B. – Connelly, DCM Belgrave, et al. (2020): AI for Social Good: Unlocking the Opportunity for Positive Impact. *Nature Communications* 11 (1). <https://doi.org/10.1038/s41467-020-15871-z>
- Torrent, N. L.** – Visani, G. – Bagli, E. (2020): PSD2 Explainable AI Model for Credit Scoring. *ArXiv abs/2011.10367* (2020): n. pag. Online: <https://www.semanticscholar.org/paper/PSD2-Explainable-AI-Model-for-Credit-Scoring-Torrent-Visani/e521eb055cbfc3142db74f01b2504b116ec80c8a>
- Tripathi, A. M.** (2018): *Learning Robotic Process Automation*. Packt Publishing Ltd., UK, Birmingham.
- Tripathi, D.** – Edla, D.R. – Bablani, A. – Shukla, A.K. – Reddy, B.R. (2021): Experimental analysis of machine learning methods for credit score classification. *Prog Artif Intell*. 2021;15:1–27. <https://doi.org/10.1007/s13748-021-00238-2>
- Turing, A.M.** (1950): Computing Machinery and Intelligence. *Mind*, 59(236), pp. 433–460. <https://doi.org/10.1093/mind/lix.236.433>
- Uddin, H.** – Mollah, S. – Islam, N. – Ali, H. (2023): Does digital transformation matter for operational risk exposure? *Technological Forecasting and Social Change*, 197, 122919. <https://doi.org/10.1016/j.techfore.2023.122919>
- Ulrich-Diener, F.** – Dvouletý, O. – Špaček, M. (2023): The future of banking: What are the actual barriers to bank digitalization? *BRQ Business Research Quarterly*, 0(0). <https://doi.org/10.1177/23409444231211597>
- Ulrich-Diener, F.** – Špaček, M. (2021): Digital Transformation in Banking: A Managerial Perspective on Barriers to Change. *Sustainability*. 13. 2032. <https://doi.org/10.3390/su13042032>

- Valverde, S. C.** – Fernández, F. R. (2020): Financial digitalization: banks, fintech, bigtech, and consumers. *Journal of Financial Management, Markets and Institutions*, Vol. 08, No. 01, 2040001 (2020). <https://doi.org/10.1142/s2282717x20400010>
- Van H.** – Nguyen, S. N. H. - Nguyen Thi, H. B. (2017): A hybrid feature selection method for credit scoring. EAI Endorsed Trans. *Context aware Syst. Appl.* Volume 4 issue 11.1-6. <https://doi.org/10.4108/eai.6-3-2017.152335>
- van Liebergen, B.** (2017): Machine Learning: A Revolution in Risk Management and Compliance? *Journal of financial transformation*, 45 (2017): 60-67. Online: https://www.iif.com/portals/0/Files/private/32370132_van_liebergen_-_machine_learning_in_compliance_risk_management.pdf
- Varga D.** (2017): Fintech, the new era of financial services. *Vezetéstudomány*, 48(11), p. 22–32. <https://doi.org/10.14267/veztud.2017.11.03>
- Vasantham, T. S.** (2021): The Role of Artificial Intelligence in Human Research Management. *Engineering and Scientific International Journal (ESIJ)*. Volume 8, Issue 2, April-June 2021. pp 499-509. <http://doi.org/10.30726/esij/v8.i2.2021.82013>
- Verdiesen, I.** – Santoni de Sio, F. – Dignum, V. (2021): Accountability and control over autonomous weapon systems: a framework for comprehensive human oversight. *Minds Mach.* 31(1), 137–163. <https://doi.org/10.1007/s11023-020-09532-9>
- Verma, P.** (2019): Churn Prediction for Savings Bank Customers: A Machine Learning Approach. *J. Stat. Appl. Pro.* 9, No. 3, 535–547 (2020). <https://doi.org/10.18576/jsap/090310>
- Verma, R.** – Shashidhar, N. – Hossain, N. (2012): Detecting Phishing Emails the Natural Language Way. In: Foresti, S., Yung, M., Martinelli, F. (eds) *Computer Security – ESORICS 2012*. ESORICS 2012. Lecture Notes in Computer Science, vol 7459. Springer, Berlin, Heidelberg. https://doi.org/10.1007/978-3-642-33167-1_47.

- Verma, S.** – Rubin, J. (2018). Fairness Definitions Explained. *Proceedings of the International Workshop on Software Fairness*. <https://doi.org/10.1145/3194770.3194776>
- Vial, G.** (2019): Understanding digital transformation: A review and a research agenda. *The Journal of Strategic Information Systems* 28(2)118 – 144. <https://doi.org/10.1016/j.jsis.2019.01.003>
- Vijai, C.** –Suriyalakshmi, S. M. – Elayaraja, M. (2020): The Future of Robotic Process Automation (RPA) in the Banking Sector for Better Customer Experience. *Shanlax International Journal of Commerce*, vol. 8, no. 2, 2020, pp. 61–65. <https://doi.org/10.34293/commerce.v8i2.1709>
- Vinoth, S.** – Vemula, H. L. – Haralayya, B. – Mamgain, P. – Hasan, M. F. – Naved, M. (2022): Application of cloud computing in banking and e-commerce and related security threats. *Materials Today: Proceedings*. Volume 51, Part 8, 2022, Pages 2172-2175. <https://doi.org/10.1016/j.matpr.2021.11.121>
- Vivek, K.** – Rishi, S. – Mohita, T. – Vishal, V. (2022): Escalate the Returns With AI- Based Technical Analysis Before Investment in the Stock Market Escalate the Returns With AI-Based Technical Analysis Before Investment in the Stock Market. <https://doi.org/10.4018/978-1-6684-5528-9.ch007>
- Wang L.** – Li, J. – X. Li, (2020): Efficiency Analysis of Machine Learning Intelligent Investment Based on K-Means Algorithm, *IEEE Access*, vol. 8, pp. 147463-147470. <https://doi.org/10.1109/access.2020.3011366>
- Wang, P.** (2019): On Defining Artificial Intelligence. *Journal of Artificial General Intelligence*. 10(2):1-37. <https://doi.org/10.2478/jagi-2019-0002> .
- Wang, S. N.** – Yang, J. G. (2007): A Money Laundering Risk Evaluation Method Based on Decision Tree. *IEEE. The 6th International Conference on Machine Learning and Cybernetics*, 1, pp. 283–286, ISBN:978-1-4244-0972-3. <https://doi.org/10.1109/icmlc.2007.4370155>

- Wang, Y.** (2023): Review: Application of Machine Learning to Investment Portfolios. *BCP Business & Management*, volume 38 on pages 3494 to 3498. <https://doi.org/10.54691/bcpbm.v38i.4351>
- Wei, W.** – Li, J. – Cao, L. – Ou, Y. – Chen, J. (2012): *Effective detection of sophisticated online banking fraud on extremely imbalanced data*. *World Wide Web* 16, pp. 449–475 (2013). <https://doi.org/10.1007/s11280-012-0178-0>
- Weizenbaum, J.** (1976): *Computer power and Human Reason: From Judgment to Calculation*. W. H. Freeman and Company, New York. Online: <http://blogs.evergreen.edu/cpat/files/2013/05/Computer-Power-and-Human-Reason.pdf>
- Wu, D.** – Wang, Y. – Han, M. – Song, L. – Shang, Y. – Zhang, X. – Song, H. (2021): Using a CNN-LSTM for basic behaviors detection of a single dairy cow in a complex environment. *Computers and Electronics in Agriculture*. Volume 182, March 2021, p. 106016. <https://doi.org/10.1016/j.compag.2021.106016>
- Xiaotian, R.** – Jiang, Z. – Jionglong, S. (2021): *The Use of Features to Enhance the Capability of Deep Reinforcement Learning for Investment Portfolio Management*. 44-50. <https://doi.org/10.1109/icbda51983.2021.9403019>
- Xu, H.** – Ying, C. – Qinna, F. – Heng, L. (2022): Augmented Reality in Professional Training: A Review of the Literature from 2001 to 2020. *Applied Sciences*, volume 12 issue 3. p. 1024. <https://doi.org/10.3390/app12031024>
- Yates, R. D.** – Vaessen, C. – Roupret, M. (2011): From Leonardo to da Vinci: the history of robot-assisted surgery in urology. *BJU International*. 108. 1708–13. <https://doi.org/10.1111/j.1464-410x.2011.10600.x>
- Yip, A. W.H.** – Bocken, N.M.P. (2018): Sustainable business model archetypes for the banking industry. *Journal of cleaner production*, 174, pp. 150–169. <https://doi.org/10.1016/j.jclepro.2017.10.190>

- Yoo, Y.** – Lim, D. – Heo, T-S (2021): Solar cell patent classification method based on keyword extraction and deep neural network. Online: <https://arxiv.org/abs/2109.08796>
- Yu, H.** – Liu, Z. – Wang, Y. – Jiang, X. (2018): Building Ethics into Artificial Intelligence. *IEEE Intelligent Systems*, 33(4), 77-83. <https://doi.org/10.24963/ijcai.2018/779>
- Zhang W.** – Yang D. – Zhang S. – Ablanedo-Rosas J.H. – Wu, X, – Lou Y. (2021): A novel multi-stage ensemble model with enhanced outlier adaptation for credit scoring. *Expert Syst Appl.* 2021;165:113872. <https://doi.org/10.1016/j.eswa.2020.113872>
- Zhang, M.** (2018): *China Construction Bank opens a branch managed by robots.* South China Morning, 11 April. <https://www.scmp.com/business/companies/article/2141203/meet-new-face-branch-banking>
- Zhang, Q.** – Zhu, J. – Qingyang, D. (2020): OBBC: A Blockchain-Based Data Sharing Scheme for Open Banking. *Blockchain Technology and application*, 2020, pp. 1–16. https://doi.org/10.1007/978-981-15-3278-8_1
- Zhang, Y.** – Trubey, P. (2019): Machine Learning and Sampling Scheme: An Empirical Study of Money Laundering Detection. *Computational Economics*, 54, pp. 1043–1063, <https://doi.org/10.1007/s10614-018-9864-z>
- Zheng, H.** – Zhang, H. – Zhang. Y. (2023): Stock Portfolio Management by Using Fuzzy Ensemble Deep Reinforcement Learning algorithm. *Journal of Risk and Financial Management*, 16: 201. <https://doi.org/10.3390/jrfm16030201>

Elektronikus adatbázis

AI Incident Database: <https://incidentdatabase.ai/>

Google Patent Database: <https://patents.google.com/>

Jogszabályok

Directive 2013/36/EU of the European Parliament and of the Council of 26 June 2013 on access to the activity of credit institutions and the prudential supervision of credit institutions and investment firms, amending Directive 2002/87/EC and repealing Directives 2006/48/EC and 2006/49/EC

European Commission (2018): COMMUNICATION FROM THE COMMISSION TO THE EUROPEAN PARLIAMENT, THE EUROPEAN COUNCIL, THE COUNCIL, THE EUROPEAN ECONOMIC AND SOCIAL COMMITTEE AND THE COMMITTEE OF THE REGIONS Artificial Intelligence for Europe (COM/2018/237 final)

European Commission (2021): Proposal for a REGULATION OF THE EUROPEAN PARLIAMENT AND OF THE COUNCIL LAYING DOWN HARMONISED RULES ON ARTIFICIAL INTELLIGENCE (ARTIFICIAL INTELLIGENCE ACT) AND AMENDING CERTAIN UNION LEGISLATIVE ACTS (COM/2021/206 final)

Javaslat AZ EURÓPAI PARLAMENT ÉS A TANÁCS RENDELETE A MESTERSÉGES INTELLIGENCIÁRA VONATKOZÓ HARMONIZÁLT SZABÁLYOK (A MESTERSÉGES INTELLIGENCIÁRÓL SZÓLÓ JOGSZABÁLY) MEGÁLLAPÍTÁSÁRÓL ÉS EGYES UNIÓS JOGALKOTÁSI AKTUSOK MÓDOSÍTÁSÁRÓL (COM/2021/206 final)

Proposal for a REGULATION OF THE EUROPEAN PARLIAMENT AND OF THE COUNCIL on harmonised rules on fair access to and use of data (Data Act) COM/2022/68 final

Regulation (EU) 2016/679 of the European Parliament and of the Council of 27 April 2016 on the protection of natural persons with regard to the processing of personal data and on the free movement of such data, and repealing Directive 95/46/EC (General Data Protection Regulation)

Regulation (EU) 2024/1689 of the European Parliament and of the Council of 13 June 2024 laying down harmonised rules on artificial intelligence and amending Regulations (EC) No 300/2008, (EU) No 167/2013, (EU) No 168/2013, (EU) 2018/858, (EU) 2018/1139

and (EU) 2019/2144 and Directives 2014/90/EU, (EU) 2016/797 and (EU) 2020/1828 (Artificial Intelligence Act)

Regulation (EU) No 575/2013 of the European Parliament and of the Council of 26 June 2013 on prudential requirements for credit institutions and investment firms and amending Regulation (EU) No 648/2012

Regulation (EU) No 648/2012 of the European Parliament and of the Council of 4 July 2012 on OTC derivatives, central counterparties and trade repositories