


Metatanulási modell a Fülöp-szigeteki bankok hitelezési magatartásának vizsgálatára

Christian S. de Leon 

Jelen tanulmány egy metatanuláson alapuló keretrendszert határoz meg a Fülöp-szigeteki kereskedelmi bankok hitelezési magatartásának előrejelzésére, aggregált banki pénzügyi mutatók és makrogazdasági változók alapján. Öt alapvető gépi tanulási modellt – a boostingot, a k-legközelebbi szomszéd módszerét, a neurális hálókat, a véletlen erdőt és a támogatóvektorgép-módszert – alkalmaztunk, amelyek kimeneti adatait LASSO-regularizált regresszióval szintetizáltuk. Az eredmények azt mutatják, hogy a metamodell következetesen nagyobb becslési pontosságot és alacsonyabb hibaszintet ér el, valamint közelebb áll a bankok érzékelt hitelezési magatartásához. A ridge-regresszióval és rugalmas háló alkalmazásával elvégzett robusztussági vizsgálatok a modell stabilitását igazolták mind volatilis, mind alacsony varianciájú környezetekben, míg a változók fontosságának elemzése a jövedelmezőséget és az eszközminőséget azonosította a hitelezési magatartás fő meghatározó tényezőiként.

Journal of Economic Literature (JEL) kódok: C45, E58, G21

Kulcsszavak: gépi tanulás, metamodellezés, banki hitelezési magatartás

1. Bevezetés

A banki hitelezési magatartás alakítja a gazdasági tevékenységet, a pénzügyi stabilitást és a monetáris politika transzmisszióját. A bankok hitelezési döntései közvetlenül befolyásolják a lakosság és vállalatok hitelhez jutását, ezáltal hatással vannak a befektetésekre, a fogyasztásra és a gazdasági növekedés egészére (Anyanwu et al. 2017). Olyan feltörekvő gazdaságokban, mint a Fülöp-szigeteki, ahol a banki intézmények a pénzügyi közvetítés elsődleges csatornáját jelentik, a hitelezési magatartás meghatározó tényezőinek megértése elengedhetetlen a szabályozók, a politikai döntéshozók és a piaci szereplők számára.

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

Christian S. de Leon: *Bangko Sentral ng Pilipinas, vezető bankfelügyelő; San Beda Egyetem – Manila, kutató.*
E-mail: chansdeleon@gmail.com

A szerző ezúton mond köszönetet Genesis Austria professzornak, a Fülöp-szigeteki Műszaki Egyetem – Manila oktatójának; Francis Lee Martinez professzornak, a San Beda Egyetem – Manila oktatójának; valamint Charmaine T. Velasco jegybanki közgazdásznak, a Bangko Sentral ng Pilipinas munkatársának a tanulmány elkészítéséhez nyújtott értékes iránymutatásáért. Külön köszönet illeti az anonim bírálókat, valamint a Hitelintézeti Szemle szerkesztőbizottságát és munkatársait.

Az angol nyelvű kézirat első változata 2025. december 17-én érkezett szerkesztőségünkbe.

DOI: <https://doi.org/10.25201/HSZ.25.2.125>

A hitelezési magatartás hagyományos elemzései gyakran lineáris ökonometriai modellekre támaszkodnak, amelyek stabil kapcsolatot feltételeznek a bankspecifikus mutatók és a makrogazdasági változók között. Az empirikus bizonyítékok azonban arra utalnak, hogy a hitelezést végeredményben összetett, nemlineáris kölcsönhatások alakítják, amelyek a gazdasági ciklusok és az intézményi kontextusok függvényében változnak (Dou et al. 2023). Ezek a korlátok egyre növekvő érdeklődést váltottak ki a gépi tanulási módszerek iránt, amelyek képesek feltárni a rejtett mintákat és javítani a pénzügyi rendszerek előrejelzési pontosságát (Adegbite 2024; Olowe et al. 2024).

A legújabb tanulmányok a gépi tanulást a banki szektorban jelentkező különböző kihívásokra alkalmazták, ideértve a hitelkockázat-értékelést, a csalások felderítését és a nemteljesítő hitelek előrejelzését (Hashemi et al. 2023; Muslim et al. 2023). Azonban mindeddig kevés tanulmány foglalkozott a hitelezési magatartás előrejelzésével, annak ellenére, hogy az tükrözi a bankrendszer hitelstandardokkal kapcsolatos kollektív álláspontját, valamint központi szerepet játszik a monetáris politika transzmissziójában és a rendszer stabilitásában. Ráadásul az egyetlen modellre támaszkodó megközelítések gyakran túlzott, késleltetett vagy rosszul kalibrált előrejelzésekhez vezetnek, ami a pénzügyi adatokat generáló folyamatok inherens bizonytalanságát tükrözi (Wu – Levinson 2021). Ezen korlátok fényében a tanulmány két fő kérdésre kereste a választ: (i) *Felülmúlhatja-e egy metatanulási modell a referencia- és az egyedi gépi tanulási modelleket a banki hitelezési magatartás előrejelzésében?* (ii) *Mely bankspecifikus és makrogazdasági mutatók a legmeghatározóbbak a banki hitelezési magatartás előrejelzésében?*

A kérdések megválaszolására egy kétszintű metatanulási keretrendszer került kialakításra, amely több gépi tanulási alapmodellt – boostingot, k-legközelebbi szomszéd módszerét, neurális hálókat, véletlen erdőt és támogatóvektorgép-módszert – integrál egy egységes és szabályozott metamodellbe. A 2009-től 2024-ig terjedő negyedéves adatok felhasználásával a keretrendszer mind az aggregált banki pénzügyi mutatókat (pl. tőke megfelelés, eszközminőség, jövedelmezőség), mind a makrogazdasági változókat (pl. GDP-növekedés, infláció, irányadó kamatlábak) figyelembe veszi. Az egyes tanuló modellek erősségeinek szintetizálásával a metamodell robusztusabb és pontosabb előrejelzéseket ad a hitelezési magatartásra vonatkozóan, különösen olyan volatilis időszakokban, mint a Covid19-világjárvány.


A tanulmány három szempontból vizsgálja a jelenséget. Először is bemutatja a metatanulás újszerű alkalmazását a Fülöp-szigeteki bankrendszer hitelezési magatartásának előrejelzésére. Másodsor, bemutatja, hogy a metamodell mennyire ellenálló és mennyiben múlja felül az egyetlen modellre épülő megközelítéseket a strukturális törések és a rezsimváltások megragadása szempontjából. Harmadszor, gyakorlati betekintést nyújt a szabályozók és döntéshozók számára a hitelezési magatartás legfontosabb meghatározó tényezőinek azonosítása révén, ezáltal támogatva a rendszerkockázat és a monetáris politikai transzmisszió hatékonyabb monitorozását.

2. Szakirodalmi kitekintés

2.1. A Fülöp-szigeteki bankszektor

A Fülöp-szigeteki bankrendszer a pénzügyi közvetítés gerincét képezi. A rendszer négy fő csoportra osztható, amelyek mindegyike eltérő funkciókat lát el. 2024-ben összesen 44 univerzális és kereskedelmi bank dominálta a szektor teljes eszközállományának (27,4 billió peso) 93,8 százalékát (*Bangko Sentral ng Pilipinas* (Fülöp-szigeteki jegybank, BSP) 2025a). Ezek a bankok elsősorban teljes körű banki szolgáltatásokat és befektetési szolgáltatásokat kínálnak, valamint nagyvállalatoknak nyújtanak hiteleket. Mellettük 41 takarékszövetkezet működik, amelyek a lakossági-, fogyasztói- és lakáshitelekre specializálódtak; valamint 383 vidéki és szövetségi bank is működik, amelyek elsősorban a mezőgazdasági, valamint a mikro- és kisvállalkozások számára nyújtanak közösségi alapú hiteleket; továbbá hat digitális bank, amelyek fizikai fiókok nélkül, digitális platformokon keresztül kínálnak teljes körű banki szolgáltatásokat.

A hitelezési tevékenység a bankok egyik fő tevékenysége. A rendszer teljes hitelállománya 2024-ben körülbelül 14,3 billió pesót tett ki. Ezen hitelek kibocsátását illetően főként az univerzális és kereskedelmi bankok dominálnak, amelyek aránya 92,3 százalék. Az 1. ábra a Fülöp-szigeteki bankrendszer, valamint az univerzális és kereskedelmi bankok hitelállományát mutatja be, amely az elmúlt évek során stabil emelkedő tendenciát mutat.



2.2. Gépi tanulás és metamodellezés

Az előrejelzés egyik központi kihívása a modell bizonytalansága. A hagyományos megközelítések gyakran feltételezik egy olyan valós modell létezését, amely teljes mértékben leírja az adatokat generáló folyamatot. Az empirikus bizonyítékok azonban azt mutatják, hogy az egyetlen modellen alapuló megközelítések gyakran alulteljesítenek, mivel nem képesek megragadni a valós pénzügyi környezetben rejlő tényleges komplexitást és változékonyságot. *Siegert et al. (2016)* megállapította, hogy a modell bizonytalanságának figyelmen kívül hagyása torzított paraméterbecslésekhez és túlságosan szűk előrejelzési intervallumokhoz vezet, ami pontatlan előrejelzéseket eredményez. Ezenkívül *Makridakis és Bakas (2016)* arra a következtetésre jutott, hogy a modellstruktúrával kapcsolatos bizonytalanság pontos kezelése gyakran háttérbe szorul, ami túlzottan magabiztos előrejelzésekhez és a bizonytalanságok elégtelen figyelembevételéhez vezethet.

Az egyetlen modellre épülő előrejelzések korlátai ösztönözték a jelen tanulmányt arra, hogy metatanulási megközelítést alkalmazzon. *Lin et al. (2019)* több modell kombinációját javasolta az előrejelzés megbízhatóságának javítására és a modell bizonytalanságának kezelésére. *Wu és Levinson (2021)* megjegyezte, hogy az egyetlen modellre való támaszkodás gyakran alulteljesít, és nagyobb valószínűséggel vezet hibás eredményekhez, míg az egyes modellek kombinálása ellensúlyozza azok belső gyengeségeit, ezáltal pontosabb és kevésbé hibás előrejelzéseket tesz lehetővé. Ezt *Rane et al. (2024)* eredményei is igazolják, amelyek szerint az előrejelzési módszerek kombinálása jobb teljesítményt nyújt az egyedi modelleknél, ha a becslési pontosság és a diverzitás egyensúlyba kerül. Erre építve *Montero-Manso et al. (2020)* olyan metatanulási algoritmusokat vezetett be, amelyek automatikusan kiválasztják és súlyozzák az előrejelzéseket, bizonyítva azt, hogy az átlagok felülmúlják mind az egyszerű kombinációkat, mind a legjobb egyedi modellt. Ezek az előrelépések az optimális súlyok torzítás vagy instabilitás nélküli meghatározásának kihívására nyújtanak megoldást.

Ezen felül a metatanulás kis és korlátozott adatmennyiség esetén is alkalmazható, mivel eredendően átveszi és továbbfejleszti más modellek kezdeti paramétereit. Bebizonyosodott, hogy ez a „tanulni tanulás” (learning-to-learn) megközelítése jobban képes alkalmazkodni kis mennyiségű adat esetén. Például korlátozott interakciós előzmények ellenére is személyre szabott ajánlásokat tud készíteni az e-kereskedelem új felhasználói számára (*Naser 2026*). *Safonova et al. (2023)* ugyancsak rámutatott, hogy a kis mintanagysággal kapcsolatos problémák tíz technikával orvosolhatók. Ezek közé tartozik a különböző felépítésű, eltérő tanulási logikát követő egyedi modellek kombinálása, valamint a modellek többszörös betanítása a torzítások és a túlzottan optimista teljesítménymutatók csökkentése céljából. Továbbá, a túlilleszkedés elkerülése érdekében a legkisebb abszolút értékű zsugorítás és szelekció

operátor (Least Absolute Shrinkage and Selection Operator, LASSO), a ridge-eljárás vagy a rugalmas háló (Elastic Net, ENET) segítségével megvalósított regularizációs megközelítések lehetővé teszik az információk maximalizálását még kis adathalmazokban is (Naser 2026). Ezért a tanulmány egy táguló időablakos (expanding window) sémát és egy kétlépcsős, regularizációs metatanulási megközelítést alkalmazott a kevés megfigyelés problémájának kezelésére.

A metamodell segítségével gépi tanulási módszereket integráló, rendelkezésre álló bankszektorra fókuszáló tanulmányok jelentős eredményeket mutattak fel olyan kihívások kezelésében, mint a hitelkockázat és a működési hatékonyság. Kavirathne et al. (2022) egy olyan metatanulási modellt fejlesztett ki a Srí Lanka-i pénzügyi intézmények nemteljesítő hiteleinek előrejelzésére, amely kiemelkedő becslési pontosságot ért el, és hatékonyan kezelte a hitelkockázatot. Ezenkívül Savolainen és Collan (2020) bemutatta, hogy a metamodellek hogyan csökkentik a befektetések szimulációinak komplexitását és számítási igényét, lehetővé téve a gyorsabb és hatékonyabb kockázatelemzést. Paz et al. (2025) ezt támasztotta alá a hitelkockázat-értékelés során a jellemzők kiválasztására szolgáló optimalizálási módszerek alkalmazásával, amelyek fokozták a gépi tanulási modellek robusztusságát és hatékonyságát.

2.3. A gépi tanulási alkalmazások a banki szektorban

A gépi tanulási módszereket széles körben alkalmazzák a bankszektorban, különösen a kockázatkezelés és a csalásfelderítés területén. Donepudi (2017) és Olowe et al. (2024) arra a következtetésre jutott, hogy a fejlett gépi tanulási megközelítések integrálása nemcsak a hatékonyságot növeli, hanem a döntéshozatalt és az ügyfélélményt is javítja a banki műveletek során. Leo et al. (2019) megállapította, hogy e módszerek a különböző banki kockázatok – például a hitel-, piaci, működési és likviditási kockázatok – megfelelőbb kezelésére használják. Guerra és Castelli (2021) rámutatott, hogy ezek a megközelítések a banki stressztesztelésre is alkalmazhatók, és ígéretes eredményeket mutatnak a csődelőrejelző rendszerek fejlesztése terén. Hashemi et al. (2023) ugyanakkor gépi tanulási megközelítést alkalmazott a csalárd tranzakciók felderítésének javítására, és kiváló teljesítménymutatókat ért el. A hitelezési magatartás tekintetében a gépi tanulás a hitelkockázat-értékelés javítására és a hiteljövahagyások fejlesztésére használható, mivel a módszer jelentős hatékonyságot mutatott a nemteljesítő hitelek előrejelzésében és a hitelképesség értékelésében (Anand et al. 2022; Chen 2022).

A rendelkezésre álló szakirodalom alapján Leo et al. (2019) rámutatott, hogy a gépi tanulás alkalmazhatóságát a jövőbeli kutatások során még tovább kell vizsgálni. Ezért ez a tanulmány a gépi tanulás módszerét egy másik megközelítéshez használta: a Fülöp-szigeteki kereskedelmi bankok hitelezési magatartásának előrejelzéséhez, a bankok összesített pénzügyi mutatóit és makrogazdasági változókat használva

jellemzőként (feature). *Abdolshah et al. (2020)* megállapította, hogy a makrogazdasági sokkok a kockázati profil alapján befolyásolják a bankok hitelezését. Emellett *Yitayaw (2021)* rámutatott arra, hogy a tőkemegfelelés ösztönzi a hitelezést, míg a makrogazdasági sokkok kedvezőtlen hatással lehetnek arra. *Ahmed et al. (2021)* eredményei szerint a nemteljesítő hitelek a hitelezési tevékenység következményei, amelyet a bruttó hazai termék (GDP) növekedési üteme is befolyásol.

2.4. A banki hitelezési magatartás és annak előrejelzői

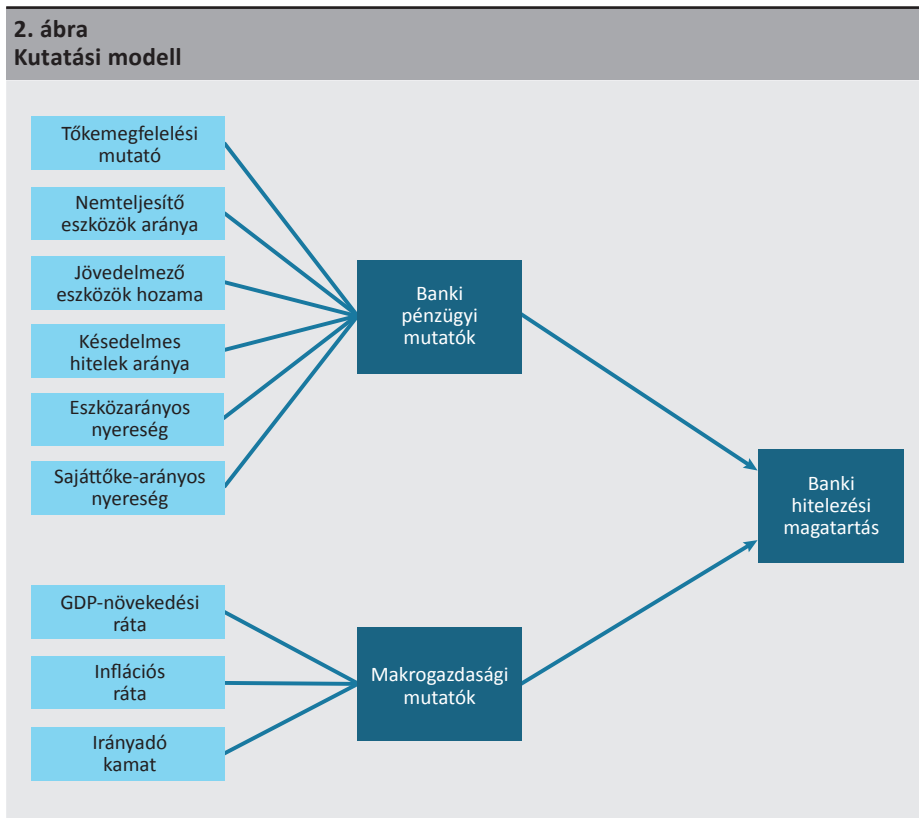
A banki hitelezési magatartás szisztematikus nyomon követése és elemzése – különösen a hitelkínálati feltételek szigorítását vagy enyhítését illetően – több okból is elengedhetetlen. Először is, a hitelkínálati feltételek közvetlenül befolyásolják a vállalkozások és a lakosság finanszírozáshoz való hozzáférését és annak költségét, ezzel alakítva a befektetési döntéseket, a fogyasztási mintákat és általában véve az összgazdasági tevékenységet (*Anyanwu et al. 2017; Bernanke 2018*). Amikor a bankok szigorítják a hitelkondíciókat, a finanszírozáshoz való hozzáférés korlátozottá válik, ami behatárolja a növekedési és a terjeszkedési lehetőségeket. Ezzel szemben a hitelkínálati feltételek enyhítése növeli a forrásokhoz való hozzáférést, ösztönözve a hitelfelvételt és a beruházásokat. Másodsor, a hitelezési magatartás változásainak megértése lehetővé teszi a központi bankok és a szabályozó hatóságok számára, hogy értékeljék a monetáris politika transzmissziójának hatékonyságát. Például, ha a kamatmódosítások nincsenek összhangban a hitelkondíciók változásával, a monetáris politika reálgazdaságra gyakorolt várt hatása visszafogott vagy akár hatástalan maradhat (*Aikman et al. 2016; Fung et al. 2000*). Harmadszor, a hitelkondíciókat meghatározó tényezők értékes betekintést nyújtanak a bankrendszeren belüli potenciális sebezhetőségekbe. Ezen tényezők azonosítása lehetővé teszi a döntéshozók számára olyan beavatkozások kidolgozását, amelyek enyhítik a rendszerkockázatokat és megelőzik a pénzügyi válságokat (*Bernanke 2018; Claessens – Kodres 2014*). Továbbá a gazdasági és bankspecifikus tényezők hitelezési kiigazításokra gyakorolt hatásának számszerűsítése elengedhetetlen a mögöttes problémák kezeléséhez a túlzott szigorítás vagy lazítás időszakaiban (*Ahmed et al. 2021; Bassett et al. 2014*).

A rendelkezésre álló kutatások rávilágítanak a makrogazdasági mutatók jelentős szerepére a hitelezési magatartás alakításában. Az infláció például következetesen összefüggésbe hozható a szigorúbb hitelkínálati feltételekkel. *Rostagno et al. (2021)* megállapította, hogy az infláció szabályozására irányuló jegybanki beavatkozások gyakran csökkentik a hitelkínálatot, mivel a bankok a szigorúbb monetáris politikára óvatosabb hitelezési gyakorlat bevezetésével reagálnak. *Ashraf (2021)* és *Nguyen et al. (2025)* továbbá kiemelte, hogy a magas infláció bizonytalanságot okoz a bankok számára, különösen a visszafizetési kockázatok tekintetében, ami szigorúbb hitelfeltételekhez és fedezeti követelményekhez vezet. Ezzel szemben

a magas GDP-növekedési ráták általában a hitelnyújtási feltételek enyhítésével járnak együtt. *Naili és Lahrichi (2020)*, valamint *Yurdakul (2014)* kimutatta, hogy a kedvező makrogazdasági körülmények csökkentik az észlelt hitelkockázatot, ezáltal ösztönözve a bankokat arra, hogy több hitelt nyújtsanak. Ez a magatartás a növekvő gazdaságban a hitelfelvevők javuló visszafizetési képességét tükrözi, ami ösztönzi a bankokat a hitelfeltételek enyhítésére és a hitelkeretek bővítésére.

A makrogazdasági feltételeken túl a bankok pénzügyi mutatói is kritikus szerepet játszanak a hitelezési magatartás meghatározásában. Bebizonyosodott például, hogy a tőke megfelelés növeli a bankok hitelezési képességét. *Madugu et al. (2020)* és *Olawale (2024)* rámutatott arra, hogy a magasabb tőke megfelelési mutatók lehetővé teszik a bankok számára, hogy a gazdasági ciklusokon átívelően fenntartsák vagy akár enyhítsék a hitelkínálati feltételeket. *Kozak (2021)* hasonlóképpen amellett érvel, hogy a jó tőkeellátottságú bankok ellenállóbbak és nagyobb a sokkelnyelő képességük, ami lehetővé teszi számukra, hogy rugalmasabb hitelpolitikát folytassanak. A késedelmes hitelek arányán keresztül mért eszközminőség egy másik fontos meghatározó tényező. *Schiantarelli et al. (2016)* arra a következtetésre jutott, hogy a nemteljesítő hitelek növekedése arra készíti a bankokat, hogy óvatosabb hitelezési politikát alkalmazzanak a likviditás védelme és a további veszteségek megelőzése érdekében. *Naili és Lahrichi (2020)* hozzátette, hogy a késedelmes hitelek aránya nemcsak a bank meglévő adósainak teljesítményét tükrözi, hanem a tágabb iparági környezetet is, így megbízható mutatója a megnövekedett hitelkockázatnak.

Az olyan jövedelmezőségi mutatók, mint az eszközarányos nyereség (ROA) és a sajáttőke-arányos nyereség (ROE), szintén szorosan kapcsolódnak a hitelezési magatartáshoz. *Miglo (2018)* és *Parker (2002)* arról számolt be, hogy a magasabb jövedelmezőség növeli a bank kockázatviselő képességét, ami arra ösztönzi a bankot, hogy a hitelezést enyhébb hitelkínálati feltételek mellett bővítse. A nyereséges bankok előnyösebb helyzetük révén kedvezőbb feltételek kínálatával könnyebben vonzzák magukhoz a hitelfelvevőket, ezáltal növelve a hitelezési volumeneket. *Bancel és Mittoo (2011)* továbbá megjegyezte, hogy a jövedelmezőség növeli a pénzügyi rugalmasságot, lehetővé téve a bankok számára, hogy gazdasági bizonytalanság idején is magas szintű hitelezési aktivitást tartsanak fenn. Ennélfogva a jövedelmezőség hitelbővítést ösztönző szerepe jól tükrözi, hogy a nyereséges bankok alapvetően meghatározza a bankok hitelkínálati feltételek enyhítésére irányuló hajlandóságát.



A 2. ábra bemutatja azt a kutatási keretrendszert, amely összekapcsolja a bank-specifikus pénzügyi mutatókat és a makrogazdasági feltételeket a Fülöp-szigeteki kereskedelmi bankok hitelezési magatartásával. A modell azt hangsúlyozza, hogy a pénzügyi helyzet belső mutatói miként lépnek kölcsönhatásba a külső gazdasági erővel a hitelezési döntések alakítása során.

3. Módszerek

3.1. Adatleírás és források

E tanulmány elkészítése során a Bangko Sentral ng Pilipinas által szolgáltatott, a 2009–2024 közötti időszakra vonatkozó negyedéves adatokat használtuk fel. A cél a banki hitelezési magatartás előrejelzése aggregált banki pénzügyi mutatók és makrogazdasági változók segítségével. A célváltozó a BSP vezető hitelintézeti referensek körében végzett felmérésének (Senior Bank Loan Officers' Survey, SLOS) diffúziós indexe, amely a hitelezési feltételek szigorítását vagy enyhítését méri. A felmérés a bankok kollektív véleményét tükrözi a vállalati és lakossági hitelek kezeléséről – a hitelnyújtási hajlandóságról – a fennálló feltételek mellett.

1. táblázat

Az első szintű tanulók jellemzőinek és célváltozójának leíró statisztikái (2009–2024, n=64)

Változó	Mértékegység	Min	Átlag	SD	Medián	Max	r
Banki hitelezési magatartás	%	-9,700	11,461	13,790	9,900	65,200	-
Tőke megfelelési mutató	%	15,000	16,656	0,954	16,500	19,200	-0,265
Nemteljesítő eszközök aránya	%	2,200	5,106	2,038	5,150	9,800	0,170
Jövedelmező eszközök hozama	%	3,800	4,706	0,821	4,550	6,800	-0,335
GDP-növekedési ráta	%	-15,000	7,848	5,201	9,000	15,200	-0,523
Inflációs ráta	%	-0,200	3,509	1,770	3,300	8,700	0,209
Késedelmes hitelek aránya	%	1,500	3,072	1,010	3,300	4,700	0,362
Eszközarányos nyereség	%	0,800	1,305	0,256	1,300	2,000	-0,537
Saját tőke-arányos nyereség	%	6,500	10,877	1,939	10,550	15,800	-0,535
Irányadó kamat	%	2,000	3,938	1,215	4,000	6,500	-0,105

Megjegyzés: SD - szórás. A várakozások szerint a pozitív korrelációk (r) a hitelezési feltételek szigorítására, míg a negatív korrelációk azok enyhítésére utalnak.

Az 1. táblázatban látható módon a pozitív és negatív korrelációs értékek a jellemzők és a banki hitelezési magatartás közötti összefüggéseket jelzik. A pozitív korreláció a hitelezési feltételek szigorítását, míg a negatív korreláció azok enyhítését jelenti. Az eredmények alapján a nemteljesítő eszközök, a hitelfizetési késedelem és az infláció növekedése a hitelfeltételek szigorodásával jár együtt. Ezzel szemben a magasabb tőke megfelelés, a jövedelmezőség és az irányadó kamat a hitelfeltételek enyhítését vonja maga után.

3.1.1. Banki hitelezési magatartás

Az SLOS diffúziós index a hitelezési szigorításra és lazításra adott válaszok nettó mérőszáma, amelyet a szigorítást jelző bankok arányának és a lazítást jelző bankok arányának különbségeként számítanak ki. A pozitív nettó index azt jelzi, hogy több bank szigorította a hitelezési feltételeket, mint amennyi enyhítette azokat, míg a negatív nettó index ennek ellenkezőjét mutatja. Mivel az index egy közvetlen, felmérésen alapuló mutatószám, a bankok kollektív hitelezési pozíciójának operatív proxyváltozójaként kezelendő mind a banki pénzügyi mutatók, mind a külső gazdasági hatások tekintetében. Az SLOS csak az univerzális és kereskedelmi bankokat fedi le.

3.1.2. Aggregált banki pénzügyi mutatók

Az aggregált banki pénzügyi mutatók arra vonatkozóan adnak becslést, hogy a bankok pénzügyi helyzete miként befolyásolja hitelezési magatartásukat. Ezeket az arányokat a Fülöp-szigeteki univerzális és kereskedelmi bankok teljes körére vonatkozó átlagként számítják ki. Más típusú bankok, mint például a takaréki-, szövetkezeti és vidéki bankok mutatóit kizártuk ebből az elemzésből, mivel azok nem vesznek

részt az SLOS-felmérésben. Bár az egyes bankok szintjén rendelkezésre álló adatok konkrét betekintést nyújthatnak számunkra, ez a tanulmány két okból is az aggregált pénzügyi mutatókat használja. Először is, a tanulmány célváltozója a banki hitelezési magatartást mérő SLOS diffúziós index. Mivel az SLOS diffúziós index az univerzális és kereskedelmi bankrendszer egészének kollektív véleményét tükrözi, ezért a magyarázó változókat is ugyanazon az aggregációs szinten kell mérni a konzisztencia biztosítása érdekében. Másodszor, az egyes bankok eltérő viselkedést mutathatnak specifikus vállalati stratégiák, fúziók vagy helyi sokkok miatt, amelyek nem tükrözik a tágabb iparági trendet. Az aggregáció kisimítja ezeket a fluktuációkat, lehetővé téve az előrejelzési modellek számára, hogy a hitelkondíciók szisztematikus meghatározó tényezőire összpontosítsanak.

A tőke megfelelési mutató azt méri, hogy a bank tőkéje milyen mértékben elegendő a kockázattal súlyozott eszközeihez viszonyítva. A mutató következetesen magas átlaga és alacsony variabilitása a vizsgált időszakok során tartós tőkeerősséget és hitelezési kapacitást jelez. Az eszközminőséget a nemteljesítő eszközök és a késedelmes hitelek aránya tükrözi. A nemteljesítő eszközök aránya a nemteljesítő és átstrukturált eszközök arányát mutatja, és a hitelkockázat proxyváltozójaként szolgál. A késedelmes hitelek aránya a fizetési késedelmek szintjét méri, ahol a magasabb értékek a megnövekedett hitelkockázatot és a hitelnyújtási hajlandóság csökkenését jelzik. Mindkét mutató időbeli ingadozást mutat, ami a bankok kockázati környezetének változására utal. A jövedelmezőség egy további dimenzióval szolgál az elemzéshez. A sajáttőke-arányos nyereség a részvényesek számára elérhető jövedelmezőséget tükrözi, míg az eszközarányos nyereség a teljes eszközállományra vetített jövedelmezőséget értékeli. Mindkettő a működési hatékonyságra mutat rá. A jövedelmező eszközök hozama a termelő eszközökből származó hozamot méri, és betekintést nyújt abba, hogy az eszközök teljesítménye hogyan befolyásolja a hitelezési ösztönzőket.

3.1.3. Makrogazdasági mutatók

A makrogazdasági mutatók azt a tágabb gazdasági környezetet írják le, amelyben a bankok hitelezési döntéseiket hozzák. A GDP-növekedési ráta az általános gazdasági aktivitást tükrözi, és az intenzívebb növekedés általában támogatja a megnövekedett hitelkeresletet. Ez az adathalmaz legvolatilisabb magyarázó változója, átlagos értéke közel áll a szórásához, ami arra utal, hogy a vizsgált időszakban jelentős gazdasági sokkhatásoknak volt kitéve. Az inflációs ráta az árstabilitást tükrözi, és hatással van a reálhozamokra, valamint a bankok hitelezési kockázatról alkotott véleményére. Az irányadó kamat a BSP elsődleges monetáris politikai eszközeként szolgál, és közvetlenül befolyásolja a finanszírozási költségeket, a likviditási feltételeket és az általános hitelezési környezetet. Az infláció és az irányadó kamatlábak alakulása egyaránt tükrözi az aktív monetáris politikai alkalmazkodást és a változó


makrogazdasági feltételeket, amelyek befolyásolják a kereskedelmi bankok hitelezési magatartását.

3.2. Adat-előkészítés és a modell betanítása

Az adatbázis nem tartalmaz hiányzó megfigyeléseket. Az adatokat a referencia- és az első szintű gépi tanulási modellek teljesítményének javítása érdekében alakítottuk át. A célváltozót és a magyarázó változókat kiigazítottuk, majd egyenként ellenőriztük a stacionaritásukat. A nem-stacionaritás a nyers adatok, idősorok esetében állt fenn. Első differencia ($d = 1$) használata után sikerült stacionaritást elérni, amit a banki hitelezési magatartást bemutató 3. ábra is jelez, ahol a késleltetések a 95 százalékos konfidenciaintervallumon belülre esnek. Ezt támasztják alá a kiterjesztett Dickey–Fuller (ADF) teszt eredményei is, $t(3) = -5,240$, $p < 0,01$, valamint a Phillips–Perron (PP) teszt eredményei, $Z\rho = -58,266$, $p < 0,01$, amelyek mindegyike szignifikanciát mutat 5 százalékos szinten.

3. ábra

A banki hitelezési magatartás autokorrelációja és parciális autokorrelációja első differencia képzése után



Ezenkívül a tanulmány egy negyedévre előretékintő, mintán kívüli (out-of-sample) előrejelzési struktúrát alkalmazott az előretékintési torzítás (look-ahead bias) kiküszöbölésére. A célváltozót egy negyedévvvel ($t-1$) késleltetett bankspecifikus és makrogazdasági jellemzők felhasználásával becsültük meg. A késleltetett specifikáció azt biztosítja, hogy az eredmények valódi, mintán kívüli előrejelzésnek

minősüljenek, ami több hónapos felkészülési időt biztosít a döntéshozók számára a tényleges adatok közzététele előtt.

3.2.1. Referenciamodellek

A metatanulási keretrendszer felállítása előtt a tanulmány minimális teljesítmény-elvárászt rögzítő, viszonyítási alapként szolgáló modelleket határozott meg. Ezeket a referenciamodelleket a központi bankok gyakran használják összetettebb megközelítések értékelésére. Az első referenciamodell egy konstans taggal rendelkező véletlen bolyongás (random walk, RW) [ARIMA(0,1,0)]. Ezt az egyváltozós modellt az ADF- és PP-tesztek eredményei alapján választottuk ki. Ezen felül az autoregresszív integrált mozgóátlag (ARIMA) modellek két típusának becslésére is sor került. Egy nem szezonális ARIMA(3,1,1)-modell három autoregresszív- és egy mozgóátlag-tagot használ a hitelezési magatartás rövid távú mintázatainak leírására. Emellett az Akaike-féle információs kritérium (AIC) alapján, visszafelé haladó szelekcióval (backward testing) egy szezonális ARIMA-modellt (SARIMA) is kiválasztottunk. Ez egy szezonális ARIMA(1,0,1) tagot is tartalmazott a diagnosztikai szakaszban azonosított szezonális ciklusok kezelésére. Ezen viszonyítási alapul szolgáló modellek (továbbiakban referenciamodellek) specifikációjának helytállóságát igazolja, hogy a reziduumaik normális eloszlást követnek, és független, azonos eloszlású fehér zajként viselkednek.

3.2.2. Első szintű gépi tanulási modellek

Ezt követően öt első szintű gépi tanulási modellt alkalmaztunk az első szintű előrejelzések generálására a metamodell (MTM) felépítése előtt. Mindegyik algoritmus eltérő módszertani torzítással (methodological bias) rendelkezik, ami lehetővé teszi a metamodell számára a különböző előrejelzési mintázatok kihasználását.

Bár a referencia ARIMA-modellek tartalmaznak autoregresszív komponenst, a jelen tanulmányban a magyarázó változók köréből szándékosan kihagytuk az SLOS-diffúziós index késleltetett értékeit. Ez a döntés közvetlenül kapcsolódik ahhoz a kutatási kérdés megválaszolásához, hogy mely bankspecifikus és makrogazdasági mutatók a leginkább meghatározóak a banki hitelezési magatartás előrejelzésében. Emellett ez a megközelítés mérsékli a túlfedési hatást (swapping effect), és megőrzi a meglévő magyarázó változók előrejelző erejét. A SLOS-diffúziós index késleltetett értékeinek bevonása torzítaná a változók fontossági mutatóit (változómaszkolás – feature masking), ami megnehezítené annak azonosítását, hogy mely mutatók bírnak valódi magyarázó erővel. Ennek következtében a referenciamodellek kénytelenek kizárólag a mutatókból kinyerni az előrejelzési információkat. Ezáltal a döntéshozók számára közvetlenebb, gyakorlatiasabb betekintést nyújtanak a hitelezési magatartás mögöttes okaira, ahelyett hogy a SLOS-diffúziós index trendperzisztenciájára támaszkodnának. Mindazonáltal az összehasonlítás technikailag robusztus marad, mivel minden modell ugyanahhoz az időrendi korláthoz igazodik,

vagyis az összes bemeneti adat a vizsgált negyedévet megelőzően rendelkezésre álló adatokra korlátozódik.

A boosting regressziót (BST) azért vontuk be, mert képes iteratív módon csökkenteni a torzítást a döntési fákból álló együttesek (ensembles) maradékhibáinak korrigálásával. Ezáltal a BST érzékenyen reagál az adatokban rejlő nemlinearitásokra és a lokális strukturális változásokra, mint például a hitelezési standardok változásaira a különböző gazdasági időszakokban. Amint azt az (1) egyenlet mutatja, a modell betanítása 0,1-es zsugorítási (shrinkage) paraméterrel (ν), 1,0-s interakciós mélységgel (interaction depth), végponti csomópontként (terminal node) legalább tíz megfigyeléssel, valamint 100 fával (M) történt, Gauss-féle veszteségfüggvényt alkalmazva 50 százalékos mintavételezéssel. A $h_m(x_{t-1})$ tartalmazza azokat az egyedi „gyenge tanulókat” (weak learners), amelyeket iteratív módon adnak hozzá a modellhez az előzőek hibáinak korrigálása érdekében. Ahogy a betanítási időablak (training window) bővült, a zsugorítási paramétert 0,01-re csökkentettük, az interakciós mélységet pedig 2,0-ra növeltük, így a modell növekvő információmennyiség mellett is biztonságosan képes tanulni anélkül, hogy a korábbi, kisebb mintákon túlilleszkedne (overfittig).

$$\hat{y}_t^{BST} = \sum_{m=1}^M \nu h_m(x_{t-1}) \quad (1)$$

A k-legközelebbi szomszéd (k-nearest neighbours) regressziót (KNN) olyan egyszerű, nem paraméteres tanulóalgoritmusként alkalmaztuk, amely a leginkább hasonló korábbi megfigyelések alapján jelzi előre az értékeket. Ez lehetővé teszi a hitelezési magatartásban fellelhető lokális mintázatok azonosítását, rugalmas módszert kínálva a variancia magyarázatára a helyi szomszédsági struktúrák segítségével. A modell betanítása egyenletes súlyozás (rectangular weights) és euklideszi távolság mellett történt, ahol a legközelebbi szomszédok számát (k) a tanító mintában szereplő megfigyelések száma függvényében hattól nyolcig optimalizáltuk. Erre azért van szükség, mert a szomszédságok sűrűsége a tanítási időablak tágulásával együtt növekszik. Az $N_k(x_{t-1})$ az x_{t-1} -hez legközelebb eső k szomszéd indexeinek halmaza, amint azt a (2) egyenlet mutatja.

$$\hat{y}_t^{KNN} = \frac{1}{k} \sum_{i \in N_k(x_{t-1})} y_i \quad (2)$$

A neurális hálókön alapuló regressziót (NNR) a sokdimenziós interakciók modellezésére, valamint a banki pénzügyi mutatók és a makrogazdasági változók kölcsönhatásaiban rejlő látens struktúrák azonosítására használtuk. Az eljárás egy olyan adaptív keretrendszert biztosít, amely képes a pénzügyi szektorra jellemző dinamikus mintázatok modellezésére. Az NNR-modell becslése egy egyenirányított lineáris aktivációs függvény (rectified linear activation function, \emptyset), legfeljebb 100 000 iteráció, valamint egy genetikussal optimalizált architektúra mellett történt, amely a táguló időablakmérethez igazodva skálázódott. Ez az eljárás egy

20 egyedből álló populációmérettel dolgozott, és a kezdeti időablakokban alkalmazott, egy rejtett rétegből álló egyszerű felépítéstől kezdve fokozatosan fejlődve elérte a legfeljebb három réteget és rétegenként tíz csomópontot. A w a súlyokat, a b pedig az optimalizált konstans tagokat (biased) jelenti, amint azt a (3) egyenlet mutatja. A szülőgyedek kiválasztása véletlenszerűen (rulettkerékmódszerrel) történt, 10 százalékos mutációs valószínűség és 10 százalékos rátermettség alapú túlélés mellett.

$$\hat{y}_t^{NNR} = \sigma \left(\sum_{j=1}^H w_j \cdot \Phi \left(\sum_{i=1}^D w_{ij} x_{i,t-1} + b_i \right) + b_j \right) \quad (3)$$

A véletlen erdő regressziót (random forest regression, RFR) annak robusztussága és varianciacsökkentő tulajdonságai miatt választottuk. Azáltal, hogy több dekorrelált (korrelációmentesített) döntési fa előrejelzéseit átlagolja, a modell egy olyan megbízható viszonyítási alapot biztosít, amely csökkenti a túlílleszkedés kockázatát, ami egy gyakori probléma az adatok velejáró bizonytalanságának kezelésekor. Amint azt a (4) egyenlet szemlélteti, a modell becslése 100 fából álló együttesen történt, fánként 50 százalékos lefedettség (coverage) mellett. A B a fák teljes száma, a $T_b(x_{t-1})$ pedig egy adott fa előrejelzése.

$$\hat{y}_t^{RFR} = \frac{1}{B} \sum_{b=1}^B T_b(x_{t-1}) \quad (4)$$

A támogatóvektor-gép (vagy szupportvektorgép) regressziót (Support vector machine regression, SVM) a sáv szélesség (margin) maximalizálására és a sokdimenziójú kontextusokban való hatékonysága miatt alkalmaztuk. A regresszió egy strukturált megközelítést kínál, ami hasznos a becslési pontosság fenntartásához még komplex változótér esetén is. A modell illesztése lineáris súlyokkal, 0,001-es leállítási toleranciával (termination tolerance), 0,01-es érzéketlen veszteségfüggvénnyel, valamint legfeljebb ötig terjedő hibabüntetéssel (violation cost) történt, amelyet felfelé módosítottunk, ahogy a táguló időablak több bizonyítékkal szolgált. A (5) egyenletben az $\alpha_i - \alpha_i^*$ a Lagrange-féle multiplikátorok, míg az $\langle x_i, x_{t-1} \rangle$ a változóvektorok belső (skaláris) szorzatát jelöli.

$$\hat{y}_t^{SVM} = \sum_{i=1}^n (\alpha_i - \alpha_i^*) \langle x_i, x_{t-1} \rangle + b \quad (5)$$

A (6) egyenletben minden referenciamodell egy olyan előrejelzési függvényt becsül, amelyben az x_{t-1} tartalmazza mind a késleltetett bankspecifikus mutatókat, mind a makrogazdasági változókat. Bár az egyes algoritmusok eltérően közelítik meg az $f(\cdot)$ függvényt, mindegyikük ugyanazt az alapegyenletet használja:


$$\hat{y}_t = f(x_{t-1}) + \epsilon_t, \quad x_{t-1} = [CAR_{t-1}, DAR_{t-1}, EAY_{t-1}, \dots] \quad (6)$$

Minden mintán kívüli előrejelzést, mind a referencia-, mind az első szintű tanulási modellek esetében, visszszámítottunk az első differenciákról az eredeti skálára. Ezek a referenciamodellek együttesen olyan előrejelzési mintázatokat hoznak létre, amelyek elengedhetetlenek jelen tanulmány metatanulási stratégiájához. Egymást kiegészítő erősségeik és gyengeségeik biztosítják az információk azon sokszínűségét, amelyeket a metamodel egy pontosabb és stabilabb banki hitelezési magatartásra vonatkozó előrejelzéssé szintetizál.

3.3. Táguló időablakos eljárás

A referencia- és a gépi tanulási modellek betanítása szigorúan kronologikus, táguló időablakos protokoll szerint történt. A 2009-től 2024-ig terjedő 16 évet lefedő adatbázis a mintaelemek időrendjének megőrzésével osztjuk fel tanító- és teszt-részhalmozokra. Mivel változónként mindössze 64 negyedéves megfigyelés áll rendelkezésre, ez a tanulmány a táguló időablak, a metatanulás és a regularizáció segítségével kezeli a kis mintaméret és a korlátozott adathalmazok problémáit, *Naser (2026)* és *Safonova et al. (2023)* ajánlásának megfelelően.

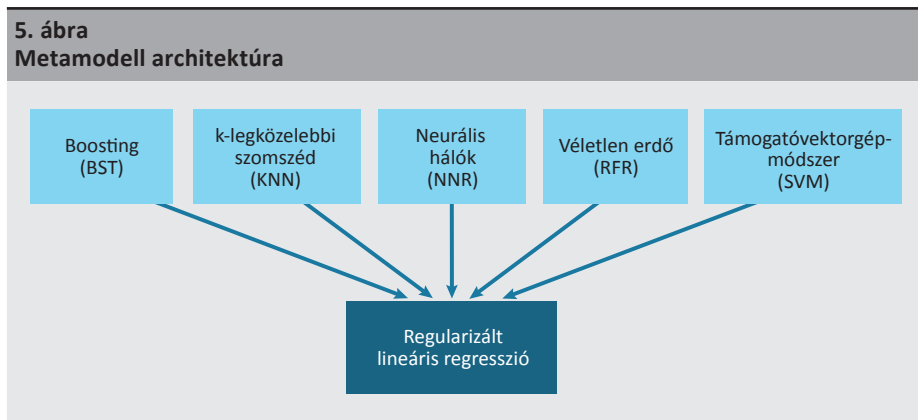
A 4. ábra szerint az első tanítóablak a magyarázó- és célváltozók tényleges adatait fedi le a 2009 első negyedétől 2017 utolsó negyedévéig terjedő időszakban, ami a minta körülbelül 56,25 százalékát kitevő kezdeti tanítási arányának felel meg. Ezután a következő teszt-részhalmozok további negyedévekkel egészülnek ki egészen 2024 harmadik negyedévéig. A teljes folyamat összesen 28 mintán kívüli, egy negyedévre előtekintő előrejelzést eredményezett.



E protokoll szerinti mintán kívüli előrejelzések három időszavat fednek le. Az első sáv a Covid19 előtti időszak egy negyedévre előretekintő előrejelzéseit tartalmazta 2018 első negyedétől 2019 utolsó negyedévéig, ami összesen nyolc negyedéves előrejelzést jelent. Ezt követően a modellek tovább bővítették a tanulási időszakot, hogy hasonló előrejelzéseket készítsenek a pandémia időszakára (2020. I. né. – 2022. IV. né., tizenkét negyedéves előrejelzés), egészen a pandémiát követő időszakig (2023. I. né. – 2024. IV. né., nyolc negyedéves előrejelzés).

3.4. Metamodellezési keretrendszer

Az 5. ábrán bemutatott kétszintű metamodel architektúrát alkalmazzuk a Fülöp-szigeteki bankok hitelezési magatartásának előrejelzésére. Az első szinten a táguló időablakos eljárás minden egyes lépésénél az összes modellt újranítják, kizárólag az előre jelzett negyedévet közvetlenül megelőző negyedévig ($t-1$) rendelkezésre álló adatok felhasználásával. Ezután minden modell egy negyedévre előretekintő, mintán kívüli előrejelzést készít, a protokollban leírtak szerint. A hiperparaméterek optimalizálása kizárólag az egyes tanítóablakokban rendelkezésre álló adatokon belül történik, az előretekintési torzítás (look-ahead bias) elkerülése érdekében.



Ez a tanulmány elismeri, hogy az egyes első szintű tanulóalgoritmusok mindegyike különböző erősségekkel rendelkezik. A BST a hibakorrekcióna helyezi a hangsúlyt, a KNN a lokális hasonlóságra épít, az NNR a sokdimenziós mintázatokat ragadja meg, az RFR az átlagolás révén biztosít stabilitást, az SVM pedig sáv szélesség-alapú (margin-based) regressziót alkalmaz. Ezért erősségeik ötvözése csökkenti a teljes varianciát és javítja az előrejelző képességet. Ennek érdekében az első szint előrejelzései a második szinten egy metatanulóhoz kerülnek továbbításra, egy LASSO-büntetőtaggal ellátott regularizált lineáris regresszió alkalmazásával. Ez három gyakorlati okból szolgál elsődleges specifikációként: (1) a LASSO képes nullára csökkenteni a csekély hozzájárulást nyújtó alapmodellek súlyát; (2) szűkíti és szelektálja az alapmodelleket a súlyok instabilitásának mérséklése és a kis mintából eredő

túlilleszkedés csökkentése érdekében; valamint (3) mérsékli az egyedi mintázatokra való túlreagálási hajlamot bármelyik tanulóalgoritmus esetében, ami különösen hasznos olyan strukturális törések idején, mint a Covid19 alatti kiugró értékek.

A metatanulási regressziós egyenlet a következőképpen írható fel:

$$\hat{y}_t^{MTM} = \alpha + \beta_1 \hat{y}_t^{BST}(x_{t-1}) + \beta_2 \hat{y}_t^{KNN}(x_{t-1}) + \beta_3 \hat{y}_t^{NNR}(x_{t-1}) + \beta_4 \hat{y}_t^{RFR}(x_{t-1}) + \beta_5 \hat{y}_t^{SVM}(x_{t-1}) + \epsilon_t \quad (7)$$

LASSO-büntetőtaggal:

$$\frac{\min}{\beta} \left\{ \sum_{t=1}^n (y_t - \hat{y}_t^{MTM}(x_{t-1}))^2 + \lambda \sum_{j=1}^5 |\beta_j| \right\} \quad (8)$$

Annak igazolására, hogy az eredmények nem pusztán a LASSO-büntetőtag következményei, jelen tanulmány két alternatív metatanulási sémát is implementált: a ridge és a rugalmas háló algoritmusokat. A ridge stabil zsugorítást biztosít a prediktorok közötti erős multikollinearitás esetén, ugyanakkor minden alapmodellt megtart kis pozitív súlyokkal, míg a rugalmas háló ötvözi a LASSO ritkító tulajdonságát a ridge csoportosítási stabilitásával. A regularizációs intenzitások – beleértve a rugalmas háló keverési paraméterét is – ugyanazzal a táguló időablakos eljárással kerültek kiválasztásra, mint amelyet az első szintű, mintán kívüli előrejelzések kialakításához használtunk, biztosítva, hogy az optimalizálási folyamat során ne kerüljenek felhasználásra jövőbeli adatok. A regularizált regresszió egyenlete ridge-büntetőtaggal:

$$\frac{\min}{\beta} \left\{ \frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t^{MTM}(x_{t-1}))^2 + \lambda \sum_{j=1}^5 |\beta_j^2| \right\} \quad (9)$$

Míg a rugalmasháló-büntetőtaggal ellátott regularizált regresszió egyenlete:

$$\frac{\min}{\beta} \left[\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t^{MTM}(x_{t-1}))^2 + \lambda \left(\frac{1-\alpha}{2} \sum_{j=1}^5 \beta_j^2 + \alpha \sum_{j=1}^5 |\beta_j| \right) \right] \quad (10)$$

3.5. Teljesítménymutatók és az előrejelzések irányhelyességének értékelése

A generált becsléseket összevetjük a megfelelő tényadatokkal. Minden egyes táguló időablakra kiszámítjuk az olyan teljesítménymutatókat, mint az átlagos négyzetes hiba négyzetgyöke (RMSE) és az átlagos abszolút hiba (MAE), annak értékelésére, hogy az előrejelzési teljesítmény javul-e a tanítóminták növekedésével. Az RMSE- és az MAE-értékek csökkenése azt jelzi, hogy a modellek hatékonyan tanulnak a táguló időablakos eljárás keretében bevont többletadatokból. E mutatók alapul szolgálnak az alapmodellek és a gépi tanuló algoritmusok összehasonlításához, valamint annak meghatározásához is, hogy melyik modell adja a legpontosabb előrejelzést a banki hitelezési magatartásra vonatkozóan. Hasonlóképpen kiszámítjuk a determinációs együtthatókat (R^2) is, a célváltozók meggyarazott varianciájának mérésére.

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2} \quad (11)$$

$$MAE = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t| \quad (12)$$

Az értékelés további kiterjesztéseként a célváltozó tényadatait és összesített előre jelzett értékeit binarizáltuk. A binarizálás célja annak megállapítása, hogy az előrejelzések a tényadatokkal megegyező irányú változást mutatnak-e. Ez az előrejelzési eredmények másodlagos diagnosztikai tesztjeként szolgált. Ehhez az adott negyedév értékéből levonjuk az előző negyedév értékét ($x_t - x_{t-1}$), ami pozitív vagy negatív változást eredményez. A pozitív változáshoz (vagy a szigorítás növekedéséhez) 1-es, a negatív változáshoz (vagy a lazítás csökkenéséhez) pedig -1 -es értéket rendeltük hozzá. Mivel semleges kimenet nem létezik, egyéb értékek hozzárendelését nem vesszük figyelembe.

Ezt követően kiszámítottuk a tévesztési mátrix mutatóit. Az előre jelzett adatokat összehasonlítottuk a tényadatokkal a valós pozitív (TP), az álpozitív (FP), a valós negatív (TN) és az álnegatív (FN) értékek meghatározásához. Az eredményeket ezt követően értékeltük a becslési pontosság (accuracy), a precizitás (precision), a szenzitivitás (recall), az F1-érték és a téves felfedezési arány (false discovery rate) segítségével.

$$\text{Becslési pontosság} = \frac{TP + TN}{TP + FP + TN + FN} \quad (13)$$

$$\text{Precizitás} = \frac{TP}{TP + FP} \quad (14)$$

$$\text{Szenzitivitás} = \frac{TP}{TP + FN} \quad (15)$$

$$F1\text{-érték} = \frac{2 \times \text{Precizitás} \times \text{Szenzitivitás}}{\text{Precizitás} + \text{Szenzitivitás}} \quad (16)$$

$$\text{Téves felfedezési arány} = \frac{FP}{TP + FP} \quad (17)$$

4. Eredmények és megbeszélés


4.1. Előrejelzési pontosság az RMSE- és MAE-hibamutatók szerint

A 6. ábra az átlagos RMSE segítségével összehasonlítja, hogy az egyes modellek milyen megbízhatósággal jelzik előre a hitelezési magatartást három különböző időszakban. Ez azt méri, hogy a modellek előrejelzései mennyire térnek el a tényleges értékektől. A világvárvány előtt (2018. I. né. – 2019. IV. né.) a banki hitelezési

magatartás viszonylag stabil volt. Ebben az időszakban az MTM mutatta a legalacsonyabb *RMSE*-értéket (0,335), ami azt jelzi, hogy ez a modell biztosítja a tényleges SLOS diffúziós indexhez legközelebb álló előrejelzéseket. Az első szintű alapmodellek, mint a BST (0,417) és a KNN (0,591) szintén meglehetősen jól teljesítettek, de nem érték el az MTM konzisztenciáját. Ugyanakkor az alapmodellek nagyobb hibákat produkáltak, ami azt mutatja, hogy nehezen tudják megragadni az adatokban rejlő korai mintázatokat.

6. ábra

Az egy negyedévre előretekintő, mintán kívüli előrejelzések átlagos *RMSE*-értéke időablakonként



Megjegyzés: Az alacsonyabb *RMSE* nagyobb becslési pontosságot jelent.

A Covid19-időszak (2020. I. né. – 2022. IV. né.) hirtelen, nagy ingadozásokat okozott a hitelezési feltételekben. A 6. ábra (b) panelje azt mutatja, hogy még turbulens körülmények között is az MTM 0,692-es értékkel marad a legpontosabb az összes modell közül, melyek értékei 0,867 és 3,040 között mozogtak. Minden modell esetében nőtt a hiba, ami arra utal, hogy a pandémia alatt nehézségekbe ütközött a hitelezési magatartás előrejelzése, mivel kizárólag normál gazdasági körülmények között lettek betanítva. Ahogy a táguló időablakos protokoll keretében folyamatosan tanultak, a Covid19 utáni időszakra (2023. I. né. – 2024. IV. né.) vonatkozó előrejelzések megbízhatóbbak lettek, sőt még a Covid19 előtti időszakhoz képest is javultak.


A teljes vizsgálati időszakra (2018. I. né. – 2024. IV. né.) vonatkozó általános RMSE-érték (0,467) azt mutatta, hogy az MTM hatékonyan jelzi előre a banki hitelezési magatartást. Ezt követi a KNN 0,625-ös értékkel, majd a BST 0,701-es értékkel. Az egyedi alapmodellek teljesítménye az időszaktól függően változik. A referencia-modellek minden időszakban következetesen kevésbé pontosak maradnak.

A 7. ábra a három időablakra vonatkozó átlagos MAE-értéket szemlélteti. Az RMSE-hez hasonlóan az alacsonyabb MAE-érték jobb előrejelzési pontosságot jelent, és a nagy hibák túlsúlyozása helyett inkább a hibák átlagos nagyságára fókuszál. Az MTM minden időszakban a legalacsonyabb MAE-értéket éri el, ami megerősíti, hogy következetesen a legkisebb átlagos eltérést produkálja a tényleges hitelezési feltételektől.

Összességében az időablaktól függetlenül az MTM nyújtja a legkövetkezetesebben pontos, egy negyedévre előretekintő előrejelzéseket. Emellett az első szintű alapmodellek is felülmúlták a referenciamodelleket, de egyikük sem előzte meg az MTM-et. A két hibamutató kiegészítésével az MTM nemcsak a nagy hibákat csökkenti, hanem az egy negyedévre előretekintő előrejelzési hibákat is alacsonyan tartja, így a legmegbízhatóbb eszköznek bizonyul a banki hitelezési magatartás változásainak nyomon követéséhez.

7. ábra

Az egy negyedévre előretekintő, mintán kívüli előrejelzések átlagos MAE-értéke időablakonként



Megjegyzés: Az alacsonyabb MAE nagyobb becslési pontosságot jelent.

4.2. Összesített előrejelzési teljesítmény

A 2. táblázat bemutatja a gépi tanulási alapmodellek összesített teljesítménymutatóit a legrobustusabb és legpontosabb előrejelző modell meghatározása érdekében. Az egyes modellek közül a KNN rendelkezik a legalacsonyabb MSE-, RMSE- és MAE-értékekkel, ami azt jelzi, hogy az előrejelzéseinek volt a legkisebb az átlagos hibamértéke és minimális a tényleges értékektől való átlagos távolsága. A BST-vel és az NNR-rel együtt erős determinációs együtthatóval rendelkezőnek minősítették, közülük is a KNN érte el a legmagasabb magyarázott varianciát. A fennmaradó alapmodellek a három legjobban teljesítőhöz képest alulteljesítettek, csak mérsékelt magyarázott varianciát értek el, ami a kiugró értékekre és az előrejelzési hibákra való nagyobb érzékenységet jelez.

Ugyanakkor a referenciamodellek magas hibaszámmal rendelkeznek, gyenge vagy mérsékelt magyarázott varianciával kísérve. Ez azt mutatja, hogy a SLOS diffúziós index múltbeli momentumát megragadó autoregresszív tagok önmagukban nem elegendők a hitelezési magatartás hatékony előrejelzéséhez. Mivel a gépi tanulási alapmodellek jobban teljesítettek, mint a referenciamodellek, a bankspecifikus és makrogazdasági mutatók jobb előrejelzőnek bizonyultak, mint az egyszerű autoregresszív minták.

2. táblázat					
Az egy negyedévre előretekinthető, mintán kívüli előrejelzések összesített teljesítménye (2018. I. né. – 2024. IV. né.)					
Modell	MSE	RMSE	MAE	R ²	Magyarázó erő
RW	2,807	1,675	0,243	0,519	Közepes
ARIMA	4,572	2,138	0,308	0,464	Gyenge
SARIMA	6,185	2,487	0,363	0,340	Gyenge
BST	0,491	0,701	0,101	0,902	Erős
KNN	0,390	0,625	0,091	0,931	Erős
NNR	0,762	0,873	0,126	0,875	Erős
RFR	1,149	1,072	0,155	0,750	Közepes
SVM	0,958	0,979	0,143	0,846	Közepes
MTM	0,218	0,467	0,067	0,963	Erős

Megjegyzés: A félkövérrel szedett értékek a többi modellelhez képest jobb teljesítményt jeleznek. Az értékek az összes időszakra vonatkozó átlagot mutatják.

Összességében az MTM jellemezhető a legkisebb hibával az összes modell közül, megerősítve fölényét mind az összesített hibamérték, mind a nagy hibák büntetésének minimalizálásában, miközben fenntartotta a legnagyobb előrejelzési erőt is. Ez az MTM-et a tanulmány optimális előrejelzési modelljévé teszi. Fő előnye abban rejlik, hogy képes szintetizálni az alapmodellek specifikus erősségeit, miközben azok alkalmazkodnak a táguló időablakokhoz. Az időablakonkénti elemzés egyik

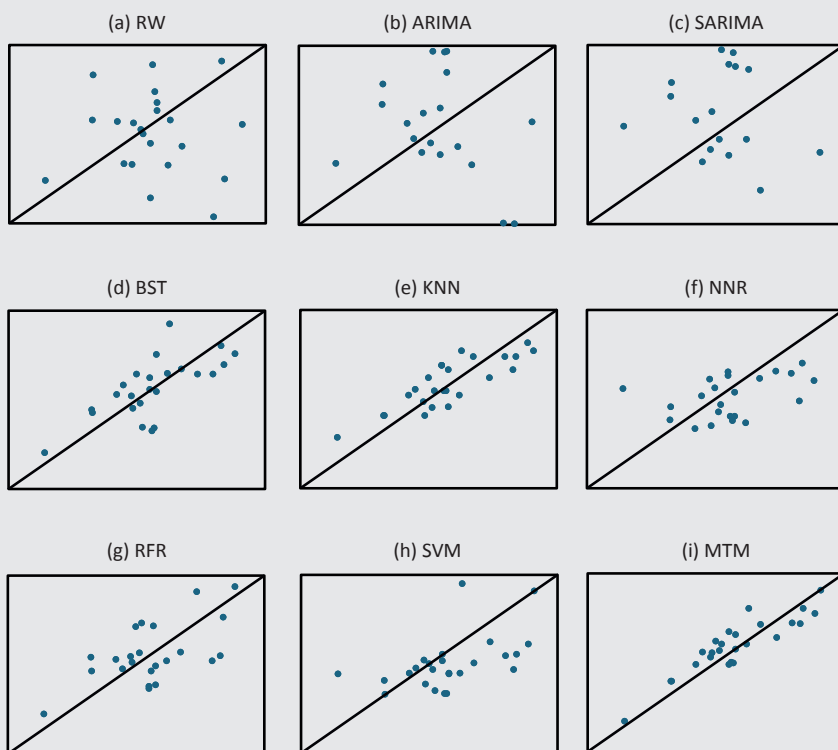
legfontosabb megfigyelése, hogy az egyes modellek legjobb teljesítménye a teljes tárguló időszaki horizonton oszlik meg. Az MTM pontosan ezt az eltolódó becslési pontossági mintázatot képes megragadni, így még az alapmodellek ingadozása esetén is megbízható teljesítményt nyújt.

4.3. Pontbecslések: mintán kívüli előrejelzési pontosság

A különböző előrejelző modellek teljesítményének értékeléséhez a 8. ábra szórási diagramokat mutat be, amelyek a teljes tesztadatbázison vett előre jelzett értékeket vetik össze a megfigyelt tényadatokkal. Az y-tengelyen a tényleges értékeket, az x-tengelyen pedig az előre jelzett értékeket tüntetjük fel. A diagonális egyenes a tökéletes előrejelzést reprezentálja, ahol az előre jelzett érték megegyezik a tényleges értékkel. Az egyes modellek relatív becslési pontosságát és kalibrálását az adatpontok diagonálishoz való közelségéből lehet kikövetkeztetni, ahol a szorosabb csoportosulás jobb előrejelző képességet és alacsonyabb hibavariációt jelez.

8. ábra

Pontbecslések: az egy negyedévre előretekintő, mintán kívüli előrejelzések pontossága



Megjegyzés: A diagonális egyenes a tökéletes előrejelzést jelzi. A diagonálishoz való közelség a modell becslési pontosságát és kalibráltságát tükrözi.

A referenciamodellek pontjai messze szóródnak a diagonális egyenestől. Az RW elvétette a főbb emelkedő és csökkenő trendeket, míg az ARIMA és a SARIMA hajlamos az előrejelzéseket az átlag felé húzni, ami a magas értékek alulbecslését és az alacsony értékek felülbecslését eredményezte. Ezzel szemben az első szintű gépi tanuló modellek jobban teljesítettek. A BST megragadta a mintázatokat, de néhány esetben túlreagált, jelentős túl- és alulbecsléseket eredményezve. A KNN rendezett pontcsoportokat hozott létre, és a többi modellhez képest jól teljesített. Az NNR pontjai szórtabbak és inkonzisztensebbek voltak, valamint láthatóan nehezen talált mintázatokat. Az RFR általában a diagonális egyenes közelében maradt a középső értékeknél, de alulbecsülte a szélsőségesen magas értékeket, az előrejelzéseket a biztonságosabb középső tartomány felé húzva. Végül az SVM egyenes trendet követett, de túl merev volt ahhoz, hogy reagáljon a hirtelen változásokra, ami az értékek éles elmozdulásakor szórt pontokhoz vezetett.

Az MTM teljesített a leghatékonyabban. A pontok többsége szorosan a diagonális egyenes köré tömörült, ami azt mutatja, hogy előrejelzései nagyon közel állnak a tényadatokhoz. Elkerüli a nagy hibákat, és a hitelezési magatartás enyhe és éles elmozdulásait egyaránt megragadja. Ez a minta tükrözi az MTM azon képességét, hogy egyesítse az összes első szintű gépi tanuló modell erősségeit, miközben minimalizálja gyengeségeiket. Ezért az MTM a legmegbízhatóbb előrejelzője a banki hitelezési magatartás szigorításának és enyhítésének.


4.4. Irányhelyesség

A tanulmány célváltozója binarizálható, mivel a nettó pozitív index a hitelezési feltételek szigorításának, a nettó negatív index pedig azok lazításának felel meg. Ebből kiindulva elvégeztük annak értékelését, hogy a modellek milyen mértékben tudták helyesen meghatározni az irányhelyességet. A 9. ábrán látható módon az előrejelzések négy kategóriába sorolhatók: valós pozitív, valós negatív, álpozitív és álnegatív. Az MTM 0,846-os valós pozitív arányt ért el, ami magasabb, mint a többi modell 0,308 és 0,769 közötti értéke. Ez azt jelzi, hogy a tényadatok alapján az előre jelzett pozitív értékek 84,6 százalékát helyesen azonosította pozitívként. Ezen felül az MTM 0,867-es valós negatív arányt ért el, felülmúlva a többi modellt, amelyek eredményei 0,467 és 0,667 között mozogtak. Ez azt jelenti, hogy a tényleges negatív értékek 86,7 százalékát sikerült helyesen azonosítani.

A hibák tekintetében az MTM hatékonyabban teljesített az egyes modelleknél. Az álpozitív aránya 0,133, ami a KNN-hez hasonló, de jelentősen alacsonyabb a többi modellénél, amelyek 0,333 és 0,667 között mozogtak. Ez azt jelenti, hogy az elsőfajú hibának – vagyis a ténylegesen negatív adatok téves pozitívként való megjelölésének – a valószínűsége csupán 13,3 százalék. Ezenkívül az MTM álnegatív aránya 0,154, ami alacsonyabb a többi modellénél, amelyek értékei 0,231 és 0,692 között mozogtak. Eszerint a másodfajú hibának – vagyis a ténylegesen pozitív adatok tévesen negatívnak való megjelölésének – a valószínűsége csupán 15,4 százalék.

9. ábra

A modellek előre jelzett értékeinek tévesztési számossági mutatói



Ha csak az egyes alapmodelleket értékeljük, akkor a BST teljesített a legjobban a valós pozitívok előrejelzésében és az álnegatív értékek csökkentésében. Kevésbé bizonyult azonban hatékonyak a valós negatív értékek előrejelzésében és az álpozitív értékek csökkentésében. Ugyanakkor a KNN jobb teljesítményt nyújtott a valós negatívok előrejelzésében és az álpozitívok csökkentésében. A valós pozitívok előrejelzése és az álnegatívok csökkentése szempontjából a SARIMA teljesített a legrosszabbul.

3. táblázat

Az egyes modellek előrejelzéseinek megkülönböztető mutatói

Modell	Becslési pontosság	Precizitás	Szenzitivitás	F1-érték	Téves felfedezési arány
RW	0,500	0,462	0,462	0,462	0,538
ARIMA	0,464	0,417	0,385	0,400	0,583
SARIMA	0,500	0,444	0,308	0,364	0,556
BST	0,643	0,588	0,769	0,667	0,412
KNN	0,750	0,800	0,615	0,696	0,200
NNR	0,500	0,462	0,462	0,462	0,538
RFR	0,571	0,533	0,615	0,571	0,467
SVM	0,536	0,500	0,615	0,552	0,500
MTM	0,857	0,846	0,846	0,846	0,154

Megjegyzés: A félkövérrel szedett értékek a többi modellhez képest jobb eredményeket jelölnek.

Az előre jelzett értékek irányhelyességi megbízhatóságának további vizsgálata érdekében a modelleket tovább elemeztük annak feltérképezésére, hogy képesek-e megkülönböztetni a szigorító és az enyhítő magatartást. A 3. táblázat eredményei azt mutatják, hogy az MTM érte el a legmagasabb pontosságot (0,857), miközben a precizitása, a szenzitivitása és az F1-mértéke is 0,846. Ez arra utal, hogy bár az alapmodellek hasonlóan hatékonyak a trendek követésében, az MTM képes magasabb teljesítményt fenntartani még a tényadatokban is megjelenő, jelentős volatilitású időszakokban is. Továbbá az MTM érte el a legalacsonyabb téves felfedezési arányt (0,154), szemben a többi alapmodellel, amelyek értékei 0,200 és 0,583 között mozogtak.

4.5. Változófontosság

A 4. táblázat az öt gépi tanulási alapmodellre vonatkozóan az egyes magyarázóváltozók átlagos elhagyási veszteségét (mean dropout loss) mutatja be. Az 50 permutáción alapuló átlagos elhagyási veszteség számszerűsíti a modell teljesítményének csökkenését egy-egy változó elhagyásakor, így a változó fontosságának mutatójaként (proxyjaként) szolgál. A magasabb értékek az előrejelzési pontossághoz való erősebb hozzájárulást jelzik.

4. táblázat							
Permutációs változófontossági mutatók							
Jellemző	Átlagos elhagyási veszteség					Átlag	Besorolás
	BST	KNN	NNR	RFR	SVM		
Tőke megfelelési mutató	8,514	7,213	10,71	8,679	9,665	8,956	7
Nemteljesítő eszközök aránya	8,380	7,169	12,16	7,018	10,331	9,012	6
Jövedelmező eszközök hozama	10,663	6,802	13,19	6,275	11,141	9,614	4
GDP-növekedési ráta	8,820	11,612	11,80	6,942	10,184	9,872	3
Inflációs ráta	8,195	7,438	11,56	6,078	9,512	8,557	9
Késedelmes hitelek aránya	10,673	8,017	13,61	6,707	12,132	10,228	2
Eszközarányos nyereség	7,958	6,535	12,22	9,141	9,966	9,164	5
Sajáttőke-arányos nyereség	13,789	6,633	14,32	9,847	10,668	11,051	1
Irányadó kamat	8,109	6,833	12,00	7,242	9,313	8,699	8

Megjegyzés: A félkövérrel szedett értékek a modellenkénti legmagasabb átlagos elhagyási veszteséget jelzik a kiterjesztett időablakban.

Az eredmények számos konzisztens mintázatot tárnak fel. A sajáttőke-arányos nyereség (ROE) bizonyul a legmeghatározóbb változónak, az összes modellt tekintve a legmagasabb átlagos elhagyási veszteséggel az első helyen áll. Ez hangsúlyozza központi szerepét a hitelezési magatartás magyarázatában, rámutatva arra, hogy a jövedelmezőség erősen meghatározza a bankok hitelnyújtási hajlandóságát. A késedelmes hitelek aránya (PDR) a második helyezett, kiemelve az eszközminőség és

a késedelmes fizetések szintjének fontosságát a hitelezési kimenetek alakulásában. A megnövekedett késedelmes kintlévőségek csökkentik a bankok kockázatvállalási kedvét, így ez a változó az előrejelzési pontosság kulcsfontosságú tényezője.

Más változók, mint például a GDP-növekedési ráta és a jövedelmező eszközök hozama, szintén előkelő helyen szerepelnek, jelezve, hogy mind a makrogazdasági feltételek, mind az eszközhasznosítás hatékonysága érdemben befolyásolja a hitelezési magatartást. Jelentőségük megerősíti a külső gazdasági környezet és a belső teljesítménymutatók kettős szerepét a hitelezési döntések alakításában. Ezzel szemben az olyan változók, mint az inflációs ráta és az irányadó kamat, alacsonyabb átlagos elhagyási veszteségeket mutatnak, ami arra utal, hogy bár hozzájárulnak az előrejelzési keretrendszerhez, marginális hatásuk kevésbé számottevő a jövedelmezőségi és eszközminőségi mutatókhoz képest.

Az a megállapítás, hogy a ROE és a PDR végzett az első helyeken – megelőzve a GDP-növekedési rátát –, arra utal, hogy a hitelezési magatartás nagymértékben függ a bank kockázatviselő képességétől. A magasabb jövedelmezőség növeli ezt a kockázatviselő képességet azáltal, hogy biztosítja a hitelezési tevékenység fenntartásához szükséges pénzügyi rugalmasságot még a gazdasági bizonytalanság idején is. Ugyanakkor a magasabb PDR a hitelezési magatartás óvatossági szempontjaira világít rá. A késedelmes fizetések megnövekedett száma arra készíti a bankokat, hogy védekező hitelezési politikát alkalmazzanak a likviditás megőrzése és a szabályozási előírások teljesítése érdekében.


Míg a GDP-növekedési ráta hitelkeresletet teremt, a ROE és a PDR egy küszöbértéket jelöl ki. Még a magas GDP-növekedéssel jellemzett időszakokban is, ha egy bank jövedelmezősége alacsony vagy a hitel-nemteljesítések aránya emelkedik, a kínálati oldali korlátok valószínűleg felülírják a keresleti oldali ösztönzőket. Ezért a bankok először saját pénzügyi stabilitásukat biztosítják, mielőtt reagálnának makrogazdasági impulzusokra.

A változók fontosságának eloszlása a modellek között rávilágít a módszertani sokszínűségekre is. Az NNR és az SVM általában nagyobb elhagyási veszteségeket rendel a jövedelmezőségi és eszközminőségi változókhoz, ami a nem arányos kölcsönhatásokkal szembeni érzékenységüket tükrözi. Ezzel szemben a KNN inkább a makrogazdasági változókat helyezi előtérbe, összhangban a varianciamagyarázat felé irányuló strukturális torzításával. Összességében a hitelezési magatartást leginkább a jövedelmezőségi mutatók és az eszközminőségi mutatók határozzák meg, a makrogazdasági növekedés pedig további magyarázóerőt biztosít. Az MTM kihasználja ezt az eloszlást azáltal, hogy szintetizálja az egyes modellek eltérő hangsúlyait, biztosítva, hogy a legnagyobb információtartalmú változók megtartását, míg a kevésbé fontosakat bünteti.

4.6. Robusztussági vizsgálatok


Jelen tanulmányban két alternatív metamodellt futtattunk annak ellenőrzésére, hogy az első szintű modellek kimeneteinek regularizálása nemcsak a LASSO-büntetőtaggal, hanem más módszerekkel is hasonló eredményeket hozhat-e. Ez a két alternatíva ugyanazt a táguló időablakos eljárást követi ridge- és rugalmas háló-büntetőtagok mellett. Amint az a 10. ábrán látható, a három metamodell egy negyedévre előretekintő, mintán kívüli előrejelzései szinte azonos mértékben képesek előrejelezni a banki hitelezési magatartást.

10. ábra
A LASSO-, ridge- és rugalmas háló eljárásokkal regularizált metamodellek előrejelző képessége



A ridge-büntetőtaggal rendelkező metamodell meghatározási együtthatója 0,953, a rugalmas háló-büntetőtagúé pedig 0,960, ami azt jelzi, hogy a metamodell erőssége még a két különböző regularizációs megközelítés mellett is erősek. Ezt támasztják alá a 11. ábrán látható *RMSE*- és *MAE*-mutatók is, amelyek minimális különbségeket mutatnak a teljesítményükben.

11. ábra
A LASSO-, ridge- és rugalmas háló büntetőtaggal regularizált metamodellek RMSE- és MAE-értékei



Ezenfelül az első szintű modellekhez hasonló permutációkkal számított változófontossági mutatók azt jelzik, hogy a ridge- és a rugalmas háló büntetőtagok esetében az átlagos elhagyási veszteség szinte megegyezik az MTM eredményeivel. A ridge esetében a KNN produkálta a legmagasabb átlagos elhagyási veszteséget (8,673), amelyet a BST (8,255) és az NNR (7,494) követett. A rugalmas háló esetében a BST produkálta a legmagasabb értéket (8,995), amelyet a KNN (6,070) és az NNR (6,468) követett. Ez a három első szintű modell járult hozzá a legnagyobb mértékben a banki hitelezési magatartás előrejelzéséhez.

5. Következtetések és implikációk

Jelen tanulmány egy LASSO-regularizált metatanulási modellt fejlesztett ki és értékelte, amely öt gépi tanulási eljárást – a boostingot, a k-legközelebbi szomszéd módszerét, a neurális hálókat, a véletlen erdőt és a támogatóvektor-gép módszert – integrál a Fülöp-szigeteki univerzális és kereskedelmi bankok hitelezési magatartásának előrejelzésére. A 2009-től 2024-ig terjedő, táguló időablakos, mintán kívüli értékelés során a metamodell alacsonyabb előrejelzési hibákat és nagyobb irányhelyességet produkált, mint az egyes első szintű alap- és a hagyományos referenciamodellek. A ridge- és rugalmas háló büntetőtagokat alkalmazó robusztussági vizsgálatok hasonló eredményeket hoztak, és igazolták a megközelítés stabilitását.

Ezenkívül az eredmények több fontos megállapításra világítanak rá. Először is, a jövedelmezőség és az eszközminőség bizonyult a hitelezési magatartás legfontosabb mozgatórugójának. Ez megerősíti a bankok belső teljesítményének kritikus szerepét a hitelallokációs döntések alakításában. Másodszor, kiderült, hogy a makrogazdasági feltételek, például a GDP-növekedés, külső nyomást gyakorolnak, tükrözve a bankok működésének makrogazdasági impulzusait. Harmadrészt, a metatanulási megközelítés az egyes gépi tanuló alapmodellekhez viszonyítva jobb alkalmazkodóképességet mutatott az extrém eseményekkel szemben, például a Covid19-világjárvány alatt bekövetkezett hirtelen és jelentős kiugráshoz képest.

Ezek az eredmények szakpolitikai következményekkel járnak a szabályozók, a politikai döntéshozók és a banki szakemberek számára, nemcsak a Fülöp-szigeteken, hanem más kis, nyitott gazdaságokban is.

Először is, ez a tanulmány hozzájárul a gépi tanulás bankfelügyeleti tevékenységbe való integrálásáról szóló globális diskurzushoz. A kétszintű metamodellezési architektúra előrejelzési viszonyítási alapot teremt az adatszegény környezetekben. Míg a fejlett gazdaságok nagy gyakoriságú adathalmazokkal (big datával) dolgoznak, sok feltörekvő piac adatszolgáltatási késedelemmel és kisebb adatbázisokkal szembesül. Utóbbi esetekben a metamodell alkalmazása képes jelentős előrejelzési értéket teremteni a különböző algoritmusok erősségeinek kiegyensúlyozásával.

Másodszor, ez a tanulmány további indokot szolgáltat a központi bankok számára a felügyeleti technológiák (SupTech) bevezetésére. A banki hitelezési felmérések adatszolgáltatási késedelme vakfoltot hoz létre a monetáris politikai transzmisszióban, ezért a negyedéves pénzügyi kimutatások gépi tanulás alapú elemzése felé történő szakpolitikai elmozdulás áthidalhatja ezt a szakadékot. A bankok által már benyújtott nyers pénzügyi adatok elegendő előrejelzési erővel rendelkeznek ahhoz, hogy előre lehessen jelezni a bankok későbbi hitelezési magatartását. A tanulmányban bemutatott modell egy SupTech platformba történő beépítése javítaná a központi bankok proaktív intézkedéseit a jegybanki kamatok és a likviditási intézkedések kiigazítását illetően.

Harmadszor, a bankok aggregált mutatóinak monitorozása korai figyelmeztető jelzésekkel szolgál, mivel a romló jövedelmezőség és eszközminőség könnyen a hitelezési feltételek szigorításához vezethet. A modell beépítése a központi bankok felügyeleti eszköztárába megerősíti a rendszerszintű kockázatok megfigyelését. A döntéshozóknak a banki mutatók alakulására kell alapozniuk intézkedéseiket annak érdekében, hogy a stresszesemények kedvezőtlen következményei csökkenthetők vagy megelőzhetők legyenek.

Negyedszer, e kulcsfontosságú tényezők azonosítása iránymutatást nyújt a pénzügyi stabilitást és ellenálló képességet erősítő beavatkozások kidolgozásához. Az eredmények alapján a monetáris politikai kiigazítások hatékonysága nem csupán a kamatlábak változásától függ, hanem a bankok alapvető pénzügyi helyzetétől is. Emiatt egy olyan válság idején, mint a Covid19-világjárvány, a szakpolitikai beavatkozásoknak a bankok jövedelmezőségének megerősítésére és a mérleg rendbetételére (kínálati oldali támogatás), valamint a makrogazdaság ösztönzésére (keresleti oldali támogatás) egyaránt összpontosítaniuk kell. Ez biztosítja, hogy a monetáris politika transzmissziója hatékony maradjon stabil és hitelezésre hajlandó szereplők mellett.

Ötödször, a modell robusztussága a volatilis időszakokban – beleértve a Covid19-világjárványt is – jól mutatja annak használhatóságát a stressztesztelés és a forgatókönyv-elemzés terén. A szabályozók felhasználhatják a keretrendszert a hitelezési reakciók szimulálására kedvezőtlen körülmények mellett, javítva ezzel a jövőbeli sokkokra való felkészültséget. Például a bankspecifikus és makrogazdasági mutatók feltételezett legrosszabb forgatókönyvek szerinti stresszelése előrejelezheti a bankok potenciális magatartási reakcióit. Fontos azonban megjegyezni, hogy bár az SLOS diffúziós index hasznos proxyváltozó a hitelezési magatartás szempontjából, inkább az érzékeléseket tükrözi, mint a tényleges hitelfolyósítást. Emiatt a szabályozóknak a modell kimeneteit kiegészítő információként kell kezelniük a döntéshozatal során, kiegyensúlyozott támaszkodást biztosítva mind a hangulati mutatókra, mind a tényleges hitelkihelyezési aktivitásra.

Hatodszor, a Fülöp-szigeteki tapasztalatok példát nyújtanak más olyan kis, nyitott gazdaságok számára, amelyek bankközpontú pénzügyi rendszerrel rendelkeznek, és bizonyos mértékben ki vannak téve a globális gazdasági hatásoknak. Ilyen környezetben a metatanulási megközelítés robusztus módszert kínál a korai figyelmeztető rendszerek fejlesztésére, lehetővé téve a makroprudenciális eszközök pontosabb kalibrálását. Például a modellt felhasználhatják az anticiklikus tőkepufferek felszabadításának vagy felhalmozásának megfelelő időzítésére összhangban a Bazel III. szabványokkal, hogy megakadályozzák a túlzott hitelállomány-növekedést gazdasági fellendülés idején, és biztosítsák a hitelek elérhetőségét a visszaesés időszakában. Azáltal, hogy a hitelkínálati feltételek potenciális enyhítését vagy szigorítását még annak teljes kibontakozása előtt azonosítják, a kis, nyitott gazdaságok megelőző intézkedéseket vezethetnek be.

Hetedszer, a modellből nyert ismeretek elősegíthetik a monetáris és fiskális hatóságok közötti koordinációt. Például, ha a jövedelmezőség korlátozza a bankok hitelezési hajlandóságát a lazító (ösztönző) jellegű monetáris politika ellenére, akkor fiskális intézkedésekre, akár hitelgaranciákra vagy célzott támogatásokra, lehet szükség a lakosság és a vállalkozások felé irányuló hiteláramlás fenntartása érdekében.

Végül a bankok számára az eredmények igazolják a jövedelmezőség és az eszközminőség fenntartásának fontosságát a prudens hitelezési gyakorlatok támogatása érdekében. Ez rámutat a hatékony hitelkockázat-kezelési rendszer fontosságára. A megfelelő hitelkockázat-kezelésre, a megalapozott hitelnyújtási folyamatra, valamint a robusztus hitelmérési és -ellenőrzési politikákra épülő hitelportfólió biztosítja, hogy a hitelek stresszesemények ellenére is jól teljesítsenek. A jövedelmezőség nemcsak növeli a bankok sokkelenyelő képességét, hanem rugalmasságot is biztosít a kedvező feltételek melletti hitelnyújtáshoz, ezáltal élénkítve a gazdasági aktivitást. Ugyanakkor a stabil eszközminőség csökkenti a hitelkockázati kitettséget, biztosítja azt, hogy a hitelállomány növekedése ne veszélyeztesse a pénzügyi stabilitást. Ezek a tényezők együttesen rávilágítanak arra, hogy a hitelezés nem csupán a hitelportfóliók bővítéséről szól, hanem a növekedés és a rugalmasság közötti egyensúly megteremtéséről is. Azok a bankok, amelyek prioritásként kezelik a jövedelmezőséget és az eszközminőséget, jobb helyzetben vannak ahhoz, hogy alkalmazkodjanak a volatilis makrogazdasági feltételekhez, megfeleljenek a szabályozói elvárásoknak, és hozzájáruljanak a monetáris politika hatékony transzmissziójához.

A jövőbeli kutatásoknak érdemes továbbfejleszteniük ezt a tanulmányt azáltal, hogy kiterjesztik a keretrendszert más gépi tanulási módszerekre, vagy figyelembe vesznek más, bankspecifikus és makrogazdasági változókat, amelyek tovább javíthatják a metamodell előrejelző képességét.

Felhasznált irodalom

- Abdolshah, F. – Moshiri, S. – Worthington, A. (2020): *Macroeconomic shocks and credit risk stress testing the Iranian banking sector*. Journal of Economic Studies, 48(2): 275–295. <https://doi.org/10.1108/jes-11-2019-0498>
- Adegbite, A. (2024): *Finance modeling approach using machine learning*. IOSR Journal of Economics and Finance, 15(5): 29–41. <https://doi.org/10.9790/5933-1505072941>
- Ahmed, S. – Majeed, M. – Thalassinou, E. – Thalassinou, Y. (2021): *The impact of bank specific and macro-economic factors on non-performing loans in the banking sector: Evidence from an emerging economy*. Journal of Risk and Financial Management, 14(5), 217. <https://doi.org/10.3390/jrfm14050217>
- Aikman, D. – Bush, O. – Taylor, A. (2016): *Monetary versus macroprudential policies: Causal impacts of interest rates and credit controls in the era of the UK Radcliffe report*. NBER Working Paper 22380. <https://doi.org/10.3386/w22380>
- Anand, M. – Velu, A. – Whig, P. (2022): *Prediction of loan behaviour with machine learning models for secure banking*. Journal of Computer Science and Engineering, 3(1): 1–13. <https://doi.org/10.36596/jcse.v3i1.237>

- Anyanwu, F.A. – Ananwude, A.C. – Okoye, N.T. (2017): *An empirical assessment of the impact of commercial banks' lending on economic development of Nigeria*. International Journal of Applied Economics, Finance and Accounting, 1(1): 14–29. <https://doi.org/10.33094/8.2017.11.14.29>
- Ashraf, B.N. (2021): *Is economic uncertainty a risk factor in bank loan pricing decisions? International evidence*. Risks, 9(5), 81. <https://doi.org/10.3390/risks9050081>
- Bancel, F. – Mittoo, U.R. (2011): *Financial flexibility and the impact of the global financial crisis: Evidence from France*. International Journal of Managerial Finance, 7(2): 179–216. <https://doi.org/10.1108/17439131111122157>
- Bangko Sentral ng Pilipinas (2025a): *Balance Sheet – Philippine Banking System [Dataset]*. Bangko Sentral ng Pilipinas. <https://www.bsp.gov.ph/SitePages/Statistics/BSFinancialStatements.aspx?TabId=1>
- Bangko Sentral ng Pilipinas (2025b): *Senior Bank Loan Officers' Survey [Dataset]*. Bangko Sentral ng Pilipinas. https://www.bsp.gov.ph/Pages/MediaAndResearch/PublicationsAndReports/regular_slos.aspx
- Bangko Sentral ng Pilipinas (2025c): *Media and Research – Prices [Dataset]*. Bangko Sentral ng Pilipinas. <https://www.bsp.gov.ph/SitePages/Statistics/Prices.aspx?TabId=1>
- Bassett, W.F. – Chosak, M.B. – Driscoll, J.C. – Zakrajšek, E. (2014): *Changes in bank lending standards and the macroeconomy*. Journal of Monetary Economics, 62: 23–40. <https://doi.org/10.1016/j.jmoneco.2013.12.005>
- Bernanke, B.S. (2018): *The real effects of disrupted credit: Evidence from the global financial crisis*. Brookings Papers on Economic Activity, 2018(2): 251–342. <https://doi.org/10.1353/eca.2018.0012>
- Chen, H. (2022): *Prediction and analysis of financial default loan behavior based on machine learning model*. Computational Intelligence and Neuroscience, 2022, 7907210. <https://doi.org/10.1155/2022/7907210>
- Claessens, S. – Kodres, L. (2014): *The regulatory responses to the global financial crisis: Some uncomfortable questions*. IMF Working Paper 14/46. <https://doi.org/10.5089/9781484335970.001>
- Donepudi, P.K. (2017): *Machine learning and artificial intelligence in banking*. Engineering International, 5(2): 83–86. <https://doi.org/10.18034/ei.v5i2.490>
- Dou, W.W. – Fang, X. – Lo, A.W. – Uhlig, H. (2023): *Macro-finance models with nonlinear dynamics*. Annual Review of Financial Economics, 15(1): 407–432. <https://doi.org/10.1146/annurev-financial-110921-112053>

- Fung, M.K.-Y. – Ho, W.-M. – Zhu, L. (2000): *The impact of credit control and interest rate regulation on the transforming Chinese economy: An analysis of long-run effects*. Journal of Comparative Economics, 28(2): 293–320. <https://doi.org/10.1006/jcec.2000.1655>
- Guerra, P. – Castelli, M. (2021): *Machine learning applied to banking supervision a literature review*. Risks, 9(7), 136. <https://doi.org/10.3390/risks9070136>
- Hashemi, S.K. – Mirtaheeri, S.L. – Greco, S. (2023): *Fraud detection in banking data by machine learning techniques*. IEEE Access, 11(1): 3034–3043. <https://doi.org/10.1109/access.2022.3232287>
- Kavirathne, G.P.R.A. – Perera, V.A.S. – Karunathunge, L.C.R. – Dewapura, B.N. – Karunasena, A. – Pemadasa, M.G.N.M. (2022): *A Meta-learning approach to predict non-performing loans in Sri Lankan financial institutions*. 13th International Conference on Computing Communication and Networking Technologies (ICCCNT), Kharagpur, India, pp. 1–6. <https://doi.org/10.1109/icccnt54827.2022.9984519>
- Kozak, S. (2021): *The impact of COVID-19 on bank equity and performance: The case of Central Eastern South European countries*. Sustainability, 13(19), 11036. <https://doi.org/10.3390/su131911036>
- Leo, M. – Sharma, S. – Maddulety, K. (2019): *Machine learning in banking risk management: A literature review*. Risks, 7(1): 1–22. <https://doi.org/10.3390/risks7010029>
- Lin, Y. – Yang, M. – Wan, C. – Wang, J. – Song, Y. (2019): *A multi-model combination approach for probabilistic wind power forecasting*. IEEE Transactions on Sustainable Energy, 10(1): 226–237. <https://doi.org/10.1109/tste.2018.2831238>
- Madugu, A.H. – Ibrahim, M. – Amoah, J.O. (2020): *Differential effects of credit risk and capital adequacy ratio on profitability of the domestic banking sector in Ghana*. Transnational Corporations Review, 12(1): 37–52. <https://doi.org/10.1080/19186444.2019.1704582>
- Makridakis, S. – Bakas, N. (2016): *Forecasting and uncertainty: A survey*. Risk and Decision Analysis, 6(1): 37–64. <https://doi.org/10.3233/rda-150114>
- Miglo, A. (2018): *Credit rationing, signaling by risk-bearing, flexibility theory and other theories of financing for entrepreneurial firms*. SSRN Electronic Journal. <https://doi.org/10.2139/ssrn.3147650>
- Montero-Manso, P. – Athanasopoulos, G. – Hyndman, R.J. – Talagala, T.S. (2020): *FFORMA: Feature-based forecast model averaging*. International Journal of Forecasting, 36(1): 86–92. <https://doi.org/10.1016/j.ijforecast.2019.02.011>

- Muslim, M.A. – Nikmah, T.L. – Pertiwi, D.A.A. – Subhan – Jumanto – Dasril, Y. et al. (2023): *New model combination meta-learner to improve accuracy prediction P2P lending with stacking ensemble learning*. Intelligent Systems with Applications, 18, 200204. <https://doi.org/10.1016/j.iswa.2023.200204>
- Naili, M. – Lahrichi, Y. (2020): *The determinants of banks' credit risk: Review of the literature and future research agenda*. International Journal of Finance & Economics, 27(1): 334–360. <https://doi.org/10.1002/ijfe.2156>
- Naser, M.Z. (2026): *A review of machine learning with small and limited data*. Journal of Big Data, 13, article 18. <https://doi.org/10.1186/s40537-025-01346-9>
- Nguyen, T. – Minhaj, A.B. – Doan, A.-T. (2025): *How do economic policy uncertainty and inflation individually and collectively influence bank loan pricing decisions in China?*. Journal of Chinese Economic and Foreign Trade Studies, 18(3): 398–428. <https://doi.org/10.1108/jcefts-09-2024-0072>
- Olawale, A. (2024): *Capital adequacy and financial stability: A study of Nigerian banks' resilience in a volatile economy*. GSC Advanced Research and Reviews, 21(1): 001–012. <https://doi.org/10.30574/gscarr.2024.21.1.0346>
- Olowe, K.J. – Edoh, N.L. – Zouo, S.J.C. – Olamijuwon, J. (2024): *Review of predictive modeling and machine learning applications in financial service analysis*. Computer Science & IT Research Journal, 5(11): 2609–2626. <https://doi.org/10.51594/csitrj.v5i11.1731>
- Parker, S.C. (2002): *Do banks ration credit to new enterprises? And should governments intervene?*. Scottish Journal of Political Economy, 49(2): 162–195. <https://doi.org/10.1111/1467-9485.00227>
- Paz, Á. – Crawford, B. – Monfroy, E. – Barrera-García, J. – Peña Fritz, Á. – Soto, R. et al. (2025): *Machine learning and metaheuristics approach for individual credit risk assessment: A systematic literature review*. Biomimetics, 10(5), 326. <https://doi.org/10.3390/biomimetics10050326>
- Rane, N. – Choudhary, S.P. – Rane, J. (2024): *Ensemble deep learning and machine learning: Applications, opportunities, challenges, and future directions*. Studies in Medical and Health Sciences, 1(2): 18–41. <https://doi.org/10.48185/smhs.v1i2.1225>
- Rostagno, M. – Altavilla, C. – Carboni, G. – Lemke, W. – Motto, R. – Saint Guilhem, A. et al. (2021): *Monetary policy in times of crisis: A Tale of Two Decades of the European Central Bank*. Oxford University Press. <https://doi.org/10.1093/oso/9780192895912.001.0001>

- Safonova, A. – Ghazaryan, G. – Stiller, S. – Main-Knorn, M. – Nendel, C. – Ryo, M. (2023): *Ten deep learning techniques to address small data problems with remote sensing*. International Journal of Applied Earth Observation and Geoinformation, 125, 103569. <https://doi.org/10.1016/j.jag.2023.103569>
- Savolainen, J. – Collan, M. (2020): *Using meta-models in simulation-based investment analysis: Studying the financing mix of metal mining investments*. Fuzzy Economic Review, 25(01). <https://doi.org/10.25102/fer.2020.01.04>
- Schiantarelli, F. – Stacchini, M. – Strahan, P. (2016): *Bank quality, judicial efficiency and borrower runs: Loan repayment delays in Italy*. National Bureau of Economic Research. <https://doi.org/10.3386/w22034>
- Siegert, S. – Sansom, P.G. – Williams, R.M. (2016): *Parameter uncertainty in forecast recalibration*. Quarterly Journal of the Royal Meteorological Society, 142(696): 1213–1221. <https://doi.org/10.1002/qj.2716>
- Wu, H. – Levinson, D. (2021): *The ensemble approach to forecasting: A review and synthesis*. Transportation Research Part C: Emerging Technologies, 132(1), 103357. <https://doi.org/10.1016/j.trc.2021.103357>
- Yitayaw, M. (2021): *Firm-specific, industry-specific and macroeconomic determinants of commercial banks' lending in Ethiopia: Panel data approach*. Cogent Economics & Finance, 9(1). <https://doi.org/10.1080/23322039.2021.1952718>
- Yurdakul, F. (2014): *Macroeconomic modelling of credit risk for banks*. Procedia – Social and Behavioral Sciences, 109: 784–793. <https://doi.org/10.1016/j.sbspro.2013.12.544>

Függelék

A. A magyarázó- és célváltozók közzétételének ütemezése

Változó	Jelentés	Adatok időbeli gyakorisága	Közzététel ütemezése
SLOS diffúziós index	BSP vezető hitelintézeti referensek felmérése	Negyedéves	~ Egy hónappal a referencia-időszak után
Tőke megfelelési mutató	Az univerzális/kereskedelmi bankcsoport kiválasztott teljesítménymutatói	Havi	~ Két héttel a referencia-időszak után
Nemteljesítő eszközök aránya	Az univerzális/kereskedelmi bankcsoport kiválasztott teljesítménymutatói	Havi	~ Két héttel a referencia-időszak után
Jövedelmező eszközök hozama	Az univerzális/kereskedelmi bankcsoport kiválasztott teljesítménymutatói	Havi	~ Két héttel a referencia-időszak után
Késedelmes hitelek aránya	Az univerzális/kereskedelmi bankcsoport kiválasztott teljesítménymutatói	Havi	~ Két héttel a referencia-időszak után
Eszközarányos nyereség	Az univerzális/kereskedelmi bankcsoport kiválasztott teljesítménymutatói	Havi	~ Két héttel a referencia-időszak után
Sajáttőkearányos nyereség	Az univerzális/kereskedelmi bankcsoport kiválasztott teljesítménymutatói	Havi	~ Két héttel a referencia-időszak után
GDP-növekedési ráta	Kiválasztott Fülöp-szigeteki gazdasági mutatók	Havi	~ Két héttel a referencia-időszak után
Inflációs ráta	Inflációs ráta sajtóközlemény	Havi	~ Egy héttel a referencia-időszak után
Irányadó kamat	BSP irányadó kamatlábak	Napi	Minden munkanapon 13:00-kor

Megjegyzés: Körülbelül négy hónapot vesz igénybe egy adott negyedév tényleges banki hitelezési magatartásának azonosítása. A magyarázó változók ugyanakkor már körülbelül két héttel az előző időszak (a tanító adatbázis utolsó adatai) után elérhetők. Például a 2024. decemberi hitelezési magatartás előrejelzéséhez (amelyet 2025. januárban tettek közzé) szükség volt a 2024. szeptemberi aggregált banki hitelezési arányokra és makrogazdasági mutatókra (az adatok 2024. október második hetében rendelkezésre állnak). Ez elegendő előkészítési időt biztosít olyan proaktív szakpolitikák implementálására, amelyek a hitelkinálati feltételek szigorításának vagy enyhítésének következményeit kezelik.

Forrás: A Bangko Sentral ng Pilipinas előzetes közzétételi naptára alapján <https://www.bsp.gov.ph/Statistics/Advance%20Release%20Schedule/AdvanceReleaseSchedule.aspx>

B. A magyarázó- és célváltozók stacionaritása első differencia képzését követően

Megfigyelés	Kiterjesztett Dickey–Fuller t	Phillips–Perron	Megjegyzések
Banki hitelezési magatartás	-5,240**	-58,266**	Stacioner
Tőke megfelelési mutató	-3,086*	-53,341**	Stacioner
Nemtjeljesítő eszközök aránya	-2,459*	-64,660**	Stacioner
Jövedelmező eszközök hozama	-2,133*	-42,927**	Stacioner
GDP-növekedési ráta	-5,658**	-54,070**	Stacioner
Inflációs ráta	-5,538**	-53,841**	Stacioner
Késedelmes hitelek aránya	-2,217*	-90,611**	Stacioner
Eszközarányos nyereség	-4,541**	-42,638**	Stacioner
Sajáttőke-arányos nyereség	-4,909**	-33,919**	Stacioner
Irányadó kamat	-3,354*	-30,629**	Stacioner

Megjegyzés: * $p < 0,05$, ** $p < 0,01$.

C. A referencia- és metamodellek reziduumok normális eloszlása

Modellek	Shapiro-Wilk W	p-érték	Lilliefors D	p-érték	Megjegyzések
RW	0,394	0,962	0,123	0,344	Normális eloszlású
ARIMA	0,995	0,266	0,106	0,582	Normális eloszlású
SARIMA	0,939	0,104	0,145	0,140	Normális eloszlású
MTM-LASSO	0,945	0,171	0,140	0,170	Normális eloszlású
MTM-ridge	0,934	0,078	0,138	0,192	Normális eloszlású
MTM-rugalmas háló	0,955	0,264	0,143	0,151	Normális eloszlású

Megjegyzés: A 0,05-nél nagyobb p-értékek normális eloszlást jeleznek.

D. RMSE-értékek időablakonkénti bontásban

Ablak	RW	ARIMA	SARIMA	BST	KNN	NNR	RFR	SVM	MTM	Ridge	ENET
2018. I. né.	0,559	1,118	2,325	0,354	0,822	2,374	0,455	1,717	0,164	0,242	0,280
2018. II. né.	0,649	0,170	0,570	0,756	0,548	0,391	0,161	0,143	0,606	0,444	0,546
2018. III. né.	1,377	1,916	2,722	0,022	0,344	0,347	0,592	0,947	0,219	0,179	0,214
2018. IV. né.	3,273	4,643	6,502	0,793	0,577	0,768	0,408	1,591	0,221	0,145	0,379
2019. I. né.	4,154	4,333	6,213	0,839	0,336	0,844	1,515	1,390	0,434	0,872	0,937
2019. II. né.	2,207	0,887	0,905	0,027	0,733	0,414	1,011	0,002	0,653	0,120	0,105
2019. III. né.	0,549	0,518	1,822	0,375	0,724	0,539	0,937	0,182	0,351	0,215	0,289
2019. IV. né.	0,513	1,432	4,229	0,166	0,641	0,915	1,001	0,693	0,030	0,056	0,177
2020. I. né.	1,327	1,484	0,488	1,734	2,803	0,312	3,960	2,410	2,076	2,295	2,148
2020. II. né.	5,957	7,164	7,045	4,074	2,691	2,568	6,125	5,596	1,519	1,643	1,431
2020. III. né.	3,880	3,895	4,281	0,555	0,605	0,798	1,991	1,783	0,673	0,283	0,967
2020. IV. né.	1,804	1,697	2,560	0,640	0,707	1,346	0,616	0,002	0,036	0,284	0,169
2021. I. né.	0,257	1,984	1,174	1,471	0,700	3,026	2,083	1,601	0,857	1,608	0,982
2021. II. né.	1,032	7,161	6,516	0,645	0,368	1,415	0,253	1,357	0,568	0,622	0,954
2021. III. né.	5,951	2,494	2,879	0,455	0,581	0,411	0,836	0,566	0,480	0,318	0,661
2021. IV. né.	3,938	3,203	3,790	0,700	0,576	0,298	1,038	0,001	0,572	0,541	0,456
2022. I. né.	0,385	1,020	1,250	0,130	0,790	1,645	1,343	1,739	0,536	0,959	0,741
2022. II. né.	0,245	1,853	1,448	0,830	0,415	0,199	0,403	0,648	0,365	0,155	0,366
2022. III. né.	1,537	2,688	2,649	1,101	0,067	0,747	0,464	1,075	0,283	0,689	0,723
2022. IV. né.	0,788	1,837	1,827	1,065	0,107	0,885	0,693	1,097	0,339	0,538	0,734
2023. I. né.	0,106	2,065	2,085	0,830	0,106	0,252	0,979	0,800	0,371	0,235	0,470
2023. II. né.	2,298	2,093	2,128	0,449	0,361	0,582	0,611	0,001	0,302	0,348	0,474
2023. III. né.	1,146	1,557	1,763	0,537	0,365	0,255	0,979	0,365	0,317	0,438	0,491
2023. IV. né.	0,336	0,600	0,649	0,150	0,362	0,625	0,126	0,455	0,296	0,332	0,231
2024. I. né.	0,653	0,632	0,707	0,473	0,442	0,400	0,477	0,101	0,286	0,256	0,324
2024. II. né.	0,038	0,264	0,182	0,162	0,279	0,395	0,245	0,211	0,218	0,219	0,224
2024. III. né.	0,668	0,352	0,289	0,171	0,013	0,578	0,279	0,175	0,217	0,166	0,123
2024. IV. né.	1,288	0,813	0,637	0,125	0,431	1,117	0,442	0,765	0,089	0,080	0,102

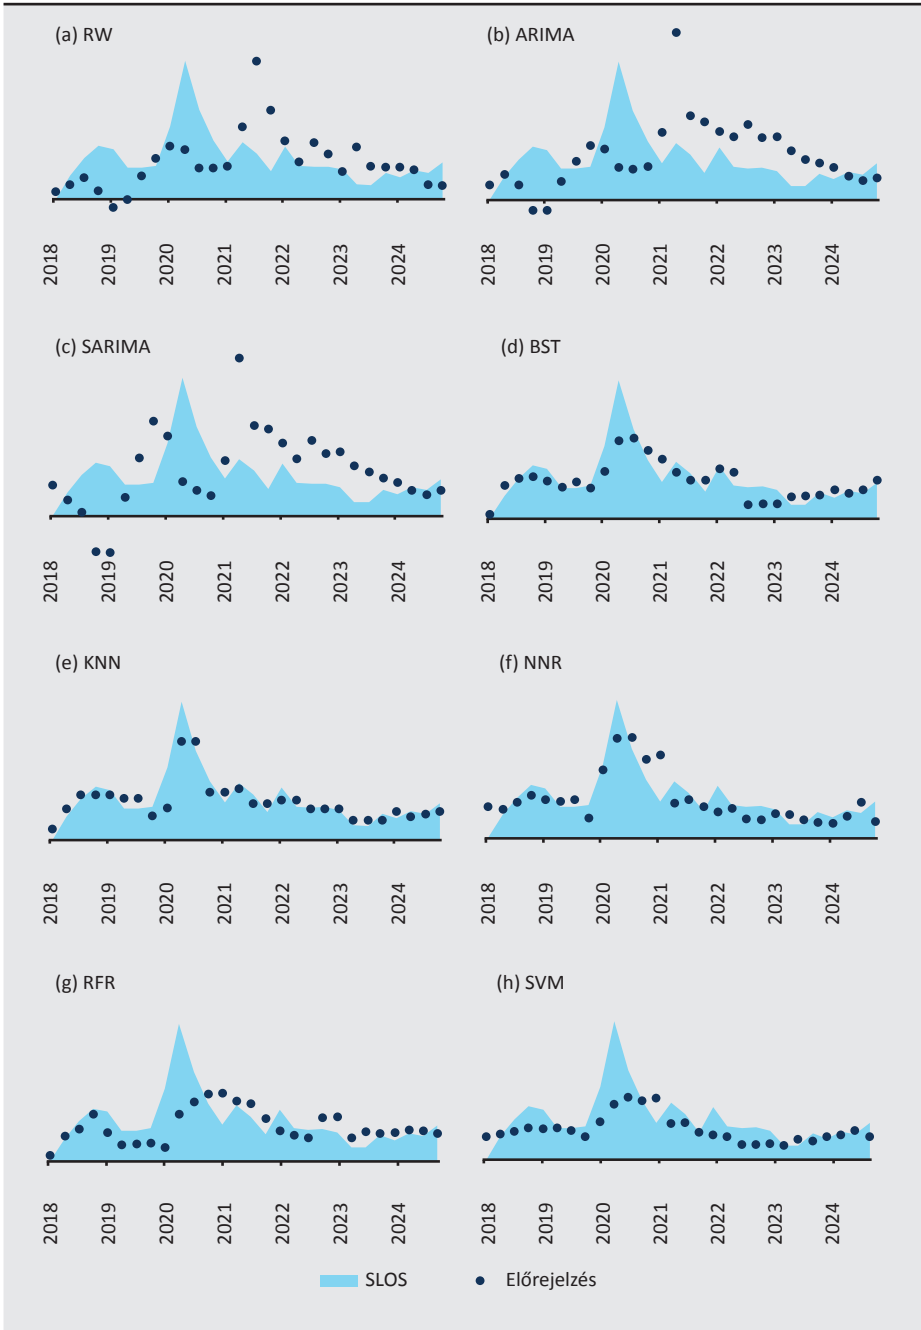
E. MAE-értékek időablakonkénti bontásban

Ablak	RW	ARIMA	SARIMA	BST	KNN	NNR	RFR	SVM	MTM	Ridge	ENET
2018. I. né.	0,092	0,184	0,382	0,058	0,135	0,391	0,075	0,282	0,027	0,040	0,046
2018. II. né.	0,105	0,028	0,093	0,123	0,095	0,064	0,026	0,023	0,098	0,072	0,089
2018. III. né.	0,221	0,307	0,436	0,004	0,055	0,056	0,095	0,152	0,035	0,029	0,034
2018. IV. né.	0,518	0,734	1,028	0,125	0,091	0,121	0,065	0,252	0,035	0,023	0,060
2019. I. né.	0,649	0,677	0,970	0,131	0,052	0,132	0,237	0,217	0,068	0,136	0,146
2019. II. né.	0,341	0,137	0,140	0,004	0,113	0,064	0,156	0,000	0,101	0,018	0,016
2019. III. né.	0,084	0,079	0,278	0,057	0,111	0,082	0,143	0,028	0,054	0,033	0,044
2019. IV. né.	0,077	0,216	0,638	0,025	0,097	0,138	0,151	0,105	0,005	0,009	0,027
2020. I. né.	0,198	0,221	0,073	0,259	0,418	0,047	0,590	0,359	0,310	0,342	0,320
2020. II. né.	0,878	1,056	1,039	0,601	0,397	0,379	0,903	0,825	0,224	0,242	0,211
2020. III. né.	0,566	0,568	0,625	0,081	0,088	0,117	0,290	0,260	0,098	0,041	0,140
2020. IV. né.	0,260	0,245	0,370	0,092	0,102	0,194	0,089	0,000	0,005	0,041	0,024
2021. I. né.	0,037	0,283	0,168	0,210	0,100	0,432	0,298	0,229	0,122	0,230	0,140
2021. II. né.	0,146	1,013	0,922	0,091	0,052	0,200	0,036	0,192	0,080	0,088	0,135
2021. III. né.	0,833	0,349	0,403	0,064	0,081	0,058	0,117	0,079	0,067	0,045	0,093
2021. IV. né.	0,546	0,444	0,526	0,097	0,080	0,041	0,144	0,000	0,079	0,075	0,063
2022. I. né.	0,053	0,140	0,172	0,018	0,109	0,226	0,185	0,239	0,074	0,132	0,102
2022. II. né.	0,033	0,252	0,197	0,113	0,057	0,027	0,055	0,088	0,050	0,021	0,050
2022. III. né.	0,207	0,362	0,357	0,149	0,009	0,101	0,063	0,145	0,038	0,093	0,098
2022. IV. né.	0,105	0,246	0,244	0,142	0,014	0,118	0,093	0,147	0,045	0,072	0,098
2023. I. né.	0,014	0,274	0,276	0,110	0,014	0,033	0,130	0,106	0,049	0,031	0,062
2023. II. né.	0,302	0,275	0,279	0,059	0,047	0,076	0,080	0,000	0,040	0,046	0,062
2023. III. né.	0,149	0,203	0,230	0,070	0,048	0,033	0,128	0,048	0,041	0,057	0,064
2023. IV. né.	0,043	0,077	0,084	0,019	0,047	0,081	0,016	0,059	0,038	0,043	0,030
2024. I. né.	0,084	0,081	0,091	0,061	0,057	0,051	0,061	0,013	0,037	0,033	0,042
2024. II. né.	0,005	0,034	0,023	0,021	0,036	0,050	0,029	0,027	0,028	0,028	0,025
2024. III. né.	0,084	0,044	0,036	0,022	0,002	0,073	0,035	0,022	0,024	0,021	0,015
2024. IV. né.	0,161	0,102	0,080	0,016	0,054	0,140	0,055	0,096	0,011	0,010	0,013

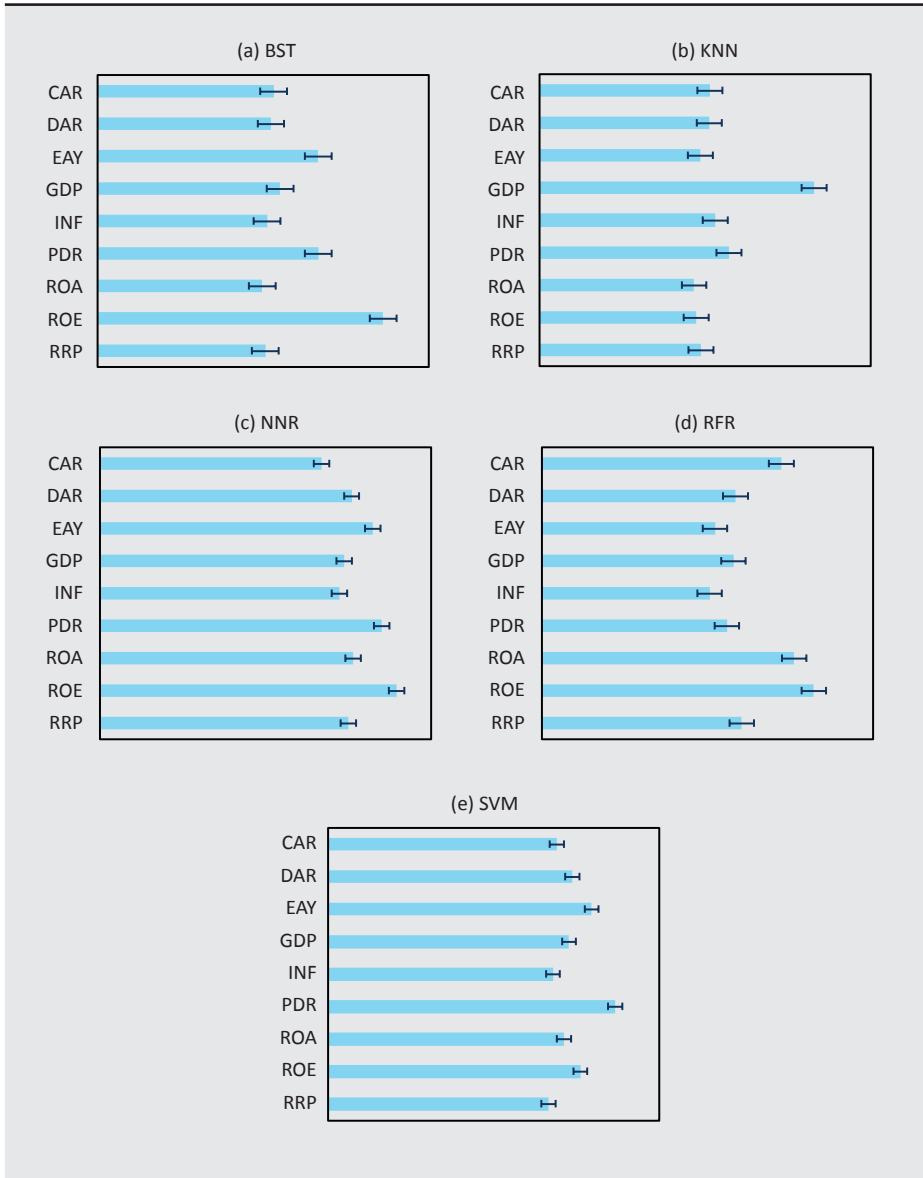
F. A referencia- és az egyedi alapmodellek binarizált előrejelzési eredményei

	Valós pozitív (TP)	Álpozitív (FP)	Valós negatív (TN)	Álnegatív (FN)	TP-arány	FP-arány	TN-arány	FN-arány
RW	11	2	13	2	0,846	0,133	0,867	0,154
ARIMA	8	8	7	5	0,615	0,533	0,467	0,385
SARIMA	8	7	8	5	0,615	0,467	0,533	0,385
BST	6	7	8	7	0,462	0,467	0,533	0,538
KNN	8	2	13	5	0,615	0,133	0,867	0,385
NNR	10	7	8	3	0,769	0,467	0,533	0,231
RFR	4	5	10	9	0,308	0,333	0,667	0,692
SVM	5	7	8	8	0,385	0,467	0,533	0,615

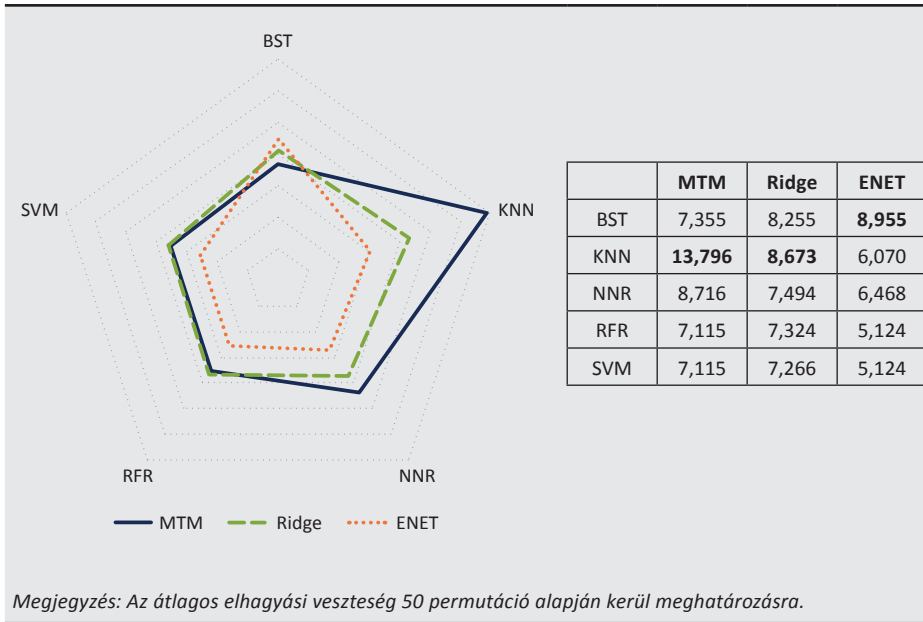
G. A referencia- és az egyedi alapmodellek előrejelzéseinek alakulása



H. A magyarázó változók átlagos elhagyási vesztesége 50 permutáció alapján, standard hibásávokkal



I. Az egyedi alapmodellek fontossága az alternatív metamodellekben



J. A metamodellek regressziós együtthatói az utolsó kiterjesztett időablakban

