

Közgazdász Fórum

Forum on Economics and Business



UNIVERSITATEA BABEŞ-BOLYAI
BABEŞ-BOLYAI TUDOMÁNYEGYETEM
BABEŞ-BOLYAI UNIVERSITY
BABEŞ-BOLYAI UNIVERSITY
TRADITIO ET EXCELLENTIA



ROMÁNIAI
MAGYAR
KÖZGAZDÁSZ
TÁRSASÁG



PARTIUMI
KERESZTÉNY
EGYETEM

A tartalomból:

3. **Antal András**
A turizmus hatása a gazdasági fejlődésre
Kelet- és Közép-Európa országaiban
20. **Kovács Edina**
A kriptovaluták hozamát befolyásoló tényezők
különböző piaci körülmények között
35. **Oborocea Mónika**
A lakástranzakciók volumenét befolyásoló tényezők Romániában
a Covid-19-világjárvány alatt
58. **Szilágyi-Nagy Zétény**
Hitelminősítő algoritmusok összehasonlítása: mesterséges
intelligencia alapú algoritmusok vs. hagyományos módszerek

A kiadvány megjelenését a Magyar Tudományos Akadémia támogatja.

A XXVI. évfolyam, 149. szám szerkesztői: Benedek Botond, Csiki Ottó, Dézsi-Benyovszki Annamária és Szabó Tünde-Petra.



Kiadja a

Romániai Magyar Közgazdász Társaság

Aurel Suciú utca 12. szám

400440 Kolozsvár/Cluj-Napoca

tel.: +40 787-890-686

email: office@rmkt.ro

honlap: www.rmkt.ro

Főszerkesztő: Kerekes Kinga

Főszerkesztő-helyettes: Alt Mónika Anetta

Szerkesztőbizottság: Bélyácz Iván, Benedek József, Berács József, Cardoso Ildikó Réka, Dézsi-Benyovszki Annamária, Fekete Szilveszter, Andrew Fieldsend, Fogarasi József, Györfy Lehel-Zoltán, Juhász Jácint, Kovács Gyöngyvér Emese, Kovács Levente, Králik Lóránd István, Molnár Judit, Nagy Ágnes, Nagy Bálint Zsolt, Poór József, Săplăcan Zsuzsa, Vatroslav Škare, Somai József (alapító főszerkesztő), Szabó Tünde Petra, Szász Erzsébet, Szász Levente, Szász János, Szilágyi Ferenc, Török Ádám, Vincze Mária

Felelős kiadó: Venczel Enikő

Nyelvi lektor: Szenkovics Enikő

Számítógépes tördelés: Balázs Bence

KÖZGAZDÁSZ FÓRUM

Forum on Economics
and Business



Tartalomjegyzék

ANTAL ANDRÁS

A turizmus hatása a gazdasági fejlődésre
Kelet- és Közép-Európa országaiban3

KOVÁCS EDINA

A kriptovaluták hozamát befolyásoló tényezők különböző
piaci körülmények között20

OBOROCEA MÓNICA

A lakástranzakciók volumenét befolyásoló tényezők Romániában
a Covid-19-világjárvány alatt35

SZILÁGYI-NAGY ZÉTÉNY

Hitelminősítő algoritmusok összehasonlítása:
mesterséges intelligencia alapú algoritmusok vs. hagyományos módszerek58

RMKT-hírek87

Angol nyelvű kivonatok96

Contents

ANDRÁS ANTAL

The impact of tourism on economic development
in Eastern and Central European countries3

EDINA KOVÁCS

Factors affecting cryptocurrency returns in different market conditions20

MÓNIKA OBOROCEA

Influencing factors of housing transaction volumes in Romania during
the Covid-19 pandemic35

ZÉTÉNY SZILÁGYI-NAGY

Comparison of credit scoring algorithms: artificial intelligence-based
algorithms vs. traditional methods58

News of HESR87

Abstracts (in English)96

A turizmus hatása a gazdasági fejlődésre Kelet- és Közép-Európa országaiban

ANTAL ANDRÁS¹

A tanulmány célja, hogy feltérképezze a turizmus és a gazdasági fejlődés közötti kapcsolatot Kelet- és Közép-Európa országaiban. A fő kérdés az, hogy a nemzetközi turistaérkezések száma hogyan befolyásolja az egy főre jutó GDP-t a régió országaiban? A kérdés megválaszolása iránymutató lehet állami intézmények vagy turisztikai szolgáltatók számára, hiszen bizonyíthatja, hogy a turizmus népszerűsítését célzó befektetések megtérülnek és pozitív hatással vannak a gazdaságra. A vizsgált periódus a 2006 és 2020 közötti időszakra vonatkozik. A fő kérdés megválaszolásához panel regressziót alkalmaztam, melyben kontrollváltozónak a kereskedelmet, az emberi fejlesztési indexet, a munkaerő-részesedési rátát, valamint a városi lakosság arányát használtam. Az eredmények összhangban vannak a szakirodalom túlnyomó többségével, melyek alátámasztják a turizmus által vezérelt gazdasági növekedés hipotézisét, kiemelve a turizmus által nyújtott lehetőségeket a kormányzati és vállalati szektor számára a régióban.

Kulcsszavak: turizmus, GDP, Kelet-Európa, Közép-Európa.

JEL kódok: L83, O11, C23.

Bevezető

A turizmus a modern világ egyik legdinamikusabban fejlődő ágazata (Scott et al. 2019), amely jelentős hatással van a gazdasági fejlődésre (Brida et al. 2020). A World Travel & Tourism Council (WTTC) elemzése alapján 2019-ben, mielőtt a Covid-19-világjárvány kitört volna, a turizmus – beleértve a közvetlen, közvetett és egyéb hatásokat is – a világ munkahelyeinek 10,5%-át (334 millió munkahely) és a globális GDP 10,4%-át (10,3 billió dollár) képezte. A Covid-19-világjárvány alatt a turizmus jelentősen visszaesett a szigorú utazást korlátozó szabályozások miatt, viszont a járvány után gyors ütemben kezdett visszatérni az azt megelőző szintre. 2023-ban az idegenforgalmi és turisztikai ágazat 9,1%-kal járult hozzá a globális GDP-hez, ami 23,2%-os növekedést jelent 2022-höz képest, és csupán 4,1%-kal marad el a 2019-es szinttől. 2023-ban 27 millió új munkahely jött létre az ágazatban, ami 9,1%-os növekedést jelent 2022-höz képest, és csak 1,4%-kal marad el a 2019-es szinttől.

A fenti statisztikák alátámasztják a turizmus fontosságát a világgazdaságban. A tanulmány célja megvizsgálni, hogy a turizmus által vezérelt gazdasági növe-

¹ BSc-hallgató, Babeş-Bolyai Tudományegyetem, Közgazdaság- és Gazdálkodástudományi Kar, e-mail: andras.antal@stud.ubbcluj.ro.

kedés megfigyelhető-e a kelet- és közép-európai országokban, azaz az egy főre eső turistaérkezések száma pozitív és szignifikáns hatással van-e az egy főre jutó GDP-re. Az eredmények alapján a kutatás célja rávilágítani a turizmus fontosságára és potenciáljára a gazdasági fejlődés elősegítésében.

Világszinten számos kutatás született a témával kapcsolatban, viszont egyik sem foglalkozott kiemelten a közép- és kelet-európai régióval. Ezen országcsoportot nem vizsgálták önállóan a szakirodalomban, viszont különleges, mivel más gazdasági és társadalmi történelemmel rendelkezik, mint a nyugat-európai államok (Balázs et al. 2014). Az említett országok elemzése azért fontos, mert a vasfüggöny keleti oldalán rekedtek, így a turizmus csak az 1990-es években kezdett fejlődni (Hall 1992). A nyugat-európai és a kelet-európai turizmus között hangsúlyos különbségek vannak napjainkban is, bár ezek jelenleg elsősorban a fenntarthatóság terén mutatkoznak meg (Kumar et al. 2020).

Az elemzés során panel regressziót becsültem, hogy vizsgáljam az egy főre eső turistaérkezések és az egy főre eső GDP közötti kapcsolatot. A vizsgált periódus a 2006–2020 közötti időszak, melynek alsó korlátja Montenegró Szerbiától való leválása. A kutatás során 19 közép- és kelet-európai országot vizsgáltam.

Szakirodalmi áttekintés

Hipotézisek a turizmus és a gazdasági növekedés kapcsolatáról

Számos kutatás tanulmányozta a turizmus és a gazdasági növekedés kapcsolatát. A szakirodalom négy fő hipotézist taglal (Kyara et al. 2021; Badulescu et al. 2020). Az első a turizmus által vezérelt növekedési hipotézis (TLGH – tourism-led growth hypothesis), amely szerint a turizmus a gazdasági növekedés egyik fő hajtóereje. A második a gazdasági növekedés vezérelt turizmus hipotézis (GLTH – growth-led tourism hypothesis), amely úgy véli, hogy a gazdasági növekedés hozzájárul a turizmus fejlődéséhez. A harmadik a kétirányú oksági hipotézis (BC – bidirectional causality hypothesis), amely a kettő közötti kétirányú kapcsolatot tartja fenn. Végül a negyedik nézet a semlegesség hipotézise (NC – no causality hypothesis), amely a kapcsolat hiányát tartja fent. Az 1. melléklet szemlélteti a vizsgált tanulmányokban alkalmazott nézetek szerint az alkalmazott ökonometriai módszereket, vizsgált periódust és országot vagy tartományt. Az elméletek igazolása nem minden esetben egyértelmű, mivel sokszor különböző hipotézisek igazolódnak be különböző országcsoportok (Gao–Zhang 2021; Lee –Chang 2008) vagy periódusok vizsgálatakor (Dogan–Zhang

2023; Croes et al. 2021). A turizmus és a gazdasági fejlődés közötti dinamikus kapcsolat vizsgálata során a kutatók különböző megközelítéseket alkalmaztak az adatok típusa és a módszertan tekintetében. Egyes kutatások idősoros adatokat felhasználva elemezték a kapcsolatot (Wang et al. 2022; Kyara et al. 2021) egy-egy országban, míg mások összehasonlító vizsgálatokat végeztek (El Menyari 2021; Ohlan 2017), melynek érdekében több országra vagy országon belüli régiókra lebontott paneladatokat vizsgáltak (Tu–Zhang 2020; Tang és Abosedra 2014). A kutatás az elemzett tanulmányok alapján a turizmus által vezérelt gazdasági növekedés hipotézisét vizsgálja 19 közép- és kelet-európai ország esetén.

Változók közötti összefüggések

Az egy főre jutó GDP-t számos tanulmányban alkalmazták a gazdasági növekedés indikátoraként (Tu–Zhang 2020; Ohlan 2017). A GDP és az egy főre jutó GDP általában a gazdasági növekedés mutatójaként szolgálnak, azonban fontos megjegyezni, hogy a GDP szorosan kapcsolódik a népesség méretéhez egy adott országban, és emiatt nem tükrözi pontosan és objektíven a gazdasági fejlettség szintjét. Mivel az egy főre jutó GDP figyelembe veszi a népesség méretét, és ezzel kiküszöböli annak gazdasági növekedésre gyakorolt hatását, így bizonyos mértékig korrigálja a GDP korlátait a gazdasági fejlődés mérésében. Ezért a jelen tanulmány az egy főre jutó GDP-t használja a gazdasági növekedés jellemzésére.

A turizmus mérőszámaként a nemzetközi turistaérkezések a legnépszerűbb indikátor a szakirodalomban (Liu–Song 2018; Usmani et al. 2021; Dogan–Zhang 2023; Narayan et al. 2013). Az egy főre jutó nemzetközi turistaérkezések viszont összehasonlíthatóbbá teszi az eredményeket különböző lakosságú országok között, különösen, ha az egy főre jutó GDP-re gyakorolt hatását vizsgáljuk (Brida et al. 2020).

A kereskedelem egy gyakori kontrollváltozó a gazdasági növekedés és a turizmus kapcsolatának vizsgálatakor. A kereskedelmet több különböző néven is emlegetik, mint például gazdasági nyitottság (Seetanah 2011), nemzetközi kereskedelem (Wang et al. 2022) vagy kereskedelmi nyitottság (Dogan–Zhang 2023), azonban mindhárom esetben az export és import összegét alkalmazzák GDP-arányosan. A változó releváns, mivel több tanulmány bizonyította a kereskedelem hatását a gazdasági növekedésre (Singh 2010).

Az Egyesült Nemzetek Szervezete által publikált emberi fejlettségi indexet (Human Development Index – HDI) a frissebb tanulmányokban előszeretettel használják független változónak a turizmus által vezérelt növekedés vizsgálatokor (Croes et al. 2021). Ennek oka, hogy a HDI több dimenzióban méri egy ország lakosságának jólétét, így átfogó képet nyújt a turizmus gazdasági növekedésre gyakorolt hatásairól.

A munkaerő is lényeges független változó a turizmus és a gazdasági fejlődés összefüggésének vizsgálatokor. A változót különböző módokon implementálják az elemzésekbe, mint például humántőke (Seetanah 2011; Holzner 2011), a 15 és 65 év közötti lakosság aránya az össznépeséghez viszonyítva (Tiwari 2011) vagy a munkaerőpiaci részvétel aránya (Dogan–Zhang 2023). Ezt azért teszik, mert a munkaerő jelenti a gazdasági tevékenység alapját, és a turizmus sok munkahelyet teremt, befolyásolva ezzel a gazdasági fejlődést.

Az urbanizáció mértéke is a kiemelt kontrollváltozók közé tartozik. Az országok turistavonzó erejét remekül méri az urbanizációs ráta (Tu–Zhang 2020). A megnövekedett urbanizációs arány gyakran jobb infrastruktúrát jelent (Betten-court et al. 2007), amely fokozhatja a turisztikai befogadókapacitást, és ezáltal indukálja a turisztikai fejlődést.

Adatok és módszertan

Adatok

A kutatás során a vásárlóerő-paritáson mért egy főre jutó GDP a függő változó, míg a turizmus mérőszáma az egy főre jutó nemzetközi turistaérkezések száma. A magyarázó változók közé bevontam az import és export összegét GDP-arányosan kifejezve, az emberi fejlettségi indexet, a munkaerőpiaci részvételi arányt és a városi lakosság arányát, mivel a szakirodalom ezeket a kontrollváltozókat gyakran alkalmazta. Az emberi fejlettségi index kivételével az összes adatot a Világbank WDI (World Development Indicators – világ fejlettségi mutatói) adatbázisából töltöttem le, míg az emberi fejlettségi index (Human Development Index, HDI) az ENSZ (Egyesült Nemzetek Szervezete) Emberi Fejlődési Programjának adatbázisából származik. A következő táblázat összegzi az elemzésben használt változókat.

1. táblázat: Az adatkészlet leírása

Változó	Szimbólum	Mérési skála	Forrás
GDP/fő	<i>GDPPC</i>	Egy főre jutó GDP vásárlóerőparitáson, amerikai dollár folyó árfolyamon	World Development Indicators
Turistaérkezések/fő	<i>ITAPC</i>	Érkezések száma/évközi tényleges népesség	World Development Indicators
Kereskedelem	<i>TP</i>	Export és import összege a GDP arányában	World Development Indicators
Emberi fejlettségi index	<i>HDI</i>	Átlagos iskolai végzettség, várható iskolai végzettség, születéskor várható élettartam és egy főre jutó GNI	Human Development Reports
Munkaerő	<i>LF</i>	Munkaerő-részesedési ráta, összesen a 15 év feletti teljes népesség arányában	World Development Indicators
Urbanizáció	<i>UP</i>	Városi lakosság aránya	World Development Indicators

Forrás: Saját szerkesztés

A tanulmányban éves adatokat használtam fel a 2006 és 2020 közötti időszakra vonatkozóan 19 közép- és kelet-európai országot vizsgálva. A 19 országban van egy lényeges dolog, mely egységesen megkülönbözteti őket a nyugatabbra fekvő országoktól, mégpedig a közös történelem, azaz a késői kapitalizmus. Az elemzett országok: Albánia, Belarusz, Bosznia-Hercegovina, Bulgária, Csehország, Észak-Macedónia, Észtország, Horvátország, Lengyelország, Lettország, Litvánia, Magyarország, Moldova, Montenegró, Románia, Szerbia, Szlovákia, Szlovénia és Ukrajna.

Módszertan

Először a változók közötti lineáris kapcsolatot a Pearson-féle korrelációs együttható segítségével vizsgáltam. A változók stacionaritásának vizsgálata fontos a statisztikai elemzések során, mivel a paneladatokban lévő változók gyakran nem mutatnak állandó szórást vagy állandó átlagot az időbeli változások miatt. A nem stacionárius változók esetén a statisztikai következtetések nem megbízhatóak. A „madwu” inverz chi-négyzet egységgyök tesztet vizsgáltam a stacionaritást (Maddala–Wu 1999), melyet P-tesztnek is neveznek (Choi 2001). Ezután a statisztikát a késleltetett változóhoz kapcsolódó t-statisztikák felhasználásával számítják ki.

A stacionaritás vizsgálata után kerül sor a panel regressziók becslésére. A fix hatású, a véletlen hatású és az egyesített legkisebb négyzetek módszerét alkalmaztam (Seetaram–Petit 2012). A fix hatású modellben a csoportok közötti változásokra koncentrálunk. A modell tartalmazza a csoportok közötti állandó hatásokat (például országok), így minden csoportnak saját állandója van, amely befolyásolja a függő változót. A fix hatású modellek lehetővé teszik, hogy megvizsgáljuk azokat a változásokat, amelyek csak az egyedi csoportokon belül történnek, miközben kiszűrjük a csoportok közötti különbségeket (Brüderl–Ludwig 2015). Véletlen hatású modellben a csoportok közötti változásokra összpontosítunk, anélkül, hogy egyedi hatásokat feltételeznénk. Ehelyett a modell tartalmazza a csoportok közötti véletlen hibákat, amelyeket normális eloszlásúaknak feltételezünk. A véletlen hatású modellek azt vizsgálják, hogy a csoportok közötti változások milyen mértékben befolyásolják a függő változót (Bell–Jones 2015). Az egyesített legkisebb négyzetek (OLS) módszere a legkisebb négyzetes eltérések elvét alkalmazza a becslések meghatározásához. Ez a módszer nem veszi figyelembe a paneladatok speciális jellegét, mint például a csoportok közötti korrelációt vagy a csoporton belüli idősorokat, mivel az idősorokra vonatkozó információt integrálja a becslésekbe azáltal, hogy a függő változót és a magyarázó változókat idősorokként kezeli (Pedroni 2001).

A modellek közötti választásra az F-tesztet, a Breusch–Pagan Lagrange Multiplier tesztet és a Hausmann-tesztet használtam. Az F-teszt nullhipotézise az, hogy az egyesített legkisebb négyzetek modell a jobb választás a fix hatású modellhez képest. A Breusch–Pagan Lagrange Multiplier teszt nullhipotézise, hogy az egyesített legkisebb négyzetek módszere jobb a véletlen hatású modellnél, vagyis a véletlen hatás varianciája nulla. A Hausmann-teszt segítségével ellenőrizzük, hogy van-e korreláció az egyedi specifikus hatások és a független változók között, mely alapján eldönthetjük, hogy véletlen hatású modell-e a megfelelő választás. A Hausmann-teszt nullhipotézise, hogy a véletlen hatású modellt érdemes választani a fix hatásúval szemben.

A legjobb modell kiválasztása után a modell tesztelése következik. A Pesaran CD-teszttel megvizsgálható, hogy van-e keresztmetszeti függőség.² A Breusch–Godfrey-teszttel ellenőrizhető, hogy a hibatagok autokorreláltak-e. A Breusch–Pagan-teszt segítségével meghatározzuk, hogy a modell homoszkedasztikus-e.

² Olyan jelenség, amikor két vagy több változó között kapcsolat van, de ez a kapcsolat más változók befolyásától függetlenül áll fenn.

Az autokorreláció és a heteroszkedaszticitás korrigálása a vcov becslésével történik. Ez a módszer a heteroszkedaszticitás-robosztus standard hibákat számolja ki, ami az autokorreláció és a heteroszkedaszticitás problémáit korrigálja a modellben. A módszerrel kiszámolt új standardhibák és becslések pontosabb és megbízhatóbb eredményeket nyújtanak az elemzés során (Atkinson et al. 2016).

Előzetes elemzés

A kutatás során 285 adatot (19 ország 15 évre vonatkozó megfigyelését) elemeztem minden változóra. A 2. táblázat tartalmazza a változók leíró statisztikai jellemzőit. Az átlagos egy főre jutó GDP- (GDPPC-) érték 20 325,82 dollár volt, míg az egy főre jutó nemzetközi turistaérkezések száma (ITAPC) 2,07 személy. A kereskedelem (TP) változó átlagos értéke 114,91% a GDP-hez képest. Az emberi fejlettségi index (HDI) átlagos értéke 0,82, ami azt jelzi, hogy a vizsgált országok emberi fejlettségi szintjének átlaga magas. A munkaerő-részvételi arány (LF) és az urbanizációs ráta (UP) átlagos értékei 55,26% és 61,34%, amelyek közepesen alacsony, illetve közepesen magas szintet jelentenek a vizsgált országokban. Az adatok szórása jelzi a változók eloszlásának változatosságát az elemzett adathalmazban, és segít megérteni az adatpontok közötti széles körű különbségeket. Az adatok szórása jelzi a változók eloszlásának változatosságát az elemzett adathalmazban. A ferdeség a szimmetria mértéke. Pozitív ferdeség esetén az adatok jobbra húzóttak (a medián nagyobb az átlagnál), míg negatív ferdeség esetén balra húzóttak (a medián kisebb az átlagnál).

2. táblázat: A változók leíró statisztikai jellemzői

	Átlag	Medián	Szórás	Min	Max	Ferdeség	N
GDPPC	20 325,820	19 248,542	8768,472	5270,871	44 212,750	0,470	285
ITAPC	2,070	1,323	2,731	0,0121	14,761	2,781	285
TP	114,910	110,651	30,471	58,470	189,802	0,362	285
HDI	0,820	0,820	0,051	0,691	0,920	-0,230	285
LF	55,260	55,821	5,152	40,320	63,771	-0,753	285
UP	61,341	60,781	9,403	42,492	79,482	-0,201	285

Forrás: Saját számítások a HDI (2023) és WDI (2023) alapján

Az elemzett országok közül a vásárlóerő-paritáson mért egy főre jutó GDP Csehországban a legmagasabb (32 827,125 USD), az egy főre jutó turistaérkezések Horvátországban (11,96), a GDP-arányos kereskedelem Szlovákiában

(172,02%), az emberi fejlettségi index Szlovéniában (0,90), a munkaerő-részvételi arány Belaruszban (62,79%), míg az urbanizációs ráta szintén Belaruszban a legmagasabb (76,17%). A legmagasabb értékek mellett szükséges kiemelni a legalacsonyabbakat is. A vásárlóerő-paritáson mért egy főre jutó GDP Moldovában a legalacsonyabb (8653,95 USD), az egy főre jutó turistaérkezések szintén Moldovában (0,03), a GDP-arányos kereskedelem Albániában (75,55%), az emberi fejlettségi index Moldovában (0,74), a munkaerő-részvételi arány Moldovában (43,10%), míg az urbanizációs ráta szintén Moldovában a legalacsonyabb (42,62%). A 2. melléklet tartalmazza az összes elemzett ország átlagolt értékeit változókra lebontva a 2006–2020-as periódusra.

Eredmények

A téves regressziós eredmények elkerülése érdekében az empirikus elemzés első részében az egységgyöktesztet alkalmazom az adatok stacionaritásának vizsgálata érdekében. Az eredményeket a 3. táblázat tartalmazza. Az eredmények egyértelműen rávilágítanak arra, hogy minden idősor stacionárius, mivel a p-érték 0,05 alatt van, tehát az egységgyök nullhipotézise elutasításra került.

3. táblázat: Egységgyöktesztek eredményei

Változó	p-érték	Eredmény
1 GDPPC	< 0,001	stacionárius
2 ITAPC	< 0,001	stacionárius
3 TP	< 0,001	stacionárius
4 HDI	< 0,001	stacionárius
5 LF	< 0,001	stacionárius
6 UP	< 0,001	stacionárius

Forrás: Saját számítás

A 4. táblázatban az értékek melletti csillagok (*) azt jelzik, hogy a korrelációs együtthatók szignifikánsak a p-értékük alapján. Minél magasabb az abszolút érték, annál erősebb a kapcsolat az adott két változó között. Az értékek a -1 és 1 között lehetnek, ahol az 1 a teljes pozitív korrelációt, a -1 a teljes negatív korrelációt, a 0 pedig az összefüggés hiányát jelzi. Esetemben a függő változó mind az 5 független változóval erős pozitív korrelációt mutat. Különösen a HDI és a GDPPC közötti korreláció erős, ugyanis 0,916 az együttható, amely azt jelenti, hogy az emberi fejlettségi index és az egy főre jutó GDP között erős pozitív kapcsolat van.

4. táblázat: Korrelációs mátrix

	<i>GDPPC</i>	<i>ITAPC</i>	<i>TP</i>	<i>HDI</i>	<i>LF</i>	<i>UP</i>
<i>GDPPC</i>	1,000					
<i>ITAPC</i>	0,372***	1,000				
<i>TP</i>	0,581***	0,105	1,000			
<i>HDI</i>	0,916***	0,407***	0,536***	1,000		
<i>LF</i>	0,560***	0,065	0,446***	0,626***	1,000	
<i>UP</i>	0,317***	0,118*	0,378***	0,390***	0,640***	1,000

Megjegyzés: . $p < 0,1$, * $p < 0,05$, ** $p < 0,01$, *** $p < 0,001$

Forrás: Saját számítás

Az elemzés során három modellt becsültem: a fix hatású modellt (fixed effects – FE), a véletlen hatású modellt (random effects – RE) és az egyesített legkisebb négyzetek (Pooled OLS) módszerét. A modellek közötti választás meghozatalához az F-tesztet, a Breusch–Pagan Lagrange Multiplier tesztet és a Hausmann-tesztet alkalmaztam. Az F-teszt eredményei alapján elutasítjuk a nullhipotézist, amely szerint az egyesített OLS-modell alkalmasabb a paneladatok elemzésére, és elfogadjuk az alternatív hipotézist, miszerint a fix hatású (FE) modell hatékonyabb. Az F-statisztika értéke 9,860, ami szignifikánsan magasabb a szabadsági fokokkal korrigált küszöbértéknél. A p-érték, ami kisebb, mint 0,001, tovább erősíti a szignifikáns különbséget a két modell között. Tehát a paneladatok elemzéséhez a fix hatású modell használata javasolt az egyesített OLS-modell helyett. A Breusch–Pagan Lagrange Multiplier teszt eredményei alapján arra a következtetésre jutottam, hogy az alternatív hipotézist (H1) fogadom el. Ez azt jelenti, hogy a RE (véletlen hatású) modell kiválasztása indokolt a paneladatok elemzése során. A teszt statisztikai értéke 88,27, ami szignifikánsan magasabb, mint az elfogadási küszöbérték. A p-érték, ami kisebb, mint 0,001, szintén azt szemlélteti, hogy a modell szignifikáns hatásokat mutat. Ezért a paneladatok elemzésére a véletlen hatású modell alkalmazása javasolt az egyesített OLS-modell helyett. A Hausman-teszt eredményei alapján elutasítom a nullhipotézist, amely szerint a véletlen hatású modell jobban illeszkedik a paneladatokra, és elfogadjuk az alternatív hipotézist, miszerint a fix hatású modell alkalmasabb. A teszt nagyon alacsony p-értéke (kisebb, mint 0,001) azt mutatja, hogy a különbség a két modell között statisztikailag szignifikáns. Tehát a paneladatok elemzéséhez a fix hatású modell használata javasolt a véletlen hatású modell helyett.

A megfelelő modell, azaz a fix hatású modell kiválasztása után ellenőriztem a keresztmetszeti függőség, az autokorreláció és a heteroszkedaszticitás je-

lenlétét a Pesaran CD-, a Breusch–Godfrey, illetve a Bresch–Pagan-tesztekkel. A Pesaran CD-teszt eredményei alapján elutasítjuk a nullhipotézist, miszerint nincs keresztmetszeti függőség a panelek között, és elfogadjuk az alternatív hipotézist, miszerint van keresztmetszeti függőség. A teszt khi-négyzet értéke 1044,1, ami jelentős a szabadsági fokokhoz képest. A p-érték, ami kisebb, mint 0,001, tovább erősíti a szignifikáns keresztmetszeti függőséget. A Breusch–Godfrey-/Wooldridge-teszt eredményei alapján elutasítjuk a nullhipotézist, miszerint nincs autokorreláció a panelmodellekben az egyedi hibákban, és elfogadjuk az alternatív hipotézist, miszerint van autokorreláció. A teszt khi-négyzet-értéke 163,18, ami jelentős a szabadsági fokokhoz képest. A p-érték, ami kisebb, mint 0,001, tovább erősíti az autokorreláció jelenlétét az egyedi hibákban a panelmodellekben. A Bresch–Pagan-teszt eredményei alapján elutasítjuk a nullhipotézist, miszerint homoszkedasztikus a modell, és elfogadjuk az alternatív hipotézist, miszerint van heteroszkedaszticitás. A teszt statisztikai értéke (BP) 77,486, a szabadsági fokok száma (df) 23, és a p-érték kisebb, mint 0,001. Ez azt jelenti, hogy a heteroszkedaszticitás jelen van a modellben, és a modell nem illeszkedik megfelelően az adatokra a heteroszkedaszticitás miatt.

A keresztmetszeti függőség, az autokorreláció és a heteroszkedaszticitás korrigálása érdekében a vcov becslés Arellano transzformációját (Arellano 1987) használtam. A korrekció utáni eredmények már nem tartalmazzák az eredmények szignifikanciáját cáfoló tényezőt, így a fix hatású panelregresszió eredményei az 5. táblázatban figyelhetőek meg.

Az elemzés során különböző változók hatását vizsgáltam a GDP/fő alakulására. A fix hatású panelregresszió eredményei alapján számos érdekes összefüggést fedeztem fel. Először is, az ITAPC (turistaérkezések/fő) változó pozitív és szignifikáns hatást mutat az egy főre eső GDP-re. Ez azt jelenti, hogy minél több turista érkezik egy országba, annál magasabb lesz az egy főre jutó GDP. Ez az adott ország turizmusának fontosságát és jövedelemtermelő képességét tükrözi. A kereskedelem (TP) szintén pozitív hatással van az egy főre eső GDP-re, bár ez a hatás kevésbé szignifikáns, azt sugallja, hogy a kereskedelmi tevékenység, az export és import összege a GDP arányában, pozitív hatással van a gazdasági teljesítményre, akárcsak Dogan és Zhang (2023). Az emberi fejlettségi index (HDI) viszont nem mutat szignifikáns hatást az egy főre eső GDP-re, hasonlóan Croes et al. (2021) eredményeihez, akik bebizonyították, hogy az emberi fejlettségi index nemlineáris Lengyelország gazdasági növekedésére. Ez meglepő lehet, mivel általában azt gondolnánk, hogy a jobb oktatás, egészségügy és jövedelem ma-

gasabb GDP-t eredményez. A munkaerő-részesedési ráta (LF) és a városi lakosság aránya (UP) viszont szignifikáns hatással vannak a GDP/fő-re. A magasabb munkaerő-részesedési ráta pozitívan (Tiwari 2011), míg a városi lakosság aránya negatívan befolyásolja a gazdasági teljesítményt (Zheng és Walsh 2019). Ez arra utal, hogy a munkaerő aktív részvételének növelése és a városiasodás csökkentése fontos lehet a gazdasági növekedés szempontjából.

5. táblázat: A fix hatású panelregresszió eredménye

Változók	Regressziós együtthatók	Együtthatók hibája	t-érték	Szignifikanciaszint (%)
ITAPC	435,461	219,794	1,981	0,048 *
TP	21,380	12,697	1,684	0,093 .
HDI	11660,580	20168,869	0,578	0,564
LF	479,981	105,950	4,530	< 0,001 ***
UP	-732,082	102,417	-7,148	< 0,001 ***

Megjegyzés: . p<0,1, * p<0,05, ** p<0,01, *** p<0,001

Forrás: Saját számítás

A kutatás során az alábbi regressziós egyenletet kaptam eredményként, melyben az egy főre jutó GDP-változó becslésére használom a többi változó adatait.

$$GDPPC_{it} = 435,461 \cdot ITAPC_{it} + 21,380 \cdot TP_{it} + 479,981 \cdot LF_{it} - 732,082 \cdot UP_{it} + \varepsilon_{it}$$

Minél több turista érkezik egy országba, annál magasabb lesz az egy főre jutó GDP az országban. Az együttható értéke, 435,461, azt jelzi, hogy minden egy főre jutó turistaérkezés növeli a GDP/fő értékét 435,46 amerikai dollárral.

A kereskedelem arányának növekedése szintén hozzájárul a GDP/fő emelkedéséhez. Az együttható értéke, 21,380, azt mutatja, hogy minden 1%-os növekedés a kereskedelem arányában 21,380 amerikai dollárnyi növekedést eredményez az egy főre jutó GDP-re.

A munkaerő-részesedési ráta növekedése is pozitív hatással van az egy főre jutó GDP-re. Az együttható értéke, 479,981, azt jelzi, hogy minden 1%-os növekedés a munkaerő-részesedési rátában 479,981 egységnyi növekedést eredményez a GDP/fő-ben.

A városi lakosság arányának növekedése csökkenti a GDP/fő értékét. Az együttható értéke, -732,082, azt mutatja, hogy minden 1%-os növekedés a városi lakosság arányában 732,082 egységnyi csökkenést okoz a GDP/fő-ben.

Ez a regressziós modell lehetővé teszi, hogy megértjük ezen változók hatását az egy főre jutó GDP-változóra, és hogy megbecsüljük a függő változó értékét, ha ismerjük a többi változó értékeit. Összességében tehát a turizmus, a kereskedelem, a munkaerő-részesedési ráta és a városi lakosság aránya mind fontos tényezők lehetnek az egy főre jutó GDP növelésében, míg az emberi fejlettségi index hatása nem szignifikáns. Fontos azonban megjegyezni, hogy más tényezők is befolyásolhatják a gazdasági teljesítményt.

Következtetések

Több szerző vizsgálja a turizmus és a gazdasági növekedés közötti kapcsolatot, kifejezetten a turizmus által vezérelt gazdasági növekedés hipotézist (TLGH). Jelen kutatás 19 közép- és kelet-európai ország adatai alapján támasztja alá a turizmus által vezérelt gazdasági növekedés hipotézisét.

A kutatás eredményei alapján a turizmus fejlesztése prioritást kell élvezzen a kormányok és szakpolitikuskok részéről. A turizmus jelentős potenciállal rendelkezik a gazdasági növekedés előmozdításában és a munkahelyteremtésben. Ennek megfelelően a kormányoknak előnyös támogatniuk a turizmusfejlesztést célzó programokat. Emellett a kormányoknak érdemes olyan intézkedéseket hozniuk, amelyek segítik a turizmusbarát környezet kialakítását. Ez magában foglalhatja az adókedvezményeket, a bürokratikus akadályok csökkentését és a turizmus infrastruktúrájának fejlesztését célzó beruházásokat.

A turisztikai szektorban tevékenykedő vállalatok előnyre tehetnek szert a kutatás eredményeinek ismeretében. A turisták számának növekedése szorosan összefügg az egy főre jutó GDP növekedésével. Ez azt jelenti, hogy a turisztikai szolgáltatások fejlesztése és bővítése potenciálisan jelentős növekedést hozhat a vállalkozások számára. Így a szállodák, éttermek, idegenforgalmi látványosságok és egyéb turisztikai szolgáltatások számára kínálkozik lehetőség a termékeik és szolgáltatásaik fejlesztésére, valamint az utazási élmények javítására. A turisztikai vállalkozásoknak érdemes együttműködniük a kormányzattal és más szereplőkkel annak érdekében, hogy javítsák a turisztikai infrastruktúrát és létrehozzanak egy vonzó környezetet. Ez magában foglalhatja az új szállodák, éttermek, látványosságok és kulturális események létrehozását.

A turizmus potenciáljának kiaknázása elősegíti a gazdasági növekedést a közép- és kelet-európai régióban, miközben elősegíti a kulturális és gazdasági

kapcsolatok erősítését a világ más területeivel. Ezért a vállalkozások és a kormányzatok közötti együttműködés kulcsfontosságú a turizmusipar fejlesztésében és fenntartható növekedésében.

A tanulmány összhangban van a szakirodalomban olvasottakkal, ami arra késztet, hogy a jövőben is folytassam a témával kapcsolatos kutatást az említett országcsoportokra (balti államok, visegrádi országok, Balkán-félsziget országai és kelet-európai országok), külön-külön készítsem el az empirikus elemzésem, illetve vizsgáljam a szűkebb régiók közötti különbséget a turizmus és gazdasági növekedés kapcsolatát illetően. A tanulmány legfontosabb korlátja a felhasznált időperiódus relatív rövidege.

Szakirodalom

Arellano, M. 1987. Computing robust standard errors for within-groups estimators. *Oxford Bulletin of Economics & Statistics* 49(4), 431–434. <https://doi.org/10.1111/j.1468-0084.1987.mp49004006.x>

Atkinson, A. C.–Riani, M.–Torti, F. 2016. Robust methods for heteroskedastic regression. *Computational Statistics & Data Analysis* 104, 209–222. <https://doi.org/10.1016/j.csda.2016.07.002>

Badulescu, A.–Badulescu, D.–Simut, R.–Dzitac, S. 2020. Tourism–economic growth nexus. The case of Romania. *Technological and Economic Development of Economy* 26(4), 867–884. <https://doi.org/10.3846/tede.2020.12532>

Balázs, P.–Bozóki, A.–Catrina, Ş.–Gotseva, A.–Horvath, J.–Limani, D.–Perla-ky-Tóth, K. 2014. 25 years after the fall of Iron Curtain: The state of integration of East and West in the European Union. *EU Publication*, <https://data.europa.eu/doi/10.2777/75613>

Bell, A.–Jones, K. 2015. Explaining fixed effects: Random effects modeling of time-series cross-sectional and panel data. *Political Science Research and Methods* 3(1), 133–153.

Bettencourt, L. M.–Lobo, J.–Helbing, D.–Kühnert, C.–West, G. B. 2007. Growth, innovation, scaling, and the pace of life in cities. *Proceedings of the national academy of sciences* 104(17), 7301–7306. <https://doi.org/10.1073/pnas.0610172104>

Brida, J. G.–Gómez, D. M.–Segarra, V. 2020. On the empirical relationship between tourism and economic growth. *Tourism Management* 81, 104131. <https://doi.org/10.1016/j.tourman.2020.104131>

Choi, I. 2001. Unit root tests for panel data. *Journal of international money and Finance* 20(2), 249–272. [https://doi.org/10.1016/S0261-5606\(00\)00048-6](https://doi.org/10.1016/S0261-5606(00)00048-6)

Croes, R.–Ridderstaat, J.–Bağ, M.–Zientara, P. 2021. Tourism specialization, economic growth, human development and transition economies: The case of Poland. *Tourism Management* 82, 104181. <https://doi.org/10.1016/j.tourman.2020.104181>

Dogan, E.–Zhang, X. 2023. A nonparametric panel data model for examining the contribution of tourism to economic growth. *Economic Modelling* 128, 106487. <https://doi.org/10.1016/j.econmod.2023.106487>

El Menyari, Y. 2021. Effect of tourism FDI and international tourism to the economic growth in Morocco: Evidence from ARDL bound testing approach. *Journal of Policy Research in Tourism, Leisure and Events* 13(2), 222–242. <https://doi.org/10.1080/19407963.2020.1771567>

Gao, J.–Xu, W.–Zhang, L. 2021. Tourism, economic growth, and tourism-induced EKC hypothesis: Evidence from the Mediterranean region. *Empirical Economics* 60, 1507–1529. <https://doi.org/10.1007/s00181-019-01787-1>

Hall, D. R. 1992. The challenge of international tourism in Eastern Europe. *Tourism Management* 13(1), 41–44. [10.1016/0261-5177\(92\)90030-B](https://doi.org/10.1016/0261-5177(92)90030-B)

HDI 2023. <https://hdr.undp.org/data-center/human-development-index#/indicies/HDI>, letöltve: 2023. 05. 12.

Holzner, M. 2011. Tourism and economic development: The beach disease?. *Tourism Management* 32(4), 922–933. <https://doi.org/10.1016/j.tourman.2010.08.007>

Kumar, S.–Dhir, A. 2020. Associations between travel and tourism competitiveness and culture. *Journal of Destination Marketing & Management* 18, 100501. <https://doi.org/10.1016/j.jdmm.2020.100501>

Kyara, V. C.–Rahman, M. M.–Khanam, R. 2021. Tourism expansion and economic growth in Tanzania: A causality analysis. *Heliyon* 7(5), e06966. <https://doi.org/10.1016/j.heliyon.2021.e06966>

Lee, C. C.–Chang, C. P. 2008. Tourism development and economic growth: A closer look at panels. *Tourism Management* 29(1), 180–192. <https://doi.org/10.1016/j.tourman.2007.02.013>

Liu, H.–Song, H. 2018. New evidence of dynamic links between tourism and economic growth based on mixed-frequency granger causality tests. *Journal of Travel Research* 57(7), 899–907. <https://doi.org/10.1177/0047287517723531>

Maddala, G. S.–Wu, S. 1999. A comparative study of unit root tests with panel data and a new simple test. *Oxford Bulletin of Economics and statistics* 61(S1), 631–652. <https://doi.org/10.1111/1468-0084.0610s1631>

Narayan, P. K.–Sharma, S. S.–Bannigidadmath, D. 2013. Does tourism predict macroeconomic performance in Pacific Island countries?. *Economic Modelling* 33, 780–786. <https://doi.org/10.1016/j.econmod.2013.05.018>

Ohlan, R. 2017. The relationship between tourism, financial development and economic growth in India. *Future Business Journal* 3(1), 9–22. <https://doi.org/10.1016/j.fbj.2017.01.003>

Pedroni, P. 2001. Fully modified OLS for heterogeneous cointegrated panels. In: Baltagi, B.H.–Fomby, T.B.–Carter Hill, R. (eds.) *Nonstationary Panels, Panel Cointegration*,

and Dynamic Panels (Advances in Econometrics, Vol. 15), Leeds: Emerald Group Publishing Limited, 93–130. [https://doi.org/10.1016/S0731-9053\(00\)15004-2](https://doi.org/10.1016/S0731-9053(00)15004-2)

Scott, D.–Hall, C. M.–Gössling, S. 2019. Global tourism vulnerability to climate change. *Annals of Tourism Research* 77, 49–61. <https://doi.org/10.1016/j.annals.2019.05.007>

Seetanah, B. 2011. Assessing the dynamic economic impact of tourism for island economies. *Annals of Tourism Research* 38(1), 291–308. <https://doi.org/10.1016/j.annals.2010.08.009>

Seetaram, N.–Petit, S. 2012. Panel data analysis. In *Handbook of research methods in tourism*. Edward Elgar Publishing.

Singh, T. 2010. Does international trade cause economic growth? A survey. *The World Economy* 33(11), 1517–1564. <https://doi.org/10.1111/j.1467-9701.2010.01243.x>

Tang, C. F.–Abosedra, S. 2014. The impacts of tourism, energy consumption and political instability on economic growth in the MENA countries. *Energy Policy* 68, 458–464. <https://doi.org/10.1016/j.enpol.2014.01.004>

Tiwari, A. 2011. Tourism, Exports and FDI as a Means of Growth: Evidence from four Asian Countries. *Romanian Economic Journal* 14(40), 131–151.

Tu, J.–Zhang, D. 2020. Does tourism promote economic growth in Chinese ethnic minority areas? A nonlinear perspective. *Journal of Destination Marketing & Management* 18, 100473. <https://doi.org/10.1016/j.jdmm.2020.100473>

Usmani, G.–Akram, V.–Praveen, B. 2021. Tourist arrivals, international tourist expenditure, and economic growth in BRIC countries. *Journal of Public Affairs* 21(2), e2202. <https://doi.org/10.1002/pa.2202>

Wang, C. M.–Pan, S. L.–Morrison, A. M.–Wu, T. P. 2022. The dynamic linkages among outbound tourism, economic growth, and international trade: empirical evidence from China. *SN Business & Economics* 2(11), 169. <https://doi.org/10.1007/s43546-022-00314-2>

WDI 2023. <https://databank.worldbank.org/source/world-development-indicators>, Letöltve: 2023. 05. 12

World Travel & Tourism Council. 2023. WTTC Economic Impact Research 2023.

Zheng, W.–Walsh, P. P. 2019. Economic growth, urbanization and energy consumption. A provincial level analysis of China. *Energy Economics* 80, 153–162. <https://doi.org/10.1016/j.eneco.2019.01.004>

1. melléklet: A GDP és a turizmus közötti kapcsolatra vonatkozó szakirodalom áttekintése

Szerzők (év)	Időszak	Módszertan	Terület	Összefüggés
Narayan et al. (2013)	1985–2010	Prediktív regressziós modell	Csendes-óceáni szigetországok	T → G
Holzner (2011)	1970–2007	OLS	134 ország	T → G
Tiwari (2011)	1995–2008	Fix és véletlen hatású modellek	Kína, Pakisztán, Oroszország, India	T → G
Schubert et al. (2011)	1970–2008	VEC-modell	Antigua és Barbuda	T → G
Seetanah (2011)	1970–2007	GMM	19 szigetország	T → G
Chen és Chiou-Wei (2009)	1975–2007	EGARCH-M-modell	Taiwan és Dél-Korea	T → G
Po és Huag (2008)	1995–2005	Határérték Autoregresszív modell	88 ország	T → G
			23 OECD	T → G
Lee és Chang (2008)	1990–2002	Panel kointegráció	32 nem OECD ország	T ↔ G
			Észak-mediterrán országok	T ↔ G
Gao és Zhang (2021)	1995–2010	Kointegrációs polinomiális regresszió	Dél-mediterrán országok	T → G
Tang és Abosedra (2014)	2001–2009	GMM	24 MENA ország	T → G
Katircioglu (2009)	1960–2006	Johansen-megközelítés	Törökország	T ≠ G
Dogan és Zhang (2023)	1995–2003	Nemparametrikus panel adatmodell	17 Schengen tagállam	T → G
Tu és Zhang (2020)	2007–2016	Küszöbérték-modell	75 kínai autonóm tartomány	T → G
Kyara et al. (2021)	1983–2018	VAR-modell	Tanzánia	T → G
Brida et al. (2020)	1995–2016	Nemparametrikus panel adatmodell	80 ország	T → G
Croes et al. (2021)	1995–2017	Holzner-modell	Lengyelország	T ≠ G
Ohlan (2017)	1960–2014	Bayer és Hanck-modell	India	T → G

T = Turizmus, G = Gazdaság

„Turizmus → Gazdaság”: a turizmus fejlesztése hatással van a gazdasági növekedésre.

„Gazdaság → Turizmus”: a gazdasági növekedés hatással van a turizmus fejlesztésére.

„Gazdaság ↔ Turizmus”: a turizmus fejlődése és a gazdasági növekedés között kölcsönhatás van.

„Turizmus ≠ Gazdaság”: nincs ok-okozati összefüggés a turizmus és a gazdasági növekedés között.

Szerzők (év)	Időszak	Módszertan	Terület	Összefüggés
Enilov és Wang (2022)	1981–2017	MF-VAR-modell	23 ország	T ↔ G
Liu és Song (2018)	1974–2016	MF-VAR-modell	Hong Kong	G → T
Usmani et al. (2021)	1995–2016	Fix hatású modell	BRIC országok	T → G
Naseem (2021)	2003–2019	FMOLS, DOLS, CCR	Szaúd-Arábia	T → G
Badulescu et al. (2020)	1995–2016	VECM	Románia	T ↔ G
El Menyari (2021)	1983–2018	ARDL	Marokkó	T → G
Zuo és Huang (2018)	1995–2013	Fix és véletlen hatású modellek	Kína 31 tartománya	T → G
Wang et al. (2022)	1995–2018	ARDL	Kína	T ↔ G

Forrás: Saját szerkesztés

2. melléklet: Összefoglaló statisztikák, 2006–2020

Ország	GDPPC	ITAPC	TP	HDI	LF	UP
Mértékegység	USD	Turista- érkezések per fő	%	-	%	%
Észtország	28 171,591	3,561	147,314	0,880	61,712	68,464
Lettország	23 505,712	2,942	114,241	0,850	60,171	67,983
Litvánia	27 136,013	1,662	137,231	0,860	58,561	67,154
Csehország	32 827,130	2,590	139,261	0,880	59,301	73,502
Magyarország	25 477,532	4,581	160,442	0,840	53,002	69,743
Lengyelország	24 902,621	1,881	90,374	0,860	56,135	60,584
Szlovákia	27 355,102	2,312	172,025	0,850	59,334	54,332
Albánia	10 770,864	1,164	75,551	0,780	56,211	55,224
Bosznia-H.	11 188,042	0,164	87,132	0,740	45,612	46,575
Bulgária	17 831,331	1,273	119,993	0,790	53,863	73,313
Észak-Macedónia	13 170,891	0,192	112,813	0,760	55,184	57,471
Horvátország	23 429,344	11,964	85,994	0,840	51,764	55,831
Montenegró	16 133,483	2,121	107,801	0,810	51,711	65,141
Románia	21 559,502	0,434	76,163	0,810	54,672	53,841
Szerbia	14 697,172	0,144	90,092	0,780	52,431	55,372
Szlovénia	32 072,162	1,291	141,983	0,900	58,300	53,370
Belarusz	16 894,200	0,732	127,451	0,800	62,790	76,171
Moldova	8653,951	0,031	101,232	0,740	43,100	42,621
Ukrajna	10 414,072	0,424	96,203	0,770	56,171	68,852
Átlag	20 325,821	2,072	114,911	0,820	55,263	61,344

Forrás: Saját számítások a HDI (2023) és WDI (2023) alapján

A kriptovaluták hozamát befolyásoló tényezők különböző piaci körülmények között

KOVÁCS EDINA¹

Az elmúlt években a pénzügyi szakemberek, a média, a szabályozó hatóságok és a befektetők egyre nagyobb érdeklődést mutattak a kriptovaluták, különösen a bitcoin iránt. Ez nem meglepő, hiszen a bitcoin értéke a 2013-as 13 dollárról 2023 végére elérte a 42 000 dolláros értéket. A kutatás a 2018. január 1. és 2023. december 31. közötti időszakban vizsgálja a bitcoin, ethereum és binance hozamának érzékenységet olyan tényezők változására, mint az arany és tőkepiaci hozamok, a volatilitásindex, az Amihud illikviditási mutató, vagy a Google trend által mért, bitcoinra vonatkozó keresések száma. A kutatás során a Bai–Perron-teszt által azonosított strukturális töréspontok figyelembevételével három különböző alperiódusra alkalmaztam a legkisebb négyzetek összegének módszerét. Az eredmények alapján a vizsgált tényezők a különböző periódusokban más-más befolyásoló erővel bírnak. Az első periódusban, amikor a kriptopiac viszonylag stabil volt, a vizsgált kriptovaluták hozamát főként az arany és a volatilitásindex befolyásolta. A második időszakban, amikor a piacot turbulencia jellemezte, a bitcoinra történő keresések száma és a tőkepiaci hozam voltak a legfontosabb tényezők, míg a harmadik periódusban, a piaci visszaesés során, a tőkepiaci hozamok váltak a legmeghatározóbbá.

Kulcsszavak: bitcoin, kriptovaluták, strukturális törések.

JEL kód: C32.

Bevezető

A bitcoin 2009-es megjelenése után az elmúlt évtizedben számos kriptovaluta jelent meg, például az ethereum (2015), a tether (2015), a binance (2017), majd az utóbbi néhány évben több ezer másik. Ugyanakkor a kriptovaluta-piacok egyre nagyobb figyelmet kaptak a pénzügyi szakemberek, a média, a szabályozó hatóságok, a befektetők és a kutatók részéről. Számos empirikus kutatás tanulmányozta azokat a tényezőket, amelyek befolyásolják a kriptovaluták hozamát. A szakirodalomban vizsgálták a tőzsdei hozamok és árfolyamok (Malladi et al. 2021; Nguyen 2022; Ahmed et al. 2023), az arany (Panagiotidis et al. 2018; Ja-reño et al. 2020; Huynh et al. 2020), a gazdasági és politikai instabilitás (Shaikh 2020), az olajárváltozás (Salisu et al. 2023), a szabályozási hírek (Auer és Claes-sens 2018) és a Google-keresések számának (Kristoufek 2013) hatását.

¹ BSc-hallgató, Babeş–Bolyai Tudományegyetem, Közgazdaság- és Gazdálkodástudományi Kar, e-mail: edina.kovacs1@stud.ubbcluj.ro.

A kriptovaluták közül a bitcoin a leginkább kutatott. A bitcoin ára az elmúlt tíz évben a 2013-as 13 dollárról 2023 végére 42 000 dollár körüli értékre nőtt (Coinmarketcap 2023). Ebben a periódusban voltak magas volatilitással rendelkező alperiódusok, például 2020-ban a Covid-19-világjárvány idején a bitcoin árfolyama 300%-kal nőtt júliustól decemberig (Bloomberg 2021). 2021 áprilisában a bitcoin árfolyama közelített a 60 000 dollárhoz, 2021 július közepére a felére csökkent, majd 2021 novemberében elérte a vizsgált periódus legmagasabb árfolyamát (67 549 dollárt). Ilyen nagy árfolyammozgás nem jellemző a hagyományos valutákra vagy a tőzsdei árfolyamokra, ami arra utal, hogy a kriptovaluták árfolyamát más, a hagyományos valutáktól eltérő tényezők befolyásolhatják. Ráadásul ezen tényezők hatása változhat a különböző periódusokban, például egy magas volatilitású periódusban a Google-keresések száma fontosabb tényező lehet, mint az aranyár változása. A korábbi tanulmányok (például Auer–Claessens 2018; Baker et al. 2016; Jareño et al. 2020) nem vették figyelembe a vizsgált tényezők hatásának különböző időszakok közötti eltéréseit. Ezért a tanulmány az egyes tényezők hatását a különböző kriptovalutákra a 2018. január 1. és 2023. december 31. közötti időszakban periódusonként vizsgálja.

A cikk további szerkezete a következő: az első fejezet a kriptovaluták hozamát befolyásoló tényezőkkel foglalkozó szakirodalmat mutatja be. A második fejezetben ismertetésre kerülnek az adatok és a módszertani megközelítés. A harmadik fejezetben bemutatásra és elemzésre kerülnek az empirikus eredmények. Az utolsó fejezet összegzi a kutatás fő következtetéseit.

Szakirodalmi áttekintés és elméleti keret

A kriptovaluták hozamát befolyásoló tényezők azonosításának első lépése a kapcsolódó szakcikkek azonosítása volt egy átfogó kép elérése érdekében. A Scopus és Google Science adatbázisokban található tudományos kutatások közül a cím és a kulcsszavak alapján választottam ki a relevánsakat. Azokat a cikkeket tanulmányoztam alaposan, amelyek a „bitcoin hozamát befolyásoló tényezők”, a „kriptovaluta-árfolyam”, a „kriptovaluta-hozam”, a „kriptovaluták hozamát befolyásoló tényezők” és kapcsolódó kifejezések alapján megjelentek.

A szakirodalmi áttekintés első lépését követően megállapítható, hogy az eddigi kutatások vizsgálták a tőzsdei hozamok és árfolyamok (Malladi et al. 2021; Nguyen 2022; Ahmed et al. 2023), az arany (Panagiotidis et al. 2018; Jareño et al. 2020; Huynh et al. 2020), a Google-keresések számának (Kristoufek 2013; Chang et al. 2021), a piaci bizonytalanság (Chang et al. 2021), az illikviditás (Eross et

1. táblázat: A korábbi tudományos kutatások által vizsgált változók, valamint ezek hatása a kriptovaluták hozamára

Szerző	Függő változó	Vizsgált magyarázó változók	Megállapítások	Vizsgálták-e a változók hatását a különböző periódusokban?
Ahmed et al. (2023)	bitcoin és más kriptovaluták hozama	S&P500 index, Diebold and Yilmaz index, olajárfinanszírozás	Az S&P500 hozamok jelentős pozitív hatást gyakorolnak a bitcoinhozamokra rövid és hosszú távon.	Nem
Akin et al. (2023)	bitcoin hozama	ethereum- és binance-hozamok	Az ethereum- és a binance-hozamok szignifikáns pozitív hatással vannak a bitcoinhozamokra.	Nem
Auer és Claessens (2018)	bitcoin és más kriptovaluták árfolyama	szabályozási hírek	Kedvező események átlagosan 0,33% nyereséget, kedvezőtlen események 0,32% és 3,12% közötti veszteséget eredményeznek.	Nem
Chang et al. (2021)	bitcoin hozama	S&P500 index, VIX, Google-keresések száma	A bitcoinhozamok és a Google-keresési számok között ok-okozati kapcsolat van rövid és hosszú távon egyaránt.	Nem
Corbet et al. (2018)	bitcoin hozama	makrogazdasági mutatókkal kapcsolatos hírek (GDP, munkanélküliség, fogyasztói árindex)	Az Amerikai Egyesült Államokra vonatkozó munkanélküliségi hírek jelentős hatással vannak a bitcoinhozamra. GDP-vel és fogyasztói árindexszel kapcsolatos hírek nem szignifikánsak.	Nem
Das és Kannadhasan (2018)	bitcoin hozama	Dow Jones-index, aranyhozam, VIX, gazdasági és politikai instabilitási index, olaj árfolyama	Az olaj árfolyama és a gazdasági és politikai instabilitási index jelentős hatással van a bitcoin hozamára.	Nem
Eross et al. (2019)	bitcoin hozama	kereskedési volumen, Amihud illikviditási mutató	Szignifikáns negatív kapcsolat van a hozamok és a volatilitás között, azonban ez a kapcsolat nem hozam- vagy volatilitásvezérelt, hanem kétoldali kapcsolat.	Nem
Huynh et al. (2020)	bitcoin hozama	Arany- és platinaárfinanszírozások	Az arany árfolyamának emelkedése a platina árfolyamához képest növeli a bitcoin hozamát.	Nem
Jareño et al. (2020)	bitcoin hozama	S&P500 index, VIX, aranyárfinanszírozás	Pozitív nemlineáris kapcsolat az arany és a bitcoin hozama között.	Nem

Szerző	Függő változó	Vizsgált magyarázó változók	Megállapítások	Vizsgálták-e a változók hatását a különböző periódusokban?
Kristoufek (2013)	bitcoin árfolyama	Google-trend és Wikipedia-keresési lekérdezések	Erős kétirányú korreláció a bitcoin árfolyama és a keresési lekérdezések között.	Nem
Malladi et al. (2021)	bitcoin hozama	XRP-hozam, S&P500 és MSCI World Index, MSCI Emerging Markets Index hozamok	Az MSCI World napi hozam az egyetlen szignifikáns változó, amely befolyásolja a napi bitcoinhozamokat.	Nem
Masiak et al. (2018)	bitcoin és ethereum hozama	ethereum és bitcoin kapcsolata	A bitcoin hatása az ethereumra sokkal erősebb, mint az ethereum hatása a bitcoinra.	Nem
Nguyen (2022)	bitcoin hozama	S&P500 index hozama, gazdasági és politikai instabilitási index	Az S&P500 hozama jelentősen befolyásolta a bitcoin hozamát a Covid-19-világjárvány idején.	Nem
Panagiotidis et al. (2018)	bitcoin hozama	21 változó, köztük tőzsdei indexek, gazdasági és politikai instabilitási index, arany- és olaj- árfolyam	Az arany árfolyama gyakorolja a legnagyobb befolyást a bitcoin hozamára. Ezt követi az olaj árfolyama. Az EPU indexe Kínában, az Európai Unióban és az Amerikai Egyesült Államokban negatívan befolyásolja a bitcoin hozamát.	Nem
Salisu et al. (2023)	bitcoin hozama	olaj árfolyama	Az olajár változását figyelembe vevő befektetők nagyobb valószínűséggel érnek el nyereséget.	Nem
Shaikh (2020)	bitcoin hozama	gazdasági és politikai instabilitási index (EPU)	Az EPU pozitív hatással van a bitcoin hozamára.	Nem
Sifat et al. (2019)	bitcoin és ethereum hozama	ethereum és bitcoin kapcsolata	Az ethereum és a bitcoin kapcsolata összetett és változó.	Igen
Zhang és Li (2023)	bitcoin és más kriptovaluták hozama	Amihud illikviditási mutató	Negatív kapcsolatot mutattak ki a likviditás és a kriptovaluták hozamai között.	Nem

Forrás: Saját szerkesztés

al. 2019; Zhang–Li 2023), a gazdasági és politikai instabilitás (Shaikh 2020), az olajárváltozás (Salisu et al. 2023), a szabályozási hírek (Auer–Claessens 2018), illetve a GDP és munkanélküliség (Corbet et al. 2018) hatását a kriptovalutákra. Az 1. táblázat összefoglalja a legfontosabb tudományos kutatások során vizsgált tényezőket, valamint a kutatási eredményeket. Ez alapján megfigyelhető, hogy a tőzsdei hozamok, mint az S&P500 és az MSCI World Index, kiemelkedő szerepet játszanak a bitcoin árfolyamának alakulásában. Számos kutatás igazolta, hogy ezek a piaci indexek szoros összefüggésben állnak a bitcoin hozamának változásával. Az S&P500 hozamai rövid és hosszú távon is szignifikáns hatást gyakoroltak a bitcoin hozamára (Ahmed et al. 2023), különösen a Covid-19-világjárvány idején (Nguyen 2022). Malladi et al. (2021) a tőkepiaci indexek hatásának tanulmányozása során szintén arra a következtetésre jutottak, hogy az MSCI World Index napi hozama szignifikánsan befolyásolja a bitcoin hozamának alakulását.

Az arany árfolyama szintén gyakori változó a kriptovaluták hozamának elemzése során, egyes kutatók (például Smales 2019) a bitcoint az aranyhoz hasonlóan biztonságos menedékeszköznek (safe haven) tekintik. Panagiotidis et al. (2018) pozitív összefüggést mutattak ki a bitcoin hozamának növekedése és az arany árfolyamának emelkedése között. Jareño et al. (2020) szerint ez a pozitív kapcsolat főleg hosszú távon figyelhető meg. Ezek az eredmények alátámasztják azt, hogy a hagyományos értékálló eszközök, mint például az arany, jelentős hatással lehetnek a kriptovaluták piacára.

A szakirodalmi áttekintés alapján megállapítható, hogy a VIX-index és az illikviditási mutatók, mint például az Amihud illikviditási mutató, szintén fontos tényezők a bitcoin és más kriptovaluták árfolyamának elemzésekor. Bouri et al. (2019) például rámutattak arra, hogy a VIX-index és a bitcoin hozama közötti kapcsolat szignifikáns, különösen a piaci volatilitás időszakában. Ezzel párhuzamosan Liu és Tsyvinski (2018), illetve Eross et al. (2019) arra mutattak rá, hogy az illikviditási mutatók, például az Amihud illikviditási mutató, jelentős szerepet játszanak a bitcoin és más kriptovaluták hozamának alakulásában.

A Google-keresések száma egy másik gyakran vizsgált befolyásoló tényező. A Google-keresések száma és a bitcoin árfolyama között szoros korrelációs kapcsolat figyelhető meg, ami arra utal, hogy a keresési érdeklődés befolyásolja az árakat (Kristoufek 2013). Ez a kapcsolat a Google-keresési trendek és a bitcoin hozama között rövid és hosszú távon is megfigyelhető, ellentétben a VIX-volatilitásindex hatásával, amelyet csak hosszú távon mutattak ki (Chang et al. 2021).

Más tényezőket, például makrogazdasági tényezőket, mint a GDP vagy a munkanélküliségi ráta, szintén vizsgáltak a szakirodalomban, de ezek a tanulmányok kevésbé gyakoriak. Corbet et al. (2018) kimutatták, hogy a munkanélküliséggel kapcsolatos hírek szignifikáns hatást gyakorolnak a bitcoin hozamára, míg a GDP és a fogyasztói árindexszel kapcsolatos hírek nem.

A szakirodalom egy másik része a kriptovaluták egymásra gyakorolt hatását vizsgálja, rámutatva arra, hogy a különböző kriptovaluták közötti kölcsönhatások is jelentős hatással lehetnek az árfolyamokra. Például Akin et al. (2023) kimutatták, hogy az ethereum és a binance hozama szignifikáns pozitív hatást gyakorol a bitcoin hozamára. Más tanulmányok szerint az ethereum és a bitcoin közötti kapcsolat ennél összetettebb (Sifat et al. 2019; Masiak et al. 2018). Masiak et al. (2018) szerint a bitcoin erősebb hatással van az ethereumra, mint az ethereum a bitcoinra.

A szakirodalomban a leggyakrabban vizsgált, a kriptovaluták hozamát befolyásoló tényezők a tőkepiaci hozamok, a nemesfémek (főként az arany) hozamai és árfolyamai, a piaci kockázatok (például a volatilitás vagy az illikviditás), valamint a kriptovalutákkal kapcsolatos hírek és keresési gyakoriságok. Emellett az is megfigyelhető, hogy a korábbi tanulmányok nem vizsgálták e tényezők hatását a különböző periódusokban. A kutatás célja ennek a hiányosságnak a pótlása, azaz hogy a különböző időszakok részletes elemzésével hozzájáruljon a kriptovaluta-piac dinamikájának jobb megértéséhez és a hatékonyabb befektetési stratégiák kialakításához.

A szakirodalom alapján megfogalmazott hipotézisek a következők:

H1: A tőkepiaci hozamok változása és a vizsgált kriptovaluták hozamának változása között pozitív irányú szignifikáns kapcsolat van.

H2: Az arany hozamának változása és a vizsgált kriptovaluták hozamának változása között pozitív irányú szignifikáns kapcsolat van.

H3: A piaci kockázatok (a volatilitásindex és az illikviditás) változása és a vizsgált kriptovaluták hozamának változása között negatív irányú szignifikáns kapcsolat van.

H4: A bitcoinra vonatkozó keresési gyakoriság és a vizsgált kriptovaluták hozamának változása között pozitív irányú szignifikáns kapcsolat van.

H5: A különböző periódusokban a vizsgált tényezők befolyásoló ereje változik, más-más tényezők dominánsok az egyes periódusokban.

Adatok és módszertan

Adatok

A kutatásba bevont változók meghatározásakor két szempontot tartottunk szem előtt. Kiválasztottam azokat a kriptovalutákat és befolyásoló tényezőket, amelyekkel a szakirodalomban a leggyakrabban találkoztam. Ezen kívül, mivel napi adatokkal dolgoztam, csak azokat a változókat tudtam elemezni, amelyek napi gyakorisággal álltak rendelkezésre. E két szempont figyelembevételével a függő változók a bitcoin, az ethereum és a binance hozamai lettek (az adatok forrását lásd a 2. táblázatban), míg a magyarázó változók 1. a tőkepiaci hozamok, melynek mérésére a NASDAQ-részvényindexet használtam, 2. az arany hozama, 3. a piaci kockázat, melynek mérésére a VIX volatilitásindexet és az Amihud illikviditási mutatót (Ødegaard 2018) használtam, és 4. a bitcoin kulcsszóra történő Google-keresések száma.

Mivel a részvénypiacokon hétvégén nem kereskednek, de a kriptovalutákkal igen, a hétvégéket el kellett távolítani az adatkészletből. Az elemzés megbízhatóságának és pontosságának biztosítása érdekében a 2020. 03. 13-i dátumhoz társított 574. megfigyelés el lett távolítva az adatbázisból kiugró értéke miatt, így az adatkészlet 1565 megfigyelést tartalmaz a 2018. január 1. és 2023. december 31. közötti időszakból.

2. táblázat: Az elemzésbe bevont változók és forrásaik

Rövidítés	Megnevezés	Forrás
BTC	Bitcoin-záróárfolyam	finance.yahoo.com
ETH	Ethereum-záróárfolyam	finance.yahoo.com
BNB	Binance-záróárfolyam	finance.yahoo.com
NASDAQ	Tőkepiaci index	finance.yahoo.com
GOLD	Arany ára unciánként	investing.com
BTC_GT	A „bitcoin” kulcsszóra történt keresések száma	trends.google.com
VIX	Chicago Board Options Exchange (CBOE) volatilitási index	finance.yahoo.com
AMIHU	Amihud illikviditási mutató	Saját számítás

Forrás: Saját szerkesztés

A teljes időszakot három alperiódusra bontottam a bitcoin árfolyamára alkalmazott Bai–Perron-teszt által azonosított strukturális töréseknek megfelelően (lásd 1. ábra): 1. 2018. január 1. – 2020. december 28., 2. 2020. december 28. – 2022. május 6. és 3. 2022. május 6. – 2023 december 31. között.



Forrás: Saját szerkesztés

1. ábra: A bitcoin árfolyamának alakulása 2018 és 2023 között (USD)

Módszertan

Burton (2021) szerint a legkisebb négyzetek (ordinary least squares, OLS) módszere használható egy vagy több független mennyiségi változó és egy függő változó közötti kapcsolat leírására és a lineáris regressziós egyenletek együtthatóinak becslésére. A regresszió segítségével tudjuk mérni a változók közötti kapcsolatok erősségét és irányát, valamint azt, hogy milyen mértékben magyarázzák a függő változó varianciáját a független változók. p darab magyarázó változóval rendelkező regressziós modell egyenlete a következő:

$$Y = \beta_0 + \sum_{j=1}^p \beta_j X_j + \varepsilon, \quad (1)$$

ahol Y a függő változó, β_0 a modell metszéspontja, X_j a modell j . magyarázó változója, β_j a j . regressziós együttható ($j = \overline{1, p}$) és ε a hibtag.

Eredmények

Első lépésként az elemzett három időszakra külön-külön regressziót becsültem a bitcoin hozamára. A magyarázó változók a tőkepiaci index (NASDAQ), az arany hozama, a bitcoinra vonatkozó keresési számok, a volatilitásindex (VIX) és az Amihud illikviditási mutató voltak. A bitcoin után az ethereum és a binance a két legnagyobb és legkereskedettebb kriptovaluta a piacon (Coinmarketcap 2023). Annak érdekében, hogy teljesebb legyen a kép, megvizsgáltam, hogy a

bitcoin esetében tapasztalt hatások érvényesek-e az ethereum és a binance esetében is. Ezáltal lehetőség nyílt arra is, hogy összehasonlítsam ezeket a hatásokat a különböző kriptovaluták esetén.

3. táblázat: Diagnosztikai tesztek eredményei

BITCOIN						
Tesztek	Első periódus		Második periódus		Harmadik periódus	
	Teszt eredménye		Teszt eredménye		Teszt eredménye	
Reset teszt*	0,167	jól specifikált a modell	0,290	jól specifikált a modell	0,001	a függvényforma nem helyes
NCV teszt**	0,001	hetero-szkedaszticitás	0,063	a hibatagok szórása konstans	0,001	hetero-szkedaszticitás
Durbin-Watson-teszt***	0,551	nincs autokorreláció	0,271	nincs autokorreláció	0,268	nincs autokorreláció
ETHEREUM						
Reset teszt	0,797	jól specifikált a modell	0,057	jól specifikált a modell	0,001	a függvényforma nem helyes
NCV teszt	0,001	hetero-szkedaszticitás	0,001	hetero-szkedaszticitás	0,001	hetero-szkedaszticitás
Durbin-Watson-teszt	0,397	nincs autokorreláció	0,397	nincs autokorreláció	0,691	nincs autokorreláció
BINANCE						
Reset teszt	0,009	a függvényforma nem helyes	0,005	a függvényforma nem helyes	0,099	jól specifikált a modell
NCV teszt	0,006	hetero-szkedaszticitás	0,001	hetero-szkedaszticitás	0,001	hetero-szkedaszticitás
Durbin-Watson-teszt	0,030	van autokorreláció	0,527	nincs autokorreláció	0,467	nincs autokorreláció

*A RESET teszt p-értéke azt mutatja, hogy van-e elegendő bizonyíték a modell specifikálási hibáira. A magas p-érték azt jelenti, hogy a modell specifikálása valószínűleg helyes.

** Az NCV teszt p-értéke azt jelzi, hogy van-e szignifikáns eltérés a hiba varianciájának állandóságától. A magas p-érték az állandó varianciát jelzi.

***A Durbin-Watson-teszt nullhipotézise (H_0) szerint nincs autokorreláció, vagyis az elsőrendű autokorrelációs együttható nem különbözik szignifikánsan a nullától ($\rho=0$). Ezzel szemben az alternatív hipotézis (H_1) szerint van autokorreláció.

Forrás: Saját szerkesztés

A következő lépésben elvégeztem a modelldiagnosztikai tesztek a linearitásra (Reset teszt), a heteroszkedaszticitásra (NCV-teszt), az autokorrelációra (Durbin–Watson-teszt) és a multikollinearitásra vonatkozóan. A modelldiagnosztikai tesztek eredményei alapján a homoszkedaszticitásra vonatkozó feltétel nem teljesült (lásd 3. táblázat). A heteroszkedaszticitás jelenléte torzíthatja a becsléseket és a kapcsolódó statisztikákat. Kezelésére a heteroszkedaszticitással korrigált kovarianciamátrixot használtam. A heteroszkedaszticitás-konzisztens kovariancia-mátrix lehetővé teszi az OLS-becslések korrigálását a heteroszkedaszticitás hatásának figyelembevételével. Ezzel a módszerrel a torzítások minimalizálhatók, és megbízhatóbb becsléseket kaphatunk a modellek paramétereire és azok standard hibáira.

4. táblázat: A három periódusban becsült modellek eredményei

	Első periódus	Második periódus	Harmadik periódus
BTC			
GOLD	0,701***	-0,409.	0,442.
BTC GT	-0,000	-0,000.	-0,000
VIX	-0,002*	-0,001.	-0,002
NASDAQ	0,014	0,876 ***	0,720***
AMIHU	-0,001	0,001	0,001
Korrigált R ²	0,067	0,151	0,207
F-próba	F(5,773)=12,12 p<0,001	F(5,349)=13,57 p<0,001	F(5,425)=23,41 p<0,001
ETH			
GOLD	0,6229**	-0,151	0,468
BTC GT	<0,001	<0,001**	<0,001
VIX	-0,002*	0,001	-0,003.
NASDAQ	0,240	1,073***	0,901***
AMIHU	-0,001.	- 0,002	<0,001
Korrigált R ²	0,073	0,178	0,198
F-próba	F(5,773)=13,16 p<0,001	F(5,349)=16,28 p<0,001	F(5,425)=22,21 p<0,001
BNB			
GOLD	0,686***	-0,043	0,351
BTC GT	<0,001	<0,001*	<0,001
VIX	-0,003*	0,001	-0,003.
NASDAQ	0,060	1,347***	0,718**
AMIHU	-0,001*	-0,002	-0,001
Korrigált R ²	0,080	0,110	0,191
F-próba	F(5,773)=14,44 p<0,001	F(5,349)=9,78 p<0,001	F(5,425)=21,27 p<0,001

Megjegyzés: . p<0,1, * p<0,05, ** p<0,01, *** p<0,001

A modelldiagnosztikai tesztek eredményei alapján újrabecsült regressziós modellek eredményei azt mutatják (4. táblázat), hogy az első periódusban az arany hozama és a volatilitásindex, a második periódusban az arany hozama, a bitcoinra vonatkozó keresések száma, a volatilitásindex és a tőkepiaci hozamok, míg a harmadik periódusban a tőkepiaci hozamok azok, amelyek szignifikánsan befolyásolják a bitcoin hozamát. Az ethereum és a binance esetében is hasonló eredményeket kaptam.

A 4. táblázatban látható, hogy a regressziók determinációs együtthatója (korrigált R^2) viszonylag alacsony, ami arra utal, hogy fontos tényező hiányzik a modellekből. Katsiampa (2022) szerint a bitcoin a kriptovaluta-piac mozgatórugója, és befolyásolja más kriptovaluták hozamát. Ezért bevontam a bitcoin hozamát az ethereum és binance magyarázó változói közé. Az eredmények azt mutatják, hogy az ethereum esetében az első periódusban a bitcoin és a tőkepiaci hozamok lettek szignifikánsak (lásd 5. táblázat), a második periódusban a bitcoin hozama, a bitcoinra vonatkozó keresési számok és az Amihud illikviditási mutató, a harmadik periódusban pedig a bitcoin hozama volt szignifikáns. A binance esetében hasonló eredményeket kaptam, az egyedüli kivételt az első periódus képezi, amikor a bitcoin, a VIX- és az Amihud illikviditási mutatók voltak szignifikáns befolyásoló tényezők.

A kutatási eredmények összességüként megállapítható, hogy a tőkepiaci index hozama csak a második és harmadik időszakban van szignifikáns pozitív hatással a vizsgált kriptovaluták hozamára. Az első periódusban a hatás nem szignifikáns, tehát az első hipotézis ($H1$) csak részben igazolódott be. Hasonló eredményeket kaptam az arany hozamára vonatkozóan is: az első időszakban mindhárom vizsgált kriptovaluta esetében szignifikáns pozitív hatás mutatkozott, de a második és harmadik időszakban nem volt szignifikáns hatás. Ez arra utal, hogy a tőkepiaci indexek hozamaihoz hasonlóan az arany befolyásoló ereje is időben változó. Így a második hipotézist ($H2$) is csak részben sikerült igazolni. A piaci kockázatok, a VIX- és az Amihud illikviditási mutató negatív szignifikáns hatást mutat a vizsgált kriptovaluták hozamára. A hatás ebben az esetben is változik a különböző periódusokban. Tehát a harmadik hipotézis ($H3$) is csak részben nyert igazolást. A bitcoinra vonatkozó keresések száma csak a második periódusban mutatott szignifikáns hatást, így a negyedik hipotézist ($H4$) is csak részben sikerült igazolni. Megfigyelhető, hogy az ethereum és binance esetén ez a hatás jóval erősebb, mint a bitcoin esetében, azonban mivel az együttható értéke minden esetben nagyon alacsony, elmondható, hogy a hatás a második periódusban is marginális.

5. táblázat: A bitcoin hozamát tartalmazó regressziós eredmények

	Első periódus	Második periódus	Harmadik periódus
ETH			
BTC	1,015***	0,980***	1,107***
GOLD	-0,090	0,250	-0,021
BTC_GT	<0,001	0,001**	<0,001
VIX	-0,001	<0,001	-0,001
NASDAQ	0,226.	< 0,001	0,105
AMIHU	-0,001	0,214*	-0,001
Korrigált R ²	0,635	0,637	0,782
F-próba	F(6,772)=226,7 p<0,001	F(6,348)=104,4 p<0,001	F(6,424)=258,1 p<0,001
BNB			
BTC	0,855***	0,950***	0,788***
GOLD	0,086	0,346	0,003
BTC_GT	-0,000	- 0,000*	-0,000
VIX	-0,001*	0,001.	-0,001
NASDAQ	0,048	0,515.	0,152
AMIHU	-0,001*	- 0,002.	-0,001
Korrigált R ²	0,415	0,411	0,592
F-próba	F(6,772)=93,02 p<0,001	F(6,348)=42,24 p<0,001	F(6,424)=104,8 p<0,001

Megjegyzés: . p<0,1, * p<0,05, ** p<0,01, *** p<0,001

Forrás: Saját szerkesztés

Az eddigiek azt mutatják, hogy a vizsgált kriptovaluták árfolyamát a különböző periódusokban eltérő tényezők befolyásolták, és hogy az egyes tényezők hatásának erőssége periódusonként változik. Az első periódusban az arany árfolyama és a volatilitás dominált, míg a második periódusban a tőkepiaci index és a keresési számok váltak meghatározóvá. A harmadik periódusban a tőkepiaci index volt a fontos tényező. Ezek alapján megállapítható, hogy az ötödik hipotézis (H5) beigazolódott, azaz érdemes az elemzést különböző periódusokra elvégezni.

Következtetések

A kutatás eredményei alapján levonható legfontosabb következtetés, hogy a kriptovaluta-piac dinamikáját befolyásoló tényezők időben változnak, és különböző periódusokban eltérő fontossági sorrendben jelennek meg, ezért a jövőbeni kutatásokban érdemes az egyes időszakokat külön-külön is vizsgálni.

Emellett az is megfigyelhető, hogy az első periódusban, amikor a kriptovaluta-piacot viszonylagos stabilitás és nyugalom jellemezte, a bitcoin, az ethereum és a binance hozamát leginkább az arany hozama és a volatilitásindex befolyásolta. Ez összhangban van Panagiotidis et al. (2018) eredményeivel. Amikor a piac turbulenciákkal küzd, lásd második periódus, akkor a bitcoinra történő keresések száma és a tőkepiaci hozamok váltak a legfontosabb befolyásoló tényezőkké. Az eredményeket alátámasztja Lahmiri et al. (2020) tanulmánya is. Ez az időszak a piaci feszültség és bizonytalanság időszaka, amikor a befektetők figyelme főként a bitcoinhoz kapcsolódó információkra és a tőkepiaci hozamok változásaira irányul. A harmadik periódusban, amikor a piac visszaesést mutat, a tőkepiaci hozamok váltak a legdominánsabb befolyásoló tényezővé.

Megfigyelhető, hogy az ethereum és a binance hozamának változásait nagymértékben magyarázza a bitcoin hozamváltozása. Ez összhangban van Masiak et al. (2018) és Katsiampa (2022) megállapításaival.

A kutatás korlátjaként fontos kiemelni, hogy az elemzés során csak három kriptovalutát vizsgáltam, így az eredmények nem feltétlenül reprezentatívak a kriptovaluta-piacra. A kutatás másik korlátja, hogy a vizsgált időszakban (2018–2023) egyetlen buborékperiódus volt, így a következő buborékperiódus után érdemes a kutatást megismételni. A kutatásban csak az OLS (ordinary least squares) regressziós módszert használtam. Bár ez egy elterjedt és megbízható módszer, összetettebb modellek alkalmazásával részletesebb és pontosabb eredményeket kaphatunk.

Irodalomjegyzék

Ahmed, M. Y.–Sarkodie, S. A.–Leirvik, T. 2023. Mutual coupling between stock market and cryptocurrencies. *Heliyon* 9(5), e16179. <https://doi.org/10.1016/j.heliyon.2023.e16179>

Akin, I.–Khan, M. Z.–Hameed, A.–Chebbi, K.–Satiroglu, H. 2023. The ripple effects of CBDC-related news on Bitcoin returns: Insights from the DCC-GARCH model. *International Business and Finance* 66, 102060. <https://doi.org/10.1016/j.ribaf.2023.102060>

Auer, R.–Claessens, S. 2018. Regulating cryptocurrencies: assessing market reactions. *BIS Quarterly Review*. <https://ssrn.com/abstract=3288097>

Baker, S. R.–Bloom, N.–Davis, S. J. 2016. Measuring economic policy uncertainty. *The Quarterly Journal of Economics* 131(4), 1593–1636. <https://doi.org/10.1093/qje/qjw024>

Bloomberg 2021. *Bitcoin went mainstream in 2021. It's just as Volatile as ever.* <https://www.bloomberg.com/graphics/2021-bitcoin-volatility/>, letöltve: 2023. 10. 23.

Burton, A. L. 2021. OLS (Linear) regression. *The encyclopedia of research methods in criminology and Criminal Justice* 2, 509–514. <https://doi.org/10.1002/9781119111931.ch104>

Chang, C. Y.–Lo, C. C.–Cheng, J. C.–Chen, T. L.–Chi, L. Y.–Chen, C. C. 2021. Relationship between Bitcoin exchange rate and other financial indexes in time series. *Mathematical Problems in Engineering* 1, 8842877. <https://doi.org/10.1155/2021/8842877>

Coinmarketcap 2023. *Today's cryptocurrency prices by market cap*. <https://coinmarketcap.com>, letöltve: 2023. 12. 28.

Corbet, S.–Larkin, C. J.–Lucey, B. M.–Meegan, A.–Yarovaya, L. 2018. *The volatility generating effects of macroeconomic news on cryptocurrency returns*. <https://ssrn.com/abstract=3141986>

Das, D.–Kannadhasan, M. 2018. Do global factors impact bitcoin prices? Evidence from wavelet approach. *Journal of Economic Research* 23(3), 227–264.

Eross, A.–McGroarty, F.–Urquhart, A.–Wolfe, S. 2019. The intraday dynamics of bitcoin. *International Business and Finance* 49, 71–81. <https://doi.org/10.1016/j.ribaf.2019.01.008>

Huynh, T. L. D.–Burggraf, T.–Wang, M. 2020. Gold, platinum, and expected Bitcoin returns. *Journal of Multinational Financial Management* 56, 100628. <https://doi.org/10.1016/j.mulfin.2020.100628>

Jareño, F.–de la O González, M.–Tolentino, M.–Sierra, K. 2020. Bitcoin and gold price returns: A quantile regression and NARDL analysis. *Resources Policy* 67, 101666. <https://doi.org/10.1016/j.resourpol.2020.101666>

Katsiampa, P.–Yarovaya, L.–Zięba, D. 2022. High-frequency connectedness between Bitcoin and other top-traded crypto assets during the COVID-19 crisis. *Journal of International Financial Markets, Institutions and Money* 79, 101578. <https://doi.org/10.1016/j.intfin.2022.101578>

Kristoufek, L. 2013. BitCoin meets Google Trends and Wikipedia: Quantifying the relationship between phenomena of the Internet era. *Scientific Reports* 3(1), 3415. <https://doi.org/10.1038/srep03415>

Lahmiri, S.–Bekiros, S.–Bezzina, F. 2020. Multi-fluctuation nonlinear patterns of European financial markets based on adaptive filtering with application to family business, green, Islamic, common stocks, and comparison with Bitcoin, NASDAQ, and VIX. *Physica A: Statistical Mechanics and its Applications* 538, 122858. <https://doi.org/10.1016/j.physa.2019.122858>

Malladi, R. K.–Dheeriyaa, P. L. 2021. Time series analysis of cryptocurrency returns and volatilities. *Journal of Economics and Finance*, 45(1), 75–94. <https://doi.org/10.1007/s12197-020-09526-4>

Masiak, C.–Block, J. H.–Masiak, T.–Neuenkirch, M.–Pielen, K. N. 2018. *The triangle of ICOs, Bitcoin and Ethereum: A time series analysis*. <https://hdl.handle.net/10419/207030>

Nguyen, K. Q. 2022. The correlation between the stock market and Bitcoin during COVID-19 and other uncertainty periods. *Finance Research Letters* 46, 102284. <https://doi.org/10.1016/j.frl.2021.102284>

Panagiotidis, T.–Stengos, T.–Vravorinos, O. 2018. On the determinants of bitcoin returns: A LASSO approach. *Finance Research Letters* 27, 235–240. <https://doi.org/10.1016/j.frl.2018.03.016>

Salisu, A. A.–Ndako, U. B.–Vo, X. V. 2023. Oil price and the Bitcoin market. *Resources Policy* 82, 103437. <https://doi.org/10.1016/j.resourpol.2023.103437>

Shaikh, I. 2020. Policy uncertainty and Bitcoin returns. *Borsa Istanbul Review* 20(3), 257–268. <https://doi.org/10.1016/j.bir.2020.02.003>

Sifat, I. M.–Mohamad, A.–Shariff, M. S. B. M. 2019. Lead-lag relationship between bitcoin and ethereum: Evidence from hourly and daily data. *International Business and Finance* 50, 306–321. <https://doi.org/10.1016/j.ribaf.2019.06.012>

Smales, L. A. 2019. Bitcoin as a safe haven: Is it even worth considering?. *Finance Research Letters* 30, 385–393. <https://doi.org/10.1016/j.frl.2018.11.002>

Zhang, W.–Li, Y. 2023. Liquidity risk and expected cryptocurrency returns. *International Journal of Finance & Economics* 28(1), 472–492. <https://doi.org/10.1002/ijfe.2431>

Ødegaard, B. A. 2018. *Liquidity–The Amihud Illiquidity Estimator*, Academic Press.

A lakástranzakciók volumenét befolyásoló tényezők Romániában a Covid-19-világjárvány alatt

OBOROCEA MÓNKA¹

A Covid-19-világjárvány alatt Romániában az új fertőzési esetszámok növekedésével nőtt a lakások tranzakciós volumene. A tanulmány azt vizsgálja, hogy mi állhat ennek a növekedésnek a hátterében a 2020 áprilisa és 2022 októbere közötti periódusban. A panelregresszió eredményei azt mutatják, hogy a tranzakciós volumen változására a legerősebben a munkanélküliségi ráta hatott, a kapcsolat iránya negatív. Az adásvételek számát a lejben folyósított lakáshitelek kamatlába és az építkezési költségindex is befolyásolta, a kapcsolatok iránya szintén negatív. Az eredmények azt mutatják, hogy a járvány ideje alatt a tranzakciós volumen követte a gazdasági hangulatindex mozgását a két változó közötti egyenes irányú kapcsolaton keresztül, tehát a hangulatindex hatékony előrejelzője lehet a kereskedési volumennek. A lakások tranzakciós volumene és a nettó reálbér között nem sikerült szignifikáns kapcsolatot kimutatni. Ennek egyik lehetséges oka, hogy a kormányzati intézkedéseknek köszönhetően (például technikai munkanélküliség) nem csökkent szignifikánsan a vizsgált időszakban az átlagos nettó reálbér Romániában.

Kulcsszavak: Covid-19, ingatlanpiac, lakások tranzakciós volumene.

JEL kódok: R21, C23.

Bevezetés

Korábbi gazdasági válságokhoz képest szokatlan jelenség zajlott le a Covid-19-világjárvány alatt Romániában, ahol a romló gazdasági mutatók ellenére jelentősen nőtt a lakások tranzakciós volumene 2020 és 2022 között. A növekvő munkanélküliségi rátával és a csökkenő GDP-vel egy időben a lakások tranzakciós volumene 2020-ban éves szinten 8 százalékkal volt nagyobb 2019-hez képest, még úgy is, hogy 2020 második negyedévében 28 százalékos csökkenést jegyzett az Országos Kataszteri és Ingatlan-nyilvántartási Hivatal (ANCP, Agenția Națională de Cadastru și Publicitate Imobiliară) 2019 hasonló negyedévéhez képest. Ez azt jelenti, hogy lakások adásvétele 2020 negyedik negyedévében közel 40 százalékkal volt nagyobb az előző év hasonló negyedévéhez viszonyítva. A növekvő trend 2021-ben és 2022-ben is folytatódott.

¹ MSc-hallgató, Babeș-Bolyai Tudományegyetem, Közgazdaság- és Gazdálkodástudományi Kar, e-mail: monika.oborocea@stud.ubbcluj.ro.

A növekvő tranzakciók jelentős részét ráadásul a lakosság hitelből finanszírozta a Román Nemzeti Bank (RNB) adatai szerint. A lakásvásárlásra felvett, lejben folyósított lakáshitelek volumene 2020-ban 0,9 százalékkal volt nagyobb 2019-hez képest, 2021-ben pedig már 43 százalékkal volt több, mint 2020-ban. A növekvő tendencia 2022-ben sem állt meg, 13 százalékkal több lakáshitelt vettek fel a háztartások az előző évhez képest úgy, hogy 2022 végére a romániai fogyasztói árindex megközelítette a 16 százalékot éves szinten. A központi bank jelentése (RNB 2022) szerint 2022. január és szeptember közötti periódusban a háztartások a lakások adásvételi tranzakcióinak 38 százalékát finanszírozták hitelből.

Jelen tanulmány azt vizsgálja, mi áll ennek a gazdaságilag kedvezőtlen környezetben bekövetkező lakásadásvételi növekedésnek a hátterében. A kutatás egyediségét az adja, hogy ez idáig még nem született olyan kutatás, amely ökonometriai modellekkel vizsgálta volna a romániai lakások tranzakciós volumenének alakulását a Covid-19-világjárvány alatt. Jelen kutatás R statisztikai programban RStudio integrált fejlesztői környezetben végzett ökonometriai becslésen és teszteken alapszik. A kutatási téma nemcsak az ingatlanközvetítő irodák számára bírhat kiemelkedő fontossággal, hanem a lakosság számára is, a romániaiak 95 százaléka ugyanis saját lakásban él az Eurostat legfrissebb, 2022-es adatai szerint (Eurostat 2023). Ezzel élen járunk az Európai Unióban, az uniós átlag 69 százalék.

A szakirodalmi áttekintés után az adatok és azok leíró statisztikai jellemzői következnek, majd a módszertan. Az eredmények elemzése után a következtetések levonásával zárul a tanulmány.

Szakirodalmi áttekintés

A szakirodalom a lakások adásvételi volumenét a Covid-19-világjárvány alatt a következő fontosabb változók szerint vizsgálja: új fertőzési esetszámok, inflációs ráta (építkezési költségindex), hitelkamatláb, gazdasági hangulatindex, munkanélküliségi ráta és jövedelem.

Vitatott a szakirodalomban a Covid-19-világjárványnak a lakástranzakciók volumenére gyakorolt hatása. Egyrészt a növekvő Covid-esetszámok és a fertőzéstől való félelem, illetve a távolságtartásra vonatkozó szabályok visszatartották a háztartásokat a fogyasztástól (Pichler et al. 2020; Baker et al. 2020), így a lakásadásvételtől is, ugyanakkor a járvány miatti bezártság és a sűrűn lakott településeken a betegség terjedésének üteme (kiegészülve fiskális és monetáris ösztönzőkkel) felülírták a lakáskeresletre és -kínálatra vonatkozó negatív nyomást (Diamond et al. 2022; Gallent et al. 2023).

A tranzakciós volumen és az esetszámok kapcsolatának másik sajátossága, hogy az ingatlan-adásvételek kivétel nélkül csökkentek akkor, amikor a járvány megfékezése érdekében hatósági lezárásokat (lockdown) vezettek be, ám a lockdown után növekedni kezdtek (Liu–Tang 2021; Tsai et al. 2022). A növekedés több országban akkora volt, hogy éves szinten kompenzálni tudta a lezárások alatti keresletcsökkenést. Ez a jelenség zajlott le az amerikai ingatlanpiacon is (Gamber et al. 2023).

Az infláció hatása a tranzakciós volumenre szintén vitatott. Malmström és Schultz (2017) a svéd ingatlanpiacot vizsgálva bebizonyították, hogy a növekvő infláció növekvő tranzakciós volument jelent. A szerzőpáros a svéd ingatlanpiacba történt közvetlen külfölditőke-befektetéseket befolyásoló gazdasági tényezőket vizsgálta egy svéd ingatlanügynökség, a Newsec 2016-os tranzakciós adatain. Az eredményeik alapján magas inflációs környezetben az ingatlanpiacon történő közvetlentőke-befektetések fedezeti ügyletként szolgálnak a pénz fizetőértékének elértéktelenedésével szemben.

Az infláció és a tranzakciós volumen fordított irányú kapcsolata több csatornán keresztül érvényesül. Follain (1982) kimutatta, hogy a magas inflációs ráta növeli a nominális kamatlábakat, ezzel együtt a jelzáloghitelek nominális törlesztőrészetét is. Dekimpe és van Heerde (2023) szerint ez oda vezet, hogy kevesebb háztartás engedheti meg magának a hitelfelvételt, és így csökken a lakástranzakciók száma. Ez a jelenség zajlott az európai ingatlanpiacon a Covid-19-világjárvány idején, amikor 2021–22-ben a magas infláció arra kényszerítette a központi bankokat, hogy növeljék az alapkamatot (EKB 2023). Ennek hatására a jelzáloghitel-kamatlábak 2022-ben a legtöbb európai országban megduplázódtak, Finnországban, Szlovákiában, Svájcban, az Egyesült Királyságban pedig megháromszorozódtak.

Az infláció a béreken keresztül is csökkentheti az ingatlanok iránti keresletet. A magas infláció reálértéken csökkenti a háztartások rendelkezésre álló jövedelmét, a csökkenő jövedelem pedig egyenes irányú kapcsolatban áll a tranzakciós volumennel (Ortalo-Magné–Rady 2004). Valderrama et al. (2023) arra mutattak rá, hogy a változó kamatozású jelzáloghitelek esetében a háztartások reáljövedelmének csökkenése és a jelzáloghitel-kamatlábak emelkedése növeli a hitelfelvevők nemfizetési kockázatát, ez utóbbi negatívan hat a bankok tőkéjére, amelynek következtében csökken a kihelyezett hitelek volumene.

Az infláció alakulását követő építkezési költségindexről Meen (2002) amerikai és brit adatsorokon bizonyította be, hogy fordított kapcsolatban áll a lakás-

árakkal, a növekvő árak pedig csökkenő kereslethez vezetnek (Stein 1995; Andrew–Meen 2003; Akkoyun et al. 2013).

A munkanélküliségi ráta hatása a lakások tranzakciós volumenére nem egyértelmű. Gan et al. (2018) úgy találták, hogy a munkanélküliségi ráta növekedése magasabb lakásárakhoz és kevesebb adásvételi tranzakcióhoz vezetett Texas állam ingatlanpiacán. A szerzők rámutattak, hogy a munkanélküliségi ráta növekedése a keresleti és a kínálati oldalon is befolyásolja az ingatlanpiac méretét: a keresleti oldalon pénzügyi korlátként szolgál és csökkenti a vevők számát, kínálati oldalon a növekvő munkanélküliségi ráta miatt az eladók kívárnak a tranzakcióval, tudva, hogy csökken a kereslet. A munkanélküliségi ráta és a tranzakciós volumen fordított irányú kapcsolatát igazolták Clayton et al. (2008) is, a lakásárak és a munkanélküliségi ráta egyenes irányú kapcsolatát pedig a következőképpen magyarázták: a munkanélküliségi ráta növekedésének hatására az eladók maguk is pénzügyi nehézségekkel küszködnek, így megemelik az ingatlanok árát.

Slavata (2021) a fentiekkel ellentétben rámutatott, hogy a munkanélküliség növekedésével az eladásra vagy bérletre kínált lakások száma megnövekszik, mivel a szűkös munkaerő-kínálat miatt megnő az álláskeresők költözési szándéka. A szerző szerint a munkaerőpiacon bekövetkező változások valós időben hatnak a lakáspiacra.

Több tanulmány foglalkozott a gazdasági hangulatindexszel, mint a GDP alakulásának proxy változójával (Guzmán 2009). Kitarar (2021) tanulmánya oroszországi, 1998–2020 közötti adatokon mutatta ki, hogy a bruttó hazai termék (GDP) és a gazdasági hangulatindex szorosan együtt mozognak.

A gazdasági hangulatindex és az adásvételek volumene közötti egyenes irányú kapcsolat nem vitatott. Białowolski (2019) tanulmányában a gazdasági hangulatindex és a lengyel háztartások pénzügyi döntései közötti kapcsolatot vizsgálva rámutatott, hogy a háztartások hitelezési és megtakarítási magatartását a fogyasztói hangulat befolyásolja. Ha nő a fogyasztói bizalom, nő az abba vetett hit, hogy a gazdaság jól teljesít, nő a háztartások hajlandósága, hogy hitelt vegyenek fel tartós fogyasztási cikkekre, beleértve a lakásvásárlást is. Ez a következtetés megegyezik Lamdin (2008) megállapításával, miszerint a rulírozó hitelek általában a fogyasztói hangulat növekedésével együtt nőnek. Hui és Wang (2014) bebizonyították, hogy mivel az ingatlankeresletet részben a piaci szereplők hangulata vezérli, ezért a piaci hangulatindex hatékony előrejelzője lehet az árak, illetve a kereskedési volumennek.

Nagyon kevés olyan romániai adatokat feldolgozó tanulmány jelent meg, amely ökonometriai modellekkel vizsgálja a lakások adásvételi volumenét.

Enăchescu és Bănică (2019) lineáris regresszióval becsülték az ingatlan-adásvételek alakulását Romániában 2009–2018 között. A szerzők becslésében a magyarázó változók az állandó lakhellyel rendelkező lakosság száma, a jövedelem és az egy főre jutó GDP voltak. A szerzőknek bár nem sikerült lineáris kapcsolatot kimutatni a változók között, a tranzakciós volumen leíró statisztikai jellemzőin keresztül sikerült beazonosítani a növekedési és csökkenési trendeket.

Ion et al. (2021) szintén a leíró statisztikai jellemzők segítségével vizsgálták a Covid-19-világjárványnak az építőiparra és az ingatlanügyletekre gyakorolt hatását. A kutatás mennyiségi adatokkal támasztja alá az új építkezések iránti kereslet visszaesését, az ingatlanügyletek számának csökkenését a hatósági zárlatok ideje alatt.

Az adásvételeken kívül néhány tanulmány az ingatlanárakat elemezte. Moșan et al. (2020) azt vizsgálták, hogy 2014–2019 között hogyan befolyásolta a lakásárakat az ingatlanvásárlásra nyújtott lakossági hitelek száma és a lakosság jövedelmének nagysága. Az eredmények szerint mindkét változó befolyásolja a lakásárakat, ám a tanulmány arra nem ad választ, hogy milyen csatornákon keresztül érvényesül a magyarázó változók hatása. A szakirodalmi áttekintés összefoglalása a 1. táblázatban található.

1. táblázat: A szakirodalmi áttekintő összefoglaló táblázata

Szerző	Év	Vizsgált régió	Kimutatott hatások
A Covid-esetszámok hatása a lakások adásvételi számára			
Pichler et al.	2020	UK	A növekvő Covid-esetszámok, a fertőzéstől való félelem, a távolságtartásra vonatkozó szabályok visszatartották a háztartásokat a fogyasztástól, a lakásadásvételtől.
Baker et al.	2020	USA	
Diamond et al.	2022	USA	A járvány miatti bezártság és a sűrűn lakott településeken a betegség terjedésének üteme felülírták a lakáskeresletre és -kínálatra vonatkozó negatív nyomást.
Gallent et al.	2023	UK	
Liu–Tang	2021	Kína	Az ingatlan-adásvételek kivétel nélkül csökkentek akkor, amikor a járvány megfékezése érdekében hatósági lezárásokat (lockdown) vezettek be, ám a lockdown után növekedni kezdtek.
Tsai et al.	2022	Kína	
Gamber et al.	2023	USA	
Ion et al.	2021	Románia	Leíró statisztikai jellemzők segítségével vizsgálták a világjárványnak az építőiparra és az ingatlanügyletekre gyakorolt hatását. A kutatás mennyiségi adatokkal támasztja alá az új építkezések iránti kereslet visszaesését, az ingatlanügyletek számának csökkenését a hatósági lezárások ideje alatt.

Szerző	Év	Vizsgált régió	Kimutatott hatások
Az infláció és a háztartások jövedelmének hatása a lakások adásvételi számára			
Malmström–Schultz	2017	Svédo.	Magas inflációs környezetben az ingatlanpiacon történő közvetlentőke-befektetések fedezeti ügyletként szolgálnak a pénz fizetőértékének elértéktelenedésével szemben.
Follain	1982	USA	Az infláció és a tranzakciós volumen fordított irányú kapcsolata több csatornán keresztül érvényesül. A magas inflációs ráta növeli a nominális kamatlábakat. Ez oda vezet, hogy kevesebb háztartás engedheti meg magának a hitelfelvételt, és így csökken a lakások adásvételi száma.
Dekimpe–van Heerde	2023	OECD	
EKB	2023	Európa	
Meen	2002	UK – USA	Az infláció alakulását követő építkezési költségindexről bebizonyították, hogy fordított kapcsolatban áll a lakásárakkal. A növekvő árak pedig csökkenő kereslethez vezetnek.
Stein	1995	USA	
Andrew–Meen	2003	UK	
Akkoyun et al.	2013	USA	
Ortalo–Magné–Rady	2004	UK	A magas infláció reálértéken csökkenti a háztartások rendelkezésre álló jövedelmét, a csökkenő jövedelem pedig egyenes irányú kapcsolatban áll a tranzakciós volumennel.
Valderrama et al.	2023	30 európai ország, köztük Románia	A változó kamatozású jelzáloghitelek esetében a háztartások reáljövedelmének csökkenése és a jelzáloghitel-kamatlábak emelkedése növeli a hitelfelvevők nemfizetési kockázatát, ez utóbbi negatívan hat a bankok tőkéjére, aminek következtében csökken a kihelyezett hitelek volumene.
Enăchescu–Bănică	2019	Románia	Az állandó lakhellyel rendelkező lakosság számának, a jövedelemnek és egy főre jutó GDP-nek a hatását vizsgálták az ingatlan-adásvételek alakulására. A szerzőknek bár nem sikerült kapcsolatot kimutatni a változók között, a tranzakciós volumen leíró statisztikai jellemzőin keresztül sikerült beazonosítaniuk a növekedési és csökkenési trendeket.
Moroşan et al.	2020	Románia	Azt vizsgálták, hogy 2014–2019 között hogyan befolyásolta a lakásárakat az ingatlanvásárlásra nyújtott lakossági hitelek száma és a lakosság jövedelmének nagysága. Az eredmények szerint mindkét változó befolyásolja a lakásárakat, ám a tanulmány arra nem ad választ, hogy milyen csatornákon keresztül érvényesül a magyarázó változók hatása.
A munkanélküliségi ráta hatása a lakások tranzakciós volumenére			
Gan et al.	2018	USA	A munkanélküliségi ráta növekedése magasabb lakásárakhoz és kevesebb adásvételi tranzakcióhoz vezet.
Clayton et al.	2008	USA	

Szerző	Év	Vizsgált régió	Kimutatott hatások
Slavata	2021	Cseho.	A munkanélküliség növekedésével az eladásra vagy bérlésre kínált lakások száma megnövekszik, mivel a szűkös munkaerő-kínálat miatt megnő az álláskeresők költözési szándéka.
A gazdasági hangulatindex hatása a lakások adásvételének volumenére			
Kitrar	2021	Oroszo.	A bruttó hazai termék (GDP) és a gazdasági hangulatindex szorosan együtt mozognak.
Guzmán	2009	USA	Mivel az ingatlankeresletet részben a piaci szereplők hangulata vezérli, ezért a piaci hangulatindex hatékony előrejelzője lehet az árak, illetve a kereskedési volumennek.
Hui–Wang	2014	Hong Kong	Ha nő a fogyasztói bizalom, nő a háztartások hajlandósága, hogy hitelt vegyenek fel tartós fogyasztási cikkekre, beleértve a lakásvásárlást is.
Lamdin	2008	USA	A rülőző hitelek általában a fogyasztói hangulat növekedésével együtt nőnek.

USA: Amerikai Egyesült Államok; UK: Egyesült Királyság

Forrás: Saját szerkesztés

Mivel romániai adatokat felhasználva még nem született olyan tanulmány, amely ökonometriai modellekkel becsülte volna a Covid-19-járvány hatását a lakások tranzakciós volumenére, jelen tanulmány ezt a hiányt igyekszik pótolni.

A szakirodalom alapján a tanulmányban megfogalmazott hipotézisek a következők:

H1: A romániai lakások adásvételi volumenére pozitív hatással vannak a Covid-esetszámok.

H2: A romániai lakások adásvételi volumenére negatív hatással van az inflációs ráta.

H3: A romániai lakások adásvételi volumenére negatív hatással vannak a lakáshitelek kamatlábai.

H4: A romániai lakások adásvételi volumenére negatív hatással van a munkanélküliségi ráta.

H5: A romániai lakások adásvételi volumenére pozitív hatással van a háztartások jövedelme.

H6: A romániai lakások adásvételi volumenére pozitív hatással van a gazdasági hangulatindex.

Adatok és módszertan

Adatok és leíró statisztikai jellemzők

A becslt modellben a függő változó az ANCPPI által közzétett lakások havi adásvételi száma. A magyarázó változó az új fertőzési esetszám, a kontrollváltozók pedig az országos átlagos nettó reálbér, az építkezési költségindex, a változó kamatozású lejalapú lakáshitelek kamatlába, a harmonizált munkanélküliségi ráta és a gazdasági hangulatindex (a GDP proxy változója).

Vizsgált időszak a 2020 áprilisa és 2022 októbere közötti periódus. A kiválasztott időszakot az adatok hozzáférhetősége indokolja: az Országos Közegészségügyi Igazgatóság az új fertőzési esetszámokra vonatkozó megyei szintű havi folytonos adatokat 2020 áprilisa és 2022 októbere között tette közzé.


Annak érdekében, hogy a megyei bontású adatok összehasonlíthatóak legyenek, a tranzakciós volumen és a Covid-esetszámok változók transzformációjára volt szükség. Ennek megfelelően a lakások tranzakciós volumenére vonatkozó havi megyei szintű adatokat 1000 főre volt észszerű vetíteni az 1-es képlet alapján. A megyék lakosságának számát az Országos Statisztikai Hivatal 2021-es népszámlálási adatai adták.

$$T_TRANS_UNIT = \frac{\text{havi tranzakciós volumen az adott megyében}}{\text{megye lakosság száma}} * 1000 \quad (1)$$

Ugyanígy jártam el az új fertőzési esetszámok változónál, az 1-es képlethez képest a havi tranzakciós volument cseréltem fel a havi új fertőzési esetszámmal az adott megyében. Az 1. és a 2. ábrán látható adatok a vizsgált periódusra vetített megyei átlagot mutatják.

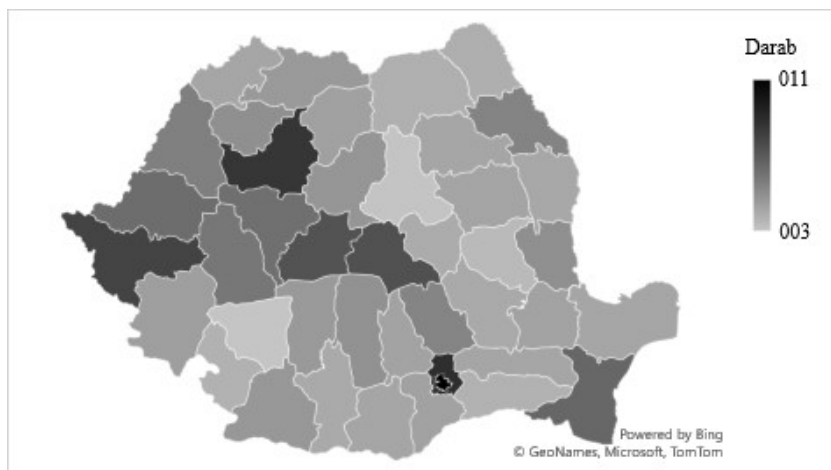
A többi változóról készült ábrák a mellékletben tekinthetők meg. A 2. táblázatban a vizsgált változók összefoglalója látható.

A változók leíró statisztikai jellemzőinek összefoglalója a 3. táblázatban vehető szemügyre, a megfigyelések száma 1302. A tranzakciós volumen és a Covid-esetszámok esetében a medián és az átlag között jelentős az eltérés, a szórás pedig nagy. Mivel e két változónál az értékek nem követnek normális eloszlást, panelregressziós modelleknél „within” becslésre van szükség (Bramati–Croux 2007). A jövedelem, a munkanélküliségi ráta, a hitelkamatlábak, az építkezési költségindex és a gazdasági hangulatindex változók a medián és az átlag értékei alapján normális eloszlást követnek.



Forrás: Saját szerkesztés

1. ábra: Ezer lakosra jutó lakásadásvételek volumene megyei bontásban átlagolt adatok alapján. Vizsgált periódus: 2020 áprilisa és 2022 októbere közötti időszak



Forrás: Saját szerkesztés

2. ábra: Ezer lakosra jutó új fertőzések száma megyei bontásban átlagolt adatok alapján. Vizsgált periódus: 2020 áprilisa és 2022 októbere közötti időszak

2. táblázat: Vizsgált változók (havi adatok)

Változó neve	Rövidítés	Magyarázat	Forrás
Ezer lakosra jutó lakásadásvétel volumene	T_TRANS_UNIT (darab)	1000 lakosra jutó adásvétel száma az adott megyében és az adott hónapban.	Országos Kataszteri és Ingatlan-nyilván tartási Hivatal
Ezer lakosra jutó új fertőzések száma	T_COVID_19 (darab)	Napi lejelentett új fertőzések száma 1000 lakosra vetítve az adott megyében havi bontásban. A járvány proxy változója.	Országos Közegészségügyi Igazgatóság
Nettó átlagjövedelem	WAGE_H (1000 RON)	Az Országos Statisztikai Hivatal által kiszámított havi átlagos nettó bér.	Országos Statisztikai Hivatal
Építkezési költségindex	CCI (%)	Deflátorindex, az építési költségek egyik időszakról a másikra történő alakulását méri. Bázisév 2015.	Országos Statisztikai Hivatal (CNS107C)
Változó kamatozású lejalapú lakáshitelek kamatlába	F2_INT_RATE (%)	Háztartásoknak nyújtott, lejben felvett lakáshitelek kamatlába. Fix kamatozás periódusa: 1-5 év.	Román Nemzeti Bank (N14RL_CNGI5A)
Harmonizált munkanélküliségi ráta	UNEMP_RATE (%)	A ráta a munkanélküli személyek számának a munkaerőhöz viszonyított arányát adja meg a Nemzetközi Munkaügyi Szervezet definíciója alapján. A munkaerő a 25–74 éves foglalkoztatott és munkanélküli személyek száma. Az adatok szezonálisan kiigazítottak.	Eurostat (EI_LMHR_M_custom_7124140)
Gazdasági hangulatindex (ESI)	SENT_ECON (%)	Bizalmi index. Vállalatok és fizikai személyek felmérése alapján számolják ki. Lefedett ágazatok: ipar (súlya 40%), szolgáltatások (30%), fogyasztók (20%), kiskereskedelem (5%), építőipar (5%). Skálázása a következő módon értelmezhető: 100 felett pozitív, alatta negatív a gazdasági várakozás. A gazdaság állapotának proxy változója.	Eurostat (EI_BSSI_M_R2_custom_7124049)

Forrás: Saját szerkesztés

3. táblázat: Leíró statisztikák

Változók	Átlag	Medián	Szórás	Minimum	Maximum
T_TRANS_UNIT	4,810	2,380	6,710	0,000	74,850
T_COVID_19	0,530	0,380	0,490	0,020	3,370
WAGE_H	3,150	3,040	0,500	2,330	5,490
UNEMP_RATE	5,830	5,700	0,430	5,100	6,900
F2_INT_RATE	5,040	5,260	0,710	4,100	6,730
CCI	156,330	155,600	18,260	133,700	187,100
SENT_ECON	95,480	101,000	10,370	59,900	103,400

Forrás: Saját szerkesztés

A változók közötti lineáris kapcsolatok előzetes feltárása, illetve a magyarázó változók közötti multikollinearitás elkerülése érdekében számolt Pearson-féle korrelációs együtthatók értékei a 4. táblázatban láthatók.

4. táblázat: Pearson-féle korrelációs együtthatók

	T_TRANS_UNIT	T_COVID_19	WAGE_H	CCI	UNEMP_RATE	F2_INT_RATE	SENT_ECON
T_TRANS_UNIT							
T_COVID_19	0,288***						
WAGE_H	0,671***	0,197***					
CCI	0,129***	0,103***	0,334***				
UNEMP_RATE	-0,181***	-0,005	0,163***	-0,644***			
F2_INT_RATE	-0,125***	-0,323***	-0,025	-0,294***	0,452***		
SENT_ECON	0,211***	0,194***	0,212***	0,691***	-0,787***	-0,496***	

Megjegyzés: * $p < 0,05$, ** $p < 0,01$, *** $p < 0,001$

Forrás: Saját szerkesztés

Módszertan

Mivel egyszerre vannak keresztmetszeti és idősoros megfigyelések, a hipotézisek elvetéséhez vagy megtartásához a szakirodalom elsősorban a panelregressziós modelleket javasolja (Phillips–Han 2019; Yilmazkuday 2023).

A panelregressziós modellek becslésének lépései (Baltagi 1998):

- a változók stacionaritásának vizsgálata (Dickey–Fuller 1981),

- modellek becslése (egyesített legkisebb négyzetek, fix hatású, véletlen hatású modellek),
- modellek közötti döntés F teszt, Breusch–Pagan Lagrange Multiplier teszt, illetve Hausman- (1978) teszt segítségével,
- modelldiagnosztikai tesztek (keresztmetszeti függőség, autokorreláció, heteroszkedaszticitás).

Az egyesített legkisebb négyzetek (Pooled Ordinary Least Squares, POLS) modellje a legegyszerűbb panelregressziós modell, de nem veszi figyelembe a heterogenitást a csoporton, illetve az idődimenzió belül (Pedroni 2001). Általános képlete a következőképpen írható fel:

$$Y_{it} = \alpha + \beta_1 X_{it} + \varepsilon_{it}, \quad (2)$$

ahol α konstans, Y_{it} függő változó, t idődimenzió, i keresztmetszeti dimenzió, X_{it} független változó, β_1 független változó együtthatója, ε_{it} a teljes regresszióra vonatkozó hibateg, $i = \overline{1, N}$.

A fix hatású modell (Fixed Effects, FE) abból indul ki, hogy minden megfigyelt egységnek megvan a maga sajátossága. Azt feltételezzük, hogy ez a sajátosság hatással van a magyarázó vagy függő változóra. Ez a feltételezés áll annak a korrelációnak a háttérében, amely az FE-modellben a magyarázó változó és a nem megfigyelhető, csoportra vonatkozó hibateg között áll fenn. Ha eltávolítjuk ezt az időtől független sajátosságot a magyarázó változóból, akkor megkapjuk a magyarázó változó nettó hatását (Stock–Watson 2004; Bartels 2008). Ha az időtől független fix hatásokat szeretnénk figyelembe venni, akkor a modell a következőképpen írható fel:

$$Y_{it} = \alpha + \beta_1 X_{it} + u_i + \varepsilon_{it}, \quad (3)$$

ahol u_i nem megfigyelhető, csoportra vonatkozó hibateg, i csoport vagy keresztmetszeti dimenzió, $i = \overline{1, N}$.

Ha nincs kapcsolat u_i és X_{it} között, akkor a véletlen hatású modell alkalmazható. A véletlen hatású modell előnyösebb lehet, ha a csoportok közötti különbségek véletlenszerűek (Bell–Jones 2015). Az egyénenként eltérő, de időben állandó véletlen hatásokat becselő modell általános képlete:

$$Y_{it} = \alpha + \beta_1 X_{it} + (u_i + \varepsilon_{it}), \quad (4)$$

Modellszelekciós tesztek a Hausman- (1978) teszt, illetve F-teszt (Baltagi 1998). A Hausman-teszt a fix hatású és a véletlen hatású modellek közötti választást segíti, hipotézisei:

H_0 : Nincs kapcsolat u_i és X_{it} között, ezért a véletlen hatású modell konzisztens.

H_1 : Van kapcsolat u_i és X_{it} között, vagyis a fix hatású modell konzisztens.

Az F-teszt a POLS- és a fix hatású modell közötti választást könnyíti meg, hipotézisei:

H_0 : A POLS-modell konzisztens.

H_1 : A fix hatású modell konzisztens.

A kiválasztott modell diagnosztikai tesztjei közé tartoznak a csoportok közötti függetlenségteszt (Breusch–Pagan LM-teszt, illetve Pasaran CD teszt), a hibatagok autokorrelációjára vonatkozó tesztek (Breusch–Godfrey/Wooldridge-teszt), a hibatagok homoszkedaszticitására vonatkozó tesztek (Breusch–Pagan-teszt).

Eredmények

A változók stacionaritásának vizsgálatához Choi (2001) Pure tesztet használ, amely paneladatbázis esetén vizsgálja az egységgyök meglétét. A Pure tesztbe több tesztelési eljárás is beépíthető, ilyen például a Maddala–Wu (1999) vagy a Levinlin (Levin et al. 2002). Mindkét eljárás a kiterjesztett Dickey–Fuller- (Augmented Dickey–Fuller-, ADF-) teszten alapul. Választott késleltetettek száma 1 év, azaz 12 hónap. A változók stacionaritására vonatkozó Pure teszt eredményei az 5. táblázatban láthatók.

5. táblázat: Stacionaritás vizsgálata

Változók	p-érték	Eredmény
T_TRANS_UNIT	0,000	stacionárius
T_COVID_19	0,000	stacionárius
WAGE_H	0,000	stacionárius
UNEMP_RATE	0,000	stacionárius
F2_INT_RATE	0,000	stacionárius
CCI	0,000	stacionárius
SENT_ECON	0,000	stacionárius

Forrás: Saját szerkesztés

A becült POLS, a fix hatású és véletlen hatású modellek globális F-próba eredményei (lásd 6. táblázat) szerint mindhárom modell létezik. A korrigált R^2 azt mutatja meg, hogy a független változók együttesen hány százalékban magyarázzák a lakások adásvételi volumenének varianciáját.

Mivel létezik a POLS-modell, a magyarázó és a kontrollváltozók közötti multikollinertás elemzésére VIF (Variance Inflation Factor, varianciát infláló faktort) mutatót kell számolni, amelynek eredményei a következő táblázatban láthatók. A VIF-értékek alapján minden változó maradhatott a becslésben.

6. táblázat: Globális F-próba eredményei

Modellek	F próba p-értéke	Korrigált R^2	Eredmény
OLS	0,000	0,520	A modell létezik
Fix hatás	0,000	0,250	A modell létezik
Véletlen hatás	0,000	0,250	A modell létezik

Forrás: Saját szerkesztés

7. táblázat: VIF-értékek

Változók	VIF	Eredmény
T_COVID_19	1,270	Nincs multikollinearitás
WAGE_H	1,180	Nincs multikollinearitás
UNEMP_RATE	3,080	Nincs multikollinearitás
F2_INT. RATE	1,530	Nincs multikollinearitás
CCI	2,190	Nincs multikollinearitás
SENT_ECON	3,500	Nincs multikollinearitás

Forrás: Saját szerkesztés

A kiigazított R^2 alapján a POLS a három közül a legjobb modell, ám a modellszelekciós tesztek mást mutattak. Az F-teszt, illetve a Hausman-teszt eredménye szerint a fix hatású modell a legmegfelelőbb a becsléshez.

Mivel az adatbázisban két változó esetén (az ezer főre jutó új fertőzések esetek száma, illetve az ezer főre jutó lakások tranzakciós volumene) nagyon heterogének a megfigyelések, és vannak kiugró értékek, amelyek jelentős eltéréseket okozhatnak a valós paraméterektől, ezért within becslést kell alkalmazni, amellyel a becslött paraméterek robusztussá tehetők (Bramati–Croux 2007). Az így becslött modell esetében végrehajtott t-tesztek és azok eredményei a 8. táblázatban láthatók.

8. táblázat: Fix hatású modell t-tesztjeinek eredményei

Változók	Becslött együtthatók	t-teszt p-értéke	Együtthatók standard hibái
T_COVID_19	0,002	0,041*	0,001
WAGE_H	0,020	0,361	0,023
UNEMP_RATE	-0,066	0,001**	0,020
F2_INT. RATE	-0,009	0,273	0,008
CCI	-0,001	0,003**	0,005
SENT_ECON	0,008	0,000***	0,009

Megjegyzés: * $p < 0,05$, ** $p < 0,01$, *** $p < 0,001$

Forrás: Saját szerkesztés

A modelldiagnosztikai tesztek eredményei szerint a fix hatású modellben a csoportok között van keresztmetszeti függőség, a hibatagok autokorrelálnak és heteroszkedasztikusak. Mivel a modelldiagnosztikai tesztek szerint a becült fix hatású modell eredményei torzítottak, ezért Arellano-transzformációt volt szükséges végrehajtani (Arellano–Bond 1991) és újra kellett becslni a modellt. A transzformáció utáni t-tesztek eredményei a 9. táblázatban láthatók.

9. táblázat: Arellano-transzformáció után fix hatású modell eredményei

Változók	Becült együtthatók	t-teszt p-értéke	Együtthatók standard hibái
T_COVID_19	0,002	0,007 **	0,001
WAGE_H	0,021	0,719	0,058
UNEMP_RATE	-0,066	0,000 ***	0,014
F2_INT.RATE	-0,009	0,0815 .	0,005
CCI	-0,001	0,0436 *	0,001
SENT_ECON	0,008	0,000 ***	0,001

Megjegyzés: * p<0,05, ** p<0,01, *** p<0,001

Forrás: Saját szerkesztés

A transzformáció utáni modellben a nettó átlagbér nem lett szignifikáns, a hitelkamatláb pedig 8,15 százalékon szignifikáns, a többi változónál a szignifikanciaszint kisebb, mint 5 százalék. A becült együtthatók előjelei alapján elmondható, hogy a lakások tranzakciós volumenére a Covid-esetszámok, illetve a gazdasági hangulatindex pozitív hatással voltak. Az adásvételek számát a munkanélküliségi ráta, a hitelek kamatlába, illetve az építkezési költségindex negatívan befolyásolta.

A fix hatású modell képlete:

$$T_TRANS_UNIT_{it} = 0,002 * T_{COVID19_{it}} - 0,066 * UNEMP_{RATE_{it}} - 0,009 * F2_{INTRATE_{it}} - 0,001 * CCI_{it} + 0,008 * SENT_ECON_{it} + \epsilon_{it}, t = 1,1302, i = 1,1302 \quad (5)$$

Következtetések

A becült fix hatású modell eredményei azt mutatják, hogy Romániában 2020 áprilisa és 2022 októbere között, ha nőtt az új fertőzések száma, illetve a gazdasági hangulatindex, nőtt a lakásadásvétel volumene is. Ellenben, ha felfele mozdult el a változó kamatozású lejalapú lakáshitelek kamatlába, az építkezési költségindex, illetve a harmonizált munkanélküliségi ráta, ez csökkenést okozott a lakástranzakciók számában.

Az eredmények összhangban vannak Diamond et al. (2022) és Gallent et al. (2023) következtetéseivel, miszerint minél nagyobb volt a vizsgált időszakban az új fertőzések száma, annál többen vásároltak lakást. A járvány miatti bezártság és a sűrűn lakott településeken (városon) a betegség terjedésének üteme (kiegészülve fiskális és monetáris ösztönzőkkel) felülírták a lakáskeresletre és -kínálatra vonatkozó negatív nyomást Romániában.

A romániai lakástranzakciók száma fordított kapcsolatban állt a lakáshitel kamatlábával és az építkezési költségindexszel, ez utóbbi az infláció egyik proxy változójaként viselkedik (Meen 2002; Akkoyun et al. 2013). Romániában 2020 áprilisa és 2022 októbere között az inflációs ráta növekedése nem arra ösztönözte a lakosságot jelentős részét, hogy befektetéseket eszközöljön az ingatlanpiacon, ellentétben például a svéd lakossággal (Malmström–Schultz 2017), hanem a nominális kamatlábak emelkedése oda vezetett, hogy kevesebb háztartás engedhette meg magának a hitelfelvételt, így csökkent a lakástranzakciók száma Dekimpe és van Heerde (2023) eredményeihez hasonlóan. Ez a következtetés kiemelten fontos lehet például az ingatlanközvetítő irodák, illetve az ingatlanfejlesztésekre szakosodott cégek számára, különösen akkor, ha a kormány és a központi bank gazdasági válság idején olyan intézkedéseket hoz, amelyekkel kompenzálni próbálja a lakáshitelek emelkedő kamatlábait.

A panelregressziós becslést követően elmondható, hogy a romániai lakástranzakciók száma a vizsgált időszakban fordított kapcsolatban állt a munkanélküliségi rátával Gan et al. (2018) eredményeivel összhangban, és az összes változó közül a munkanélküliségi ráta hatott a leginkább a függő változóra. Ezt a hatást érdemes olyan fizikai személyeknek is szem előtt tartaniuk, akik gazdasági válság idején lakást szeretnének venni, illetve eladni, ugyanis ha tartósan emelkedik a munkanélküliségi ráta, nagy valószínűséggel kevesebben fognak lakástranzakcióba bocsátkozni.

A lakások tranzakciós volumenének növekedését az is befolyásolta, hogy a kormány a munkavállalóknak és munkaadóknak nyújtott támogatásokkal viszonylag alacsonyan tartotta a munkanélküliségi rátát az úgynevezett technikai munkanélküliségen keresztül (a munkaadók állami kompenzáció fejében nem bocsátották el alkalmazottjaikat annak ellenére, hogy tényleges munkát nem vagy alig végeztek). A vizsgált időszakban a romániai harmonizált munkanélküliségi ráta 5,83 százalékos volt, a mutató egyetlen hónapban, 2020 júniusában érte el maximumát, a 6,90 százalékot. Ezzel szemben az Európai Unióban az Eurostat (2023) adatai szerint az átlagos harmonizált munkanélküliségi ráta 2020 második

negyedévétől egészen 2021 első negyedévének végéig tartósan 7,5 százalék vagy e feletti értéken mozgott, és mindössze a vizsgált időszak végén, 2022 első negyedévétől közelítette meg az 5,83 százalékos romániai átlagot.

Romániában a járvány ideje alatt a tranzakciós volumen követte a gazdasági hangulatindex mozgását, így a hangulatindex hatékony előrejelzője lehet a kereskedési volumennek Białowolski (2019) és Hui és Wang (2014) következtetéseivel összhangban.

Az eredmények azt mutatják, hogy a tanulmányban megfogalmazott hat hipotézisből ötöt a modellbecslést követően igazolni lehetett. Egy hipotézist (H_5 : A romániai lakástranzakciók volumenére pozitív hatással van a háztartások jövedelme) el kellett vetni, mert a nettó jövedelem és a lakástranzakciók volumene között nem sikerült szignifikáns kapcsolatot kimutatni. Ennek egyik lehetséges oka, hogy a kormányzati intézkedéseknek köszönhetően nem csökkent a vizsgált időszakban a nettó átlagbér Romániában.

A kutatás korlátai közé sorolható, hogy nem vizsgálja, hogyan hatottak a Covid-esetszámok a lakásoktól eltérő típusú ingatlanokra. Nem vizsgálja továbbá a lakásfelújítási piac viselkedését a világjárvány alatt, amely szorosan kapcsolódik a lakásértékesítéshez, lakásépítéshez. A kutatás további kiterjesztése lehet annak elemzése, hogy miként alakult a telkek adásvétele a pandémia alatt Romániában. Feltehetően Romániában is sokkal többen vásároltak telket vidéken a mobilitási korlátozások miatt, mint a járványt megelőző, illetve azt követő években.

Irodalomjegyzék

- Akkoyun, H. C.–Arslan, Y.–Kanik, B. 2013. Housing prices and transaction volume. *Journal of Housing Economics* 22(2), 119–134.
- Andrew, M.–Meen, G. 2003. House Price Appreciation, Transactions and Structural Change in the British Housing Market: A Macroeconomic Perspective. *Real Estate Economics* 31(1), 99–116.
- Arellano, M.–Bond, S. 1991. Some Tests of Specification for Panel Data: Monte Carlo Evidence and an Application to Employment Equations. *The Review of Economic Studies* 58(2), 277–297.
- Baker, S. R.–Farrokhnia, R. A.–Meyer, S.–Pagel, M.–Yannelis, C. 2020. How Does Household Spending Respond to an Epidemic? Consumption during the 2020 COVID-19 Pandemic. *The Review of Asset Pricing Studies* 10(4), 834–862.
- Baltagi, B. H. 1998. Panel Data Methods. In: Ullah, A.–Giles, D. E. A. (szerk.) *Handbook of Applied Economic Statistics*. New York: Marcel Dekker Publishing, 291–323.

- Bartels, B. L. 2008. Beyond „fixed versus random effects”: a framework for improving substantive and statistical analysis of panel, time-series cross-sectional, and multilevel data. *The Society for Political Methodology* 9, 1–43.
- Bell, A.–Jones, K. 2015. Explaining Fixed Effects: Random Effects Modeling of Time-Series Cross-Sectional and Panel Data. *Political Science Research and Methods* 3(1), 133–153.
- Białowolski, P. 2019. Economic sentiment as a driver for household financial behavior. *Journal of Behavioral and Experimental Economics* 80, 59–66.
- Bramati, M. C.–Croux, C. 2007. Robust estimators for the fixed effects panel data model. *The Econometrics Journal* 10(3), 521–540.
- Clayton, J.–Miller, N.–Peng, L. 2008. Price-volume Correlation in the Housing Market: Causality and Co-movements. *The Journal of Real Estate Finance and Economics* 40, 14–40.
- Choi, I. 2001. Unit root tests for panel data. *Journal of International Money and Finance* 20, 249–272.
- Dekimpe, M. G.–van Heerde, H. J. 2023. Retailing in times of soaring inflation: What we know, what we don't know, and a research agenda. *Journal of Retailing* 99(3), 322–336.
- Diamond, W.–Landvoigt, T.–Sanchez, G. 2022. *Printing Away the Mortgages: Fiscal Inflation and the Post-Covid Housing Boom*. https://papers.ssrn.com/sol3/papers.cfm?abstract_id=4283119, letöltve: 2023. 03. 13.
- Dickey, D. A.–Fuller, W. A. 1981. Likelihood Ratio Statistics for Autoregressive Time Series with a Unit Root. *Econometrica* 44, 1057–1072.
- Enăchescu, P. C.–Bănică, C. 2019. Analysis Of The Real Estate Market In Romania From The Point Of View Of The Number Of Transactions During 2009-2018. *Scientific Bulletin-Economic Sciences* 18(3), 39–46.
- European Central Bank 2023. *Economic Bulletin Issue 5*. <https://www.ecb.europa.eu/press/economic-bulletin/html/eb202305.en.html#:~:text=Energy%20prices%20fell%20again%2C%20dropping,%2C%20from%205.8%25%20in%20May,letoltve:2023.12.12>.
- Eurostat 2023. *Housing in Europe – 2023 interactive publication*. <https://ec.europa.eu/eurostat/en/web/products-eurostat-news/w/wdn-20231130-1,letoltve:2023.11.30>.
- Follain Jr, J. R. 1982. Does Inflation Affect Real Behavior: The Case of Housing. *Southern Economic Journal* 48, 570–582.
- Gallent, N.–Stirling, P.–Hamiduddin, I. 2023. Pandemic mobility, second homes and housing market change in a rural amenity area during COVID-19 – The Brecon Beacons National Park, Wales. *Progress in Planning* 172, 100731.
- Gamber, W.–Graham, J.–Yadav, A. 2023. Stuck at home: Housing demand during the COVID-19 pandemic. *Journal of Housing Economics* 59, 101908.
- Gan, L.–Wang, P.–Zhang, Q. 2018. Market thickness and the impact of unemployment on housing market outcomes. *Journal of Monetary Economics* 98, 27–49.
-

Guzmán, G. 2009. Using sentiment surveys to predict GDP growth and stock returns. In: Klein L. R. (szerk.) *The Making of National Economic Forecasts*. Massachusetts: Edward Elgar Publishing, 319–348.

Hausman, J. A. 1978. Specification Tests in Econometrics. *Econometrica* 46, 1251–1271.

Hui, E. C.–Wan, Z. 2014. Market sentiment in private housing market. *Habitat International* 44, 375–385.

Ion, A.–Cezar-Petre, S.–Costin, C.–Elena, I.–Ovidiu, D. 2021. The Impact of COVID-19 on the Building Industry and on Real Estate Transactions in Romania. In: Dima, A. M.–Anghel, I.–Dobrea R. C. (szerk.) *Economic Recovery After COVID-19*. Bukarest: 3rd International Conference on Economics and Social Sciences, ICES 2020, 157–174.

Kitrar, L. 2021. The relationship of economic sentiment and GDP growth in Russia in light of the Covid-19 crisis. *Entrepreneurial Business and Economics Review* 9(1), 7–29.

Lamdin, D. J. 2008. Does Consumer Sentiment Foretell Revolving Credit Use? *Journal of Family and Economic Issues* 29, 279–288.

Levin, A.–Lin, C. F.–Chu, C. S. J. 2002. Unit root tests in panel data: asymptotic and finite-sample properties. *Journal of Econometrics* 108(1), 1–24.

Li, G.–Pengfei, W.–Qinghua, Z. 2018. Market thickness and the impact of unemployment on housing market outcomes. *Journal of Monetary Economics* 2018(98), 27–49.

Liu, Y.–Tang, Y. 2021. Epidemic shocks and housing price responses: Evidence from China's urban residential communities. *Regional Science and Urban Economics* 89, 103695.

Maddala, G. S.–Wu, S. 1999. A Comparative Study of Unit Root Tests with Panel Data and a New Simple Test. *Oxford Bulletin of Economics and Statistics* 61(S1), 631–652.

Malmström, D.–Schultz, A. 2017. *Foreign Direct Investments on the Swedish Real Estate Market: Fundamentals Impact on Foreign Transaction Volume*. <https://www.diva-portal.org/smash/record.jsf?pid=diva2%3A1127714&dsid=3618>, letöltve: 2023. 12. 05.

Meen, G. 2002. The Time-Series Behavior of House Prices: A Transatlantic Divide? *Journal of Housing Economics* 11, 1–23.

Moroşan, G.–Condratov, I.–Filipciuc, L. 2020. Influencing factors on housing prices in Romania. *The USV Annals of Economics and Public Administration* 20, 115–128.

Ortalo-Magné, F.–Rady, S. 2004. Housing transactions and macroeconomic fluctuations: a case study of England and Wales. *Journal of Housing Economics* 13, 287–303.

Pedroni, P. 2001. Fully modified OLS for heterogeneous cointegrated panels. In: Baltagi B. H.–Fomby T. B.–Hill R. C. *Nonstationary panels, panel cointegration, and dynamic panels*. Emerald Group Publishing, 93–130.

Phillips, P. C. B.–Han, C. 2019. Dynamic panel GMM using R. *Handbook of Statistics* 41, 119–144.

Pichler, A.–Pangallo, M.–del Rio-Chanona, R. M.–Lafond, F.–Farmer, J. D. 2020. *Production networks and epidemic spreading: How to restart the UK economy?* <https://arxiv.org/abs/2005.10585>, letöltve: 2023. 05. 07.

Román Nemzeti Bank 2022. *Raport asupra stabilității financiare*. <https://bnr.ro/PublicationDocuments.aspx?icid=19966>, letöltve: 2023. 12. 12.

Slavata, D. 2021. Estimation of Unemployment Using Changes in the Housing Market. *Public Economics and Administration* 2021, 375–382.

Stein, J. C. 1995. Prices and Trading Volume in the Housing Market: A Model with Down-Payment Effects. *The Quarterly Journal of Economics* 110(2), 379–406.

Stock, J. H.–Watson, M. W. 2004. Combination forecasts of output growth in a seven-country data set. *Journal of Forecasting* 23(6), 405–430.

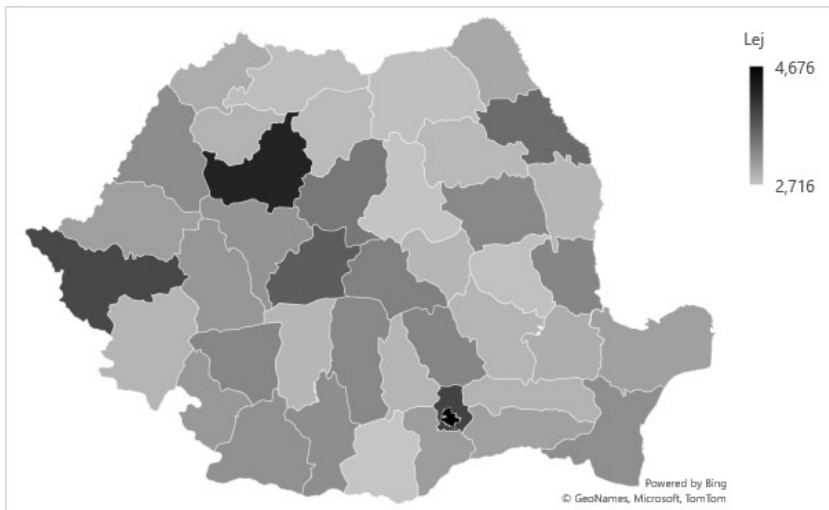
Tsai, I. C.–Chiang, Y. H.–Lin, S. Y. 2022. Effect of COVID-19 lockdowns on city-center and suburban housing markets: Evidence from Hangzhou, China. *Journal of Asian Economic* 83, 101544.

Valderrama, L.–Gorse, P.–Marinkov, M.–Topalova, P. 2023. *European Housing Markets at a Turning Point. Risks, Household and Bank Vulnerabilities, and Policy Options*. Washington, D.C.: International Monetary Fund.

Yilmazkuday, H. 2023. COVID-19 and housing prices: evidence from U.S. county-level data. *Review of Regional Research* 43, 241–263.

Mellékletek

1. melléklet: Nettó átlagjövedelem megyei bontásban átlagolt adatok alapján. Vizsgált periódus: 2020 áprilisa és 2022 októbere közötti időszak




Forrás: Saját szerkesztés

2. melléklet: Építkezési költségindex. Vizsgált periódus: 2020 áprilisa és 2022 októbere közötti időszak




Forrás: Saját szerkesztés

3. melléklet: Harmonizált munkanélküliségi ráta. Vizsgált periódus: 2020 áprilisa és 2022 októbere közötti időszak




Forrás: Saját szerkesztés

4. melléklet: Változó kamatozású lejalapú lakáshitelek kamatlába. Vizsgált periódus: 2020 áprilisa és 2022 októbere közötti időszak



Forrás: Saját szerkesztés

5. melléklet: Gazdasági hangulatindex. Vizsgált periódus: 2020 áprilisa és 2022 októbere közötti időszak

Forrás: Saját szerkesztés

Hitelminősítő algoritmusok összehasonlítása: mesterséges intelligencia alapú algoritmusok vs. hagyományos módszerek

SZILÁGYI-NAGY ZÉTÉNY¹

A tanulmány célja összehasonlítani a logisztikus regresszió, döntési fa és a véletlen erdő teljesítményét egy valós P2P (peer-to-peer) hitelezési adatbázison. A peer-to-peer (vagy személyközi, P2P) hitelezési piac megkönnyíti a hitelfelvevők és a hitelezők közötti pénzügyi tranzakciókat. A hitelkockázat-kezelés hagyományosan a hitelpontozáson alapszik, amely segítségével a hitelek nemteljesítésének valószínűségét becsüljük. A megfelelő hitelminősítési technika nagyon fontos mind a pénzügyi intézmények, mind a P2P hitelezési platformok hosszú távú sikere szempontjából. A hitelminősítő algoritmusok összehasonlítása a Lending Clubról származó adatok alapján történik. Az adatbázis 2017 első negyedévére terjed ki, 563 847 megfigyelést és 23 különböző változót tartalmaz. Az eredmények alapján arra a következtetésre jutunk, hogy a véletlen erdő a jobb hitelminősítő algoritmus a Lending Club adatbázisa esetében.

Kulcsszavak: hitelminősítés, személyközi hitelezés, logisztikus regresszió, véletlen erdő, döntési fa.

JEL kódok: G21, G23, D14.

Bevezető

Teply és Polena (2020) szerint a FinTech pénzügyi innovációjaként a személyközi (peer-to-peer, P2P) hitelezés egy új, online pénzügyi közvetítés, amely a hitelfelvevőket köti össze a hitelezőkkel. A hitelfelvevők és a hitelezők online P2P-hitelezési platformokon keresztül kerülnek kapcsolatba egymással. A P2P-hitelezési platformok a hagyományos bankoknál alacsonyabb közvetítési költséggel tudnak hiteleket nyújtani, mivel az online jelenlétük miatt a működési költségeik alacsonyabbak, mint a fizikai bankoké. Ez teszi lehetővé a versenyképesebb feltételek kínálását a hitelfelvevők és a hitelezők számára. A hitelfelvevők átlagosan alacsonyabb kamatlábakat fizetnek a P2P-hitelezési platformokon, mint a bank által nyújtott hitelek esetén. A jól diverzifikált hitelfortfólióval rendelkező hitelezők magasabb hozamot érnek el, mint a hagyományos megtakarítási számlákon. Ezek a tények egyre inkább népszerűvé teszik a P2P-hitelezést mind a hitelfelvevők, mind a hitelezők számára.

¹ BSc-hallgató, Babeş–Bolyai Tudományegyetem, Közgazdaság- és Gazdálkodástudományi Kar, e-mail: zeteny.szilagyi@stud.ubbcluj.ro.

Fontos kiemelni a P2P-hitelezés korlátait is ahhoz, hogy a hitelezési piacról egy átfogó képet kapjunk. Zhao et al. (2021) szerint az egyik jelentős korlát a kockázatkezeléssel kapcsolatos, hiszen a P2P-hitelezési platformokon a hitelfelvevők hitelképességének értékelése gyakran kevésbé alapos, mint a hagyományos bankok esetében, ami magasabb kockázatot jelent a hitelezők számára. A hagyományos bankokkal ellentétben a hitelkockázatot nem a P2P-platformnak, hanem a befektetőknek kell viselniük (Stern et al. 2017). A P2P-hitelezés likviditási kockázata is fontos, a befektetők nem kapják azonnal vissza a befektetett összeget, meg kell várniuk a hitel futamidejének a végét. A kamatkockázat és a platformkockázat is korlátozza a P2P-hitelezést, hiszen a P2P-hitelezési platformok üzleti modelljei és pénzügyi helyzete változhat, ami a befektetők számára kockázatot jelent. Ezek mellett a platform meghibásodásából, csalásból vagy kiberbűnözésből eredő potenciális kockázati tényezők a befektetőkre és a platformokra is kockázatot jelentenek (Milne–Parboteeah 2016).

A legelső P2P-hitelezési platformot, a Zopát 2005-ben alapították az Egyesült Királyságban. A Zopát követően számos P2P-hitelezési platform jött létre, köztük több mint 1000 Kínában. Az Amerikai Egyesült Államokban a Lending Club a legfontosabb P2P-hitelezési platform, amelyet 2014-ben bevezettek a New York-i tőzsdére. A P2P-hitelezés piacának értéke 2020-ban 84,89 milliárd dollár volt, és az előrejelzések szerint 2028-ra eléri az 578,03 milliárd dollár értéket.

Az egyedi hitelkérelmek növekedésével a hitelkockázat értékelése egyre fontosabbá vált a pénzügyi szakemberek és kutatók számára is. Ágoston (2022a) szerint a hagyományos módszerek, amelyek sokáig dominálták ezt a területet, egyre nagyobb kihívásokkal szembesülnek a változó gazdasági környezet és az adatok bősége miatt. Az új technológiák, mint például a mesterséges intelligencia alapú algoritmusok, ígéretes alternatívát kínálnak a hagyományos modellek mellett.

A tanulmányban áttekintem az új megközelítéseket, majd hatékonyság és alkalmazhatóság szempontjából összehasonlítom ezeket a hagyományos módszerekkel. Az elemzés célja, hogy betekintést nyújtson abba, hogy miként lehetnek az új technológiák hatékony eszközök a hitelminősítő intézmények számára a kockázatok kezelésében és a döntéshozatalban. A klasszifikációs mátrix alapján felépített mérőszámok segítségével összehasonlítom a döntési fa, a véletlen erdő, valamint a logisztikus regresszió teljesítményét. A modellek teljesítményének értékelése alapján arra a kérdésre kapunk választ, hogy az új technológiák képe-

sek-e javítani a hitelminősítő intézmények hatékonyságát és eredményességét a hitelezési döntéshozatal folyamatában.

A tanulmány négy részből áll. Az első fejezet a szakirodalmi áttekintést tartalmazza, ezt követi az adatok és a módszertan fejezet, amelyben az elemzésben használt adatbázis, ennek tisztítási folyamata és az elemzésben használt módszerek kerülnek bemutatásra. Ezt követi az eredmények elemzése, majd a következtetések levonása.

Szakirodalmi áttekintés

A hagyományos banki hitelezéssel szemben a P2P-hitelezés újabb megközelítést jelent, amely során közvetlen kapcsolat alakul ki a kölcsönt igénylők és a befektetők között az online platformokon keresztül. Ezek a platformok alacsonyabb költségeket és gyorsabb folyamatokat kínálnak a hiteligénylőknek, miközben lehetőséget teremtenek azoknak a befektetőknek, akik hajlandóak közvetlenül részt venni a finanszírozásban. A döntéshozóknak fontos megérteniük mindkét lehetőség előnyeit és korlátait annak érdekében, hogy hatékonyan tudjanak választani a finanszírozási lehetőségek között. A hitelezési döntés hasonló a két finanszírozási forrás esetén (Kgoroadira et al. 2023).

Berger et al. (2021) szerint a hitelminősítés egy folyamat, amelynek során a pénzügyi intézmények vagy hitelezők eldöntik, hogy egy adott hitelfelvevő (fizikai személy vagy vállalat) képes-e visszafizetni a kölcsönt a megállapított feltételek szerint. Ez a folyamat segít a hitelezőknek felmérni a kockázatot, amelyet a kölcsön nyújtása jelent, valamint segít döntést hozni arra vonatkozóan, hogy milyen feltételekkel adják a hitelt, vagy hogy egyáltalán megadják-e azt. Pang et al. (2021) szerint a hitelminősítő pontszámok lehetővé teszik a hitelezők számára, hogy meghatározzák azt a valószínűséget, amellyel a hitelfelvevő vissza fogja fizetni a kölcsönt a megállapított feltételek szerint. A hitelezők és a hitelfelvevők számára egyaránt fontos, hogy ezek a hitelminősítések megbízhatóak és pontosak legyenek.

Számos tanulmány vizsgálja a hitelminősítő algoritmusokat és hasonlítja össze teljesítményüket (például Fraisse–Laporte 2022; Estran et al. 2022; Ahmed 2023; Wang et al. 2023; Song et al. 2023). A hitelminősítő algoritmusok két nagy csoportját különíti el a szakirodalom: a hagyományos módszereket és a mesterséges intelligencia alapú hitelminősítő algoritmusokat. Jagtiani és Lemieux (2019) szerint több különbség van a módszerek között. A mesterséges intelligencia alapú módszerek általában képesek nagyobb és összetettebb adathalmazokkal dolgozni.

Ezek az algoritmusok hatékonyan ki tudják használni az adatokban rejlő összefüggéseket és mintákat. Gyakran jobb teljesítményt nyújtanak a hagyományos módszereknél, mivel képesek bonyolultabb mintákat észlelni. Ez pontosabb és hatékonyabb eredményeket jelenthet a hitelminősítés során. A hagyományos módszerek eredményei könnyebben értelmezhetőek, valamint magyarázhatóak, mivel matematikai modellek alapján működnek.

A hagyományos hitelminősítő algoritmusok az 1970-es években kezdtek elterjedni. Ezek az algoritmusok általában statisztikai modelleken és számítógépes programokon alapulnak, amelyek az ügyfelek pénzügyi adatait és egyéb tényezőket elemzik a hitelképességük meghatározása során. Fraisse és Laporte (2022) szerint a hagyományos módszerek általában statisztikai modellek vagy szabályalapú rendszerek, amelyek előre definiált szabályok vagy paraméterek alapján döntenek. Ezek a módszerek általában nem tudnak adaptálódni az új adatokhoz vagy változó környezeti feltételekhez. A hitelkockázat területén leggyakrabban használt statisztikai módszerek a logisztikus regresszió és a Lasso regresszió. Dumitrescu et al. (2022) szerint a logisztikus regresszió valószínűségi alapú osztályozást alkalmaz arra, hogy előrejelezze, hogy egy ügyfél képes lesz-e törleszteni a hitelt vagy sem. A logisztikus regresszió használható azoknál a hitelezési platformoknál, amelyeknél a nemteljesítések azonosítási pontosságának javítása a cél, valamint annak megállapítása, hogy a hitel késedelmes-e.

A mesterséges intelligencia alapú hitelminősítő algoritmusok az elmúlt 10 évben terjedtek el (Zhou et al. 2019). Ezek az algoritmusok összetettebb adatelemzést végeznek, és képesek nagyobb adatmennyiségeket és változatosabb adatforrásokat feldolgozni, mint például a közösségi média aktivitás vagy az online vásárlási szokások. Fraisse és Laporte (2022) tanulmányozták a különbségeket a mesterséges intelligencia alapú algoritmusok és hagyományos módszerek között a hitelminősítés esetén. A módszerek közötti fő különbség a flexibilitás és az adatok elemzésének mélysége.

Dzik-Walczak és Heba (2021) összehasonlította a logisztikus regresszió és a döntési fa teljesítményét. Az elemzésben használt adatbázis a Lending Club oldaláról származik, a 2011 és 2013 közötti periódusra vonatkozik. Megállapították, hogy a logisztikus regresszió jobb eredményt ért el, mint a döntési fán alapuló hitelkockázati modell. Ugyancsak a logisztikus regresszió és a döntési fa teljesítményét hasonlította össze Jagtiani és Lemieux (2019), akik megerősítik az előbbi eredményt.

Wang et al. (2022) a magánszemélyek hitelkockázati jellemzőit vizsgálták logisztikus regresszióval, valamint XGBooston alapuló diszkriminációs modellel. A nemteljesítések közötti megkülönböztetések, a minél pontosabb eredmény eléréséhez, XGBoosttal történtek. A logisztikus regresszió esetén volt a legmagasabb az AUC értéke és a legnagyobb pontossággal rendelkezett. Arra a következtetésre jutottak, hogy az XGBooston alapuló hitelkockázat-értékelési modell nagyon jó nemteljesítési megkülönböztető képességgel és robusztussággal rendelkezik.

Zhou et al. (2019) egy véletlen erdő algoritmuson alapuló osztályozási módszert vizsgáltak, majd hasonlították össze az eredményeit egy XGBoost algoritmussal. Ha a hitelező nagyon alacsony elfogadási szintet alkalmaz, vagyis nagyon kis kockázatot vállal, akkor a véletlen erdő hatékonysága csökken. Ez azt jelenti, hogy a módszer kevésbé lesz pontos vagy megbízható az alacsonyabb elfogadási szinteken. A költségérzékenység figyelembevételénél sem sikerült jelentősen javítani a módszer nemteljesítő hitelfelvevők azonosítására vonatkozó képességét. Ágoston (2022b) az SVM-módszert hasonlította össze a neurális hálózattal, valamint a véletlen erdővel. Az AdaBoostot és a Bagginget használta az adatok kiegyensúlyozásához, elemzéséhez, valamint rendezéséhez. Az SVM több mint 5%-kal magasabb osztályozási pontosságot ért el az elemzett adatbázison. Megállapította, hogy a csodelőrejelzésben a fejlődés leginkább a mesterséges intelligenciának, valamint a gépi tanulásnak köszönhető.

A hitelminősítés területén egyre nagyobb szerepet kapnak a modern algoritmusok, mint például a neurális hálózatok, transzformerek és természetes nyelvfeldolgozási (NLP) modellek, mivel jelentős előrelépést jelentenek a hagyományos statisztikai és gépi tanulási módszerekhez képest. A neurális hálózatok képesek komplex mintázatok felismerésére, ami hasznos a hitelminősítés során, ahol számos változó kölcsönhatását kell figyelembe venni. A mélytanulási technikák, mint a visszacsatolt neurális hálózatok, lehetővé teszik nagy mennyiségű adat feldolgozását és az adatok közötti rejtett összefüggések feltárását, ami különösen előnyös a nemlineáris kapcsolatok felismerésében.

Wang és Xiao (2022) szerint a transzformerek, amelyeket eredetileg a természetes nyelvfeldolgozásban alkalmaztak, egyre inkább beépülnek a hitelminősítés területére is. Ezek a modellek hatékonyan kezelik a szekvenciális adatokat és képesek hosszú távú kapcsolatok azonosítására, ami lehetőséget biztosít arra, hogy a hitelminősítési folyamatban figyelembe vegyék az időben változó adatokat, például az ügyfél hiteltörténetének alakulását.

Az NLP-modellek különösen hatékonyak, amikor nem strukturált adatokat, például szöveges értékeléseket vagy ügyfélpanaszokat kell elemezni. Ezek a modellek lehetővé teszik, hogy a hitelminősítési folyamatba integrálják az ilyen típusú információkat is, ezáltal növelve a modellek előrejelző képességét. Az NLP-technikák segítségével a szöveges adatok elemzése révén még teljesebb képet kaphatunk egy hitelfelvevő kockázatosságáról Alonso Robisco és Carbo Martinez (2022) alapján.

Az elmúlt években a kutatások arra a következtetésre jutottak, hogy számos hitelkockázat-értékelési területen a mélytanulás felülmúlja a hagyományos gépi tanulási módszereket, és az osztályozók együttesen jelentősen jobban teljesítenek, mint az egyes osztályozók (Shen et al. 2021). Xia et al. (2017) kutatása az együttes gépi tanulásra épül, amely több technika kombinációja, amelynek teljesítménye jobb, mint az egyes technikáké külön-külön. Ezen túl arra is kitérnek, hogy ezek a modellek hogyan használhatók fel hatékonyan a hitelminősítésben. Emellett a hibrid modellek, amelyek többféle algoritmust ötvöznek, pontosságuk miatt egyre népszerűbbek.


Rudin (2019) a modern hitelminősítő modellek átláthatóságának és magyarázhatóságának a fontosságát elemzi, főként a mélytanulási algoritmusok esetében, amelyek gyakran fekete doboz módszereket alkalmaznak. Kiemeli a magyarázható mesterséges intelligencia (XAI) jelentőségét, amely növelheti a hitelminősítési modellekbe vetett bizalmat.

Adatok és módszertan

Ebben a fejezetben bemutatom az elemzésben használt adatbázist és az adattisztítási folyamatot, amely magába foglalja a nem releváns változók törlését, a változók transzformációját, a hiányzó és kiugró értékek kezelését és az alulmintavételezést. Az adatok bemutatása után az elemzésben használt módszerekre is kitérek.

Wang et al. (2021) szerint a Lending Club egy olyan peer-to-peer hitelyújtó vállalat, amely egy online platformon keresztül hozza össze a hitelfelvevőket a befektetőkkel. Olyan személyeknek nyújt hitelt, akiknek 1000 és 40 000 dollár közötti személyi kölcsönre van szükségük. A hitelfelvevők a kölcsön teljes összege és a kezelési költség közötti különbséget megkapják. A befektetők a személyi kölcsönökkel fedezett kötvényeket vásárolnak és a Lending Clubnak szolgáltatási díjat fizetnek. A vállalat megosztja a platformján keresztül bizonyos időszakokban kibocsátott összes hitel adatait.

Az 1. ábrán látható, hogy az elmúlt években hány új kölcsön került fel a Lending Club oldalára. Az adatokból látszik a P2P-hitelezés dinamikus fejlődése.



Forrás: Saját szerkesztés a Lending Club adatai alapján

1. ábra: A Lending Club által folyósított hitelek száma, 2016–2022

Az elemzés a Lending Club 2017-es első negyedévének hiteladataira épül. Az adatbázis 58 102 hitelfelvevő adatait tartalmazta. Az eredeti adatkészlet 117 változót tartalmazott, amelyből 35, az elemzés szempontjából releváns változót választottam ki. Az 1. táblázatban láthatók a változók nevei, leírásuk, hogy át lettek-e alakítva vagy sem, valamint hogy tartalmaztak-e kiugró vagy hiányzó értékeket.

1. táblázat: A változók leírása

Átalakítva	Változó neve	Leírás	Mértékegység
Nem	loan_amnt (hitel összege)	A hitel összege.	USD
Igen	term (futamidő)	Hitelezési periódus hossza: 36 vagy 60 hónap.	Hónap
Igen	grade (minősítés)	Minősítési kategória: A, B, ..., F.	–
Igen	sub_grade (al-minősítés)	Minősítési alkategória: az „A”-tól „G”-ig terjedő minősítések további alosztályokra bontása, például „A1”, „A2” stb.	–
Igen	emp_length (régiség)	Munkaviszony hossza a jelenlegi munkahelyen.	Év

Átalakítva	Változó neve	Leírás	Mértékegység
Igen	home_ownership (lakástulajdon)	A lakástulajdoni státusz: bérelt, saját, jelzálog, egyéb.	–
Igen	annual_income (jövedelem)	A hitelfelvevő éves jövedelme.	USD
Igen	verification_status (ellenőrzési állapot)	A hitelfelvevő jövedelmének ellenőrzési állapota: ellenőrzött, részben ellenőrzött, nem ellenőrzött.	–
Igen	loan_status (nemteljesítés)	A hitel jelenlegi állapota: folyamatban, késedelmes, elfogadva, visszautasítva.	–
Igen	purpose (cél)	A hitel célja.	–
Igen	addr_state (állam)	A hitelfelvevő lakhelyének állama.	–
Nem	delinq_2yrs (30 nap késedelmek)	A 30 napon túli késedelmes esetek száma az elmúlt 2 évben.	Darab
Igen	dti (adósságjövdelem arány)	A hitelfelvevő havi jövedelméhez viszonyított teljes adósságának aránya.	%
Nem	inq_last_6mths (megkeresések száma 6 hónapra)	Megkeresések száma az elmúlt 6 hónapban.	Darab
Igen	earliest_cr_line (legkorábbi hitelkeret nyitás)	A hitelfelvevő legkorábbi bejelentett hitelkerete megnyitásának napja.	Dátum
Igen	open_acc (számlák száma)	A számlák száma.	Darab
Nem	pub_rec (negatív események száma)	Nyilvános nyilvántartásokban szereplő negatív események száma.	Darab
Nem	acc_now_delinq (késedelmes számlák)	A jelenleg késedelmes számlák száma.	Darab
Igen	total_rev_hi_lim (hitelkeret felső határa)	A hitelfelvevő összes rendelkezésre álló hitelkeretének felső határa.	USD
Igen	total_cu_tl (hitelszámla számok)	A hitelfelvevő összes hitelszámlájának száma.	Darab
Nem	bc_open_to_buy (hitelkeret aránya)	A rendelkezésre álló, fel nem használt hitelkeret összegének aránya a bankkártyák esetében.	USD
Igen	mo_sin_rcnt_rev_tl_op (rulírozó hitelkeret megnyitás napja)	A legutóbbi rulírozó hitelszámla megnyitása óta eltelt hónapok száma.	Hónap
Nem	num_actv_rev_tl (aktív rulírozó hitelek)	A hitelfelvevő által jelenleg használt aktív rulírozó hitelszámlák száma.	Darab

Átalakítva	Változó neve	Leírás	Mértékegység
Nem	num_il_tl (nem rulírozó hitelszámlák)	A hitelfelvevő által használt egyéb hitelszámlák (nem rulírozó) száma.	Darab
Nem	num_op_rev_tl megnyitott rulírozó hitelek)	A hitelfelvevő által megnyitott rulírozó hitelszámlák száma.	Darab
Igen	revol_util (rulírozó hitelhez felhasznált hitelösszeg-arány)	A hitelfelvevő által felhasznált hitelösszeg az összes rendelkezésre álló rulírozó hitelhez viszonyítva.	%
Nem	num_tl_op_past_12m (egy éven belül megnyitott hitelszámlák)	A hitelfelvevő által az elmúlt 12 hónapban megnyitott hitelszámlák száma.	Darab
Nem	percent_bc_gt_75 (hitelkeret-kihasználtság 75% felett)	A bankkártyák aránya, amelyek esetében a hitelkeret kihasználtsága meghaladja a 75%-ot.	%
Nem	pub_rec_bankruptcies (csődök száma)	A nyilvános nyilvántartásokban szereplő csődök száma.	Darab
Nem	total_acc (hitelkeret száma)	A hitelfelvevő hitelkereteinek száma.	Darab
Nem	chargeoff_within_12_months (12 hónapban lévő hitelkiesések)	A 12 hónapon belüli hitelkiesések száma.	Darab
Igen	delinq_amnt (késedelmi számlák összege)	Azoknak a számláknak a lejárt összege, amelyek kifizetésével a hitelfelvevő késik.	USD
Nem	tax_liens (adótartozások)	Adótartozások száma, amely jelzi, hogy hányszor jegyezték be adótartozásokat, 14 különböző típusa van.	Darab
Nem	fico_range_low (legkisebb FICO-érték)	A FICO-pontszám* legkisebb értéke.	Pontszám
Nem	fico_range_high (legnagyobb FICO-érték)	A FICO-pontszám legnagyobb értéke.	Pontszám

* A FICO Score egy általánosan elfogadott hitelkockázat-értékelő pontszám. A Fair Isaac Corporation (FICO) fejlesztette ki, és a hitelképesség értékelésére használják.

Forrás: A Kaggle-ről származó változók magyarázata

Minden változó esetén megvizsgáltam a kiugró értékeket, valamint a hiányzó értékeket. Egyik változó sem tartalmazott hiányzó értékeket, viszont kiugró értékeket találtam több változó esetében is. A kiugró értékek kezelése fontos lépés az adatelemzés során, mivel ezek jelentősen befolyásolhatják a modellezés eredményét. A kiugró értékek azok az adatok, amelyek jelentősen eltérnek a többi adatponttól, és gyakran torzítják a statisztikai elemzéseket, például a modellek pontosságát

és megbízhatóságát. Kiugró értékeknek azokat az értékeket tekintetem, amelyek meghaladják a felső kvartilis (Q3) és az interkvartilis terjedelem (IQR) másfélszeresének az összegét. A jövedelem változó esetében a 170 900 USD feletti értékeket szűrtem ki (2913 megfigyelés). Az adózáskötelezettségi arány a havi törlesztőrészlet változó esetében a 44,39% feletti értékeket, a számlák száma változó esetében a 23 darab feletti értékeket szűrtem ki. A rulírozó hiteleknél felhasznált hitelösszeg esetében a 122,05 USD volt a küszöbérték, a hitelező hitelkereteinek felső határa esetében pedig a 82 800 USD. A hitelfelvevő hitelszámlának száma esetében az 5 darab hitelszámla feletti értékeket szűrtem ki. A 2. táblázat tartalmazza a változókat, a küszöbértéket a kiugró értékek esetén, és az ezt meghaladó megfigyelések számát. A kiugró értékeket kitöröltem az adatbázisból.

2. táblázat: Kiugró értékek elemzése

Változó	Küszöbérték	Mértékegység	Megfigyelések száma
annual_inc (jövedelem)	170 900	USD	2913
dti (adósság arány havi törlesztéssel)	44,391	%	758
open_acc (számlák száma)	23	Darab	2213
revol_util (rulírozó hitelhez felhasznált hitelösszegarány)	122,054	USD	3
total_rev_hi_lim (hitelkeret felső határa)	82 800	USD	2579
total_cu_tl (hitelszámlaszámok)	5	Darab	3310
delinq_amnt (késedelmi számlák száma)	10	Darab	143
mo_sin_rcnt_rev_tl_op (rulírozó hitelkeret megnyitásának napja)	39	Hónap	3149

Forrás: Saját szerkesztés

A mennyiségi változók leíró statisztikáit a 3. táblázat tartalmazza.

A hitel státusza változónak hat értéke volt az eredeti adatbázisban (teljesen visszafizetve, leírásra került, folyamatban levő, türelmi időben levő, 16–30 nap közötti késedelemmel rendelkezik, 31–120 nap közötti késedelemmel rendelkezik), az elemzés szempontjából ezek közül kettő volt releváns (a teljesen visszafizetett és a nemteljesítő hitelek), a másik négy értéket eltávolítottam az adatbázisból. A hitel státusza változóból létrehoztam így a nemteljesítés változót. A nemteljesítés változó bináris változó: a 0 érték a teljesítő hiteleket, az 1-es érték a nemteljesítő hiteleket jelöli, amint az a 4. táblázatban is látható.

Az adattisztítás után az adatbázis 13 182 olyan ügyfél adatát tartalmazta, aki visszafizette a hitelt, illetve 3904 nemteljesítő ügyfél adatát.

3. táblázat: A mennyiségi változók leíró statisztikái

Változó	Min	Medián	Átlag	Max	Mértékegység
loan amnt	1000,000	12 000,000	14 180,000	40 000,000	USD
annual income	5000,000	64 000,000	69 433,000	170 000,000	USD
loan status	0,000	0,000	0,231	1,000	Kategória
delinq 2yrs	0,000	0,000	0,322	25,000	Darab
dti	0,000	17,422	17,983	44,333	%
inq last 6mths	0,000	0,000	0,491	5,000	Darab
open acc	1,000	10,000	10,000	23,000	Darab
pub rec	0,000	0,000	0,254	47,000	Darab
acc now delinq	0,000	0,000	0,010	1,000	Darab
total rev hi lim	300,000	23 300,000	27 342,000	82 800,000	USD
total cu tl	0,000	0,000	0,941	5,000	Darab
bc open to buy	0,000	5650,000	9644,000	78 827,000	USD
mo sin rent rev tl op	0,000	7,000	10,051	39,000	Hónap
num actv rev tl	0,000	5,000	5,172	21,000	Darab
num il tl	0,000	6,000	8,123	81,000	Darab
num op rev tl	1,000	7,000	7,732	23,000	Darab
revol util	0,000	46,300	46,894	116,200	%
num tl op past 12m	0,000	2,000	2,321	20,000	Darab
percent bc gt 75	0,000	33,300	38,832	100,000	%
pub rec bankruptcies	0,000	0,000	0,162	5,000	Darab
total acc	2,000	21,000	22,611	87,000	Darab
chargeoff within 12 months	0,000	0,000	0,070	6,000	Darab
delinq amnt	0,000	0,000	0,000	0,000	USD
tax liens	0,000	0,000	0,060	46,000	Darab
fico range low	660,000	690,000	696,100	845,000	Pontszám
fico range high	664,000	694,000	700,100	850,000	Pontszám

Forrás: Saját számítás

4. táblázat: Hitelek száma az átalakítások előtt és után

Változó	Hitelek száma
<i>Hitel státusza</i>	
Teljesen visszafizetve	13 182
Leírásra került	3 904
Folyamatban levő	24 952
Tűrelmi időben lévő	238
16–30 nap közötti késedelemmel rendelkezik	115
31–120 nap közötti késedelemmel rendelkezik	643
Összesen	43 034
<i>Nemteljesítés</i>	
Teljesítő (0)	13 182
Nemteljesítő (1)	3 904
Összesen	17 086

Forrás: A Lending Club oldaláról származó adatok alapján saját szerkesztés

Módszertan

Az adatbázis tisztítása után a logisztikus regresszió, a döntési fa, valamint a véletlen erdő teljesítményét hasonlítottam össze.

Logisztikus regresszió

Chang et al. (2022) szerint a leggyakrabban használt statisztikai módszer a nemteljesítési valószínűség becslésére a logisztikus regresszió. A függő változó bináris, 0 az értéke a jól teljesítő ügyfelek esetén, 1 pedig a nemteljesítő ügyfelek esetén. A bináris logisztikus regresszió alakja a következő:

$$P(y = 1|x_1, \dots, x_k) = T(\beta_0 + \beta_1x_1 + \dots + \beta_kx_k + \varepsilon), \tag{1}$$

ahol y egy bináris függő változó, amely értéke 0 vagy 1. Az x -ek a független változók, amelyeket a T függvény leképez valós számokra 0 és 1 között, úgy, hogy a becslt érték $[0,1]$ közötti legyen. Az ε a hibtagot jelöli. A következő egyenlet mutatja, hogy a T függvény hogyan képezi le ezeket az értékeket:

$$T(x) = \frac{e^x}{1 + e^x} \tag{2}$$

Ezt követően definiálásra került $\pi(x) = P(y = 1|x)$, amely a következő:

$$\pi_{(x)} = \frac{e^{\beta_0 + \beta_1x_1 + \dots + \beta_kx_k}}{1 + e^{\beta_0 + \beta_1x_1 + \dots + \beta_kx_k}} \tag{3}$$

Majd a log-likelihood függvény maximalizálásával becsljük az együtthatókat. Brimacombe (2016) szerint a log-likelihood a bemeneti adatokra való illesztésének a mértéke, valamint azt mutatja, mennyire valószínű, hogy a modell előrejelzi a megfigyelt adatokat.

Wilkinson et al. (2022) szerint az esélyhányadosok (odds ratios) hasznosak a logisztikus regresszió eredményeinek az értelmezésében. Az esélyhányadosok segítségével könnyebben lehet értelmezni, hogy a különböző független változók milyen mértékben és irányban befolyásolják a nemteljesítési valószínűséget. A β_j együttható esélyhányadosa a következőképpen számítható ki:

$$OR_j = \frac{P(y = 0|x_j + 1)}{P(y = 1|x_j + 1)} \div \frac{P(y = 0|x_j)}{P(y = 1|x_j)} = e^{\beta_j} \tag{4}$$

Az esélyhányadosok megmutatják, hogy egy egységnyi növekedés az x_j független változóban hogyan befolyásolja az esélyeket, annak érdekében, hogy a függő változó y értéke 1 legyen. Ha az esélyhányados nagyobb, mint 1, akkor a növekedés az x_j változóban fogja növelni annak az esélyét, hogy $y=1$ legyen. Ha az esélyhányados kisebb, mint 1, akkor a növekedés az x_j változóban csökkenteni fogja az esélyét annak, hogy $y=1$ legyen.

Döntési fa

Chang et al. (2022) szerint a döntési fa egy prediktív modell, amely egy fa struktúráját használja az adatok osztályozására vagy regressziójára. A döntési fa kezdetben egy gyökér csomópontból indul ki, amely tartalmazza az összes rendelkezésre álló adatot. Ezután az algoritmus kiválaszt egy attribútumot, amely felhasználva felosztja az adatokat különböző ágakra. A felosztások az attribútum értékétől függenek, és ezzel a fa növekszik, ahogy haladunk lefelé a gyökértől a levelekig. A döntési fa folytatja az attribútumok felosztását minden új ágon, és rekurzív módon halad lefelé a fa struktúrájában. Amikor elér egy leállási feltételt, például a fa maximális mélységét, az adatok egy bizonyos számú csoportra való felosztását vagy más előre meghatározott feltételeket, akkor leveleket hoz létre. Ezek a levelek tartalmazzák az osztályozás vagy regresszió eredményeit.

Kim et al. (2019) szerint a döntési fa előnyei közé tartozik az egyszerűség és az érthetőség, mivel könnyen értelmezhető és magyarázható az eredménye. Azonban figyelembe kell venni, hogy hajlamos lehet az overfittingre, különösen bonyolult adathalmazokon. Emellett fontos az optimális paraméterezés és a túltanulás elleni védelem alkalmazása annak érdekében, hogy hatékonyan működjön az adott probléma megoldása során.

Véletlen erdő

Teply és Polena (2020) szerint a véletlen erdő egy olyan együttes tanulási módszer, amelynek célja, hogy kezelje azt a problémát, hogy a döntési fák könnyen szabálytalan mintává válnak, ha több elágazásuk van. Ez a jelenség túllillesztéshez vezethet, mivel a variancia minden esetben magas lesz, még akkor is, ha alacsony az eltérés. A véletlen erdők olyan értéket konstruálnak, amelyek minimálisan eltérnek a döntési fáktól, hogy csökkentsék a variancia hatását. Ez a minimális eltérés a mintavételezésben nyilvánul meg. Általánosságban elmondható, hogy több döntési fával az előrejelzések eredményei pontosabbak lehetnek, ami egy jobb modellstabilitást jelent. Ez azonban hosszabb képzési időt is jelent, ezért a modell teljesítményének elérésekor figyelembe vesszük az egyensúlyt a képzési idő és a modell stabilitása között.

A modellek teljesítmények összehasonlítására használt módszerek

A hitelminősítő algoritmusok teljesítményének összehasonlítására és értékelésére több módszer alkalmazható, amelyek segítenek meghatározni, hogy az egyes algoritmusok mennyire pontosak és megbízhatóak a nemteljesítő és jól teljesítő ügyfelek előrejelzésében. Az általam használt módszerek a klasszifikációs mátrix, az AUROC (AUC) és ROC görbe.

A klasszifikációs mátrix négy elemet tartalmaz, amelyek alapján mérhető az algoritmus teljesítménye. Ez a négy elem a következő: az *igaz pozitív arány* (true positive rate) azoknak az ügyfeleknek az aránya, akik ténylegesen nemteljesítők és a modell helyesen azonosította őket; az *igaz negatív arány* (true negative rate) azoknak az ügyfeleknek az aránya, akik ténylegesen teljesítők és a modell helyesen azonosította őket; a *téves pozitív arány* (false positive rate) azoknak az ügyfeleknek az aránya, akik teljesítők, de a modell tévesen nemteljesítőnek minősítette őket; valamint a *téves negatív arány* (false negative rate) azoknak az ügyfeleknek az aránya, akik nemteljesítők, de a modell tévesen teljesítőnek minősítette őket.

A klasszifikációs mátrix alapján kiszámíthatóak a következő mutatók: a *pon-tosság* (accuracy), amely az összes helyesen osztályozott ügyfél aránya az összes ügyfélhez viszonyítva; az *érzékenységi mutató* (sensitivity), amely azt mutatja, hogy a pozitív osztályba tartozó megfigyelések mekkora százaléka van helyesen azonosítva. A *specifitás* (specificity) mutató, ami azt jelzi, hogy a negatív osztályba tartozó megfigyelések hány százalékban lettek helyesen azonosítva.

Shi et al. (2019) szerint az AUROC (AUC), vagyis a Receiver Operating Characteristic (ROC) görbe alatti terület, egy fontos mérőszám a klasszifikációs modellek teljesítményének értékelésére. A ROC görbe az algoritmus érzékenységét (sensitivity) ábrázolja a téves pozitív aránnyal különböző küszöbértékek mellett. A görbe alatti terület (AUC vagy AUROC) azt mutatja meg, hogy az algoritmus mennyire jól tud különbséget tenni a nemteljesítő és a teljesítő ügyfelek között. Ez az érték 0,5 és 1 között mozog, minél kisebb, annál rosszabbul teljesít a modell, minél közelebb van 1-hez, annál jobban teljesít a modell.

Eredmények

A változók közötti összefüggéseket vizsgáltam annak érdekében, hogy megállapítsam, hogy a nemteljesítés változót milyen tényezők befolyásolják. A khi-négyszet próbát használtam a minőségi változók esetén és a t-tesztet a mennyiségi változók esetén. A tesztek eredményei a mellékletben találhatóak. A táblázatban fel van tüntetve a változók neve, a t, illetve a χ^2 statisztika értéke, valamint a szignifikanciaszint (p). Abban az esetben, ha a szignifikanciaszint kisebb 0,05-nél, kapcsolat mutatható ki az adott változó és a nemteljesítés között.

Tanuló és teszt adatbázis

Az adatbázist véletlenszerűen felosztottam tanuló és teszt adatbázisra. A felosztást követően az eredeti adatbázis 70%-a a tanuló adatbázis, 30%-a pedig a teszt adatbázis lett. A tanuló adatbázison történik a modellek becslése, a teljesít-

ményük értékelése pedig a teszt adatbázison. A tanuló adatbázis 9228 jó ügyfelet, valamint 2733 rossz ügyfelet, a teszt adatbázis pedig 3954 jó ügyfelet és 1171 rossz ügyfelet tartalmaz.

Logisztikus regresszió becslése

Első lépésben lépésenkénti (stepwise) logisztikus regressziót becsültem a nemteljesítési valószínűség becslésére a tanuló adatbázison. A stepwise logisztikus regresszió lépésről lépésre döntést hoz arról, hogy mely változókat kell hozzáadni vagy eltávolítani a modellből (Estran et al. 2022). Használata lehetővé teszi a modell automatikus optimalizálását és egyszerűsítését anélkül, hogy manuálisan döntést kellene hozni minden egyes változóról.

5. táblázat: A nemteljesítési valószínűséget befolyásoló tényezők a logisztikus regresszió alapján

Változó	Együttható	Std. hiba	z érték	Pr(> z)	Esélyhányados
Konstans	1,458	0,804	1,813	0,070	–
gradeB	0,456	8,057	4,570	< 0,001	1,578
gradeC	0,765	0,101	7,541	< 0,001	2,149
gradeD	1,036	0,112	9,231	< 0,001	2,818
gradeE	1,214	0,130	9,329	< 0,001	3,367
gradeF	1,275	0,170	7,490	< 0,001	3,579
gradeG	1,440	0,218	6,591	< 0,001	4,220
num_actv_rev_tl	0,081	0,009	8,470	< 0,001	1,084
home_ownershipJelzalog	-0,405	0,052	-7,677	< 0,001	0,667
term 60 months	0,436	0,061	7,087	< 0,001	1,546
total_rev_hi_lim	-0,004	< 0,001	-5,424	< 0,001	0,996
loan_amnt	< 0,001	< 0,001	7,705	< 0,001	1,000
annual_inc	-0,046	< 0,001	-4,727	< 0,001	0,955
fico_range_low	-0,005	0,001	-5,664	< 0,001	0,995
inq_last_6mths	0,107	0,026	4,045	< 0,001	1,113
Dti	0,010	0,003	3,452	< 0,001	1,010
verification_statusSource Verified	0,149	0,057	2,606	0,009	1,161
verification_statusVerified	0,162	0,065	2,468	0,014	1,176
tax_liens	-0,153	0,072	-2,102	0,036	0,858
purposeSmall_business	1,063	0,319	3,322	0,001	2,894
purposeVacation	0,950	0,343	2,769	0,006	2,586

Forrás: Saját számítás

A minősítés (grade), a jelenleg használt aktív rulirozó hitelszámlák száma (num_actv_rev_tl), a lakástulajdon típusa (home_ownership), a hitel hossza (term), az összes rendelkezésre álló hitelkeret felső határa (total_rev_hi_lim), a

hitel összege (loan_amnt), az éves bevétel (annual_inc), a FICO pontszám legkisebb értéke (fico_range_low), a megkeresések száma (inq_last_6mths), az összes adósságkötelezettség aránya (dti), a jövedelem ellenőrzési állapota (verification_status), az adórtartozások száma (tax_liens), valamint a hitel célja (purpose) változók bizonyultak szignifikánsnak. A logisztikus regresszió eredményeit az 5. táblázat tartalmazza.

A teszt adatbázison teszteltem a logisztikus regresszió előrejelző képességét. Az osztályozási hatékonyságot a klasszifikációs mátrix alapján vizsgáltam. A 6. táblázat a klasszifikációs mátrixot tartalmazza, amely a tényleges és logisztikus regresszió által előrejelzett értékeket mutatja.

6. táblázat: Klasszifikációs mátrix: logisztikus regresszió

Előrejelzett	Tényleges	
	Teljesítés (0)	Nemteljesítés (1)
Teljesítés (0)	1515	140
Nemteljesítés (1)	2439	1031

Forrás: Saját számítás


Az elemzés alapján a pontosság mutató értéke 0,4968, ami azt jelenti, hogy 49,68%-ban helyesen osztályozta az ügyfeleket a logisztikus regresszió. Az érzékenységi mutató 0,3832, ami azt mutatja, hogy a teljesítő osztályba tartozó ügyfelek 38,32%-a helyesen lett azonosítva. A specificitás mutató értéke 0,8804, ami azt jelzi, hogy a nemteljesítő ügyfelek 88,04%-a lett helyesen azonosítva. A pozitív előrejelzési érték 91,54%, míg a negatív előrejelzési érték 29,71%.

A ROC görbe grafikusán ábrázolja az osztályozó modell érzékenységét és specificitását különböző küszöbértékek mellett. A 2. ábra a ROC görbét szemlélteti a logisztikus regresszió esetén. Az AUC, vagyis a görbe alatti terület nagysága 0,6318, tehát a modell egy közepesen jó osztályozásba sorolható.

Ezután a WoE transzformált² adatok segítségével is becsültem a logisztikus regressziót. Stepwise logisztikus regressziót használva megállapítottam, hogy a hitel összege (loan_amnt_woe), a futamidő (term_woe), az al-minősítés (sub_

² A WoE-transzformáció lényege, hogy az adott adathalmazban lévő független változókat csoportokba rendezze a függő változó alapján, ami elősegíti az elemzést és a modellezést (Siddiqi 2012). A WoE-értékek azt mutatják meg, hogy az adott csoporthoz tartozó megfigyelések mennyire hordoznak információt a függő változó valószínűségének szempontjából. Minél magasabb a WoE-érték, annál jelentősebb és fontosabb információval rendelkezik a csoport az előrejelzések esetén.

grade_woe), a munkaviszony hossza (emp_length_woe), a lakástulajdon típusa (home_ownership_woe), az éves jövedelem (annual_inc_woe), a jövedelem ellenőrzési állapota (verification_status_woe), a lakhely (addr_state_woe), az összes adóssághkötelezettség aránya (dti_woe), a legkorábbi bejelentett hitelkeret (earliest_cr_line_woe), a FICO-pontszám legkisebb értéke (fico_range_low_woe), a megkeresések száma (inq_last_6mths_woe), a hitelkeretek száma (total_acc_woe), az összes rendelkezésre álló hitelkeret felső határa (total_rev_hi_lim_woe), valamint a hitelfelvevő által jelenleg használt aktív rulórozó hitelszámlák száma (num_actv_rev_tl_woe) bizonyultak szignifikánsnak a nemteljesítés előrejelzésében. Az eredmények a 7. táblázatban láthatóak.



Forrás: Saját szerkesztés

2. ábra: ROC görbe: logisztikus regresszió

7. táblázat: A nemteljesítési valószínűséget befolyásoló tényezők
WoE-transzformációval

Változó	Együttható	Std. hiba	Z érték	Pr(> z)
Konstans	-1,217	0,023	-51,574	< 0,001
loan_amnt_woe	0,908	0,115	7,890	< 0,001
term_woe	0,439	0,080	5,461	< 0,001
sub_grade_woe	0,469	0,087	5,366	< 0,001
emp_length_woe	0,489	0,248	1,969	< 0,001
home_ownership_woe	0,943	0,122	7,713	< 0,001
annual_inc_woe	0,747	0,169	4,421	< 0,001
verification_status_woe	0,261	0,094	2,770	< 0,001
addr_state_woe	0,879	0,238	3,681	< 0,001
dti_woe	0,467	0,110	4,251	< 0,001
earliest_cr_line_woe	0,649	0,222	2,914	< 0,001
fico_range_low_woe	0,203	0,086	2,341	< 0,001

Változó	Együttható	Std. hiba	Z érték	Pr(> z)
inq_last_6mths_woe	0,564	0,123	4,568	< 0,001
total_acc_woe	1,142	0,293	3,895	< 0,001
total_rev_hi_lim_woe	0,763	0,215	3,537	< 0,001
num_actv_rev_tl_woe	0,697	0,148	4,701	< 0,001

Forrás: Saját számítás

A 8. táblázatban a WoE-transzformációval becsült logisztikus regresszió teljesítménye látható a klasszifikációs mátrix alapján.


**8. táblázat: Klasszifikációs mátrix: logisztikus regresszió
WoE-transzformációval**

Előrejelzett	Tényleges	
	Teljesítés (0)	Nemteljesítés (1)
Teljesítés (0)	1552	147
Nemteljesítés (1)	2402	1024

Forrás: Saját számítás

Az elemzés alapján 50,26%-ban helyesen osztályozta az ügyfeleket a logisztikus regresszió WoE-transzformációval. A teljesítő ügyfelek 39,25%-a, míg a nemteljesítő ügyfelek 87,45%-a lett helyesen azonosítva a modell által. A pozitív előrejelzési érték 91,35%, míg a negatív előrejelzési érték 29,89%.

Az AUC értéke 0,6335, tehát a modell hasonlóan különbözteti meg a teljesítő és nemteljesítő ügyfeleket az adott adathalmazon, mint a nem transzformált adatokon becsült logisztikus regresszió. A ROC görbe a 3. ábrán látható.



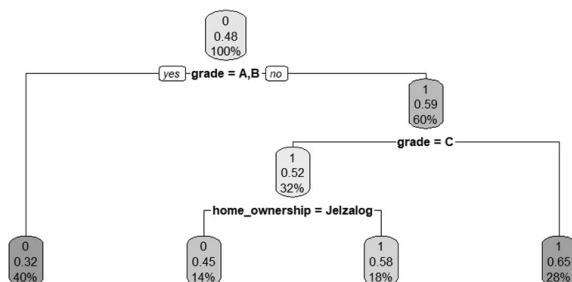
Forrás: Saját szerkesztés

3. ábra: ROC görbe: logisztikus regresszió WoE-transzformációval

Döntési fa

A döntési fát alul-mintavételezéssel használtam az első lépésben. Moscato et al. (2021) szerint az alul-mintavételezés kiegyensúlyozottabbá teszi az adatokat, ami segíti abban, hogy ne csak a többségi osztályra optimalizáljon. Ez javítja a modell pontosságát, az osztályozó helyes előrejelzéseinek aránya sokkal pontosabb lesz. Létrehoztam az alul-mintavételezett tanuló adatbázist, amelyben 2951 jó ügyfél, valamint 2733 rossz ügyfél volt.

Meghatároztam az X-relative error értékét is, amely megmutatja, hogy a keresztvalidáció során mért elemzés szerint a fa mennyire teljesít jól az adott adathalmazon. Minél kisebb az érték, annál jobban általánosítható a kapott döntési fa. Ezt követően a kapott értékkel metszettem a döntési fát, eredményképpen azt kaptam, hogy amennyiben a hitel A vagy B minősítésbe lett besorolva, a nemteljesítés valószínűsége 0,32, tehát 32% volt. A C minősítésű hitelek esetén a lakástulajdon változó is figyelembe lesz véve. A CP-értékkel metszett döntési fa a 4. ábrán figyelhető meg.



Forrás: Saját szerkesztés

4. ábra: Metszett alul-mintavételezett döntési fa


A teszt adatbázison teszteltem az alul-mintavételezett döntési fa előrejelző képességét klasszifikációs mátrixszal. Az eredmények a 9. táblázatban találhatóak.

9. táblázat: Klasszifikációs mátrix: alul-mintavételezett döntési fa

Előrejelzett	Tényleges	
	Teljesítés (0)	Nemteljesítés (1)
Teljesítés (0)	2615	442
Nemteljesítés (1)	1339	729

Forrás: Saját szerkesztés

65,25%-ban helyesen osztályozta az ügyfeleket az alul-mintavételezett döntési fa. A teljesítő ügyfelek 62,25%-a, a nemteljesítő osztályba tartozó ügyfelek 66,14%-a lett helyesen azonosítva. A klasszifikációs mátrix után megrajzoltam a ROC görbét, amely az 5. ábrán látható. Az AUC értéke 0,642, tehát a modell egy közepesen jó osztályozásba sorolható.



Forrás: Saját szerkesztés

5. ábra: ROC görbe: döntési fa alul-mintavételezéssel

Shi et al. (2019) szerint a veszteségmátrix egy olyan technika, amely figyelembe veszi az osztályozási hibák költségeit a modell építése során. Ez igen hasznos egyensúlyhiányos adatkészletek esetén, ahol az egyes osztályok előrejelzési hibái különböző mértékű költségekkel járhatnak. Három különböző költségértéket határoztam meg: amennyiben helyes a besorolás a döntési fán belül, a költség 0, amennyiben egy rossz hitelről van szó, ami jó besorolást kapott, a költség 10 lesz. A harmadik esetben, amennyiben van egy jó hitel, viszont ez rosszként van besorolva, a költség egyenlő lesz 1-gyel.

A döntési fa esetében a minősítés (grade), a rendelkezésre álló, fel nem használt hitelkeret összegének aránya a bankkártyák esetében (bc_open_to_buy), az összes rendelkezésre álló hitelkeret felső határa (total_rev_hi_lim), a munkaviszony hossza (emp_length), a FICO-pontszám legkisebb értéke (fico_range_low), valamint a hitelfeltevő által felhasznált hitelösszeg az összes rendelkezésre álló rülirozó hitelhez viszonyítva (revol_util) változók alsó határai a legfontosabbak a nemteljesítés előrejelzésében. A veszteségmátrix segítségével meghatározott dön-


tési fa előrejelzési képességének vizsgálatához a klasszifikációs mátrixot használtam. A 10. táblázatban láthatóak az eredmények.

10. táblázat: Klasszifikációs mátrix: döntési fa a veszteségmátrix bevonásával

Előrejelzett	Tényleges	
	Teljesítés (0)	Nemteljesítés (1)
Teljesítés (0)	2615	442
Nemteljesítés (1)	1339	729

Forrás: Saját szerkesztés

Az elemzés alapján 65,25%-ban helyesen osztályozta az ügyfeleket a döntési fa. Az érzékenység mutató 0,6225, a specificitás mutató értéke 0,6614. A pozitív előrejelzési érték 35,25%, míg a negatív előrejelzési érték 85,54%. A 6. ábra a ROC görbét mutatja a döntési fa esetében. Az AUC, vagyis a görbe alatti terület 0,5866, tehát a modell egy gyenge osztályozásba sorolható.

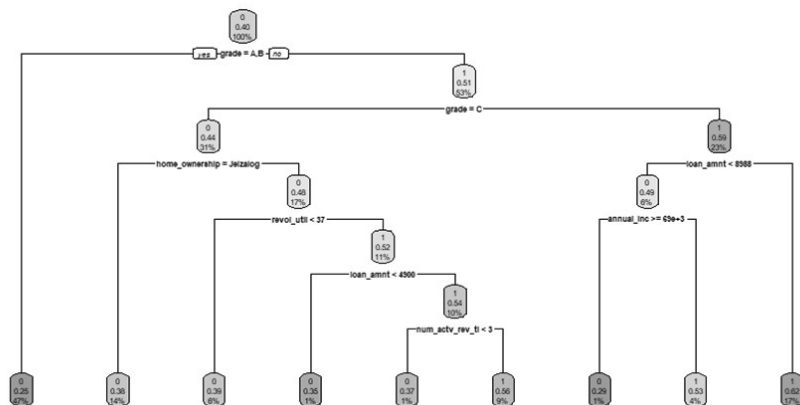


Forrás: Saját szerkesztés

6. ábra. ROC görbe: döntési fa veszteségmátrix bevonásával

Ezek után elkészítettem a döntési fát előzetes valószínűségek megadásával. Az előzetes valószínűségek megváltoztatásával becsült metszett döntési fa a 7. ábrán figyelhető meg. Az A vagy B csoportba sorolt ügyfelek esetén a nemteljesítési valószínűség 0,25. A nemteljesítési valószínűsége a D, E, F, G minősítésű

hiteleknek 0,53 abban az esetben, ha a hitel összege (loan_amnt) kisebb, mint 8988 USD, valamint az éves bevétel (annual_inc) kisebb, mint 68 500 USD.



Forrás: Saját szerkesztés

7. ábra: Döntési fa előzetes valószínűségek megváltoztatásával

A 11. táblázatban látható a döntési fa esetén a klasszifikációs mátrix.


11. táblázat: Klasszifikációs mátrix: döntési fa előzetes valószínűségek megváltoztatásával

Előrejelzett	Tényleges	
	Teljesítés (0)	Nemteljesítés (1)
Teljesítés (0)	2939	558
Nemteljesítés (1)	1015	613

Forrás: Saját szerkesztés

A döntési fa 69,31%-ban helyesen osztályozta az ügyfeleket. A teljesítő ügyfelek 52,35%-a helyesen lett azonosítva. A specificitás mutató értéke 0,7433, ami azt jelzi, hogy a nemteljesítő ügyfelek 74,33%-a lett helyesen azonosítva. A pozitív előrejelzési érték 37,65%, míg a negatív előrejelzési érték 84,04%. A ROC görbe a 8. ábrán látható.

Az AUC értéke 0,6334, azaz a modellt egy közepesen jó osztályozásba sorolható. Tehát az előzetes valószínűségek megváltoztatásával készült döntési fa esetén jobb eredményt kaptam, mint a veszteségmátrix bevonása esetén, de rosszabb eredményt, mint az alul-mintavételezés során.



Forrás: Saját szerkesztés

8. ábra: ROC görbe: döntési fa előzetes valószínűségek megváltoztatásával

Véletlen erdő

A véletlen erdő 500 döntési fa felhasználásával lett kialakítva, és az OOB (out-of-bag) becslés a hibaarányra 22,44%. Az out-of-bag becslés lényege, hogy a modellezés folyamán minden döntési fa csak azokat az adatokat használja fel a tanításhoz, amelyek nem kerültek bele az adott fa mintavételezésébe. Ezután az adott fa algoritmus kihagyott adatpontokon történő előrejelzéseit összesíti és ezáltal kap egy átlagos becslést a modell teljesítményére, anélkül, hogy külön validációs adathalmazt kellene létrehozni (Dzik-Walczak–Heba 2021). A teljesítő ügyfelek esetében a klasszifikációs hiba 11,81%, míg a nemteljesítő ügyfelek esetében 88,19% volt. A klasszifikációs mátrix a 12. táblázatban látható.


12. táblázat: Klasszifikációs mátrix: véletlen erdő

Előrejelzett	Tényleges	
	Teljesítés (0)	Nemteljesítés (1)
Teljesítés (0)	3886	1093
Nemteljesítés (1)	68	78

Forrás: Saját szerkesztés

A véletlen erdő 77,40%-ban helyesen osztályozta az ügyfeleket. A nemteljesítő ügyfelek 6,66%-a, a teljesítő ügyfelek 98,28%-a lett helyesen azonosítva.


Az AUC értéke 0,7009, tehát a modell egy jó osztályozásba sorolható. A 9. ábra a ROC görbét mutatja a véletlen erdő esetén.



Forrás: Saját szerkesztés

9. ábra: ROC görbe: véletlen erdő

Annak érdekében, hogy jobban össze lehessen hasonlítani a modelleket, a 10. ábrán látható az összes becült modell ROC görbéje.



Forrás: Saját szerkesztés

10. ábra: ROC görbék: összehasonlítás

A klasszifikációs mátrix, valamint a ROC görbe alapján arra a következtetésre jutottam, hogy a véletlen erdő a legjobban teljesítő modell az elemzettek közül. A 13. táblázat tartalmazza az összefoglaló statisztikákat.

13. táblázat: Összefoglaló táblázat

Modell neve	Pontosság	Érzékenység	Specifititás	PPV	NPV	AUC
Logisztikus regresszió	49,680%	38,320%	88,040%	91,540%	29,710%	0,631
Logisztikus-regresszió: WoE-transzformációval	50,260%	39,250%	87,450%	91,350%	29,890%	0,633
Alul-mintavételezett döntési fa	65,250%	62,250%	66,140%	35,250%	85,540%	0,642
Döntési fa a vesztésmátrix bevonásával	65,250%	62,250%	66,140%	35,250%	85,540%	0,586
Döntési fa előzetes valószínűségek megváltoztatásával	69,310%	52,350%	74,330%	37,650%	84,040%	0,633
Véletlen erdő	77,400%	6,660%	98,280%	53,450%	78,040%	0,700

Forrás: Saját számítás

Következtetések

A P2P-hitelezés egyre népszerűbbé válik mind a hitelfelvevők, mind a hitelezők számára. Az egyedi hitelkérelmek növekedésével egyre fontosabb lesz a hitelkockázat értékelése. A hagyományos módszereket használók egyre nagyobb kihívásokkal szembesülnek a változó gazdasági környezet és az adatok bősége miatt. Az új technológiák jó alternatívát kínálnak a hagyományos modellek mellett. A tanulmány azt vizsgálja, hogy az új technológiák képesek-e javítani a hitelminősítő intézmények hatékonyságát és eredményességét a hitelezési döntéshozatal folyamatában.

Klasszifikációs mátrix és ROC görbe, valamint AUROC segítségével vizsgáltam a logisztikus regresszió, döntési fa és véletlen erdő teljesítményét. Az eredmények alapján a véletlen erdő teljesített a legjobban.

A kutatás egyik korlátja a felhasznált adathalmaz minősége és mérete, amely befolyásolhatja az algoritmusok pontosságát és általánosíthatóságát. Az eredmények alátámasztják, hogy a különböző algoritmusok paraméterezése és finomhangolása szintén jelentős hatással van az eredményekre, amelyeket a hitelminősítési folyamatok optimalizálására és automatizálására lehet felhasználni, különösen a pénzügyi intézményeknél, amelyek számára fontos a kockázatkezelés és a hitelképesség pontos értékelése. A mesterséges intelligencia alapú algoritmusok alkalmazása növelheti a prediktív pontosságot és hatékonyságot, ezáltal javítva a pénzügyi döntéshozatal minőségét.

A tanulmány eredményeit összehasonlítottam a más cikkekben lévő eredményekkel. Az AUC legjobb értéke 0,700 a véletlen erdő esetén volt az elemzésben. A szakirodalomban, főként a modern gépi tanulási modelleknél gyakran találkozhatunk ennél magasabb AUC-értékekkel, akár 0,8 vagy magasabb is lehet egy jól optimalizált modell esetében. Ez arra utalhat, hogy a modell érzékenysége (sensitivity) és specifikitása (specificity) nem a legoptimálisabb. A véletlen erdő modellnél mért 77,40%-os pontosság közelíti a cikkek eredményeihez, de magasabb értékek is elérhetők megfelelő adatkezeléssel és modell-finomhangolással. A szakirodalomban gyakran találni olyan modelleket, amelyeknél a pontosság 80% fölött van, különösen kiegyensúlyozott adatok esetén. A logisztikus regressziónál és a döntési fáknál az érzékenység értékei viszonylag alacsonyak (38–66% körüliek), míg a specifikusság viszonylag magas. A szakirodalomban előfordul, hogy a kiegyensúlyozott adatok alapján felépített modelleknél mindkét érték magasabb, jelezve, hogy a modellek jobban tudják azonosítani mind a pozitív, mind a negatív osztályokat.

A kutatás javítható az adathalmaz méretének növelésével. Nagyobb adatbázis esetén a mintázatok jobb felismerésére képesek a modellek, ami javíthatja a modell teljesítményét. Az adatok kiegyensúlyozása, például felül-mintavételezés, alul-mintavételezés vagy szintetikus adatok generálása által javíthatja a modell érzékenységét. Fejlettebb modellek alkalmazása is segíthet a pontosság növelésén, a mélytanulási technikák, például a transzformer alapú modellek, sokszor jobban teljesítenek komplex mintázatok felismerésében. A hagyományos modellek fejlett algoritmusokkal való kombinálása is vezethet az eredmények pontosságának növeléséhez.

Irodalomjegyzék

Ágoston, N. 2022a. Mesterséges intelligencia és gépi tanulási módszerek a vállalati fizetési képesség becslésére. *Statisztikai Szemle* 100(6), 584–609. <https://doi.org/10.20311/stat2022.6.hu0584>

Ágoston, N. 2022b. Külföldi csődelőrejelző módszerek szisztematikus irodalomelemzése. *Vezetéstudomány* 53(1), 69–89. <https://doi.org/10.14267/VEZTUD.2022.01.06>

Ahmed, S. E. 2023. Determinants of Credit Ratings and Comparison of the Rating Prediction Performances of Machine Learning Algorithms. *In E3S Web of Conferences* 409, 05013. EDP Sciences. <https://doi.org/10.1051/e3sconf/202340905013>

Alonso Robisco, A.–Carbo Martinez, J. M. 2022. Measuring the model risk-adjusted performance of machine learning algorithms in credit default prediction. *Financial Innovation* 8(1), 70. <https://doi.org/10.1186/s40854-022-00366-1>

Berger, E. A.–Butler, A. W.–Hu, E.–Zekhnini, M. 2021. Financial integration and credit democratization: Linking banking deregulation to economic growth. *Journal of Financial Intermediation* 45, 100857. <https://doi.org/10.1016/j.jfi.2020.100857>

Brimacombe, M. 2016. Large sample convergence diagnostics for likelihood based inference: Logistic regression. *Statistical Methodology* 33, 114–130. <https://doi.org/10.1016/j.stamet.2016.08.001>

Chang, A. H.–Yang, L. K.–Tsaih, R. H.–Lin, S. K. 2022. Machine learning and artificial neural networks to construct P2P lending credit-scoring model: *A case using Lending Club data*. *Quantitative Finance and Economics* 6(2), 303–325. <https://doi.org/10.3934/QFE.2022013>

Dumitrescu, E.–Hué, S.–Hurlin, C.–Tokpavi, S. 2022. Machine learning for credit scoring: Improving logistic regression with non-linear decision-tree effects. *European Journal of Operational Research* 297(3), 1178–1192. <https://doi.org/10.1016/j.ejor.2021.06.053>

Dzik-Walczak, A.–Heba, M. 2021. An implementation of ensemble methods, logistic regression, and neural network for default prediction in Peer-to-Peer lending. *Zbornik radova Ekonomskog fakulteta u Rijeci: časopis za ekonomsku teoriju i praksu* 39(1), 163–197.

Estran, R.–Souchaud, A.–Abitbol, D. 2022. Using a genetic algorithm to optimize an expert credit rating model. *Expert Systems with Applications* 203, 117506. <https://doi.org/10.1016/j.eswa.2022.117506>

Fraisse, H.–Laporte, M. 2022. Return on investment on artificial intelligence: The case of bank capital requirement. *Journal of Banking & Finance* 138, 106401. <https://doi.org/10.1016/j.jbankfin.2022.106401>

Jagtiani, J.–Lemieux, C. 2019. The roles of alternative data and machine learning in fintech lending: evidence from the LendingClub consumer platform. *Financial Management* 48(4), 1009–1029. <https://doi.org/10.1111/fima.12295>

Kgoroadira, R.–Burke, A.–Di Pietro, F.–van Stel, A. 2023. Determinants of firms' default on unsecured loans in the P2P crowdfunding market. *Journal of International Financial Markets, Institutions and Money* 89, 101882. <https://doi.org/10.1016/j.intfin.2023.101882>

Milne, A.–Parboteeah, P. 2016. The Business Models and Economics of Peer-to-Peer Lending, *ECRI Papers* 11594, Centre for European Policy Studies.

Moscato, V.–Picariello, A.–Sperlí, G. 2021. A benchmark of machine learning approaches for credit score prediction. *Expert Systems with Applications* 165, 113986. <https://doi.org/10.1016/j.eswa.2020.113986>

Pang, S.–Hou, X.–Xia, L. (2021). Borrowers' credit quality scoring model and applications, with default discriminant analysis based on the extreme learning machine. *Technological Forecasting and Social Change* 165, 120462. <https://doi.org/10.1016/j.techfore.2020.120462>

Rudin, C. 2019. Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead. *Nature machine intelligence* 1(5), 206–215. <https://doi.org/10.1038/s42256-019-0048-x>

Shen, F.–Zhao, X.–Kou, G.–Alsaadi, F. E. 2021. A new deep learning ensemble credit risk evaluation model with an improved synthetic minority oversampling technique. *Applied Soft Computing* 98, 106852. <https://doi.org/10.1016/j.asoc.2020.106852>

Shi, B.–Zhao, X.–Wu, B.–Dong, Y. 2019. Credit rating and microfinance lending decisions based on loss given default (LGD). *Finance Research Letters* 30, 124–129. <https://doi.org/10.1016/j.frl.2019.03.033>

Siddiqi, N. 2012. *Credit risk scorecards: developing and implementing intelligent credit scoring* Vol. 3. John Wiley & Sons.

Song, Y.–Wang, Y.–Ye, X.–Zaretski, R.–Liu, C. 2023. Loan default prediction using a credit rating-specific and multi-objective ensemble learning scheme. *Information Sciences* 629, 599–617. <https://doi.org/10.1016/j.ins.2023.02.014>

Stern, C.–Makinen, M.–Qian, Z. 2017. FinTechs in China—with a special focus on peer to peer lending. *Journal of Chinese Economic and Foreign Trade Studies* 10(3), 215–228. <https://doi.org/10.1108/JCEFTS-06-2017-0015>

TePLY, P.–Polena, M. 2020. Best classification algorithms in peer-to-peer lending. *The North American Journal of Economics and Finance* 51, 100904. <https://doi.org/10.1016/j.najef.2019.01.001>

Wang, D.–Chen, Z.–Florescu, I.–Wen, B. 2023. A sparsity algorithm for finding optimal counterfactual explanations: Application to corporate credit rating. *Research in International Business and Finance* 64, 101869. <https://doi.org/10.1016/j.ribaf.2022.101869>

Wang, C.–Xiao, Z. 2022. A deep learning approach for credit scoring using feature embedded Transformer. *Applied Sciences* 12(21), 10995. <https://doi.org/10.3390/app122110995>

Wang, H.–Kou, G.–Peng, Y. 2021. Multi-class misclassification cost matrix for credit ratings in peer-to-peer lending. *Journal of the Operational Research Society* 72(4), 923–934. <https://doi.org/10.1080/01605682.2019.1705193>

Wang, K.–Li, M.–Cheng, J.–Zhou, X.–Li, G. 2022. Research on personal credit risk evaluation based on XGBoost. *Procedia computer science* 199, 1128–1135. <https://doi.org/10.1016/j.procs.2022.01.143>

Wilkinson, J. D.–Mamas, M. A.–Kontopantelis, E. 2022. Logistic regression frequently outperformed propensity score methods, especially for large datasets: a simulation study. *Journal of Clinical Epidemiology* 152, 176–184. <https://doi.org/10.1016/j.jclinepi.2022.09.009>

Xia, Y.–Liu, C.–Li, Y.–Liu, N. 2017. A boosted decision tree approach using Bayesian hyper-parameter optimization for credit scoring. *Expert Systems with Applications* 78, 225–241. <https://doi.org/10.1016/j.eswa.2017.02.017>

Zhao, C.–Li, M.–Wang, J.–Ma, S. 2021. The mechanism of credit risk contagion among internet P2P lending platforms based on a SEIR model with time-lag. *Research in International Business and Finance* 57, 101407. <https://doi.org/10.1016/j.ribaf.2021.101407>

Zhou, J.–Li, W.–Wang, J.–Ding, S.–Xia, C. 2019. Default prediction in P2P lending from high-dimensional data based on machine learning. *Physica A: Statistical Mechanics and its Applications* 534, 122370. <https://doi.org/10.1016/j.physa.2019.122370>

Melléklet: A változók közötti kapcsolat elemzése

Változó	t-statisztika	p
loan_amnt	-12,013	< 0,001
annual_income	7,831	< 0,001
Dti	-12,760	< 0,001
fico_range_low	22,491	< 0,001
fico_range_high	22,491	< 0,001
revol_util	-12,148	< 0,001
total_acc	2,348	0,018
total_rev_hi_lim	9,697	< 0,001
bc_open_to_buy	15,852	< 0,001
mo_sin_rev_tl_op	8,072	< 0,001
total_cu_tl	-11,336	< 0,001
pub_rec_bankruptcies	-2,912	0,003
delinq_2yrs	-3,032	0,002
inq_last_6mths	-10,203	< 0,001
open_acc	-3,092	< 0,001
pub_rec	-1,321	0,186
acc_now_delinq	-1,065	0,287
total_cu_tl	1,570	0,116
chargeoff_within_12_mths	0,743	0,457
num_actv_rev_tl	-12,329	< 0,001
num_il_tl	0,215	0,831
num_op_rev_tl	-4,592	< 0,001
num_tl_op_past_12m	-8,799	< 0,001
Változó	χ^2	p
term (futamidő)	372,500	< 0,001
grade (minősítés)	1231,700	< 0,001
sub_grade (alminősítés)	1323,600	< 0,001
emp_length (régiség)	30,710	< 0,001
home_ownership (lakástulajdon)	120,721	< 0,001
verification_status (ellenőrzési állapot)	192,231	< 0,001
purpose (cél)	79,332	< 0,001
addr_state (lakhely)	103,413	< 0,001

Forrás: saját szerkesztés

RMKT-hírek

RMKT országos szervezet

Pénzmágus gazdasági vetélkedő

A Pénzmágus vetélkedő egy háromfordulós gazdasági/pénzügyi/üzleti vetélkedő, amelynek célja, hogy fejlessze a középiskolás hallgatók gazdasági ismereteit, illetve ne csak az ismereteit, hanem az üzleti készségeket, gondolkodásmódot is megalapozza.

A vetélkedő 2023-ban január 25. és április 23. között zajlott. Összesen 504 diákot mozgató meg 10 különböző megyéből, 44 iskolából. 126 négyfős csapat jelentkezett a vetélkedőre. Az első fordulóban a csapatoknak egy közgazdasági fókuszú kérdésekből álló feladatsort kellett megoldani. A továbbjutók egy esettanulmánnyal találták magukat szembe a következő fordulóban. A szejkefürdői Mini Erdély Parkot felölelő esettanulmányra beérkezett legjobb megoldásokat nyújtó csapatok elnyerték annak jogát, hogy élőben, szakmai zsűri előtt bemutathassák megoldásukat. A regionális döntők négy helyszínen zajlottak: Nagyvárad, Kolozsvár, Marosvásárhely, valamint Csíkszereda. A legjobb tíz csapat (két-két csapat a csíkszeredai Márton Áron Főgimnáziumból, a székelyudvarhelyi Baczkamadarasi Kis Gergely Református Kollégiumból és a szatmárnémeti Kölcsey Ferenc Főgimnáziumból, valamint egy-egy csapat a csíkszeredai Joannes Kájoni Szakközépiskolából, a gyergyószentmiklósi Salamon Ernő Gimnáziumból, az aradi Csiky Gergely Főgimnáziumból és a nagyváradai Mihai Eminescu Főgimnáziumból) mérhette össze tudását a csíkszeredai Szuperdöntőben április 22–23-án, ahol helyben kellett kidolgozniuk, majd bemutatniuk egy újabb esettanulmányt. A vetélkedőt a Baczkamadarasi Kis Gergely Református Kollégium DreamFlow nevű csapata (Antonya Zsombor, Kacsó Nimród, Ferenc Bettina és Szilágyi Mónika-Mária, felkészítő tanár Lőrincz Edit) nyerte meg.

II. Erdélyi Vállalkozói Iskola

Az Erdélyi Vállalkozói Iskolát 2021-ben indítottuk el két partnerszervezettel, a Harghita Business Center és a Műhely – L' Atelier egyesülettel társulva. A képzés célja, hogy erdélyi magyar fiatal vállalkozóknak segítsünk a saját vállalkozásaik és a vezetői képességeik fejlesztésében. 2023-ban azokat a vállalkozókat céloztuk meg, akik már túl vannak a kezdeti nehézségeken, sikeres vállalkozást működtetnek, és készen állnak egy magasabb szintre emelni azt. A 21 jelentkezőből a zsűri választotta ki azt a 15 résztvevőt, akik a legeredményesebben tudnák hasznosítani a tanul-

takat. A képzéssorozat négy hétvégét ölelt fel. Az első hétvégén, Csíkszeredában Gyerkó Elena business coach, Kemény Dénes és Bali György (a Kemény Dénes Vezetői Akadémia trénerai), valamint Nagy Károly (a Promelek cég vezérigazgatója és az RMKT elnöke) segítségével a leadership, a vezetői képességek fejlesztése volt a középpontban. A második hétvégén Budapestre látogattak el a résztvevők, ahol betekintést nyerhettek sikeres magyar startup cégek világába. A harmadik hétvége Bukarestben zajlott, arra biztatva a résztvevőket, hogy merjenek kilépni Erdély határain túlra. Sikeres nagyvállalkozók osztották meg tapasztalataikat és válaszoltak a résztvevők kérdéseire: Iulian Stanciu (az eMAG ügyvezető igazgatója), Dragoş Petrescu (a City Grill étteremlánc alapítója), Dan Ştefan (az Autonom cég társalapítója), valamint Gruia Stoica (a Grampet vállalatcsoport tulajdonosa). Emellett egyéni mentori beszélgetések kínáltak lehetőséget minden résztvevőnek az őt érintő sajátos kérdések megválaszolására. A negyedik hétvégén az üzleti protokoll és a tárgyalástechnika terén fejleszthették képességeiket a résztvevők.

Területi elnökök találkozója

Az RMKT területi szervezeteinek vezetői évente két alkalommal találkoznak, hogy beszámoljanak az elmúlt időszak eseményeiről, és megbeszéljék a következő időszak tennivalóit. Az első találkozóra március 10–11-én került sor Szóvátán. A program csapatépítő foglalkozással kezdődött, hogy megerősítsük az új elnökség és a területek közötti együttműködést, és jobban megismerjük egymást. A második napon került sor a tényleges megbeszélésre. Minden területi vezető beszámolt helyi csapatuk terveiről és kihívásairól. Fontos teendőként határoztuk meg a kommunikáció hatékonyabbá tételét, a tevékenység összehangolását, az alapszabály megreformálását a hatékonyabb működés érdekében. A második találkozó helyszíne Tusnádfürdő volt, időpontja július 20-a. Itt a fő téma a XXXII. Közgazdász Vándorgyűlés szervezése volt.

XXXII. Közgazdász Vándorgyűlés

A Romániai Magyar Közgazdász Társaság éves legnagyobb rendezvénye a Vándorgyűlés, melyet 2023-ban XXXII. alkalommal szerveztünk meg, Marosvásárhelyen, október 13–14. között, *Változó gazdasági paradigmák és lehetőségek. Makrogazdaságtól a mesterséges intelligenciáig* címmel. A főszerző a külön jogi személyiséggel rendelkező marosvásárhelyi RMKT-fiókszervezet volt, az országos szervezet támogatásával. Az idei eseményen közel 300 résztvevő volt jelen Erdély számos településéről, valamint Magyarországról. Az érdeklődők hét plenáris előadás és négy szekció keretében tájékozódhattak a gazdaság aktuális kérdéseiről.

RMKT Bukarest

Március 29-én, a *10 éves születésnap és szakmai est* alkalmával Bálint Csaba, a Román Nemzeti Bank vezetőtanácsa tagjának segítségével egy mélyreható makrogazdasági elemzést hallgathattak meg a résztvevők.

Május 24-én Birtalan József, a Pénzügyi Felügyelő Hatóság (ASF) Vezetőtanácsának tagjának előadásán vehettek részt az érdeklődők, amelynek címe *A Pénzügyi Felügyelő Hatóság tevékenysége és a nem banki pénzügyi piac működése* volt.

RMKT Csíkszereda***BizniszVitamin***

Február 9-én Lázár Anna és Fülöp Árpád Zoltán előadásán vehettek részt az érdeklődők, amelynek címe *Adózás 2023 – Mi lesz másképp idén?*

Március 30-án Márton Zoltán, a Raiffeisen Bank helyi fiókvezetője volt a BizniszVitamin előadója, előadásának címe *IMM Invest Plus kormányprogram*.

Május 24-én *Tanulhatunk-e valamit a multiktól?* címmel István Csilla Mária és Juhász-Borsa Róbert Dávid tartott előadást az érdeklődőknek.

Augusztus 5-én újabb Bizniszvitaminra került sor, *Ember, robotok és az elme kapcsolata* címmel. A Fukuokából érkező, Csíkszeredában nevelkedett Petra Tsubaki M. D. (a Kyushu Egyetem Művészetek és Tudományok Kar Ember-Környezet Tanulmányok Tanszékének kutatója) bemutatta, hogyan formálódik az ember, a robotok és az elme közötti kapcsolat a japán mesterséges intelligencia innovációktól az etikai szempontokig, és mindez milyen társadalmi következményekkel járhat.

RMKT Kolozsvár***Közgazdász Borklub***

Február 2-án Galambos Márton, a *Forbes Magyarország* főszerkesztője *Tényleg lehet független üzleti újságot csinálni Magyarországon?* címmel adott elő, amelyet bor- és sajtókóstoló követett.

Március 2-án Bitai László pénzügyi elemző *2023: A fekete hattyú egyre fehéredik* címmel tartott előadást. Az előadást sajtótermékek kóstolója követte, borokkal párosítva.

Március 30-án Nagy-Bege Zoltán, az Országos Energiaszabályozó Hatóság (ANRE) alelnöke *Energiaválság: diagnosztika, kezelés, gyógyulás* témában adott elő.

Április 27-én Szélyes Levente, a Codespring CEO-ja vezette be a résztvevőket a csoportdinamika rejtelseibe.

Május 25-én Széll Levente tartott előadást *A zöldségvetőmag nemzetközi kereskedelmi útja* címmel.

Szeptember 28-án Mostis Gergő szakmai előadása volt soron *Moszkvától a Planiig, avagy hogyan lettem sikeresen bukó vállalkozó* címmel.

Október 26-án Diósi László adott elő a menedzsment tudományáról.

November 23-án Hajdó Csaba, az ALT Technologies Transylvania ügyvezető igazgatója *Vállalati digitalizáció, LEAN menedzsment es az ipar 4.0 összefüggései* címmel tartott előadást.

December 14-én dr. Szenkovics Dezső, a Sapientia Tudományegyetem adjunktusa beszélt az *Unipoláris pillanat vs. multipoláris világrendről*.

BizniszVitamin

Január 11-én dr. Fekete P. P. Szilveszter, a BBTE Közgazdaság- és Gazdálkodástudományi Karának adjunktusa, mérlegképes könyvelő, adótanácsadó volt a szakmai előadó. Bemutatóját gasztroelőadás követte.

Február 8-án *Információ vs. dezinformáció* címmel Kozma Dávid tartott előadást.

Március 15-én Bónis Endre, a Reform ingatlanközvetítő iroda ügyvezetője tartott szakmai előadást, amelyet Berke Sándor gasztroelőadása követett *Édes-keserű csokoládé* címmel.

Április 5-én Ilyés Szabolcs György, a RegioConsult ügyvezető igazgatójának szakmai előadására került sor *Mikor pályázzunk és miért?* címmel, melyet Berke Sándor mesterszakács gasztroelőadása követett.

Május 10-én Vincze Tamás, az East Grain csoport vezérigazgatója tartott előadást *A drága élelmiszer nyomában: hogyan alakították át az elmúlt évek változásai a mezőgazdasági termékek piacát?* címmel, ezt követte Berke Sándor *Mindegy nap kenyerünk* című gasztroelőadása.

Június 7-én Berke Sándor mesterszakács tartott gasztroelőadást, Simon Levente szoftverfejlesztő pedig szakmai előadást *ChatGPT, OpenAI és hasonló kulcsszavak* címmel.

November 8-án dr. Fekete P. P. Szilveszter *Adózási reform Romániában, avagy adózási itt a piros, hol a piros* címmel adott elő, a gasztroelőadás keretében pedig Berke Sándor az őszi ízeket mutatta be a résztvevőknek.

December 7-én Dobre Nóra, a Temenos Senior HR-menedzsere beszélt arról,

hogy mik az új trendek és kihívások a HR világában. A résztvevők ehető karácsonyi díszeket kóstolhattak, amelyeket Berke Sándor mesterszakács készített és mutatott be.

MarketingMastermind – az RMKT Kolozsvár és a RIF közös programsorozata

Január 18.: *Fesztiválmarketing vs. vállalkozás marketing* – Meghívott: Polacsek Péter, a Diversity Advertising menedzsere és ügyvezetője.

Február 22.: *A fenntartható digitális marketing jövője: Hogyan kerüljön ki a branded a mókuserékből?* – Meghívott: Erős Lóránt marketingszakértő.

Március 21.: *Marketingkonzultáció – Közösségi média hirdetés típusok* – Meghívott: Polacsek Péter, a Diversity Advertising menedzsere és ügyvezetője.

Április 19.: *Kreativitás a kontent-korban: Kommunikációs szintlépés és eszköztár* – Meghívott: Kruppa Noémi grafikus, kreatív igazgató.

Október 24.: *Miért kell nekünk TikTokozni?* – Meghívott: Petki Milán, a Bloomberry kreatív igazgatója.

November 28.: *A kisvállalkozói sales, marketing és PR arányai és fölösleges körei* – Meghívott: Farkas Levente tanácsadó.

HESR Masterclass

2023. október 5–6. között került sor a HESR Masterclass rendezvényre dr. Felix Oberholzer-Gee, a Harvard Business School professzorának vezetésével.

Vállalkozásokról nyitottan többszemközt

A *Vállalkozásokról nyitottan többszemközt* beszélgetés-sorozat kezdeményezői és moderátorai László Judit vállalkozó és Papp György, a Medline alapító ügyvezetője.

Március 16.: Gorbai Attila, a Tenrom ügyvezetője, Nagy Károly, a Promelek alapító társtulajdonosa, az RMKT elnöke és Zsigmond István, a Gynia alapító társtulajdonosa, ügyvezetője beszélgetett az elmúlt években felmerült válsághelyzetekre talált megoldásairól.

Május 17.: Gündisch Zoltán és Székely Zsuzsanna, illetve Petri Z. Endre és Varga-Pál-Petry Júlia osztotta meg tapasztalatát a cégvezetés átadásáról-átvételéről.

Június 14.: *Női vezetés a sztereotípiákon túl* – Egri Csillától, Gündisch Ágnestől és Soós Rékától többek között arról hallottunk, hogy mennyire minimalizálják a teljesítményüket, igyekeznek-e perfekcionistaik lenni, a munka vagy a karrier fontosabb számukra?

Szeptember 20.: Nagy-Bege Zoltán energetikai szakember, Nyulas Bernát, a Fomco tulajdonos igazgatója és Vincze Tamás, az East Grain vezérigazgatója a megújuló energia felhasználásáról osztotta meg a tapasztalatait a hallgatósággal.

Október 12.: *A romániai munkaerőpiac jelenlegi kihívásaira* talált megoldásokat mutatta be Dobre Nóra, a Temenos Románia HR-vezetője, a Babeş–Bolyai Tudományegyetem Magyar Szociológia és Szociális Munka Intézetének PhD-hallgatója és társult oktatója, illetve Komlódi Bence, a Prohuman Apt Kft. senior konzultánsa.

November 15.: *EXIT! Eladjam vagy ne adjam? Mikor, miért, hogy (ne)?* Ilyés Szabolcs György, a RegioConsult ügyvezető igazgatója és Nagy Károly, a Promelek vezérigazgatója, RMKT-elnök voltak a szakmai előadók.

Könyvelő Klub

Március 28-án *SAF-T. Mire jó ez? – Gyakorlati tanácsok és megoldások* címmel tartott előadást Aurel Roman, a VBM Soft Kft. alapítója és ügyvezetője.

Egyéb szakmai előadások

Március 22-én Moldován András *Az egyenes vonalú értékesítésről feketén-fehéren* címmel adott elő.

Május 11-én Balogh Petya, az RTL Klub Cápák Között műsorának befektetője *Startupok angyalszemmel: amit az első 45 befektetésből tanultam* címmel tartott előadást.

Double Rise fesztivál

Augusztus 11–13 között, a Double Rise fesztivál keretén belül az RMKT Kolozsvár és a Tóbiás Ház Ifjúsági és a Szabadidőközpont várta Torockó idegenforgalmával foglalkozó vállalkozóit, vendéglátó egységeit, illetve a fesztiválózókat a Tóbiás Udvarba több érdekes programmal. Szakmai előadások voltak hallhatóak, és sajt- és borkóstolókra is sor került.

Kolozsvári Magyar Napok

Augusztus 16-án Bóné Tibor borszakértő, Leitersdorfer Edit-Wilma, a Kárásztelki Pezsgőpincészet ügyvezetője, Sámi Zsuzsa, a Crush Distribution marketingese és Wisky-Petri András, a Petry ügyvezetője voltak a meghívottak.

Augusztus 17-én Égly János, az Accenture Industry X romániai fejlesztési igazgatója, Balogh Petya, az STRT Holding tulajdonosa, W. Szabó Péter, a Tengr.ai tulajdonosa és Székely Barnabás jogász, minősített adatvédelmi szakértő panelbeszélgetés keretében vitatták meg a *A mesterséges intelligencia hatása a munkaerőpiacra – veszély vagy lehetőség?* kérdés vetületeit.

RMKT Kovászna

Január 14.: Szakmai előadást tartottak *Új év, új lehetőségek, új kihívások az RMKT-ban és a gazdaságban*, a meghívott pedig a Romániai Magyar Közgazdász Társaság újonnan megválasztott elnöke, Nagy Károly volt. Az előadást pezsgőkóstoló követte.

Március 31.: *BizniszVitamin Nőknek – Van-e a vállalkozásnak neme?* címmel dr. Gergely Orsolya szociológus, a Sapientia EMTE Csíkszeredai Karának oktatója tartott előadást.

Május 5.: Ötödik alkalommal került megrendezésre a Székelyföldi Könyvelők Találkozója, a találkozó témája a *Versenyképesség adóoptimalizálással* volt.

November 8.: Debreczeni László adószakértő tartott előadást az *Új adócsomag hatásai a vállalkozások mindennapjaira* címmel.

December 15.: *BizniszVitamin Nőknek – A vezető pozícióban levő NŐ lelki vetületei, teherbírása és a kiegészítő kockázatairól* dr. Antalka Ágota pszichológus beszélt.

RMKT Marosvásárhely

Január 19.: *BizniszVitamin* dr. Gergely Orsolyával, előadásának címe *A görgető generáció a munkaerőpiac küszöbén* volt.

Január 26.: *Új év, új kihívások, avagy a 2023-as év adózási újdonságairól* beszélt dr. Fekete Szilveszter adjunktus.

Február 23.: *Az idei év makrogazdasági kihívásai* címmel szervezett előadást dr. Nagy Ágnes tartotta.

Március 16.: *BizniszVitamin – A fenntartható digitális marketing jövője: Hogyan kerüljön ki a branded a mókuserékből?* címmel Erős Lóránt marketingszakértő tartott előadást.

Március 30.: Halmágyi Zsófia és Bende Andreea, védjegyekre és földrajzi jelzésekre szakosodott iparjogvédelmi tanácsadók, a Simion & Baciú cégcsoport munkatársai örvendeztették meg a résztvevőket a *Márkavédelem, tények és tévhitek* előadással.

Április 20.: *Hogyan szelídítsük meg az üzleti számokat? Az eredménystruktúra megfelelő ismeretének titka* címmel tartott szakmai előadást Táncczos Levente-József üzleti tanácsadó, egyetemi oktató.

Április 27.: Arros Orsolya *Változz, hogy változtathass! Ki irányítja a munkaerőpiacot?* címmel adott elő.

Május 12.: Dr. Lorenzovici László orvos-közgazdász a *Mennyit fizetnek a megtermelt napenergiáért a prosumatoroknak? Hogyan lehet maximalizálni a bevételeket és a befektetés megtérülését?* témáról beszélt.

Május 18.: Az esemény meghívottja, Szász Péter, a Kolozsvári Magyar Napok egyik szervezője, fundraising-szakértő érdekes témát boncolgatott előadásán: *Hogyan alakítsunk ki és ápoljunk WIN-WIN viszonyt szervezetünk, rendezvényünk támogatóival?*

Június 29.: A *BizniszVitamin* soron következő eseményén dr. Gyéresi Júlia adott elő *A beszéd téged tükröz* címmel.

Október 13–14.: *Változó gazdasági paradigmák és lehetőségek. Makrogazdaságtól a mesterséges intelligenciáig* címmel a marosvásárhelyi RMKT szervezte (az országos szervezet támogatásával) a XXXII. Vándorgyűlést.

November 14.: Dr. Fekete P. P. Szilveszter, adjunktus, mérlegképes könyvelő, adótanácsadó tartott előadást *Adózási reform Romániában, avagy adózási itt a piros, hol a piros* címmel.

December 7.: A *Gyakori kérdések a védjegyoltalomról* témáról Halmágyi Zsófia és Bende Andreea beszélt.

December 15.: Évzáró borkóstolóra került sor, amelyet mangalicatermékek, kézműves sajtválogatás, olajbogyó, szárított gyümölcsök, diófélék, olívaolajjal ízesített kenyér, sajtos-magvas pogácsák kísérték.

RMKT Nagyvárad

Január 25.: Az RMKT Közgazdász Borklub keretében Lakatos Péter és Mados Attila tartott szakmai előadást.

RMKT Szatmárnémeti

Május 25.: Az esemény meghívottja Bálint Csaba volt, a Román Nemzeti Bank vezetőtanácsi tagja, aki az előadás során szakértői szemmel vizsgálta a különböző gazdasági kockázatokat és kihívásokat, valamint a velük járó lehetőségeket.

December 15.: *Hol a pénz? Adózási ABC* címmel adott elő Muhi Melinda okleveles közgazdász, a Casco Group főkönyvelője.

RMKT Székelyudvarhely

Május 16.: Szakmai vitát szerveztünk Soós Zoltán, Marosvásárhely polgármestere, Antal Árpád, Sepsiszentgyörgy polgármestere, Korodi Attila, Csíkszereda

polgármestere és Gálfi Árpád, Székelyudvarhely polgármestere részvételével, *4 város, 4 polgármester, 4 költségvetés* címmel.

Június 8.: Manfred Kets de Vries: *Leading Wisely – Becoming a Reflective Leader in Turbulent Times* című könyvét mutatta be Szécsi Kálmán banki felsővezető, az RMKT tiszteletbeli elnöke.

November 16.: *Multinacionális és helyi nagyvállalatok hasonlóságai és különbségei a globális piacokon* címmel adott elő Komoróczy Zsolt.

December 16.: Szakmai meghívott dr. Csepeti Ádám helyettes államtitkár volt, aki *A tudásintenzív gazdaságok kialakításának szükségessége* címmel tartott előadást.

RIF (az RMKT Ifjúsági Frakciója)

Ember a cég mögött

Február 28.: *Ember a cég mögött – 1. rész*, előadó: Welker Iván, a Madárláttá Pékség alapítója.

Március 28.: *Ember a cég mögött – 2. rész*, előadó: Szakács Botond, az Eco Tiny House megálmodója és ügyvezetője.

Április 25.: *Ember a cég mögött – 3. rész*, előadó: Dobolyi Tünde ügyvéd.

Május 30.: *Ember a cég mögött – 4. rész*, előadó: Buzogány Attila, a kidlet.ro megalkotója.

Június 27.: *Ember a cég mögött – 5. rész*, előadó: Porkoláb Örs-János, a DEPO és a B The Hotel népszerűsítéséért és marketingjéért felelős szakembere.

Július 25.: *Ember a cég mögött – 6. rész*, előadó: Tóth György Botond, a SIC-LA Construct SRL tulajdonosa.

Koktélest

November 8-án az esemény szakmai előadója dr. Csíki Ottó volt, a téma középpontjában pedig az autoipar és annak fenntarthatósága állt. Az előadás alatt a résztvevők dr. Szász Levente koktélijait kóstolhatták meg.

December 13-án Sándor Krisztián a fiatalon való vállalkozás tapasztalatairól, illetve a vállalkozás elindításához szükséges kezdő lépésekről tartott előadást. Hasonlóan az első koktélesthez, az előadás alatt kulináris élményekben volt részük a résztvevőknek: dr. Szász Levente keverte a csodás koktélokot.

Abstracts

The impact of tourism on economic development in Eastern and Central European countries

ANDRÁS ANTAL

The objective of this study is to examine the interrelationship between tourism and economic development in Eastern and Central European countries. The primary objective is to ascertain the impact of international tourist arrivals on GDP per capita in the countries of the region. The answer to this question can provide guidance to public institutions or travel agencies by demonstrating that investments in tourism promotion are financially beneficial and have a positive impact on the economy. The period under consideration is 2006-2020. To address the primary question, I used panel regression. The study employs a range of control variables, including trade, the human development index, labour force participation rate, and urban population share. The findings align with a substantial body of literature that supports the tourism-led economic growth hypothesis, underscoring the potential of tourism for the region's government and business sectors.

Keywords: tourism, GDP, Eastern Europe, Central Europe.

JEL codes: L83, O11, C23.

Factors affecting cryptocurrency returns in different market conditions

EDINA KOVÁCS

In recent years, there has been a growing interest in cryptocurrencies, especially Bitcoin, among financial professionals, the media, regulators and investors. This is not surprising as the price of bitcoin has increased from \$13 in 2013 to \$42 000 by the end of 2023. This research examines the sensitivity of Bitcoin, Ethereum and Binance returns to various factors between 1 January 2018 and 31 December 2023. The analysed factors are gold and capital market returns, the volatility index, Amihud's illiquidity index and the number of searches for Bitcoin as measured by Google Trends. The research applied the ordinary least square (OLS) method to three different sub-periods, considering the structural breakpoints identified by the Bai-Perron test. The results show that the factors have a different influencing power in different periods. In the first period, when the

crypto market was relatively stable, the returns of the analysed cryptocurrencies were mainly influenced by gold and the volatility index. In the second period, when the market was in turbulence, the number of searches for Bitcoin and capital market returns were the most important factors, while in the third period, during a market downturn, capital market returns became the most influential factors.

Keywords: Bitcoin, cryptocurrencies, structural breaks.

JEL code: C32.

Influencing factors of housing transaction volumes in Romania during the Covid-19 pandemic

MÓNIKA OBOROCEA

During the COVID-19 pandemic, which coincided with an increase in the number of new infections, the volume of housing transactions in Romania increased. This study examines the factors that contributed to this increase from April 2020 to October 2022. The panel regression results show that the unemployment rate had the strongest negative effect on changes in the transaction volume. The number of transactions was also negatively affected by the interest rate on home loans in RON and the construction cost index. The results indicate that, during the pandemic, transaction volumes followed the economic sentiment index trends directly. This suggests that the sentiment index could be an effective predictor of transaction volumes. However, no significant relationship was found between the volume of housing transactions and real net wages. One possible reason for this is that, due to government measures (such as technical unemployment), the average real net wage in Romania did not decrease during the studied period.

Keywords: COVID-19, real estate, housing transaction volume.

JEL codes: R21, C23.

Comparison of credit scoring algorithms: artificial intelligence-based algorithms vs. traditional methods

ZÉTÉNY SZILÁGYI-NAGY

The aim of the study is to compare the performance of logistic regression, decision tree and random forest on a real P2P (peer-to-peer) lending database. The peer-to-peer (or person-to-person, P2P) lending market facilitates financial transactions between borrowers and lenders. Credit risk management is traditionally based on credit scoring, which is used to estimate the probability of

default on a loan. An appropriate credit-scoring technique is very important for the long-term success of both financial institutions and P2P lending platforms. The comparison of credit scoring algorithms is based on Lending Club data. The database covers the first quarter of 2017 and contains 563 847 observations and 23 different variables. The results obtained suggest that random forest is the better credit scoring algorithm for the Lending Club database.

Keywords: credit score, peer-to-peer lending, logistic regression, random forest, decision tree.

JEL codes: G21, G23, D14.

Közlési feltételek

A *Közgazdász Fórum* lektorált (peer-reviewed) gazdaságtudományi szakfolyóirat a Romániai Magyar Közgazdász Társaság (RMKT), a Babeş–Bolyai Tudományegyetem Közgazdaság- és Gazdálkodástudományi Magyar Intézete és a Partiumi Keresztény Egyetem közös szakmai közlönye.

Küldetése a romániai magyar közgazdászok szakmai-tudományos ismereteinek bővítése, releváns hazai és külföldi kutatási eredmények magyar nyelven történő terjesztése révén.

Publikációs lehetőséget biztosít oktatók, kutatók és gyakorló szakemberek számára gazdaságelméleti és alkalmazott gazdaságtani tudományos munkáik közlésére.

A folyóirat 2010-től a Proquest és az EBSCO nemzetközi adatbázisokban is jegyzett.

A *Közgazdász Fórum* szerkesztősége folyamatosan fogad közlésre angol vagy magyar nyelven, eredeti, korábban máshol nem publikált tudományos cikkeket és tanulmányokat a következő tudományterületekről: makro- és mikroökonómia, regionális gazdaságtan, nemzetközi gazdaságtan, bank- és pénzügyek, gazdasági informatika, vállalati pénzügyek, számvitel és könyvvizsgálat, menedzsment, marketing, alkalmazott statisztika és ökonometria. Minden kéziratot két szakmai lektor véleményez, névtelenül (double blind review), a kézirat publikálásáról a főszerkesztő dönt. A publikálás feltételeiről a folyóirat honlapján (<http://kozgazdaszforum.ro>) tájékozódhat.

ÁRA: 20 lej



RMKT 2023

Kiadja a Romániai Magyar Közgazdász Társaság

ISSN 1582-1986
CNCSIS 755-2010