

Jelzáloghitelek hitelkockázati modellezése a Magyar Nemzeti Bank felügyeleti stresszteszt-jében*

Szabó András Viktor

Jelen kutatás célja egy olyan modell kialakítása, mely képes megbecsülni a potenciális hitelkockázati veszteségeket a háztartásoknak nyújtott lakáscélú és szabad felhasználású jelzáloghitelekre vonatkozóan makro- és mikroszemléletű adatok egyidejű használata mellett, és minden bankra egységesen alkalmazható, továbbá figyelembe veszi az új számviteli sztenderdeket (IFRS 9) is. A modell egy teljes gazdasági ciklust (2004–2018) lefedő, több hazai hitelintézet ügyletszintű adatbázisán alapul. A kockázatérékenységet erősítő gazdasági mutatók felhasználása mellett bevonja a prociklikusságot enyhítő ügylettulajdonságokat is. A modellezés kétlépcsősévé tétele lehetővé teszi az előrejelzésnél kockázati csoportok kialakítását a különböző hiteltulajdonságok mentén. Az eredmények azt mutatják, hogy a foglalkoztatottság alakulása erőteljesebben érinti a kockázatosabb, potenciálisan csak alkalmi munkából élő csoportokat, míg a nettó vagyon be sem került a – vélhetően jobban a stabil munkajövedelmükre támaszkodó – legjobb adósokat magába foglaló csoport magyarázó változói közé.

Journal of Economic Literature (JEL) kódok: C320, C530, G210, G280, G510

Kulcsszavak: idősoros modellezés, ökonometria előrejelzés, bank, stresszteszt, PD, háztartási hitelezés, IFRS 9

1. Bevezetés és szakirodalom bemutatása

A stressztesztelés és az ehhez kapcsolódó hitelkockázati modellek egyre nagyobb szerephez jutottak a 2008-as gazdasági világválságot követően. Ezt a nemzetközi bankfelügyeleti szerveknél, valamint 2017-től már a Magyar Nemzeti Bank (MNB) felügyelete által is futtatott stressztesztek bevezetése is jól mutatja. Jelen kutatás

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

Szabó András Viktor a Magyar Nemzeti Bank osztályvezetője. E-mail: szaboand@mnbb.hu

Köszönettel tartozom az MNB Alkalmazott kutatás és stresszteszt főosztályának, hogy elérhetővé tette számomra a modellezéshez felhasznált, tisztított adatbázist, illetve valamennyi olyan, a Magyar Nemzeti Bankban dolgozó kollégának, aki észrevételeivel hozzájárult a tanulmány elkészüléséhez. A fennmaradó hibákért a felelősség kizárólag a szerzőt terheli.

A magyar nyelvű kézirat első változata 2020. szeptember 15-én érkezett szerkesztőségünkbe.

DOI: <https://doi.org/10.25201/HSZ.21.1.56>

célja egy olyan modell kialakítása, mely minden bankra egységesen alkalmazható, figyelembe veszi az új számviteli sztenderdeket (IFRS 9) és képes – makro- és mikroszemléletű adatok egyidejű használata mellett – megbecsülni a potenciális hitelkockázati veszteségeket a háztartásoknak nyújtott lakáscélú és szabad felhasználású jelzáloghitelekre vonatkozóan. A modell egy teljes gazdasági ciklust (2004–2018) lefedő, több hazai hitelintézet ügyletszintű adatbázisán alapul, ami a kockázaterzékenységet erősítő gazdasági mutatók felhasználása mellett lehetőséget teremt a prociklikusságot enyhítő ügylettulajdonságok modellezésbe való bevonására is. Egyik legfőbb egyediségét a modellezés kétlépcsősé tétele adja, mely alkalmat ad az előrejelzésnél, hogy a különböző hiteltulajdonságok mentén kialakított kockázati csoportokra, azaz heterogén helyzetű és kockázatoságú adósokra eltérő makrováltozók eltérő mértékben hassanak. Az eredmények alátámasztják e gondolatot, ugyanis azt láthatjuk, hogy például a foglalkoztatottság alakulása erőteljesebben érinti a kockázatosabb, potenciálisan csak alkalmi munkából élő csoportokat, míg a nettó vagyon be sem került a – vélhetően jobban a stabil munkajövedelmükre támaszkodó – legjobb adósokat magába foglaló csoport magyarázó változói közé.

A hitelintézetek szakértői és a szabályozó hatóságok már évtizedekkel ezelőtt felismerték, hogy hitelezési tevékenységükből fakadóan milyen mértékű kockázatnak vannak kitéve ezen intézmények. A 20. század vége felé különböző kvantitatív módszertanok kifejlesztésével egyre nagyobb teret kapott a hitelkockázat portfóliószintű modellezése, és ennek kapcsán az évek során rengeteg tanulmány és referált modell született. A redukált hitelkockázati modellek között – melyek nem a cégérték változásain keresztül, hanem egy exogén módon definiált ugrófolyamat által becsülik meg a csődesemény paramétereit (*Bielecki – Rutkowski 2004*) – két modellcsaládot különít el a szakirodalom. Az első az intenzitásmódel-család, mely egyedül a csőd időpontjával foglalkozik, míg a második, a jelen tanulmány szempontjából érdekesebb, a hitelmigrációkra épülő modellek csoportja. Az 1990-es évektől kezdődően a modellek többsége három paraméter becsülésével foglalkozott: csődvalószínűség (PD), csőd esetén fennálló veszteség (LGD), valamint a csődvalószínűségek és a veszteségek közt fennálló korreláció (*Crouhy et al. 2000*). *Das és szerzőtársai (2009)* megfigyelték, hogy a Merton-féle csődfogalomra épülő csődvalószínűség-becselő modellek¹ helyét a 2000-es évek elejétől kezdte átvenni a redukált formájú modellcsalád, melybe immáron akárhány magyarázó változót – így akár ügyfélspecifikus, akár makrováltozókat – be lehet vonni, ami tovább növelte a becslés pontosságát. Ez természetesen egybevág a bázeli szabályozás II. akkordjának 2004-es megjelenésével, mely külön hangsúlyt fektet a bankok belső hitelkockázati értékelésére, így ösztönözve a korábbi módszerek megújítását, pontosabbá tételét.

¹ A Merton-féle megközelítésben egy magasan stilizált modell adja meg a csődvalószínűséget, melyben az egyetlen magyarázó változó a cég eszközeinek értéke.

A hitelminősítési modellezést *Altman (1968)* ötletének tulajdonítják, aki tanulmányában számviteli tulajdonságok² alapján próbálta megbecsülni a különböző vállalatokra vonatkozó csődvalószínűséget. Ezt a gondolatvonalat a következő évek során többen is továbbvitték, finomhangolták. Foglalkozott vele – a teljesség igénye nélkül – *Martin (1977)*, *Platt – Platt (1991)* és *Sommerville – Taffler (1995)* is. *Lawrence et al. (1992)* már nem a vállalatok csődvalószínűségét modellezte, hanem háztartási hitelezési oldalról haladt a probléma megoldása felé, ami ezáltal részben megközelíti a jelen tanulmányban bemutatott módszertant is. A hitelminősítési modellek legfőbb kritikája, hogy a magyarázó változói statikus, számviteli információk, melyek a hirtelen változásokat nem képesek azonnal, csak bizonyos idő elteltével (*Agarwal – Taffler 2008*) megfogni. Ezt felismerve, a 2000-es évektől a hitelkockázati szakértők egyre nagyobb előszeretettel kezdték használni a faktormodelleket. Ezen információtömörítést megcélzó modellek általában két vektort használnak a becsléshez. Az egyikben jellemzően a gyors hatásokat túl rugalmatlanul kezelő, azonban az ügyfél minőségi tulajdonságait jól megfogó – rendszerint számviteli – információk találhatók, míg a másik ezt kiegészítve, döntően dinamikusságot támogató makrogazdasági mutatókat tartalmaz. Az előbbi jellemzően – amennyiben időben változatlanak tekinthető (pl. hitelkamatozás típusa, futamidő, az ügyfél hiteligénylés kori végzettsége) – az egyedi kockázatok feltérképezéséért, számokba öntéséért felel, míg az utóbbi a kinttről jövő, rendszerszintű kockázatokat képes megragadni. Faktor-, illetve multifaktor-modelleket bemutató cikket több szerző is jegyzett a témában. Ezek közül *Pederzoli és Torricelli (2005)* közös munkája emelhető ki, melyben a szerzők a Bázeli II-es tőkekövetelmény-kalkuláció kapcsán mutatták be a kockázatérzékenység és prociklikusság között fennálló, egymásnak ellentmondó viszonyt, melynek enyhítésére egy hibrid, kockázati csoport alapú (rating) és TTC (*through-the-cycle*), ciklusokon átívelő szemléletet is tartalmazó csődvalószínűség-modellezést javasoltak. Jelen tanulmány is egy ilyen, kétféle vektort, változószettet is felhasználó modellezési gyakorlatot mutat be.

A 2008-as gazdasági világválság ugyanis ráébresztette a pénzügyi piac szereplőit arra, hogy az addig alkalmazott modellezési gyakorlatok vagy minőségileg, vagy mennyiségileg, vagy megközelítésükben nem tudtak pontos képet adni a bankszektor hitelkockázati kitétségéről. A pénzügyi szektor szereplői egyöntetűen változást, mégpedig – többek közt – az akkoriban érvényes IAS 39 számviteli standard leváltását követelték. Több publikáció, köztük *Chae és szerzőtársaié (2019)* is, a korábbi, múltba tekintő, csupán a megtörtént veszteségesemények utáni értékvesztésképzést támogató standard hiányosságairól írnak. Állításuk szerint a bankszektoron átívelő, nagy mennyiségű és diszkrét csomagokban elszenvedett hitelkockázati veszteségek – egy különösképpen volatilis és stresszes időszakban – komoly kockázatot jelentenek a pénzügyi stabilitásra. Ezt a fajta prociklikus értékvesztésképzést kiküszöbölve

² Altman Z-mutató: működő tőke/eszközök, eredménytartalék/eszközök, adózás és kamatfizetés előtti eredmény/eszközök, résvények piaci értéke/adósság, árbevétel/eszközök.

2018 januárjától az *International Accounting Standards Board* (IASB) életbe léptette a jelenleg is érvényes számviteli szabályozást. Az IFRS 9 – mely alapul szolgál jelen tanulmánynak is – immáron egy jövőbe tekintő, három kockázati csoportot (stage) kialakító, várható veszteségekre építő értékvesztésképzési szabályt fektet le. Ez egyrészt lehetővé teszi a hitelintézetek számára egy esetleges válságra történő előzetes, tartalékolással történő felkészülést, másrészt új kapukat nyit a hitelkockázati modellezők számára a különböző stage-migrációs modellek kifejlesztésére (lásd például *Landini et al. 2019, Gross et al. 2020*).

A szakirodalom meglehetősen limitált a stresszteszteléshez használt hitelkockázati szimulációs modellek bemutatása terén, ami részben a gyakorlat bevezetésének időbeli közelségéből, részben pedig a tevékenység használóinak kis számosságából fakad. Hitelintézetek jövedelmezőségét, kockázati profilját mérő stressztesztet többnyire csak maguk a bankok vagy az őket felügyelő szervek futtatnak, így a publikációk is jellemzően e szűk körtől származnak. Az európai bankszektorra leginkább releváns, gyakorlatban is alkalmazott módszertant az *Európai Bankhatóság* (EBA) – nagyrésztük csupán belső, nemzeti felügyeleti használatra készült – és az *Európai Központi Bank* (EKB) szolgáltatja. *Gross et al. (2015)* a modellezés szempontjából adhat releváns tapasztalatot a bayesi modell-átlagolás gyakorlati alkalmazásának bemutatásával. Ötleteket meríthetünk továbbá más európai nemzeti felügyeleti gyakorlatából is, melyek közül a holland *Daniels et al. (2017)* jegybanki publikáció emelhető ki hasonló jelzáloghiteles módszertana miatt. Jelen tanulmány a magyar bankszektor sajátosságait, kockázatát legjobban tükröző, hazai adatokon történő stressztesztelési szakirodalmat bővíti lakossági oldalról, mely idáig legfőképp vállalatokkal foglalkozó írásokat tartalmazott. Az utóbbi esetében mindenképp kiemelendő *Lang és Stancsics (2019)*, valamint *Horváth (2021)* tanulmánya. Ezek az MNB által alkalmazott stressztesztet hitelkockázati szekciójának vállalati szegmensével foglalkoznak. Míg az előbbi makroprudenciális oldalról közelíti meg a bankszektort, késedelmes napszám alapú stage-eket kialakítva, majd átmenet-valószínűségeket becsülve modellükkel, addig az utóbbi ügyfél- és makrogazdasági adatokat is felhasználó logit modellt alkalmazva a felügyeleti stresszteszt³ keretrendszerét színesíti. A jelen tanulmány szemszögéből releváns szakirodalom bemutatását a *Banai és szerzőtársai (2013)* által alkotott modellel való összehasonlítás zárja, mely sok egyeben kívül a felhasznált adatbázis és stresszteszt keretrendszerbe foglalása szempontjából is egyezőséget mutat az alább ismertetett módszertannal. A különbséget részben az adja, hogy míg az említett szerzők egy modellben szerepeltetik a kockázati csoportosítást elősegítő ügylet- és ügyféltulajdonságokat az idősoros változókkal, addig itt, a felügyeleti stresszteszt módszertani sajátossága miatt úgy láttam használhatóbbnak, ha külön veszem két modellbe. A másik fő különbség pedig a már

³ A felügyeleti stresszteszt keretrendszeréről az MNB legfrissebb „A tőke megfelelés belső értékelési folyamata (ICAAP), a likviditás megfelelőségének belső értékelési folyamata (ILAAP) és felügyeleti felülvizsgálatuk, valamint az üzleti modell elemzés (BMA)” című módszertani kézikönyve tartalmaz kivonatot.

említett új számviteli gyakorlat bevezetése miatt az eredményváltozóban rejlik. Míg *Banai és szerzőtársai (2013)* esetében a csődvalószínűség modellezése volt a cél, addig jelen kutatás a stage-ek közti átmenet-valószínűségek érzékenységét vizsgálja.

A tanulmány a következő fejezetekből tevődik össze: A 2. fejezet a hitelek ügylet- és ügyféltulajdonságokat alapul vevő kockázati besorolásának bemutatásával foglalkozik, melyből az olvasó megismerheti a modellezéshez felhasznált adatbázist, a változóselektiót, valamint a klaszterezés eredményét. Ezután először a kialakuló kockázati csoportok mentén becsült csődvalószínűségek idősoros modellezésének keretrendszerét szemléltetem, majd az eredmények kiértékelése, visszatesztelése történik meg a 3. fejezetben. A tanulmány gerince a 4. fejezet, mely a modellezett csődvalószínűségek stage-ek közötti átmenet-valószínűségekre történő átalakításának lépéseit mutatja be. Az 5. fejezetben foglalom össze a következtetéseket.

2. A hitelkockázati csoportosítás keretrendszere

A fejezet első része – összhangban a fenti tematikával – főleg a felhasznált adatbázis paramétereinek és az elérhető változók tulajdonságainak bemutatására fókuszál, megfelelő kiindulási alapként a fejezet második részében bemutatott kockázati klaszterek, valamint a későbbi fejezetekben sorra kerülő idősoros modellek kialakításához.

2.1. Felhasznált adatbázis és adattisztítás

A modellezés három, Magyarországon működő, mérlegfőösszeg alapján a 8 legnagyobb hitelintézeti csoport közé tartozó intézmény egyedi adatszolgáltatásán alapuló, hitelígényletkori ügyfél- és ügylettulajdonságokat, valamint időben változó jellemzőket is tartalmazó adatbázisra épül. Az adatokat a három intézmény kutatási célból osztotta meg az MNB-vel. Az adatállomány az említett három bank összes háztartási hitelfolyósítását tartalmazza a 2004. december és 2018. december közötti időszakban – tehát egy teljes gazdasági ciklusra –, mely intervallum alatt negyedéves frekvenciával lehet végigkövetni az ügyletek időbeli alakulását. A beadott adatokon belül jelzáloghitelnek minősül mind a lakáscélú, mind a szabadfelhasználású hitel is, melyből az utóbbi a 2008-ban kirobbanó világgazdasági válság idején ugyan még nagyobb súlyt képviselt a háztartási hitelek közt, mindazonáltal állományban jelenleg is 10 százalék feletti részt tesznek ki, így részletes hitelkockázati modellezésük indokolt volt. A jelzáloggal fedezett hitelek nagyrészt ugyanakkor a lakáscélra felvett kölcsönök adják, melyek a teljes háztartási állományban is jelentős, közel 50 százalékos súlyt képviselnek. A fedezetlen, vagy nem ingatlanfedezettel rendelkező háztartási hitelek jelen tanulmánynak nem képezik részét. Az adatbázis több mint 9 millió megfigyelést tartalmaz, ami nagyjából 370 ezer egyedi ügylet időbeli alakulását jelenti.

A változók leíró statisztikái a *Melléklet 4. táblázatában* található, melyből kiderül, hogy több ügylet- és ügyféltulajdonság is adattisztításra szorult hiányzó és/vagy szélsőséges, vélhetően hibásan töltött értékek miatt. Az adattisztítás alapvetően háromféle stratégia mentén lett végrehajtva. Azon változók esetében, melynél csak hiányzó értékek zavarták a modellezést és ez elenyésző – a megfigyelések egy ezrelékét sem meghaladó – esetszámban fordult elő, ott a megfigyelések törlése mellett döntöttem. Azon változónál, melyeknél hiányos információk mellett szélsőséges megfigyelések is szerepeltek, azokat az adatpontok átskálázásával a már valószínű értékeket⁴ adó percentiliszhez visszahúzza értem el megfelelő eloszlást. A harmadik, a modellezést potenciálisan leginkább befolyásoló technika azon változók esetében került előtérbe, melyeknél a hiányzó értékek aránya százalékosan ugyan nem volt jelentős, de az elenyésző esetszámot már meghaladták. Ezen esetekben – *Little és Rubin (2002)* adattisztítási technikákat vizsgáló tanulmányának eredményei alapján a legjobban teljesítő módszert követve – az érintett változók⁵ adott időszakban megfigyelt értékeiből számolt átlaggal helyettesítettem az érintett negyedévben töltetlen sorokat.

Acuña és Rodriguez (2004) szerint az adathiány kezelése a teljes minta 5 százaléka felett válik problémássá, és csupán 15 százalék felett lesz hatással az eredmények interpretációjára. Szerencsére e szintek egyikét se lépte át egy változónál észlelt hiányosság sem, és ugyan az adattisztítást az eredmények pontosítása érdekében elvégeztem, a továbbiakban azonban számottevő hatást nem tanúsított nekik. Az adattisztítás során alkalmazott technikák a leíró statisztikákban a teljesség igényével megtalálhatóak.

2.2. Eredmény- és magyarázó változók

A kutatásnak a felügyeleti stresszteszthez történő közvetlen hitelkockázati hozzájáruláson kívül egy másik célja annak az előzetes feltevésnek az igazolása, miszerint a Magyarországon folyósított háztartási hitelek (jelen esetben: jelzáloghitelek) a legutóbbi pénzügyi válság előtti állapothoz képest a kockázati eloszlást tekintve jelentősen javultak. Ennek több mozgatórugója is lehetett, közülük főleg az elmúlt években hozott kormányzati és szabályozói intézkedéseket⁶ emelhetjük ki, de a bankok kockázatvállalási hajlandósága is változhatott időközben. Az adósságfék szabályok⁷ lakossági hitelezésre gyakorolt hatásaival többek között *Fáykiss és szerzőtársai (2018)* foglalkoznak, rámutatva arra, hogy az valóban elérte célját, és így a hitelezés szerkezetének megmaradása mellett a legkockázatosabb hitelek kiszorultak. A tanulmány másodlagos céljaként tehát e jelenséget – ötvözve az általános, banki

⁴ Az ügyfelek koránál például az alsó határt 18, míg a felsőt 80 évnél húztam meg; a JTM esetében 0–100 százalék, míg a HFM-nél 0–200 százalék voltak a küszöbértékek; a hitelösszeget 140 millió forintban, a futamidőt pedig 40 évben maximalizáltam.

⁵ Mindösszesen a JTM, a HFM és az ügyleti kamatnál merült fel ekkora adathiány.

⁶ Pl.: devizahitelek forintosítása, adósságfék-szabályozások (hitelfedezeti mutató, jövedelemarányos törlesztőrészlet mutató)

⁷ 32/2014. (IX. 10.) MNB rendelet a jövedelemarányos törlesztőrészlet és a hitelfedezeti arányok szabályozásáról

kockázati étvágy változásával – szeretnénk a jelzáloghitelek csődvalószínűségének oldaláról megközelíteni, mely a várakozásaink szerint a PIT (*Point-in-time*, gazdasági ciklustól függő) nézeten kívül átlagos, TTC-szemléletben is csökkenő tendenciát mutatott az elmúlt években.

Az MNB felügyelete által alkalmazott stresszteszt a tanulmány megjelenésekor olyan feltételezés mellett számol hitelkockázati veszteségeket, hogy a stresszpálya két éve során amortizálódó hitelek ugyanolyan kockázati profil mellett kerülnek megújításra. Ez a gyakorlatban azt jelenti, hogy ha egy 30 éves jelzálogadós, aki hiteligényléskor főiskolai végzettséggel és nettó 300 ezer forintos jövedelemmel rendelkezett, visszatörleszti az említett kétéves periódus alatt a hitelét, akkor a helyére egy ugyanilyen tulajdonságokkal rendelkező adós kerül, mely garantálja a kockázati összetétel és a hitelállomány állandóságának fennmaradását. A hitelállomány nagysága természetesen stresszpályán is változtatható a makrogazdasági körülményeknek megfelelő dinamika hozzáadásával, mint ahogy ez meg is történik a felügyeleti stressztesztben, ugyanakkor a portfólió kockázati profilja a tanulmány publikálásakor aktuális módszertan szerint állandó marad. Ahhoz, hogy ennek megváltoztatása indokolt lehessen, egyrészt látnunk kell, hogy ez a fajta kockázati konszolidáció időben megfigyelhető volt-e, másrészt ennek mértéke is kérdéses a megfelelő módszertan kialakításához. Ezt szem előtt tartva, a makrogazdasági és egyedi ügylet-, valamint ügyféltulajdonságokat egyaránt felhasználó (pl. pooled OLS) panelregresszióval történő becslés helyett – hogy a fent említett jelenség jobban megfigyelhető és egyszerűbben mérhető legyen – egy kétlépcsős modellezési eljárást alkalmaztam, mely tehát az egyik legfőbb eltérést adja a bevezetőben már említett *Banai és szerzőtársai (2013)* által publikált lakossági PD-modellhez képest.

Első körben a hitelügyletek kockázatalapú csoportosítását, majd ezt követően az idősoros modellezést végeztem el. A kezdeti lépés megtételéhez egy kockázatot jól mérő változó, a csődesemény (*default*) pontos definiálására (mivel az adatbázis nem tartalmazott ilyen mezőt), majd számszerűsítésére volt szükség, melyet végül az alábbi képlet szerint határoztam meg:

$$Default = \begin{cases} 1, & \text{ha } DPD_0 < 90 \text{ és } (DPD_1 \geq 90 \text{ vagy } DPD_2 \geq 90 \text{ vagy } DPD_3 \geq 90 \text{ vagy } DPD_4 \geq 90); \\ 0 & \end{cases}$$

ahol az alsó indexben a kiindulási pont után eltelt negyedévek száma található, a DPD (*days past due*) pedig a be nem fizetett hiteltörlesztő esedékessége óta eltelt napok számát, tehát a késedelmes napszámot jelöli. A változó így kétféle értéket vehet fel (vagy csődbe megy az ügylet, vagy sem), mely akkor kap 1 értéket – tehát akkor következik be csődesemény –, ha az időszak elején még teljesítő ügyfél a következő egy évben bármikor legalább 90 napot csúszik a törlesztőjének fizetésével, függetlenül attól, hogy az egyéves periódus végére már befizetett minden időszerű tartozást, vagy sem. Ebből kifolyólag az éven belüli kikerülés nem lehetséges, ami összhangban van a felügyeleti stressztesztben alkalmazott feltételezésekkel. A fenti

szabály alkalmazása mellett az adatbázisban összesen 69 205 ügyletnél figyelhetünk meg csődeseményt, ami a teljes adatbázist figyelembe véve a hitelek kicsivel több mint egyhatoda.

Miután a modellezés célja, hogy a felügyeleti stresszteszt a lehető legpontosabb képet adja a Magyarországon működő hitelintézetek és hitelintézeti csoportok hitelkockázatáról⁸, így fontos, hogy az előrejelzett migrációs valószínűségek tükrözní tudják a bankok portfóliója közti kockázati különbségeket is. Ennek megfelelően a modellezést két részre bontottam: 1) homogén csoportok kialakítása, 2) kialakított csoportok (mint portfóliók) modellezése idősoros eszközökkel. Az első lépés bevezetésével elkerülhető, hogy a modellezés prociklikussá váljon a különböző tulajdonságok bevonásával, amire a felügyeleti stresszteszt végtermékének számító tőkeajánlás miatt van szükség. Másrészt azt is áthidalhatjuk vele, hogy egy átlagnál szigorúbb hitelbírálati rendszert alkalmazó, vagy egy időközben azt szigorító bankról kedvezőtlenebb képet fessünk a valódinál.

Ezt a mikroszintre fókuszáló szemléletet a gyakorlatban tehát úgy érhetjük el, hogy az IFRS 9 stage-eken kívül egyéb, ügylet- és ügyféltulajdonságokra épülő kockázati csoportokat is kialakítunk. A csődvalószínűség⁹ (*default rate, DR*) mentén ehhez tehát olyan tulajdonságok, magyarázó változók kiválasztása a feladat, melyek kockázatoság szempontjából a lehető legjobban képesek szeparálni a hitelügyleteket. Az adatbázisban fellelhető, potenciálisan jó magyarázó erővel rendelkező változók körének szűkítéséhez megvizsgáltam az adott tulajdonság kapcsolatát a hozzá tartozó átlagos – cikluson átívelő, időtől független – csődvalószínűséggel. E kapcsolatokról készült diagrammokat a *Melléklet 4. ábrája* tartalmazza. Az ábrázolással két kérdésre kerestem a választ. Az első, hogy a magyarázó változók és a DR között a kapcsolat erős és térben különböző-e, tehát hogy az adott tulajdonság értékkészlete különböző átlagos DR-ek körül összpontosul-e. A második, hogy a kapcsolat lineáris-e, vagy sem. *Jagric et al. (2011)* szlovén banki adatokon modellezte a hitelkockázat és a magyarázó változók közti kapcsolatot, mely során arra a megállapításra jutott, hogy a nem lineáris kapcsolatok nagyban befolyásolják a modellek teljesítményét. A linearitás elérése és a könnyebb, pontosabb modellezhetőség érdekében tehát több, széles értékkészlettel rendelkező, folytonos változó esetében kisebb intervallummal rendelkező kategóriák kialakítása történt meg.

A következő bekezdésben azon változókra térek ki, melyek a tesztstatistikák és az előzetes intuíciókon felül az adatbázis sajátosságai miatt is alaposabb vizsgálatra szorultak. A hitelfedezeti mutató (HFM)¹⁰ esetében felmerült, hogy annak kockázati

⁸ Ugyan a stresszteszt eredményeit a hitelkockázati költségek befolyásolják a leginkább, a gyakorlat számszerűsíti a piaci, partner-, működési és jövedelmezőségi kockázatokat is egy potenciális gazdasági romlás mellett.

⁹ A csődesemények kitettséggel súlyozott aránya a teljes időszakot figyelembe véve

¹⁰ Hitelösszeg / hitelfedezet forgalmi értéke

szegmentációs képessége – melyet *Holló (2009)* is kimutat lakossági jelzáloghitelekkel foglalkozó tanulmányában – torzulhatott a válság utáni időszakban, legfőképpen a 2015 környékén kezdődő szabályozás bevezetésével. Ez elméletben azt jelentené, hogy ugyan a válságban és közvetlen utána a hitelek magasabb HFM-értékkel rendelkező ügyleteknek és magasabb jövedelemarányos törlesztési mutató (JTM)¹¹ mellett kerültek folyósításra, azonban ez később potenciálisan megfordulhatott. Ennek a jelenségnek elméletben az lehetett volna az oka, hogy a bankok a szabályozói intézkedések következtében ugyan kockázatkerülőbbek lettek, ugyanakkor a jobb, azaz alacsonyabb JTM-mel rendelkező ügyleteknek magasabb HFM mellett továbbra is nyújtottak hiteleket. A hipotézist az adatok segítségével könnyen ellenőrizni tudtam, s ebből kiderült, hogy nincs a jelen modelladatbázissal kimutatható alapja a teóriának, hiszen adott HFM-szintekhez minden időszakra hasonló JTM-szintek tartoznak, mely az előbbi mutató emelkedésével, romlásával nő arányosan. Ugyancsak ezt támasztja alá, hogy a HFM nélkül futtatott regressziók együtthatói nem térnek el a változót magába foglaló egyenletben megfigyelttől. A másik érdekes, látszólag jól szeparáló változó a hitelfelvétel óta eltelt idő volt, melynek használata elég intuitív: minél előbb jár a törlesztésben, azaz minél többet fizetett már vissza a hitelből az adós, annál nagyobb eséllyel viszi már végig a lejáratig a törlesztést. Az eltelt idő alapján sorba rendezett csődvalószínűségekből az 5–6 év környékén töréspont volt megfigyelhető, a csődráták attól a ponttól kezdtek el rohamos mértékben csökkeni. A változó használatát és a töréspont helyességét *Balás és szerzőtársai (2015)* is megerősítik a tanulmányukban, amelyben olyan keresztmetszeti modell építése volt a cél, mely a csőd-kockázatot legjobban magyarázó változókat foglalja magában. A változó alkalmazása mégis kérdéseket vetett fel bennem, ugyanis már egy egyszerű elemzés után is kiderült, hogy az 1–5 eltelt év intervallumban a magas DR-t az idősor és az adathalmaz sajátossága miatt az is magyarázhatja, hogy 2008–2010 környékén – mikor a csődesemények többsége történt – a mintában a hitelek több mint 90 százaléka 5 évnél fiatalabb volt. A DR tehát részben nem az ügyletek korának kockázati profilját tükrözi, hanem egyszerűen azt, hogy milyen korban léptek be a válságba. Ennek ellenére végül a szakirodalom, a tesztszisztematikák, a lefutott regressziók¹², illetve a későbbiekben bemutatott, időben változó makrogazdasági adatok modellezésbe történő bevonása meggyőzőnek bizonyultak, és az eltelt idő használata mellett döntöttem.

¹¹ Hiteltörlesztő (havi) / a hiteligénylő és a hitelszerződésben adóstársként szereplők igazolt havi nettó összjövedelme

¹² Megvizsgáltam, hogy idő fixhatások (lényegében folyósítási időszak dummyk) logit-modellbe való bevonása eltérítik-e az eltelt idő paramétereit, és mivel mind az együttható, mind a sztenderd hiba stabilnak bizonyult, a változó használatát megalapozottnak tekintettem.

Az ügyleti éves átlagos kamatláb, valamint a hitelfolyósítás éve (*vintage*) végül az ábrák, illetve tesztstatisztikák eredményei alapján már nem kerültek bele a modellezésbe bevonandó változók listájába. A *Melléklet 4. ábráján* megjelenített, szűkített listán szereplő 12 potenciális magyarázó változó közül végül 10-et tartottam meg: *felvett (korrigált) hitelösszeg*¹³, *ügyfél iskolai végzettsége*, *ügyfél kora*, *hitelfelvétel óta eltelt idő*, *futamidő*, *adóstars megléte*, *JTM*, *HFM*, *termék típusa*, *termék devizaneme*. Az eltelt időn kívül minden változó – szándékosan megtartva a statikus összefüggéseket – időben állandó, vagyis mindegyik a folyósításkori állapotot tükrözi.

2.3. A kockázati kategóriák kialakítása

Következő lépésként – még a szeparáció, azaz a kockázati csoportosítás elvégzése előtt – a fent kiválasztott tulajdonságok részletesebb statisztikai elemzésére került sor. A magyarázó változók további tesztelése érdekében a banki kockázatkezelési gyakorlatban leginkább elterjedt logisztikus regresszió (logit) volt segítségemre.

$$Y(\text{csődesemény} = 1, \text{teljesítés} = 0) = G\left(\beta_0 + \sum_{i=1}^n \beta_i \cdot x_i\right)$$

ahol

$$G(x) = \frac{e^x}{1 + e^x}$$

A modellbe bevont magyarázó változók mindegyike szignifikánsnak bizonyult együttesen és külön-külön is, így kijelenthető, hogy a korábbi intuíciónak – miszerint jó szeparációs erővel rendelkeznek – és a modellezés céljának megfelelnek. A modell és a statisztikai tesztek eredményeit a *Melléklet 5. táblázata* tartalmazza, míg a logit modell pontosságát visszamérő – 70 százalék körüli, a hasonló modellek közt jónak mondható értéket adó – ROC (Receiver Operating Characteristic) görbe a *Melléklet 5. ábráján* látható. A viszonylag sok tulajdonság bevonása miatt ugyanakkor indokoltnak tartottam a multikollinearitás, azaz a magyarázó változók közti korreláció mértékének vizsgálatát (lásd *Melléklet 5. táblázata*). A lefuttatott tesztstatisztika alapján kijelenthető, hogy erős az említett korrelációs hatás a modellben. A potenciális multikollinearitás mellett a változók egyéb tulajdonságai is a transzformáció és a dimenziócsökkentés irányába mutattak. Megfigyeltem ugyanis, hogy a szeparációhoz felhasználandó változók heterogének mind eloszlás, mind értékészlet alapján, ami egybevág a már említett multikollinearitási és a logisztikus regressziót érintő nem-linearitási problémakörökkel is. *McDonald és szerzőtársai (2012)* kimutatták, hogy a logisztikus regressziót torzító, az eredmény- és magyarázó változók közt mért nem-lineáris kapcsolatot okozhatja a modellbe bevont, különböző kockázati változók közti korreláció is. Ennek kiküszöbölésére a szerzők a főkomponens-elemzést (PCA) ajánlják a tanulmányban. A transzformáció, illetve a dimenziócsökkentés


¹³ Az időérték megőrzése érdekében a 2018 előtti folyósításoknak végig a jövőértékével számoltam, melyhez a kumulált szektorális átlagbér növekedési ütemét használtam fel.

elvégzésére én is a főkomponens-elemzést választottam. Ahogyan Kovács (2014) is javasolja eltérő szórású és mértékegységű változók esetén, én is a folytonos változók sztenderdizálását végeztem el első lépésként, ami kielégíti az adatok eloszlásával szemben állított normalitási kritériumot is. A kategóriaváltozók ugyan nem normális eloszlásúak és főkomponens-elemzésben való használatuk emiatt megosztó, de több szakirodalom, köztük Kolenikov és Angeles (2004) is megmutatták, hogy alkalmazásuk nem okoz nagy torzítást, főleg, ha több, folytonos változóval vannak kombinálva. Az így elvégzett főkomponens-elemzés a 10 meglévő ügylet- és ügyféltulajdonságból 4 transzformált változót alakított ki.

A PCA elvégzése után az ügyletek kockázatalapú csoportosítására fókuszáltam, melyhez a széles körben elterjedt dimenziócsökkentő eljárást, a klaszteranalízist használtam. Ezelőtt azonban meg kellett vizsgálni, hogy a kiválasztott változók és az adattömeg milyen fajta algoritmust tesznek lehetővé. A szakirodalomban általában az adattömeg és a kiugró értékek mértékéhez kötik a módszertanválasztást. A tanulmányhoz felhasznált adatok száma a nem hierarchikus klaszterelemzést teszi kézenfekvővé, ebből az egyik legismertebbet, a k-közép módszert választottam a csoportképzéshez. Ezen algoritmus minden elemet ahhoz a klaszterhez sorol, melynek középpontja a legközelebb esik az adott elemhez. A középpont általában a pontok egy (random) csoportjának az átlaga, és jellemzően csak folytonos, η -dimenziós térben elhelyezkedő pontokra alkalmazható, így fontos a változók szempontjából, hogy azonos skálán legyenek összegyűjtve. A módszertan sajátossága, hogy egy mintán kívüli, egyedi banki csoportképzés során ugyanúgy a mintán kimért csoportszámot fogja kialakítani, ami viszonylag homogén ügyfélszerkezet esetén – például kizárólag jó ügyfeleket hitelező banknál – torzító hatással lehet a felügyeleti stresszteszt futtatásánál. A potenciális torzítás redukálása, megszüntetése érdekében a klaszterek kalibrálása bankszektor-szinten fog történni, ami lehetőséget ad arra, hogy egy-egy bank az átlagtól jelentősen eltérő klaszterstruktúrával rendelkezzen, amennyiben ügyfélköre ezt indokolja.

A kialakuló főkomponensek segítségével tehát elvégeztem az említett klaszteranalízist, aminek eredményei alapján ugyan négy különböző kockázati csoport kialakítása lett volna indokolt, azonban két klaszter a múltbeli csődvalószínűségekre nagyon hasonló eloszlást produkált, így ezek összevonása és ezáltal három klaszter kialakítása mellett döntöttem. A bemutatott folyamat eredményeit az 1. ábra foglalja össze, míg a PCA és a k-közép klaszterelemzés statisztikái a Melléklet 6. táblázatában és 6. ábráján láthatók. Az 1. ábra felső paneljén látható, hogy a létrehozott kategóriák jól elkülönülnek a rájuk időben jellemző csődvalószínűségek alapján, így kijelenthető, hogy a csoportosítás az előzetes elvárásoknak megfelelő eredményeket szolgáltatott.

1. ábra
Az egyes klaszterek csődvalószínűségeinek (felső), valamint arányának (alsó) időbeli alakulása



Az 1. ábra alsó panelje azt is elárulja, hogy az egyes klaszterek milyen arányban fordultak elő a vizsgált időszakban. A 3-as számú klaszter erőteljes fogyása a legelső dolog, ami szembeötlik az ábráról. Jól kivehető ugyanis, hogy a legkockázatosabb ügyleteket tartalmazó klaszter részaránya a 2008-as pénzügyi válság környékén megfigyelt 70 százalékos körüli értékről 30 százalékos alá csökken a modellezett időszak végére. E jelenség egybevág azzal, amit *Bodnár és szerzőtársai (2014)* figyeltek meg a pénzügyi válságok és hitelezés kapcsolatát vizsgáló tanulmányukban. A szerzők azt találták, hogy a válságokat megelőző időszakokat általában túlzott, rossz minőségű hitelállomány felépülése jellemzi, ami Magyarországon is megfigyelhető volt a háztartási szektor devizahitelezése kapcsán. Az itt használt adatbázis és az 1. ábra tanulságai azonban azt mutatják, hogy nemcsak a hiteldenomináció, hanem egyéb ügylet- és ügylettulajdonságainak megoszlása is rosszabb volt a mostaninál. Az 1. ábrán továbbá – és azon belül is legfőképp az 1-es és 2-es klaszterekben – két érdekes esemény is megfigyelhető, melyek mind kormányzati intézkedésekhez kapcsolódnak. Az első 2011 környékén jelentkezik, amikor a rossz adósok aránya elkezd meredekebben csökkenni, ami a bankok visszafogottabb hitelezésére vezethető vissza. Ugyanakkor azt is megfigyelhetjük, hogy a legjobb adósok aránya stagnál, lassan változik, ami a válság utáni időszak alacsony hitelpenetrációjának, a jelzáloghitel-portfólió mérsékelt hígulásának köszönhető. Ez egybevág azzal, amit *Balás és szerzőtársai (2015)* állítanak, miszerint a 2011-ben induló végtörlesztéssel, azaz a hitelük ingyenes kifuttatásának lehetőségével főleg a legjobb adósok tudtak élni. A második töréspont, mely a jobb ügyletek arányának növekedését eredményezi, 2015–2016 környékén figyelhető meg. Ez pedig a HFM és a JTM hitelbírálatkori használatának kötelezővé tételével vág egybe, aminek értelmében a túladosodni kívánó hitelgénylőket be se engedik a portfólióba, így – kiegészülve a kereslet élénkülésének, valamint a kamatok csökkenésének pozitív hatásaival – a jó adósok aránya elkezdett bővülni.

A granulált adatokból emellett az is kiderül, hogy ezzel a folyamattal milyen típusú ügyletek kerülnek ki nagyobb mértékben a bankok jelzáloghiteles portfóliójából. Míg a legkevésbé kockázatos, 1-es klaszterben a legfeljebb érettségivel rendelkezők aránya 35 százalékos a teljes időszakot figyelembe véve, addig a 3-asban 79 százalékos. Hasonló eloszlás figyelhető meg az összes, klaszterezésbe bevont változónál. A devizahitelek például 64 százalékos, míg a szabad felhasználású jelzáloghitelt felvevők 84 százalékos arányúak a legkockázatosabb klaszterben. Ugyanez a tendencia látható a folytonos változók esetében. Az 1-es, legjobb kategóriában levő ügyletek átlagosan 26 százalékponttal magasabb JTM-mel rendelkeznek, mint a legrosszabban levők, míg a hitelösszeg (7,6 millió forint – 10,1 millió forint) és a futamidő (187 hónap – 250 hónap) is eltérő eloszlást mutat. Érdekesség, hogy a HFM és az eltelt idő tekintetében a második klaszternek az átlagos értékei a legmagasabbak, megfigyelhető azonban az is, hogy e kiugró értékekkel rendelkező ügyletek egyéb tulajdonságai

többségében átlagon alattiak kockázati szempontból, így nem érdemtelen a középső klaszterben elfoglalt helyük.

3. Idősoros modellezési keretrendszer a kockázati csoportok mentén

E fejezet adja a modellezési keretrendszer törzsének másik fontos elemét, a dinamikát, mely a klaszterezés statikus szemlélete után jelenik meg az anyagban. A felépítés – hasonlóan az első nagyobb blokkhoz – a modellezést elősegítő adatbázis ismertetésével kezdődik, majd a csődvalószínűségek idősoros modelljeinek bemutatásával folytatódik, végül robusztusságvizsgálattal, valamint modell-vizsatesztelésekkel zárul.

3.1. Felhasznált adatok

Ügylet- és ügyféltulajdonságok alapján megbecsülhető az adott portfólió általános kockázatosága, ami egy TTC jellegű mutatószámot fog adni. Ezzel ugyan a bankokat sebezhetőségi szempontból, az adott körülményeknek megfelelően el lehet különíteni egymástól, egyfajta sorrendiséget felállítva, azonban a modell stresszhelyzetre való reakciójának mérhetőségét mégis a gazdasági ciklustól függő változók becsatornázása teremti meg. Ilyen, prociklikus változók lehetnek azon makrogazdasági mutatók, melyek időben változnak, és jól megfogják az adott ország mindenkori gazdasági helyzetét. A jelzálog-csődeseményeket előrejelző modellbe bevont makrováltozóknak azonban egy másik fő tulajdonsággal is rendelkezniük kell: képesnek kell lenniük megfogni a lakossági adósok hiteltörlesztési hajlandósága és a gazdasági ciklusok közti kapcsolatot.

E kapcsolat kimutatására lineáris regressziós modelleket használtam fel, melyek összekötik a különböző kockázati csoportok csődvalószínűségeit a kiválasztott makrováltozókkal. A modellezésbe bevonható makrováltozók körének kiválasztását két tényező befolyásolta. Egyrészt az eredményeknek tükrözniük kell egy stresszhelyzet hatását a lakossági jelzáloghitelek csődvalószínűségére, így csupán szakértői szinten is intuitív változók bevonása volt indokolt. Másrészt, predikciós modell révén szükségzerű a magyarázó változók előre jelezhetősége is, hogy egy későbbi – akár 2–3 éves távlatú – időszakra is meg lehessen becsülni a csődvalószínűségeket. Emiatt csak olyan változókat tudtam felhasználni, melyekre elérhető előrejelzés. Az utóbbi kritérium összesen 18 makrogazdasági mutatóra korlátozta az elemzést. E változóknak az 1–4 negyedévvél készített értékeit is bevontam a modellezésbe, kezelve a potenciálisan, akár egy évvel elhúzódo hatásokat is. Az először szakértői alapon, majd statisztikai megközelítésben is megvizsgált változókat az *1. táblázatban* gyűjtöttem össze.

1. táblázat**A modellezéshez felhasznált makrogazdasági változók listája, alkalmazott rövidítésük és számítási módszerük**

Változó neve	Számítás	Változó neve	Számítás
Háztartások nettó pénzügyi vagyona (<i>wealth</i>)	2015. évi áron	Háztartások rendelkezésre álló jövedelme (<i>hinc</i>)	2015. évi áron
Infláció (<i>infl</i>)	év/év	EUR/HUF árfolyam (<i>eurhuf</i>)	átlagos
Munkanélküliségi ráta (<i>unemp</i>)	munkaerőfelmérés szerinti	BUBOR-kamat (<i>bub3m</i>)	3 hónapos
GDP (<i>gdp</i>)	év/év	BUX-index (<i>bux</i>)	2015. évi áron
Export (<i>exp</i>)	2015. évi áron	BUX-index volatilitása (<i>buxvola</i>)	negyedéves
Import (<i>imp</i>)	2015. évi áron	EURIBOR kamat (<i>eurib3m</i>)	3 hónapos
Foglalkoztatottság a versenyszférában (<i>emp</i>)	ezer fő	Benchmark hozamgörbe (<i>gov1y, gov3y, gov5y, gov10y</i>)	állampapírpiazi, százalék
Bruttó átlagkereset a versenyszférában (<i>wage</i>)	2015. évi áron		

Megjegyzés: A GDP és részletelei szezonálisan és naptárhatással kiigazított és kiegyensúlyozott adatok.

A becslni kívánt eredményváltozó mindhárom, korábban kialakított klaszter esetében az éves, előrejutató csődvalószínűség. Ennek meghatározására a fent bemutatott képletből a késedelmes napszám alapján számolt $[0,1]$ értéket felvehető csődeseményekből indultam ki, melyeket az adatbázisban szereplő egyedi időpontokra és klaszterekre aggregáltam, majd a csődeseménnyel érintett ügyletek kitettségeinek arányát felhasználva számoltam átlagos, időszakos DR-t (lásd *Melléklet 7. ábrája*). A magyarázó változók adatbázisa, az eredményváltozóval összhangban a 2004–2018-as időszakra tartalmaz múltbeli értékeket.

3.2. Modellek kialakítása és eredmények

A csődvalószínűségek előrejelzését a kialakított kockázati kategóriák mentén végeztem el, összesen 3 regressziós egyenletet kialakítva. Ennek során mind a modellbe történő, magyarázóerőn alapuló bevonhatóságot, mind az egymásra ható interakciókat, az idősor megfelelőségét is ellenőriztem. E vizsgálatok egyik hozományaként a regressziókhoz felhasznált magyarázóváltozókat a stacionaritás¹⁴ elérése érdekében egyszer differenciáltam. Az eredményváltozó esetében ugyan felmerült, hogy a sztenderd gazdasági idősoroktól eltérő módon, a korlátossága miatt akár

¹⁴ Egy sztochasztikus folyamatot széles értelemben stacionáriusnak nevezünk, ha az együttes eloszlásfüggvénye nem függ az időtől (*Matyasovszky 2002*).

stacionárius is lehetne hosszú idősoron, ezt azonban a Dickey-Fuller teszt nem támasztotta alá, így ezt az idősort is differenciáltam. A kialakított regressziós egyenletek az alábbi, sztenderd struktúrában lettek felírva:

$$\Delta DR_{\text{éves átlagos}} = \beta_0 + \sum_{i=1}^n \beta_i \cdot \Delta x_i$$

ahol Δx_i a regresszióba bevont i -edik magyarázó változónak a változását jelöli, n pedig ezek számát.

A magyarázó változók kiválasztása előtt az eredményváltozó idősorának autokorreláltságát, azaz az időben késleltetett értékeinek magyarázó erejét, a tényidősza-ki értékkel vett korrelációját is megvizsgáltam. Az autokorrelációs tesztek minden klaszter esetében az első 1–2 negyedéves késleltetetre szignifikanciaszinten belüli értéket mutatott. Mivel azonban az eredményváltozó éves csődvalószínűségeket tartalmaz, tehát a következő 4 negyedév értékeivel természetes átfedésben van, és a *Melléklet 9. táblázatából* kiolvasható, teljes modellre futtatott Durbin-Watson alternatív tesztek se mutattak ki autokorrelációt, így az eredményváltozó éven belüli autokorrelációját modellezés szempontjából nem tekintetem zavarónak.

A csődvalószínűség változásának előrejelzéséhez szükséges makrováltozók kiválasztásához először egyszerű lineáris regressziókat futtattam az eredményváltozó és egy-egy makrogazdasági mutató, vagy a késleltetettjeinek változása között. Az egyenletek és tesztstatisztikák alapján szignifikánsnak mondható változókat egybe vontam, majd backward¹⁵ eliminációs módszerrel választottam ki azon változókat, melyek együttesen is szignifikánsak maradtak. Külön figyeltem arra, hogy az eljárás során a magyarázó változók közt jelen levő korreláció (lásd *Melléklet 7. táblázata*) miatt potenciálisan kieső makrováltozók a végső modellekből ne kerüljenek ki, így a módszer lefuttatása után minden szelektált változót egyesével visszapróbáltam a modellekbe, és csak ezen eljárás után tekintetem az elhagyást véglegesnek. Az így bent maradó változónál arra is figyeltem, hogy az egymás közti korreláció ne lépje át a kritikusnak beállított 0,6-os szintet. A három klaszter legmagasabb magyarázó erővel és robusztussággal bíró egyenleteit a *2. táblázat* tartalmazza, míg az ide tartozó tesztstatisztikák a *Melléklet 8., 9. és 10. táblázatában* találhatóak. A *2. táblázatból* az is kiderül, hogy a bemutatott módszertan – az idősor hosszán és aktualitásán felül – miben tér el legmarkánsabban *Banai és szerzőtársai (2013)* MNB-s makroprudenciális stressztesztben alkalmazott feltételezéseitől. Amíg én a klaszterek kialakításával lehetővé tettem, hogy az heterogén helyzetű és kockázatosságú adósokra eltérő makrováltozók eltérő mértékben hassanak, addig az említett

¹⁵ A szelektációs eljárás lépései a következők: 1) a magyarázó változóval logikailag összefüggő valamennyi változót beépítem a modellbe, 2) kiszámítom a magyarázó változók paramétereire a parciális t-próba értékét, 3) amennyiben a legalacsonyabb t-értékű változónak a t értéke alacsonyabb az adott szignifikanciaszinthez tartozó értéknél, akkor e változót kizárom a regresszióból, 4) a maradék magyarázó változók felhasználásával egy újabb modellt építek, 5) ezt addig folytatom, amíg a modellben csak szignifikáns változók maradnak.

szerzők azt látták megfelelőnek, ha minden hitelezett csődvalószínűsége ugyanazon külső körülmények mentén kerül becslésre. Az eredmények alátámasztják e gondolatot, ugyanis közgazdasági szempontból intuitívnek tartom, hogy például a klaszterek mentén egyre magasabb együtthatóval rendelkező foglalkoztatottság alakulása erőteljesebben érinti a rosszabb, egyetemet nem végzett, potenciálisan csupán alkalmi, vagy sérülékenyebb munkakörben dolgozókat, mint a diplomás, vélhetően tartósabb munkahellyel rendelkezőket. Az is megfigyelhető, hogy ugyancsak a sérülékenyebb, második és harmadik klaszterbe tartozó adósoknál mérvadó a nettó vagyon, míg a hiteltörlesztés alapján legmegbízhatóbbnak tekinthetőknél be se került ez a változó az egyenletbe. Ez, hasonlóan az előző megfigyeléshez, feltehetőleg azzal magyarázható, hogy biztosabb munkahelyen jobban keresnek (ami a JTM-szintekben is megfigyelhető), és jobban a munkajövedelmükre, mintsem a már meglévő vagyonukra támaszkodnak.

2. táblázat

A backward szelekciós eljárással meghatározott többváltozós lineáris regressziók eredményei

	Klaszterek		
	1	2	3
Eredményváltozó / Magyarázó változók	d_{DR_y}	d_{DR_y}	d_{DR_y}
d_{emp}	-0,05367**(0,0260)	-0,14823**(0,0619)	-0,28462*** (0,0886)
d_{exp}	-0,01632**(0,0067)		
$l1_d_gdp$	-0,00028**(0,0001)		
d_gov10y	0,00044**(0,0002)		
d_bub3m	0,00145*** (0,0003)	0,00229** (0,0009)	0,00549*** (0,0012)
d_wealth		-0,05383** (0,0226)	-0,08171** (0,0323)
$l3_d_gov1y$		0,00193*** (0,0006)	
$l1_d_bux$		-0,01027* (0,0055)	
$l3_d_hinc$			-0,08444** (0,0330)

Megjegyzés: * $p < 0,1$; ** $p < 0,05$; *** $p < 0,01$, zárójelben a standard hibák. A „ d ” a változó éves változását, az „ l ” a negyedéves késleltetés mértékét jelöli, míg az „ y ” az éves mivoltát jelzi a csődvalószínűségnek.

A minta hitelkockázati szempontból egy elég eseménydús időszakot fed le, tele olyan kormányzati és szabályozói intézkedéssel, melyek komoly hatással voltak a lakossági hitelek kockázati besorolására, s ezáltal a csődvalószínűségek alakulására is. Talán a legnagyobb volumenű állami intézkedés, mely jelentős kilengést okozott a csődvalószínűségek historikus idősorában, az elszámolással egyidejű forintosítás volt. Ezen intézkedések rövid távon a csőd valószínűségének időszakos növekedéséhez, majd csökkenéséhez vezettek. A 2011–2012-es jelenségről több tanulmány született. *Sepsi (2014)* az emelkedést annak tulajdonítja, hogy a kormányrendelet kihirdetése és a tevékenység tényleges megtörténte közt az adós esetlegesen nem

törődött annyit azzal, hogy befizesse az éppen aktuális törlesztőrészletét, hiszen tudta, hogy hamarosan úgyis összegszegben törlesztheti a hitelét. *Balás és szerző-társai (2015)* a csődvalószínűségek időszakos emelkedését azzal magyarázza, hogy a bankrendszerből többnyire olyan jelzálogadósok kerültek ki, akik jól teljesítettek, ami a csődvalószínűség nevezőjének csökkenéséhez vezethetett, míg a számlálóban nem okozott változást. A forintosításnál is hasonló volt a helyzet, ez esetben is a nevező zsugorodott, a devizában denominált hitelek értékének csökkenésével. Két megoldást azonosítottam az 1. vagy 3. ábrán is látható kiugrások simítására, melyből az első egy dummy változó¹⁶ modellhez való hozzáadása lehetett volna, ami potenciálisan lefedné a makrováltozókkal csak vélhetően hibásan magyarázható idősoros törést. A másik lehetséges megoldás az idősor csonkolása, mely a kérdéses 2015-ös év volatilisabb negyedéveit kivenné a modellbecslésből. Végül az idősor megvágása mellett döntöttem két okból is. Egyrészt, mivel csupán egy évet érintett a kérdéskör a közel 14 évet felölelő időorból, másrészt a dummy változó használata sem statisztikailag, sem előrejelzés és visszatesztelés szempontjából nem volt meggyőző, mivel mindkét esetben rosszabbul teljesített, mint a kiválasztott, második megoldás.

3.3. Keresztvalidáció, robusztusságvizsgálat

A tesztelés során kétféle megközelítésből is megvizsgáltam az eredményeket, melyeket ebben az alfejezetben mutatok be. Az első és legfontosabb a modellek stabilitásának vizsgálata volt, aminek során a bevont magyarázó változók együttthatójának és szignifikanciaszintjének állandóságát ellenőriztem. Céлом az volt, hogy bebizonyítsam, a modell hasonló együttthatókat rendel a változókhoz a minta keresztmetszeti és idősoros zsugorításával, valamint egyes változók egyenletből való kihagyásával is, a bent maradó makrováltozók szignifikanciájának megtartása mellett. A végrehajtás elősegítése érdekében a modellezés előtt random mintavétellel leválasztottam a meglevő teljes adathalmaz 25 százalékát. A keresztvalidációt e tesztállományon elvégezve azt tapasztaltam, hogy a tesztelés szempontjából kritikusnak meghatározott 10 százalékos szignifikanciaszintet (p -értéket) a 3 egyenletben felhasznált változók csak elenyésző számban lépik át. A keresztmetszeti csonkítás után a modelladatbázis idősorát szűkítettem felére, aminek során hasonlóan pozitív eredményeket kaptam. A modellek robusztusságvizsgálatát egy-egy változó kihagyásával fejeztem be. Ez esetben a szignifikanciaszintek egyetlen esetet leszámítva megmaradtak a kritikus 10 százalékon belül, és a magyarázó változók együttthatói se tértek el jelentős mértékben az eredeti modellekben megfigyelt értékektől. A vizsgálatok részletei megtalálhatók a *Melléklet 11. táblázatában*.


A második körös tesztelés során a modellek pontosságát a tényleges csődvalószínűségek és a modell által előre jelzett értékek összevetésével teszteltem. A 2008-ban

¹⁶ 1 értéket vesz fel azokban a negyedévekben, amikor a törés megfigyelhető (2014Q4–2015Q4), és 0-t a többiben.

kitörő pénzügyi válság első három évét választottam ki mintának, melynek két oka is volt. Az egyik, hogy stresszelőrejelző modell révén egy csődvalószínűségek szempontjából volatilis időszakra volt szükségem, másrészt pedig általában a felügyeleti stressztesztben is hasonló mértékű visszaeséseket szimulálok. A visszatesztelés eredményeit a 2. ábra mutatja, melyen látszódik, hogy a modell becslései a tényadatok mentén mozognak, jelentős eltérés nem tapasztalható.

2. ábra

Tény és modellezett csődvalószínűségek klaszterenként visszabecsülve a 2008-as válság adatain



Elmondható tehát, hogy az elvégzett, robusztusságot és modelljóságot is mérő keresztvalidációk, visszatesztelések alapján a modellek megfelelően képesek megfogni mind a makrováltozók időbeli mozgásait, mind a kockázati csoportosítás alapját képző ügylet-, illetve ügyféltulajdonságok szeparáló hatását.

4. Csődvalószínűségek transzformálása stage-átmenetvalószínűségekbe

A csődvalószínűségek előrejelzésével csupán a teljesítő és nemteljesítő ügyletek elkülönítésére lennének képesek, mely az új számviteli standard, az IFRS 9 elterjedésével már nem lett volna elegendő. Ebben a fejezetben azt mutatom be, hogy

a két, adósok hiteltörlesztési teljesítménye mentén kategorizáló csoportból hogyan lesz négy, az ügyfél fizetőképessége szerint jobban szeparáló hitelkockázati stage.

4.1. Stage-ek kialakítása


Az új számviteli standard ajánlása (IASB 2013) alapján 3 hitelkockázati kategória kialakítása szükséges. Az elsőben („stage 1”) azon ügyletek kapnak helyet, akik egyáltalán nem, vagy alig (maximum 30 nappal) késedelmesek. A nem teljesítő és a jól teljesítő ügyletek közti átmenet kategória („stage 2”) – mely részben megkülönbözteti az IFRS 9-et a korábbi számviteli standardtól¹⁷ – magában foglalja a 30-nál nagyobb, de 90 napot nem meghaladó késedelemmel rendelkező hitszerződéseket. A csoport kialakításánál a számviteli standard ajánlása alapján több ügylet- és szubjektív tulajdonság¹⁸ is figyelembe vehető. Ezt igazolja az az ICAAP-vizsgálati tapasztalatom is, miszerint ahány bank van, nagyjából annyiféle szabály létezik a stage 2 meghatározására. A modellemben végül az összehasonlíthatóság, az egyszerűség és az adatok elérhetősége miatt követtem a stage 1-es logikát, és csupán a késedelmes napszámot vettem figyelembe a csoportképzésnél, 31–90 nap közötti értékekkel. Végezetül a nemteljesítő kategóriát („stage 3”) alakítottam ki. Stage 3-ba azon ügyleteket helyeztem el, melyek 90 napot meghaladó késedelemmel rendelkeztek a megfigyelés időpontjában.

További, késedelmes napszám eloszlása mentén tett vizsgálatok ugyanakkor arra mutattak rá, hogy a stage 1 kockázatossága túlságosan heterogén az egységes modellezéshez. A 3. ábrán ugyanis megfigyelhető, hogy azon stage 1-es ügyfelek, akik a folyósítás óta legalább egyszer már 30 napnál nagyobb késedelembe estek a hiteltörlesztőjükkel, nagyobb eséllyel esnek újra ebbe a hibába, mint a mindig jól teljesítő társaik. Emellett az is látszik, hogy az átmenet kategóriában (stage 2) lévő ügyleteket átlagosan jóval nagyobb eséllyel teszik defaultba bármelyik stage 1-es társuknál, s ezenfelül a gazdaság kilengéseire is erőteljesebben reagálnak. E jelenséggel összhangban, ám az IFRS 9 ajánlásával ellentétben tehát nem három, hanem négy kockázati kategória kialakítását láttam indokoltnak. Az első alcsoportba („stage 1a”) a legjobb ügyletek kerültek, melyek aktuálisan maximum 30 napos késedelembe vannak, ráadásul – ellentétben a bankszektorban megszokott kategorizálással – a megfigyelés időpontja előtt is jól teljesítettek, azaz az ügylet keletkezése óta sosem estek 30 napnál nagyobb késedelembe. A második stage 1-es alkategória („stage 1b”) azon ügyleteket tartalmazta, akik ugyan a megfigyeléskor nem haladták meg a 30 napos késedelmet, azonban az élettartalmuk alatt ez legalább egyszer már megtörtént.

¹⁷ Az IAS 39 csupán két kockázati kategóriát különböztetett meg: teljesítő és nemteljesítő. A nemteljesítés fogalm meghatározását („default definition”) először az Európai Parlament és Tanács 2006/48/EK irányelve tartalmazta hivatalos formában.

¹⁸ Átstrukturálás, kezdeti és megfigyeléskori PD-értékek közti különbség, kockázati besorolás, szakértői értékítélet

3. ábra
A különböző kockázati besorolású, teljesítő jelzáloghitelek éves átlagos csődvalószínűsége



4.2. Átmenetvalószínűségek előrejelzése

Miután a két kockázati csoportból négy lett, így az előre jelezni kívánt – csoportok közti – migrációs valószínűségek száma is jelentősen megnövekedett. Defaultból, azaz stage 3-ból a felügyeleti és az *EBA (2021)* stresszteszt módszertanával összhangban továbbra se lehet kikerülni, így azzal az iránnyal most se foglalkoztam. A stage 1a–stage 2, stage 1a–stage 3, stage 1b–stage 2, stage 1b–stage 3, stage 2–stage 1b, stage 2–stage 3 irányok azonban mind fontosak voltak a pontos hitelkockázati veszteség előrejelzésének szempontjából. A csődvalószínűségek átalakítását ebben az alfejezetben mutatom be.

Az átalakítást az EKB által kidolgozott módszertan iránymutatásainak megfelelően végeztem el. Az anyag az EBA EU-szintű, legnagyobb bankcsoportokat egybefogó stressztesztjéhez készült, a nemzeti felügyeleték szigorúan belső felhasználására, így segítve a részt vevő bankok – Magyarországról az OTP-csoport – belső modelljeinek ellenőrzését, összehasonlítását a gyakorlat során alkalmazott minőségbiztosítási folyamat alatt. Az EKB modelljében a csődvalószínűségek közvetlenül csupán a stage 1–stage 3 (TP^{1-3}), illetve a stage 2–stage 3 (TP^{2-3}) migrációk előrejelzéséhez vannak felhasználva, az alábbi képletek alapján¹⁹:

¹⁹ Természetesen a fejezet bevezetőjével összhangban a stage 1-es állomány a modellemben – az EKB gyakorlatával ellentétben – két részre lett bontva, mely a stage 1-es képleteket is „a”, illetve „b” részre bontja.

$$TP_{T_0+h}^{1-3} = \Phi \left(\Phi^{-1}(TP_{T_0}^{1-3}) + \Phi^{-1}(DR_{T_0+h}) - \Phi^{-1}(DR_{T_0}) \right)$$

$$TP_{T_0+h}^{2-3} = \Phi \left(\Phi^{-1}(TP_{T_0}^{2-3}) + \Phi^{-1}(DR_{T_0+h}) - \Phi^{-1}(DR_{T_0}) \right)$$

ahol T_0 a kiindulási időszak értékeit, Φ a standard normális eloszlás kumulatív eloszlásfüggvényét, míg h a kiindulási időpont óta eltelt periódusok számát jelöli. A kiindulási (T_0) valószínűségeket az azt megelőző év (tényév) ténylegesen megfigyelt, stage-ek közötti kitettsévándorlások alapján számolom. A jövőbeli, fiktív TP^{1-3} átmenetvalószínűséget meghatározó képlet a stage 1 megbontásával természetesen duplikálódik, azaz a mindig teljesítő és a visszaeső ügyletekre is egyaránt kiszámolom a migráció esélyét. A számítás megtörténik mind a három klaszterre külön-külön, így összesen 9 eltérő számot kapunk arra, hogy az adott csoportba tartozó ügylet milyen valószínűséggel válik nemteljesítővé a következő évi során.

A nemteljesítő kategóriába vándorlás valószínűségének előrejelzése azért is elsődleges fontosságú, mivel mind a stage 1–stage 2, mind a stage 2–stage 1 előrejelzése is ezekre épít. Ennek becslésére egy egyszerű lineáris regressziós kapcsolatot használtam fel, az alábbi képletek szerint:

$$\Phi^{-1}(TP_t^{1-2}) = \beta_0 + \beta_1 \cdot \Phi^{-1}(TP_t^{1-3})$$

$$\Phi^{-1}(TP_t^{2-1}) = \beta_0 + \beta_1 \cdot \Phi^{-1}(TP_t^{2-3})$$

ahol tehát először a TP^{1-2} és a TP^{1-3} múltbeli együttmozgásának együtthatóját (β_1) becsülöm, majd – az eloszlások időbeli megmaradását feltételezve – ezen együttható mentén vetítem előre a TP^{1-2} értékét a már korábban előre jelzett TP^{1-3} -on keresztül. Hasonló az eljárás mód a TP^{2-1} esetében is, azzal a különbséggel, hogy e migráció mellé a TP^{2-3} kerül a magyarázó változó szerepébe. A TP^{1-2} és TP^{2-1} becslésénél, ellentétben a TP^{1-3} és TP^{2-3} átmenetekkel, már nem bontom meg a mintát klaszterekre, hiszen ezen csoportok eltérő kockázatai már beépülnek a tényadatokon, majd a regressziók magyarázó változóin keresztül is.

3. táblázat

A stage-átmenetvalószínűségek közti egyváltozós lineáris regressziók eredményei

	Eredményváltozók		
Magyarázó változók	$d_invn_s1as2_y$	$d_invn_s1bs2_y$	$d_invn_s2s1b_y$
$d_invn_s1as3_y$	0,52438*** (0,0854)		
$d_invn_s1bs3_y$		0,23393*** (0,0678)	
$d_invn_s2s3_y$			-0,69007*** (0,1002)

Megjegyzés: * $p < 0,1$; ** $p < 0,05$; *** $p < 0,01$, zárójelben a standard hibák. A „ d ” a változó éves változását, az „ $invn$ ” a kumulált standard normális eloszlás inverzét rövidíti, míg „ y ” az éves mivoltát jelzi az átmenetvalószínűségeknek.

Az átmenetvalószínűségeket végül egyszer differenciáltam, hogy az idősoros regressziók alkalmazásához elengedhetetlen stacionaritás feltétele is teljesüljön a változókra. A fent leírtak szerint kialakított modellek eredményeit a 3. táblázat tartalmazza, melyben megfigyelhető többek között az is, hogy míg a TP^{1-3} együttthatói a regressziókban – az előzetes intuíciónkkal összhangban – pozitív értékeket vesznek fel, azaz a kölcsönhatás egyirányú mozgást feltételez a TP^{1-2} értékekkel, addig a TP^{2-3} esetében – szemléltetve, hogy ott két ellentétes irányú folyamat együttmozgását vizsgálom – negatív érték szerepel.

5. Összefoglalás, tanulságok

A teljes modellezési folyamat befejeztével több következtetés, tanulság is levonható, ami a továbbiakban segítheti a Magyarországon működő hitelintézetek és hitelintézeti csoportok jelzáloghitel-portfóliójához kapcsolódó kockázatok pontosabb felmérését és megfelelő stressztesztelésüket. Az egyik ilyen – melynek miertje a korábbi felügyeleti stressztesztelési gyakorlatból nem látszódott ennyire tisztán –, hogy a jelenlegi körülmények és hitelportfóliók mellett egy, a 2008-as világválsághoz hasonló mértékű makrogazdasági sokkal a magyar bankokra nem lehetséges hasonló hitelkockázati veszteségeket becsülni. Ennek két oka is van: 1) a válság előtti időkből a kiindulási DR-k jóval magasabbak voltak, mint amik a tanulmány megjelenése előtti időszakban megfigyelhetők, 2) a turbulens időszakot megelőzően felépült egy – nem csupán a hitel denominációja, de egyéb tulajdonságai miatt is – kockázatosabb, rosszabb minőségű portfólió, melyben emiatt sokkal nagyobb volt a potenciális csődveszély is. Az első ok bizonyos mértékben a második okozata is lehet, azonban ez részben köthető a pénzügyi tudatosság, a hitelvisszafizetés pszichológiája, a hitelezési kontrollok gyengébb elterjedtségéhez, korlátozottabb megéléséhez is a korábbi időkből. Egy másik levonható tanulság, hogy sokkal pontosabb képet kaphatunk a különböző – minőségileg eltérő hiteleket beengedő – bankok hitelkockázatairól, ha ügyletszinten modellezve, különböző tulajdonságok felhasználásával stresszelünk hitelportfóliókat. Megfigyelésem szerint a legkockázatosabb és legjobb ügyfélcsoportok közt a csődvalószínűséget tekintve akár több százalékpontnyi különbség is lehet. Nem csupán az említett hiteltulajdonságok használata, de a modell kétlépcsős tétele is potenciálisan hozzájárulhat egy pontosabb becsléshez a makrováltozók heterogén felhasználásán keresztül. A modellezési eredmények arról árulkodnak, hogy a hiteltörlesztők fizetésénél leginkább a munkajövedelem stabilitása, különböző vagyonelemekre való támaszkodás mértéke befolyásolja, hogy az eltérő kockázati csoportokba sorolható adósok csődvalószínűségét milyen mutatók alakítják.

A modellek tehát hozzájárulnak a stresszpálya eredményeit leginkább befolyásoló komponens, a hitelkockázati költségek kiszámításához. A ciklusokon átívelő, hitelezési tulajdonságokat felhasználó lépés különválasztásából nyert tapasztalatokkal pedig a stresszteszt dinamikáját érintve dönthetünk arról, hogy a stresszpályán folyósított ügyletek a kifizetőkkel összhangban legyenek-e, vagy módosuljon a portfólió hitelkarakterisztikája – és ha igen, milyen irányban, mennyire.

Felhasznált irodalom

- Acuña, E. – Rodriguez, C. (2004): *The Treatment of Missing Values and its Effect on Classifier Accuracy*. Megjelent: Banks, D. – McMorris, F.R. – Arabie P. – Gaul W. (eds.): *Classification, Clustering, and Data Mining Applications*, pp. 639–647. https://doi.org/10.1007/978-3-642-17103-1_60
- Agarwal, V. – Taffler, R. (2008): *Comparing the performance of market-based and accounting-based bankruptcy prediction models*. *Journal of Banking and Finance*, 32(8): 1541–1551. <https://doi.org/10.1016/j.jbankfin.2007.07.014>
- Altman, E.I. (1968): *Financial ratios discriminant analysis and the prediction of corporate bankruptcy*. *Journal of Finance*, 23(4): 589–609. <https://doi.org/10.1111/j.1540-6261.1968.tb00843.x>
- Balás Tamás – Banai Ádám – Hosszú Zsuzsanna (2015): *A nemteljesítési valószínűség és az optimális PTI-szint modellezése egy háztartási kérdőíves felmérés felhasználásával*. MNB-tanulmányok 117, Magyar Nemzeti Bank. <https://www.mnb.hu/letoltes/117-mnb-tanulmany-hun.pdf>
- Banai Ádám – Hosszú Zsuzsanna – Körmendi Gyöngyi – Sóvágó Sándor – Szegedi Róbert (2013): *Stressztesztek a Magyar Nemzeti Bank gyakorlatában*. MNB-tanulmányok 109, Magyar Nemzeti Bank. <https://www.mnb.hu/letoltes/mt109-vegleges.pdf>
- Bielecki, T.R. – Rutkowski, M. (2004): *Credit Risk: Modeling, Valuation, and Hedging*. Springer, New York. <https://doi.org/10.1007/978-3-662-04821-4>
- Bodnár Katalin – Kovalszky Zsolt – Kreiszné Hudák Emese (2014): *A válságokból történő kilábalás és a hitelezés kapcsolata*. *Hitelintézeti Szemle*, 13(4): 57–85. <https://hitelintezetiszemle.mnb.hu/letoltes/3-bodnar-et-al-2.pdf>
- Chae, S. – Sarama, R. F. – Vojtech, C. M. – Wang, J. Z. (2019): *The Effect of the Current Expected Credit Loss Standard (CECL) on the Timing and Comparability of Reserves*. Finance and Economics Discussion Series 2018-020, Board of Governors of the Federal Reserve System (U.S.). <https://doi.org/10.17016/FEDS.2018.020r1>

- Crouhy, M. – Galai, D. – Mark, R. (2000): *A comparative analysis of current credit risk models*. Journal of Banking and Finance, 24(1–2): 59–117. [https://doi.org/10.1016/S0378-4266\(99\)00053-9](https://doi.org/10.1016/S0378-4266(99)00053-9)
- Daniels, T. – Duijm, P. – Liedorp, F. – Mokus, D. (2017): *A top-down stress testing framework for the Dutch banking sector*. Occasional Studies, 15-3, De Nederlandsche Bank. https://www.dnb.nl/media/ss1h5zks/201707_nr_3_-2017-_a_top-down_stress_testing_framework_for_the_dutch_banking_sector.pdf
- Das, S.R. – Hanouna, P. – Sarin, A. (2009): *Accounting-based versus market-based cross-sectional models of CDS spreads*. Journal of Banking and Finance, 33(4): 719–730. <https://doi.org/10.1016/j.jbankfin.2008.11.003>
- EBA (2021): *2021 EU-Wide Stress Test – Methodological note*. European Banking Authority. https://www.eba.europa.eu/sites/default/documents/files/document_library/Risk%20Analysis%20and%20Data/EU-wide%20Stress%20Testing/2021/Launch%20of%20the%20ST/962559/2021%20EU-wide%20stress%20test%20-%20Methodological%20Note.pdf. Letöltés ideje: 2021. február 5.
- Fáykiss Péter – Palicz Alexandr – Szakács János – Zsigó Márton (2018): *Az adósságfék-szabályok tapasztalatai a magyarországi lakossági hitelezésben*. Hitelintézeti Szemle, 17(1): 34–61. <https://doi.org/10.25201/HSZ.17.1.3461>
- Gross, M. – Laliotis, D. – Leika, M. – Lukyantsau, P. (2020): *Expected Credit Loss Modeling from a Top-Down Stress Testing Perspective*. IMF Working Paper WP/20/111, International Monetary Fund. <https://doi.org/10.5089/9781513549088.001>
- Gross, M. – Población, J. (2015): *A false sense of security in applying handpicked equations for stress test purposes*. ECB Working Paper 1845, European Central Bank. <https://doi.org/10.2139/ssrn.2664133>
- Holló, D. (2009): *Risk developments on the retail mortgage loan market*. MNB Bulletin, 4(3): 14–19. <https://www.mnb.hu/letoltes/hollo-2009-okt-en.pdf>
- Horváth, G. (2021): *Vállalatok hitelkockázati modellezése a Magyar Nemzeti Bank felügyeleti stressztesztjében*. Hitelintézeti Szemle, 20(1): 43–73. <https://doi.org/10.25201/HSZ.20.1.4373>
- IASB (2013): *Financial Instruments: Expected Credit Losses*. Exposure Draft, ED/2013/3, International Accounting Standards Board. <https://www.ifrs.org/content/dam/ifrs/project/fi-impairment/exposure-draft-2013/published-documents/ed-expected-credit-losses.pdf>. Letöltés ideje: 2021. március 4.
- Jagric, V. – Kracun, D. – Jagric, T. (2011): *Does Non-linearity Matter in Retail Credit Risk Modeling*. Czech Journal of Economics and Finance, 61(4): 384–402.

- Kolenikov, S. – Angeles, G. (2004): *The Use of Discrete Data in PCA: Theory, Simulations, and Applications to Socioeconomic Indices*. <https://www.measureevaluation.org/resources/publications/wp-04-85.html>. Letöltés ideje: 2021. március 11.
- Kovács Erzsébet (2014): *Többváltozós adatelemzés*. Typotex Kiadó, Budapest.
- Landini, S. – Uberti, M. – Casellina, S. (2019): *Credit risk migration rates modelling as open systems II: A simulation model and IFRS9-baseline principles*. *Structural Change and Economic Dynamics*, 50(September): 175–189. <https://doi.org/10.1016/j.strueco.2019.06.013>
- Lang, P. – Stancsics, M. (2019): *Modeling loan loss provisions under IFRS 9 in the top-down solvency stress test of the Central Bank of Hungary*. EBA Policy Research Workshop “The future of stress tests in the banking sector – approaches, governance and methodologies”, Paris. https://www.eba.europa.eu/sites/default/documents/files/document_library/Calendar/Conference-Workshop/2019/8th%20annual%20workshop%20documents/10%20Modeling%20loan%20loss%20provisions%20under%20IFRS%20in%20the%20top-down%20solvency%20stress%20test%20of%20the%20Central%20Bank%20of%20Hungary.pdf?retry=1. Letöltés ideje: 2021. április 14.
- Lawrence, E.L. – Smith, S. – Rhoades, M. (1992): *An analysis of default risk in mobile home credit*. *Journal of Banking and Finance*, 16(2): 299–312. [https://doi.org/10.1016/0378-4266\(92\)90016-5](https://doi.org/10.1016/0378-4266(92)90016-5)
- Little, R.J.A. – Rubin, D.B. (2002): *Statistical Analysis with Missing Data*. Wiley, New Jersey. <https://doi.org/10.1002/9781119013563>
- Martin, D. (1977): *Early warning of bank failure: A logit regression approach*. *Journal of Banking and Finance*, 1(3): 249–276. [https://doi.org/10.1016/0378-4266\(77\)90022-X](https://doi.org/10.1016/0378-4266(77)90022-X)
- McDonald, R.A. – Sturgess, M. – Smith, K. – Hawkins, M.S. – Xiao-Ming Huang, E. (2012): *Non-linearity of scorecard log-odds*. *International Journal of Forecasting*, 28(1): 239–247. <https://doi.org/10.1016/j.ijforecast.2011.01.001>
- Matyasovszky István (2002): *Statisztikus klimatológia (Idősorok elemzése)*. ELTE Eötvös Kiadó, Budapest.
- Pederzoli, C. – Torricelli, C. (2005): *Capital requirements and business cycle regimes: forward-looking modelling of default probabilities*. *Journal of Banking and Finance*, 29(12): 3121–3140. <https://doi.org/10.1016/j.jbankfin.2005.01.004>
- Platt, H.D. – Platt, M.B. (1991): *A note on the use of industry-relative ratios in bankruptcy prediction*. *Journal of Banking and Finance*, 15(6): 1183–1194. [https://doi.org/10.1016/0378-4266\(91\)90057-5](https://doi.org/10.1016/0378-4266(91)90057-5)

Sepsi Barbara (2014): *Így változott a 90 napon túli késedelmes devizaalapú hitelek helyzete Magyarországon*. Közgazdász Fórum, 17(119/120): 168–181.


Sommerville, R.A. – Taffler, R.J. (1995): *Banker judgement versus formal forecasting models: The case of country risk assessment*. Journal of Banking and Finance, 19(2): 281–297.
[https://doi.org/10.1016/0378-4266\(94\)00051-4](https://doi.org/10.1016/0378-4266(94)00051-4)

Melléklet

4. táblázat						
Az adatbázisból felhasznált magyarázó változók leíró statisztikái						
Változó	Megfigyelés	Átlag	Szórás	Min	Max	Adattisztítás
termek	9 350 798	1,5	0,5	1,0	2,0	
kesnap	9 350 798	110,2	405,1	0,0	4 794,0	
szla_deviza	9 350 798	2,0	0,5	1,0	3,0	
szla_futamido	9 350 798	226,5	82,0	8,0	480,0	
szla_ltv	9 350 385	0,5	0,2	0,0	9,5	törlés, skálázás
ugyf_rendjov	9 350 798	135 017,7	194 403,8	0,0	82 000 000,0	
ugyf_kor	9 350 798	37,5	9,8	1,0	152,0	skálázás
ugyf_nem	7 689 811	1,4	0,5	1,0	2,0	
ugyf_eltartott	9 331 701	0,8	1,0	0,0	32,0	
ugyf_kereso	9 350 798	1,6	0,6	0,0	25,0	
ugyf_torlkiad	9 308 471	29 192,2	283 734,4	0,0	269 000 000,0	
ugyf_iskveg	9 343 639	2,3	0,5	1,0	3,0	törlés
ugyf_csalallapot	9 346 990	1,7	0,7	1,0	3,0	törlés
adostars	9 350 798	0,6	0,5	0,0	1,0	
jaras	9 326 903	91,8	57,4	1,0	198,0	
szla_arfolyam	9 350 798	147,7	75,3	1,0	316,0	
szla_kamat	9 350 798	5,9	2,2	2,0	19,5	
pti_felv	8 717 907	7,2	741,6	0,0	230 674,0	átlag, skálázás
felv_hitelossz	9 350 798	11,9	9,3	0,5	345,0	
vintage	9 350 798	575,8	27,9	524,0	707,0	
eltelt_ido	9 350 798	52,2	37,7	0,0	183,0	


Megjegyzés: A táblázatban látható az egyes változók esetén felmerülő adathiány és az alkalmazott adattisztítási módszer is.

4. ábra
A kiválasztott ügylet- és ügyféltulajdonságok, valamint a hozzájuk tartozó átlagos csődvalószínűségek kapcsolata



4. ábra

A kiválasztott ügylet- és ügyféltulajdonságok, valamint a hozzájuk tartozó átlagos csődvalószínűségek kapcsolata (folytatás)



Megjegyzés: Folytonos változók esetén az ábra tartalmazza az adott változó és az átlagos csődvalószínűség egyszerű lineáris regressziója alapján illesztett egyenest is.


5. táblázat

Az ügyfél- és ügylettulajdonságok kiválasztásához felhasznált logit regressziók eredményei és további tesztstatisztikák

	Egyváltozós logit	Többváltozós logit
Eredményváltozó / Magyarázó változók	Default (1=csőd; 0=teljesítés)	Default (1=csőd; 0=teljesítés)
<i>szla_ltv</i>	0,85152*** (0,0106)	1,20208*** (0,0136)
<i>ugyf_iskveg</i>	-0,51747*** (0,0041)	0*** -0,20131 (0,0098) -0,74801 (0,0108)
<i>korosztaly</i>	-0,47459*** (0,0076)	0*** -0,28976 (0,0078)
<i>eltelt_ido</i>	-0,00705*** (0,0001)	-0,00870*** (0,0001)
<i>adostars</i>	-0,21042*** (0,0042)	0*** -0,22223 (0,0043)
<i>szla_futamido</i>	0,00240*** (0,0000)	0,00305*** (0,0000)
<i>pti_felv</i>	0,82692*** (0,0077)	0,55789*** (0,0074)
<i>termek</i>	0,60353*** (0,0042)	0*** 0,90221 (0,0052)
<i>szla_deviza</i>	1,12028*** (0,0085)	0*** 0,79321 (0,0087)
<i>hitelossz_kereset</i>	0,02188*** (0,0002)	0,01036*** (0,0003)
<i>vintage</i>	-0,05582*** (0,0010)	
<i>d_szla_kamat</i>	5,48997*** (0,3872)	
	VIF	1/VIF
<i>szla_ltv</i>	9,57	0,1045
<i>ugyf_iskveg</i>	0 11,82 6,33	0 0,0846 0,1581
<i>korosztaly</i>	0 13,63	0 0,0734
<i>eltelt_ido</i>	3,17	0,3151
<i>adostars</i>	0 2,66	0 0,3755
<i>szla_futamido</i>	11,80	0,0848
<i>pti_felv</i>	4,84	0,2065
<i>termek</i>	0 2,42	0 0,4133
<i>szla_deviza</i>	0 6,56	0 0,1525
<i>hitelossz_kereset</i>	4,60	0,2174
Átlagos VIF	7,04	

Megjegyzés: * $p < 0,1$; ** $p < 0,05$; *** $p < 0,01$, zárójelben a standard hibák. A kategóriaváltozók esetében az 1 értéket felvevő a bázis, a többi érték csődvalószínűsége ahhoz van viszonyítva.

5. ábra
A logit regresszióhoz tartozó ROC-görbe





Megjegyzés: Ha a modell tökéletes, akkor a ROC-görbe alatti terület 1-gyel egyenlő. Ha a modell egyszerűen véletlen találgatást végez, akkor a ROC-görbe alatti terület 0,5-tel egyenlő.

6. táblázat
A PCA és a k-közép klaszterelemzés statisztikái és ábrái

	PC1	PC2	PC3	PC4
szla_ltv	0,5100	-0,0577	0,0110	0,0918
ugyf_iskveg	0,1646	-0,4606	0,1207	0,0835
korosztaly	-0,1102	-0,0608	0,4031	0,6107
eltelt_ido	0,0504	0,3255	-0,4959	0,4856
adostars	-0,0778	0,1885	0,4448	0,4671
szla_futamido	0,4971	0,0594	-0,1819	0,1111
pti_felv	0,1601	0,4773	0,4086	-0,3275
termek	-0,4230	0,3105	0,1090	-0,1410
szla_deviza	0,1164	0,5443	-0,1918	0,0771
hitelossz_kereset	0,4764	0,1236	0,3611	-0,1109

Megjegyzés: A „PC” jelöli a kialakított főkomponenseket, míg az értékek a magyarázó változók együtthatóit jelzik a különböző főkomponensekben.

6. ábra
A PCA és a k-közép klaszterelemzés ábrái



Megjegyzés: A WSS (within sum of squares, klaszteren belüli négyzetösszeg), η^2 és PRE (a WSS százalékos csökkenése) mentén mérik az egyes klaszterstruktúrák összetartó erejét.


7. táblázat

Az idősoros vizsgálatokhoz használt magyarázó változók korrelációs mátrixa

	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)	(12)	(13)	(14)	(15)
(1) d_infl	1,0000														
(2) d_buxvola	-0,0004	1,0000													
(3) d_bux	0,2952	-0,0877	1,0000												
(4) d_bub3m	0,0810	0,0635	-0,4726	1,0000											
(5) d_eurib3m	0,0734	0,0720	0,2457	0,0293	1,0000										
(6) d_gov10y	-0,0410	0,0000	-0,4501	-0,0152	-0,2682	1,0000									
(7) d_wealth	0,3231	-0,1070	0,6185	-0,1611	0,2650	-0,6026	1,0000								
(8) d_eurhuf	-0,3043	0,0029	-0,5902	0,1138	-0,4678	0,6116	-0,4498	1,0000							
(9) d_hinc	-0,2171	-0,0803	-0,1870	-0,0234	0,1020	-0,0901	0,0308	0,1205	1,0000						
(10) d_wage	0,1661	-0,0769	0,1080	0,3364	0,1063	-0,1876	0,2527	-0,1072	-0,1297	1,0000					
(11) d_emp	-0,0409	0,2646	-0,0656	0,0123	0,3273	0,0349	0,1307	-0,0076	0,3078	0,0996	1,0000				
(12) d_imp	0,2304	-0,1627	0,4284	-0,2343	0,5885	-0,2115	0,3278	-0,3333	-0,0223	0,2057	0,1302	1,0000			
(13) d_exp	0,2054	-0,0292	0,3170	-0,1755	0,5531	-0,1249	0,2677	-0,2142	0,0060	0,1950	0,1990	0,8694	1,0000		
(14) d_gdp	0,0658	-0,1337	0,2483	-0,3437	0,4642	-0,2040	0,2963	-0,2195	0,1080	0,1499	0,1923	0,6172	0,6355	1,0000	
(15) d_unemp	0,0057	-0,0594	-0,0524	0,0495	-0,3801	0,1158	-0,0462	0,2026	-0,3743	0,3026	-0,4708	-0,2308	-0,1605	-0,0572	1,0000

Megjegyzés: A táblázatban a potenciális (idősoros) magyarázó változók közötti korrelációs együtthatók láthatók.

7. ábra
A klaszterek idősoros csődvalószínűségeinek értékei és átlaguk



8. táblázat
A stacionaritás-tesztek eredményei

<i>d_DR_y</i>	-3,328	<i>d_eurhuf</i>	-6,332
<i>d_infl</i>	-6,140	<i>d_hinc</i>	-8,101
<i>d_buxvola</i>	-10,814	<i>d_wage</i>	-8,637
<i>d_bux</i>	-4,816	<i>d_emp</i>	-4,938
<i>d_bub3m</i>	-4,965	<i>d_imp</i>	-5,363
<i>d_eurib3m</i>	-3,554	<i>d_exp</i>	-5,412
<i>d_gov10y</i>	-8,130	<i>d_gdp</i>	-5,207
<i>d_wealth</i>	-6,066	<i>d_unemp</i>	-7,739

Megjegyzés: Az 1 százalékos kritikus érték -3,576, az 5 százalékos -2,928, és a 10 százalékos -2,599

9. táblázat**A klaszterenkénti idősoros regressziókra vonatkozó tesztek eredményei**

	Klaszterek		
	1	2	3
Eredményváltozó / Tesztek	<i>d_DR_y</i>	<i>d_DR_y</i>	<i>d_DR_y</i>
Breusch-Pagan / Cook-Weisberg teszt (heteroszkedaszticitás)	2,13 (0,1443)	3,72 (0,0537)	0,01 (0,9137)
Durbin-Watson alternatív teszt (autokorreláció)	0,92 (0,3383)	0,22 (0,6377)	0,12 (0,7341)
Ramsey RESET teszt (kihagyott változó)	0,97 (0,4167)	2,49 (0,0764)	1,34 (0,2756)
Wu-Hausman F-teszt (endogenitás)		0,46 (0,4994)	

Megjegyzés: Zárójelben a p-érték szerepel.

10. táblázat**A klaszterenkénti idősoros regressziókra vonatkozó multikollinearitás tesztek eredményei**

	Klaszterek		
	1	2	3
Eredményváltozó / Magyarázó változók	VIF	VIF	VIF
<i>d_emp</i>	1,14	1,02	1,02
<i>d_exp</i>	1,09		
<i>l1_d_gdp</i>	1,10		
<i>d_gov10y</i>	1,02		
<i>d_bub3m</i>	1,03	1,33	1,04
<i>d_wealth</i>		1,06	1,06
<i>l3_d_gov1y</i>		1,06	
<i>l1_d_bux</i>		1,27	
<i>l3_d_hinc</i>			1,02
Átlagos VIF	1,08	1,15	1,03

11. táblázat
Robusztusságvizsgálat három megközelítésben
(keresztmetszeti és idősoros csonkítás, változók kihagyása)

	Klaszterek		
	1	2	3
Eredményváltozó / Magyarázó változók	<i>d_DR_y</i>	<i>d_DR_y</i>	<i>d_DR_y</i>
keresztmetszeti validáció (25%)			
<i>d_emp</i>	-0,09887** (0,0413)	-0,17727*** (0,0651)	-0,25181*** (0,0886)
<i>d_exp</i>	-0,01866* (0,0107)		
<i>l1_d_gdp</i>	-0,00029 (0,0002)		
<i>d_gov10y</i>	0,00051* (0,0003)		
<i>d_bub3m</i>	0,00128** (0,0005)	0,00223** (0,0010)	0,00472*** (0,0012)
<i>d_wealth</i>		-0,04133** (0,0237)	-0,09045** (0,0323)
<i>l3_d_gov1y</i>		0,00101 (0,0007)	
<i>l1_d_bux</i>		-0,01005* (0,0058)	
<i>l3_d_hinc</i>			-0,09309** (0,0330)
idősoros validáció (2007Q2–2014Q1)			
<i>d_emp</i>	-0,03989 (0,0340)	-0,17727* (0,0796)	-0,27969** (0,1078)
<i>d_exp</i>	-0,01786* (0,0107)		
<i>l1_d_gdp</i>	-0,00041** (0,0002)		
<i>d_gov10y</i>	0,00044* (0,0003)		
<i>d_bub3m</i>	0,00136** (0,0004)	0,00223** (0,0008)	0,00546*** (0,0015)
<i>d_wealth</i>		-0,04133* (0,0296)	-0,08887** (0,0398)
<i>l3_d_gov1y</i>		0,00101** (0,0013)	
<i>l1_d_bux</i>		-0,01005 (0,0071)	
<i>l3_d_hinc</i>			-0,12337** (0,0477)
változók elhagyása (1: <i>d_emp</i>, 2: <i>d_wealth</i>, 3: <i>d_wealth</i>)			
<i>d_emp</i>		-0,16524** (0,0650)	-0,31230*** (0,0935)
<i>d_exp</i>	-0,01906*** (0,0068)		
<i>l1_d_gdp</i>	-0,00035*** (0,0001)		
<i>d_gov10y</i>	0,00042** (0,0002)		
<i>d_bub3m</i>	0,00141*** (0,0003)	0,00251** (0,0010)	0,00602*** (0,0012)
<i>d_wealth</i>			
<i>l3_d_gov1y</i>		0,00193*** (0,0007)	
<i>l1_d_bux</i>		-0,01192** (0,0058)	
<i>l3_d_hinc</i>			-0,09476*** (0,0348)

11. táblázat

**Robusztusságvizsgálat három megközelítésben
(keresztmetszeti és idősoros csonkítás, változók kihagyása)**

	Klaszterek		
	1	2	3
Eredményváltozó / Magyarázó változók	d_{DR_y}	d_{DR_y}	d_{DR_y}
változók elhagyása (1: d_{exp}, 2: d_{emp}, 3: d_{emp})			
d_{emp}	-0,0661** (0,0267)		
d_{exp}			
$l1_d_gdp$	-0,0003** (0,0001)		
d_gov10y	0,0005** (0,0002)		
d_bub3m	0,0016*** (0,0003)	0,0021** (0,0010)	0,0053*** (0,0013)
d_wealth		-0,0600** (0,0237)	-0,0946** (0,0355)
$l3_d_gov1y$		0,0020*** (0,0007)	
$l1_d_bux$		-0,0109* (0,0058)	
$l3_d_hinc$			-0,0825** (0,0365)
változók elhagyása (1: $l1_d_gdp$, 2: $l3_d_gov1y$, 3: d_bub3m)			
d_{emp}	-0,0672*** (0,0262)	-0,1582** (0,0690)	-0,2646** (0,1086)
d_{exp}	-0,0190** (0,0069)		
$l1_d_gdp$			
d_gov10y	0,0005*** (0,0002)		
d_bub3m	0,0016** (0,0003)	0,0028*** (0,0010)	
d_wealth		-0,0546** (0,0252)	-0,1086*** (0,0391)
$l3_d_gov1y$			
$l1_d_bux$		-0,0073 (0,0058)	
$l3_d_hinc$			-0,0707* (0,0403)
változók elhagyása (1: d_gov10y, 2: d_bub3m, 3: $l3_d_rendjov$)			
d_{emp}	-0,0497* (0,0270)	-0,1374** (0,0656)	-0,2872*** (0,0925)
d_{exp}	-0,0182** (0,0069)		
$l1_d_gdp$	-0,0003** (0,0001)		
d_gov10y			
d_bub3m	0,0014*** (0,0003)		0,0054** (0,0012)
d_wealth		-0,0592** (0,0238)	-0,0891*** (0,0334)
$l3_d_gov1y$		0,0023*** (0,0007)	
$l1_d_bux$		-0,0161*** (0,0053)	
$l3_d_hinc$			

11. táblázat
Robusztusságvizsgálat három megközelítésben
(keresztmetszeti és idősoros csonkítás, változók kihagyása)

	Klaszterek		
	1	2	3
Eredményváltozó / Magyarázó változók	d_{DR_y}	d_{DR_y}	d_{DR_y}
változók elhagyása (1: d_bub3m, 2: l_d_bux, 3: -)			
d_{emp}	-0,0461 (0,0307)	-0,1540** (0,0637)	
d_{exp}	-0,0205** (0,0079)		
$l1_d_{gdp}$	-0,0003** (0,0001)		
d_{gov10y}	0,0004* (0,0002)		
d_{bub3m}		0,0030*** (0,0009)	
d_{wealth}		-0,0591** (0,0231)	
$l3_d_{gov1y}$		0,0018*** (0,0007)	
$l1_d_{bux}$			
$l3_d_{hinc}$			
Megjegyzés: * $p < 0,1$; ** $p < 0,05$; *** $p < 0,01$, zárójelben a standard hibák. A „d” a változó éves változását, az „l” a negyedéves késleltetés mértékét jelöli, míg az „y” az éves mivoltát jelzi a csődvalószínűségnek.			