

Vállalatok nemteljesítési valószínűségének becslése – Egy lehetséges felügyeleti benchmark-modell*

Szenes Márk – Dabi Zsófia

Az elmúlt években nemzetközi szinten is megingott a felügyelet bizalma a belső minősítésen alapuló módszertant alkalmazó bankok hitelkockázati paramétereinek becslésében. A felügyeleti tapasztalatok azt mutatják, hogy a kockázati mérőszámokban és végeredményben a szabályozói tőkekövetelmény-szintekben megfigyelhető eltéréseket kevésbé a bankok portfóliói között meglévő inherens kockázati különbségek, mint inkább a heterogén modellezési technikák és módszertani megközelítések okozzák. E nemkívánatos hatás elkerülése érdekében a Magyar Nemzeti Bank (MNB) a banki belső tőkemegfelelési értékelési folyamat felügyeleti felülvizsgálata során törekszik arra, hogy egységes benchmark-modellek kialakításával és alkalmazásával határozza meg a szükséges tőkekövetelményeket. Jelen tanulmány bemutatja, hogyan lehetséges a nagybanki vállalati default-ráta adatsorok és az elérhető vállalati pénzügyi adatok alapján a vállalati portfóliók egységes módszertan szerinti, az egyes ügyfelek hitelminőségében rejlő különbségeket figyelembe vevő, a tőkekövetelmény felügyeleti meghatározásához megfelelő nemteljesítési valószínűséget (PD¹) becsülni. Mindazonáltal az egyedi pénzügyi adatok mellett lehetnek más tényezők is (pl. kvalitatív/szakértői elemek, ágazati információk), melyek a hitelminőséget befolyásolhatják, ezek felkutatása a benchmark-modell fejlesztési iránya lehet.

Journal of Economic Literature (JEL) kódok: C51, G21, G32

Kulcsszavak: hitelkockázat, nemteljesítési valószínűség, minősítő rendszerek, felügyeleti benchmark-modell, PD

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

Szenes Márk a Magyar Nemzeti Bank felügyeleti tanácsadója. E-mail: szenesm@mnbb.hu
Dabi Zsófia Borbála a Magyar Nemzeti Bank pénzügyi modellezője. E-mail: dabizs@mnbb.hu

A magyar nyelvű kézirat első változata 2020. március 16-án érkezett szerkesztőségünkbe.

DOI: <http://doi.org/10.25201/HSZ.19.3.5277>

¹ Probability of Default

1. Belső modellek és felügyelés

A Bazel 2 keretrendszer kialakításakor a felügyelet egyik elsődleges célja a banki tőkekövetelmény-számítási szabályok kockázatérzékenységének erősítése volt (*BCBS 2006*), és meghatározott minimumkövetelmények mellett teret engedett az intézményeknek ahhoz, hogy saját belső modelljeik fejlesztésével pontosabban tudják megragadni a kockázataikat, remélve, hogy ezzel a kockázatkezelés színvonala is emelkedik majd. Azok az intézmények, melyek felügyeleti engedélyt kaptak a belső minősítésen alapuló (IRB²) módszer alkalmazására, a saját minősítő rendszereik segítségével számíthatják ki a hitelkockázati tőkekövetelményt.

A Bazel 2-t már kidolgozása alatt számos kritika érte, a felügyelet részéről azonban a negatív hangok a használat során felhalmozott tapasztalatok eredményeként erősödtek fel. Miután a Bazel 3 lefektette a szabályozásból addig hiányzó likviditási követelményeket, szigorította a szavatoló tőkére vonatkozó elvárásokat, bevezette a makroprudenciális és tőkefenntartási puffereket (*BCBS 2010*), a felügyelet figyelve a belső modellek, köztük a hitelkockázati paraméterbecslési bizonytalanságok felé fordult.

Amíg a bankok természetesen a minél szofisztikáltabb módszerek alkalmazásának lehetőségét, a módszertani szabadságot szorgalmazták, addig a felügyelet a kockázatérzékenység, egyszerűség és összehasonlíthatóság együttes követelményeinek összehangolására, egyensúlyának megteremtésére törekedtek (*BCBS 2013; EBA 2013*). Az elmúlt években nyilvánvalóvá vált, hogy a jelenlegi szabályozási keretek túl nagy módszertani szabadságot biztosítanak a bankoknak, aminek eredményeként a belső modellen alapuló kockázati szintek közötti különbségek kevésbé az egyes intézmények és portfóliók kockázati profiljai közötti különbségekből, mint inkább a választott módszertanok és megközelítések, az intézmény számára elérhető idősorok különbségeiből fakadnak. Nem túlzó azt mondani, hogy a felügyelet bizalma alapvetően rendült meg a belső banki modellek megbízhatóságával kapcsolatban.

A módszertani harmonizációra és összehasonlíthatóságra való törekvés a felügyelés minden szintjén megjelent. A Bázei Bizottság nemzetközi szinten a Bazel 3 csomag véglegesítésével (*BCBS 2017*) a legnagyobb modellkockázatot hordozó (alacsony default-megfigyeléssel rendelkező) szegmensek, a nagyvállalati, banki kitétségek esetében már nem engedélyezi a nemteljesítéskori veszteségráta (LGD³) és a nemteljesítéskori kitétség (EAD⁴) modellezését, a részvényjellegű kitétségek esetében csak az egyszerű súlyozáson alapuló módszertant hagyta meg, az IRB-módszertannal számszerűsített tőkekövetelmény értékét pedig a sztenderd módszertan tőkekövetelményszintjének 72,5 százalékában, alulról korlátozta (output floor).

² Internal Rating Based

³ Loss Given Default

⁴ Exposure At Default

Európai szinten az Európai Bankhatóság (European Banking Authority, EBA) elsődleges feladata éppen a prudenciális szabályoknak – így a bázeli tőkeszabályok alkalmazásának, a banki és felügyeleti gyakorlatoknak – az európai harmonizációja. Az EBA 2013-ban publikált riportjában (*EBA 2013*) azonosította, hogy milyen eltérések vannak az IRB-módszertant alkalmazó intézmények minősítő rendszereire kiterjedő felügyeleti elvárásokban, valamint ezen elvárások összehangolása érdekében felügyeleti ajánlásokat, szabályozástechnikai sztenderdeket dolgozott ki [RTS on assessment methodology (*EBA 2016*), PD LGD guideline (*EBA 2017a*)]. Az EBA továbbá 2015-től minden évben benchmark-adatokat gyűjt az IRB-t alkalmazó bankcsoportoktól (*EBA 2015; EBA 2017b; EBA 2017c; EBA 2019; EBA 2020*), és a benchmark-adatok alapján készült összefoglaló jelentésében portfólió-szegmensenként mutatja be az IRB-alapú tőkekövetelményszintek közötti eltéréseket. Az elemzés az eltérések lehetséges okaira is megkísérel választ találni, különböző megközelítésekkel választja szét a portfólió-összetétel, illetve a kockázati profilok különbségéből fakadó hatásokat azoktól a hatásoktól, melyeket inkább a módszertani eltérések okozhatnak.

Az eurozóna bankcsoportjainak felügyeletéért felelős Európai Központi Bank 2016-ban indított átfogó projektjében⁵ (*ECB 2017; ECB 2019*) méri fel és vizsgálja felül az általa felügyelt bankcsoportok IRB-modelljeit abból a célból, hogy minimalizálják a modellezési módszertanok közötti különbségeket.

Az 1. pilléres minimum szabályozói tőkekövetelmény kiegészítéseként, a tőkemegfelelés belső értékelési folyamat (ICAAP⁶) keretén belül a 2. pillérben meghatározásra kerül a gazdaságilag szükséges tőke nagysága, mely az intézmények üzleti tevékenységéből adódó kockázatokat a lehetséges jövőbeni veszteségek becslésén keresztül ragadja meg. Az intézmények a 2. pillér tőkekövetelményét saját belső eljárásuk szerint számszerűsítik úgy, hogy az összes releváns kockázati típusra – az 1. pillérben nem kezelt kockázatokra is – tőkekövetelményt határoznak meg. A felügyelet a SREP⁷ keretén belül a felügyelt intézmények által ICAAP alatt beállított tőkekövetelmény-szintjének megfelelését éves rendszerességgel felülvizsgálja. A felülvizsgálati folyamat fő célja az intézmények kockázati folyamatainak teljes körű megismerése és a materiális kockázati kitettségek azonosítása, és ezáltal a szolvens működést biztosító tőkeszint meghatározása (*MNB 2020*).

A magyar piacon jelen levő bankok 2. pilléres tőkeszükségletének meghatározásához az MNB különböző benchmark-modelleket fejleszt és alkalmaz (*MNB 2020*) annak érdekében, hogy a hazai bankok kockázatait kockázatérzékeny módon és egymással összehasonlíthatóan mérhesse. A felügyeleti benchmarkok kialakításának célja, hogy az MNB a banki definícióktól, modellezési megközelítésektől, a rendelkezésre álló historikus idősorok adatminőségétől függetlenül mérni tudja a bankok inherens

⁵ TRIM: Targeted Review of Internal Models

⁶ Internal Capital Adequacy Assessment Process

⁷ Supervisory Review and Evaluation Process

kockázatait, és ennek eredményeként a bázeli 2. pillérben szükség esetén képes legyen korrigálni a tőkekövetelmény mértékét. Végül a felügyeleti benchmarkok a fejlett, megbízható belső modellekkel nem rendelkező, elsősorban kisebb méretű intézmények esetében a kockázatérzékeny tőkekövetelmény meghatározásának egyetlen lehetőségét jelentik.

A gazdasági dekonjunkcióval összefüggésben tömegével bedőlő lakossági hitelek veszteségeiből eredő tapasztalatok világítottak rá, hogy a heterogén modellezési technikák nem kívánt különbségeket okoznak a kockázati mértékekben, de éppen e nagyszámú megfigyelés tette lehetővé az MNB lakossági PD és jelzálog LGD benchmark modelljének kifejlesztését.

2. Szakirodalmi kitekintés

A lakossági mellett azonban hasonlóan fontos felügyeleti szempontból a vállalati portfólió kockázatának felmérése is, melyet tanulmányunkban a nemteljesítési valószínűség (PD) oldaláról közelítjük meg. Mind a magyar, mind a külföldi szakirodalomban számos tudományos cikk és tanulmány található, mely a vállalati nemteljesítés modellezésével foglalkozik. A csődelőrejelzés módszertana jelentős fejlődésen ment keresztül az elmúlt évtizedek során, míg kezdetben egy-, majd többváltozós diszkriminanciaanalízis-modelleket alkalmaztak a szakértők, az évek előrehaladtával világszerte egyre népszerűbbé vált a logit (logisztikus regresszió) és probit regressziós elemzések alkalmazása. A bázeli cikluson átívelő szemléletű modellezés követelményeinek megfelelő minősítő rendszerek fejlesztésekor is kedvelt módszertannak tekinthetők a logit- és probit-modellek. Fontos továbbá megemlíteni a csődelőrejelzésre alkalmazott legújabb módszertanokat is, mint például a döntési fák, neurális háló, gépi tanulás, mesterséges intelligencia és a hibrid modellek, melyek sikeresen kombinálják egy-egy módszer előnyeit, így javítva a modellteljesítményt (*Kristóf – Virág 2019*).

Szakirodalmi kitekintésünk a teljesség igénye nélkül, a jelen tanulmány szempontjából legrelevánsabbnak tekinthető magyar modelleket, tanulmányokat helyezi fókuszpontba. Magyarországon az első idősoros input-változókat alkalmazó, through-the-cycle (TTC) szemléletű modellezés követelményeinek megfelelő vállalati modell publikálása *Imre Balázs (2008)* nevéhez köthető. Imre a 2002–2006 közötti időintervallumban megfigyelt hazai vállalati tényadatok felhasználásával modellezte a 90 napos fizetési késedelem bekövetkezését döntési fa, logisztikus regresszió és neurális háló módszertanok alkalmazásával. A szerző által fejlesztett logit modell 11 változóval dolgozik, melyek között – a jelen tanulmány modelljéhez hasonlóan – szerepelnek tőkeszerkezeti, adósságszolgálati, likviditási, jövedelmezőségi mutatók, továbbá működtőke- és eszközforgási mutatók is bekerültek a végső változók körébe.

Madar (2014) szintén a logisztikus regressziót alkalmazva fejlesztett vállalati minősítő modellt, mely a bázeli követelményeknek megfelelően a hosszú távú nemtel-

jesítési valószínűség becslésére és tőkeszámításra is alkalmas. A modellezés során a 2007–2012 között mérlegbeszámolóval rendelkező magyar KKV-k adatai kerültek felhasználásra, kiszűrve a kényszervállalkozásokat, valamint a technikai jellegű cégeket. Több mint 40 pénzügyi mutatószám erősségének vizsgálatát követően a modellbe végül 6 mutatószám Weight of Evidence (WoE) transzformáltja került be változóként. A megfigyelt mintában legerősebb változók a tőkeszerkezet-leíró mutatók voltak, de likviditási és jövedelmezőségi mutatók is jó szeparációs erővel rendelkeztek, így bekerültek a modellbe. A szerző tanulmányában bemutatja, hogy az adott populációra fejlesztett adóminősítő rendszer megkülönböztető erejében válságálló és hosszú távon stabil PD-értéket ad, továbbá bizonyítékot szolgáltat arra is, hogy minél pontosabb megkülönböztető erővel rendelkezik az adott minősítő rendszer, annál inkább leköveti a mindenkori változékony default-ráta értékeit, aminek következtében válságidőszakban a PD értéke megnő, így prociklikus és válságmélyítő hatású.

Banai et al. (2016) a mikro-, kis- és középvállalkozások nemteljesítési valószínűségének modellezéséhez a Központi Hitelinformációs Rendszer (KHR) és a vállalkozások 2007–2014 közötti pénzügyi beszámolóinak adatait kapcsolta össze és használta fel. A modell eredményváltozója a banki nemteljesítés, vagyis az elemzésben a legalább 60 napja 30 napos késedelmeket vizsgálták a szerzők (90+ késedelem). A vállalat-specifikus és a kategóriaváltozókon kívül a modellbe a meg nem magyarázott időbeli heterogenitást megragadó makrováltozók is bekerültek, valamint a késedelmi események korrigálására trendet alkalmaztak a szerzők. A méretkategóriák szerint elkülönített modellezésen kívül néhány kiemelt nemzetgazdasági ágazat esetében külön modelleket specifikáltak a működő vállalatokra kapott összefüggések vizsgálatának céljával. Eredményeik alapján a legtöbb változó hasonlóan viselkedik ezekben a modellekben is, azonban a hangsúlyeltolódásokban jelentkeznek az iparági jellemzők hatásai. A becsült PD-k alapján a vizsgált ágazatok között a mezőgazdasági vállalatok hitelkockázata a legalacsonyabb, míg az építőiparé a legmagasabb, ami összhangban van a jelen tanulmány 6. fejezetében szemléltetett eredményekkel.

Bauer és Endrész (2016) mikro- és makrováltozókat kombinálva probit-modell segítségével becsül csődvalószínűséget a magyar vállalatokra. A makro információk modellbe történő beemelése szükséges az aggregált dinamika és a kockázat szintjének megragadásához. A becslés alapjául a teljes hazai kettős könyvelést végző vállalatok 1996–2012 közötti időszora szolgált (~1,5 millió megfigyelés). A modell célváltozója a jogi szempontból történő csődbejutás, mely az Opten adatbázisban elérhető információk alapján került meghatározásra. Hasonlóan az eddig bemutatott tanulmányokhoz és a jelen cikkben bemutatott modellhez, Bauer és Endrész modellje is tartalmaz profitabilitási, likviditási és adósságszolgálati mutatókat, valamint szintén figyelembe veszi a vállalati méret szerinti heterogenitást. Eltérés ugyanakkor például a külföldi tulajdonlás és az exporttevékenység dummyként történő szerepeltetése és a makrováltozók (GDP-növekedés, hitelállomány-növekedés) beválogatása a modellbe. Ez utóbbinak szükségességét a szerzők azzal indokolják,

hogyan a makrováltozók képesek megragadni a sokk vállalati szintű változókon még nem tapasztalható hatásait, valamint a tovagyrűrűzű hatásokat is⁸.

Hasonlű megkűzűzűtűt alkalmaztak *Inzelt és szerzűtűrsai (2016)* is, akik szintűn a jogi szempontbűl valű csűdbejutűtűt becslűk ugyanazon adatkűr felhasználűsűsűval (Opten és NAV adatbűzűsa). Ugyanakkor fűű kűlűnbsűg, hogy műg Bauer és Endrűsz a negatűv eseműnyek elűrejelzűsűre alkalmas, erűű prediktűv erűvel rendelkezűű modell lűtrehozűsűt cűloztűk, addig Inzelt és szerzűtűrsainak cűlja egy egyszerű, stabil és jűl alkalmazhatűű vállalati monitoring keretrendszer bemutatűsa volt, mely lehetűvű teszi a hitelintűzetek által alkalmazott belsű modellek összehasonlűthatűsűgűt. A jelen tanulműny cűlja az Inzelt és szerzűtűrsainak tanulműnyűban bemutatott modell tovűbbfejlesztűse oly műdon, hogy az a vállalati hitelportfűlűiűk IRB-alapű tűkeűkűvetelműnyűnek meghatűrozűsűsűhoz megbűzűthűtű input PD-paraműtert szolgűltasson. Erre valű tekintettel a 3. fejezetben rűszleteiben ismertettűk a hasonlűsűgokat és eltűrűseket a kűt modell kűzűtűt.

3. A vállalati PD-modell keretei

A vállalati portfűlűiű vonatkozűsűban *Inzelt és szerzűtűrsai (2016)* mutattak be egy lehetsűges megkűzűzűtűt, egyfajta PD-modellűt az inherens vállalati hitelkockűzatok műrűsűre, monitoringjűra. Modelljűk tovűbbfejlesztűsekekűnt szűmos ponton vűltűzűtűttűnk, mivel mi a modellűnkkel hosszű tűvű banki default-valűsűnűsűgeket kűvűnűnk becslűni. Èppen ezűrt nem a teljes hazai nem pűnzűgyi vállalati szektorra, csak a banki hitellel/hitelkerettel rendelkezűű vállalati űgyfelekre modelleztűnk, kiszűrűve a projekt- és a lakossűgi szegmensbe tartozűű mikro-vűllalatokat⁹. Műg a projektek vonatkozűsűban pűldűul a projekt eszkűz¹⁰ cash-flow-termelűű kűpessűgűnek és a szponzor erejűnek feltűrűsa szűksűges, addig a pűnzűgyi vűllalkozűs esetűben a modellezűsűhez inkűbb a műgűttes portfűlűiű kockűzatainak feltűrűsa lenne elengethetetlen, melyek a pűnzűgyi adatokbűl nem állnak elű.

A PD-modell egyik legfontosabb eleme a default fogalma. Figyelembe vűve, hogy a csűd-, a felszűmolűsi stb. eljűrűsok sem idűpontjűkat, sem definűciűjűkat tekintve nem fedik le a banki default fogalműt, valamint hogy a bankok a tűkemodelljeiket is a bűzeli default-fogalom alapjűn fejlesztik, a felűgyeleti felűlűvizsgűlati folyamat sorűn a banki adatszolgűltatűs keretűben mi is az MNB szűműra biztosűtott default-adatbűzűsokot vettűk alapul.

A modell és a becslűt PD-k stabilitűsűt szem elűűt tartva fontosnak tartottűk, hogy egy adott űgyfűl kockűzati szegmense (mikro-, kis-, kűzűp-, nagyvűllalat) rűgzűtűt

⁸ űn. spill-over effect

⁹ Tűpikűsan a projektek – pl. a kereskedelmi ingatlanfinansűrozűsi kűtettsűgek – vagy a pűnzűgyi vűllalkozűsok gyűkeresen eltűrű kockűzati profillal bűrnak, és ezeket a szegmenseket a bankok is kűlűn modellezűk, ezűrt modellűnk ezeket a kűtettsűgtűpusokat nem tartalmazza.

¹⁰ Tűpikűsan: ingatlan

legyen, és a vállalat teljesítményének változása, különösen a defaultot megelőző visszaesése ne okozzon változást a szegmentációjában, ezért a vállalatok szegmensét az árbevétel, a mérlegfőösszeg, illetve a létszám adatainak historikus maximuma alapján rögzítettük. Az adatok mennyisége lehetővé tette azt is, hogy a darabszám tekintetében a legkisebb, a kockázat mértékét nézve azonban a legnagyobb jelentőségű nagyvállalati szegmensre is modellt építsünk.

A bemutatandó modell logisztikus regresszióval teremt kapcsolatot a negatív esemény (default) és a mérleg- és eredménykimutatáson alapuló magyarázó változók között, a változók körét azonban Inzelt és szerzőtársai modelljéhez képest jelentősen kibővítettük. Változtatást jelent továbbá az is, hogy míg a regressziós együtthatók modellünkben minden szegmensben azonosak, a score-hoz tartozó PD-eket szegmensenként külön-külön kalibráltuk, ami lehetővé tette, hogy egy tőkekövetelmény-számításhoz alkalmazható, a hosszú távú default-rátát megfelelően tükröző vállalati PD-t becsüljünk. A két modell közötti legfőbb eltéréseket és hasonlóságokat az 1. táblázatban részletesen szemléltetjük.

1. táblázat		
A két modell összehasonlítása		
	Inzelt és szerzőtársai (2016)	Korrigált modell
Felhasznált vállalati adatok	Magyarországon bejegyzett, kettős könyvelést vezető nem pénzügyi vállalkozások teljes köre	csak a hazai nagybankok által finanszírozott normál vállalatok (projekthitelek, lakossági/termékalapon finanszírozott mikro-vállalatok pénzügyi vállalkozások nélkül)
Negatív esemény	negatív jogi események (felszámolási eljárás, csődeljárás, bírósági törlési eljárás, befejezett felszámolás, kényszer-végelszámolás)	banki default-események
Modellfejlesztési mintaidőszak	1999–2013	2006–2017
Szegmentáció	aktuális árbevétel alapján	rögzített szegmentáció az árbevétel, mérlegfőösszeg, létszám historikus maximuma alapján
Modellezett szegmensek	mikro-, kis- és középvállalat	mikro-, kis-, közép- és nagyvállalat
Negatív eseményt magyarázó változók	mikrovállalat esetén: 4, kis- és középvállalat esetén 2 mutató az alábbiakból: adósságteher, hosszú és rövid távú likviditási helyzet, termelékenység mutató	minden szegmensben 6 mutató: hosszú és rövid távú likviditási helyzet, termelékenységi mutató, tőkeáttétel, adósságfedezet, méret
Modell	Logisztikus regresszió	
Kalibráció	szegmensenként külön logisztikus regresszió	egy logisztikus regresszió minden szegmensre, de külön PD-kalibráció
Alkalmazás	felügyeleti monitoring: kockázatok összehasonlítása, változások elemzése	IRB-alapú tőkekövetelmény-számítás, 2. pillér
<i>Forrás: Inzelt et al. (2016) saját kiegészítéssel</i>		

4. Felhasznált adatok


A vállalati PD-modell alapját a fejlett kockázatmérési módszertanokkal, éppen ezért hosszú és megbízható idősorokkal rendelkező hazai nagybankok, bankcsoportok által gyűjtött vállalati default-adatbázisok jelentették. Nemcsak az 1. pillér alatt IRB-módszertant alkalmazó bankok, hanem – a 2. pilléres tőkekövetelmény (ICAAP) számításához – a legtöbb nagybank gyűjt hitelkockázati veszteség- és default-adatokat, melyeket felhasznál minősítő rendszereiben.

A vállalati PD-modell fejlesztéséhez a banki default-adatbázisokon többfajta szűrést, adattisztítást végeztünk:

- Első lépésként csak a normál vállalati ügyfeleket tartottuk meg, és törekedtünk arra, hogy leválasszuk a gyökeresen eltérő kockázati profilú szegmenseket, különösen a projekteket, pénzügyi vállalkozásokat, melyek alapvetően eltérő modellezési megközelítést igényelnek, és amelyekre egyébként a bankok maguk is külön minősítő rendszereket fejlesztenek. A termék alapon finanszírozott, retail-kezelésben lévő mikrovállalati portfóliókat sem építettünk bele a modellbe, mivel úgy tapasztaltuk, hogy egyrészt a default-rátájuk jelentősen magasabb a hasonló méretű, de vállalati kezelésben lévő mikroügyfelekhez képest, másrészt azok kockázatát a termékjellemzők is befolyásolhatják, melyeket egy általános vállalati modellben nem szándékoztunk figyelembe venni.
- Éves gyakoriságú ügyfélszintű adatbázist készítettünk, azaz a modellezési adatbázisban minden vállalat egy megfigyelési évben csak egyszer szerepel (ha az adott naptári évben volt teljesítő státuszú időszaka), függetlenül attól, hogy esetleg több bank is finanszírozta.
- Egy vállalatot akkor tekintettünk defaultosnak, hogyha az a finanszírozó bankok legalább felénél defaultos volt, a default-eseményt pedig – mely a vállalati PD-modellünk célváltozója – a default évében regisztráltuk. A több bankos ügyfelek esetében megvizsgáltuk, hogy ez a választás nem okoz jelentős torzítást, ugyanis a több bank által is finanszírozott ügyfelek esetében döntően mindegyik bank regisztrált default-eseményt, az eltérést általában a default időzítése jelentette. Ha egymás utáni években visszatért az ügyfél a teljesítő státuszba, majd ismételen defaultba került, akkor ezeket a többszörös default-eseményeket összevontuk egyetlen default-eseménnyé, majd azt az első default időpontjához rendeltük.
- A nagyvállalatok esetében a defaultosok körében manuális adattisztítást végeztünk úgy, hogy nyilvánosan elérhető adatokból is ellenőriztük a defaultba sorolás megfelelőségét.

A szűrések és adattisztítások eredményeképpen a különböző vállalati mérettartományokon az 1. ábra mutatja a számított default-ráta-idősorokat.

1. ábra
A felhasznált nagybanki default-adatbázisokból számított default-ráta-idősorok



Figyelembe véve, hogy a default-adatbázis 2006-ban hiányos, láthatóan a mikroszegmensekben nem teljeskörűek az adatok, ezért a modell építéséhez csak 2007 utáni adatokat használtuk fel (2. táblázat). A végső adatbázisban 286 ezer megfigyelés szerepel évenként és ügyfelenként, amelyben mintegy 10 ezer default-eseményt regisztráltunk. Az éves default-ráták átlaga a mikro-, kis/közép- és nagyvállalati szegmenseken rendre 4,33; 3,00 és 1,49 százalék, ami előrevetíti a modell szegmensenkénti kalibrációjának szükségességét.

2. táblázat
A modellezéshez felhasznált default-adatbázis összetétele

Szegmens	Ügyfélszám évenként	Default-szám	Átlagos default-ráta
Mikroállalat	98 727	4 385	4,33%
Kis- és középvállalat	174 318	5 386	3,00%
Nagyállalat	13 400	211	1,49%
Összesen	286 445	9 982	3,38%

Forrás: A banki default-adatbázisok alapján számítva

A negatív esemény – default – hosszú távú valószínűségének előrejelzéséhez szükséges magyarázó változókat céginformációs adatbázis mérleg- és eredménykimutatásaiából képeztük, a szegmentáció alapját is az ebből nyert létszám-, árbevétel- és mérlegfőösszeg-adatok jelentették. A mikro-, kis-, közép- és nagyvállalati szegmensek definíciójához a *kis- és középvállalkozásokról, fejlődésük támogatásáról szóló 2004.*

évi XXXIV. törvényből (KKV törvény) indultunk ki, azonban a létszám vonatkozásában a feltételeknél nem követeltük meg az 'és' kapcsolatot. A KKV törvényben szereplő euro értékeknek általunk megfeleltetett forint összegeket a 3. táblázat tartalmazza.

3. táblázat					
A méretalapú szegmentáció definíciója					
KKV-besorolás	Létszám (fő)		Éves nettó árbevétel (millió Ft)		Mérlegfőösszeg (millió Ft)
Mikrovállalat	< 10	vagy	≤ 300	vagy	≤ 300
Kisvállalat	< 50		≤ 2 000		≤ 2 000
Középvállalat	< 250		≤ 15 000		≤ 15 000
Nagyvállalat	≥ 250		≥ 15 000		≥ 15 000

Forrás: 2004. évi XXXIV. törvény a kis- és középvállalkozásokról, fejlődésük támogatásáról

Az aktuális létszám-, árbevétel-, mérlegfőösszeg-alapú szegmentáció jelentős mozgással járhat a szegmensek között. Különösen akkor gond a szegmensváltás, ha ez a defaultot megelőzően a problémássá vált vállalat csökkenő gazdasági teljesítményének – a csökkenő mérlegfőösszeg, eredmény, létszám – a következménye. Ekkor ugyanis a defaultot már az ügyfél eredeti szegmensénél kisebb mérettartományban mutatnánk ki, így könnyen alulbecsülhetnénk a nagyobb szegmensek default-rátáját. A modellezési szegmensek definíciójához ezért a 2000. évtől mért létszám-, árbevétel-, mérlegfőösszeg maximumát használtuk úgy, hogy ha bármely, a szegmentáció alapjául szolgáló mutató alapján az adott ügyfél a nagyobb méretkategóriába tartozik, akkor azt tekintettük az ügyfél végső szegmensének (vagyis a mutatók között vagylagos feltétel van). Ezzel a módszerrel a teljes modellezési időtávon rögzítettük az ügyfelek szegmensét.

5. Minősítő rendszer – PD-modell

A benchmark modell célja, hogy egy olyan PD-t rendeljen a vállalatokhoz, mely a legjobban tükrözi a hasonló kockázati profilú vállalatok hosszú távú – ciklusokon átívelő – átlagos default-rátáját. A modelltől emellett elvárjuk, hogy a kockázatoság, kockázati profil alapján jól elkülönítse a kitettségeket, különbséget tegyen jó és rossz vállalatok között, valamint követhető legyen a portfólió minőségének a nem szisztematikus faktorok által vezérelt – azaz a gazdasági ciklustól független – változása is. A minél inkább ciklustól független, úgynevezett TTC jellegű PD-paraméter becslése több szempontból is kiemelt jelentőségű. Egyrészt az IRB tőkekövetelmény-kalkuláció input paraméterként feltétel nélküli PD-értéket vár el, másrészt mind az Európai Központi Bank belső modellek értékeléséhez kapcsolódó ajánlása (ECB 2019), mind az Európai Bankhatóság PD-becslésről és LGD-becslésről szóló iránymutatása (EBA

2017a) alapján szükséges a PD-paraméterek TTC-jellegű kalibrációja, vagyis a becslésnek reflektálnia kell a hosszú távú átlagos default-rátát. Mindemellett felügyeleti oldalról fontos a kockázatok ciklusfüggetlen felmérése és ezáltal egy stabil, gazdasági ciklusra nem érzékeny tőkekövetelmény-beállítás (elkerülve konjunktúra esetén az alul-, dekonjunktúra esetén a túlbecslést).

A kockázati profil szerinti megkülönböztetésre a banki gyakorlatban a logisztikus regresszió alapuló minősítő rendszerek terjedtek el, így akárcsak Inzelt és szerzőtársai, e tanulmány is ezt a megközelítést választja. A modellben a historikus default-események és az ügyfél kockázati profilját jellemző magyarázó változók közé logisztikus függvénykapcsolatot illesztve, regresszióval határozzuk meg a magyarázó változók súlyát, együtthatóit az alábbi módon (x_i magyarázó változók és β_i súlyok/együtthatók mellett):

$$\text{default valószínűsége} = \frac{1}{1 + e^{-(\beta_0 + \sum_{i=1}^n \beta_i x_i)}} \quad (1)$$

A magyarázó változók kiválasztásához elsősorban az *Inzelt et al. (2016)* tanulmányában szereplő változókat vettük alapul, valamint a nagybanki vállalati modellekben szereplő, a mérleg- és eredménykimutatásból képezhető, objektív pénzügyi mutatók alapján válogattunk. A változók kiválasztásakor arra törekedtünk, hogy magas magyarázóerő mellett minden főbb mutatócsoportból egyszerű, közgazdaságilag is értelmes változókat használjunk. A mutatókat az eladósodottság/tőkeáttét, likviditási helyzet, illetve mérlegszerkezet, adósságfedezet, profitabilitás és méret főbb mutatócsoportokból választottuk ki, a változók korrelációját is figyelembe véve.

Fontosnak tartjuk kiemelni, hogy a bankok szakértői, elemzői általában jóval több, a vállalat hitelminőségét meghatározó információval rendelkeznek, mint amennyi információ pusztán a vállalati pénzügyi adatokból kinyerhető. A banki vállalati modellek a pénzügyi modul mellett általában egy szakértői modult is tartalmaznak, mely az említett szakértői faktorokat gyűjti össze. A menedzsment/tulajdonos szakértelme, elkötelezettsége, mely akár magánkezességek bevonásán keresztül is tükröződhet, valamint a vállalat piaci pozíciója, az iparági kilátások mind hozzáadhatnak a modell magyarázó erejéhez. Ezen faktorok összegyűjtése azonban nyilvánvaló nehézségekbe ütközik, egyrészt bankonként tapasztalt heterogenitásuk, másrészt szubjektivitásuk miatt, viszont jövőbeli beépítése a bemutatandó modell további fejlesztési iránya lehet.

A kezdeti nagybanki változólista kb. 50 darab eltérő pénzügyi változót tartalmazott, ezt szűkítettük le korrelációs elemzéssel a felsorolt mutatócsoportonként 1–1, összesen 6 változóra. A változók szelekciójánál fontos szempont volt, hogy a modell PiT-jellegét¹¹ minél inkább tompítsuk, ezért például a profitabilitás jellegű mutatók-

¹¹ PiT: Point-in-Time

nál nem preferáltuk az adózás előtti eredmény szerepeltetését, miközben a negatív adózás előtti eredmény a default egyik legerősebb indikátora. Jellemzően a főbb mutatócsoportokban nagyon hasonló mutatók voltak definiálva, így pl. a tőkeáttétel-jellegű mutatóknál tipikus volt, hogy vagy a saját tőke, vagy a mérlegfőösszeg korrigálva volt (pl. immateriális javakkal). Ezekben az esetekben az egyszerűség alapján választottunk. A modellben felhasznált pénzügyi mutatókat az alábbiak szerint definiáltuk:

$$\text{hosszú távú likviditási helyzet} = \frac{\text{Ha}(\text{hosszú lejáratú kötelezettségek}=0, -1, \text{hosszú lejáratú kötelezettségek})}{\text{tárgyi eszközök} + \text{befektetett pénzügyi eszközök} + \text{immateriális javak}}$$

$$\text{rövid távú likviditási helyzet} = \frac{\text{pénzeszközök} + \text{értékpapírok}}{\text{rövid lejáratú kötelezettségek}}$$

$$\text{termelékenységi mutató} = \frac{\text{anyag} + \text{személyi} + \text{egyéb ráfordítások}}{\text{árbevétel}}$$

$$\text{tőkeáttétel} = \frac{\text{saját tőke}}{\text{mérlegfőösszeg}}$$

$$\text{adósságfedezet} = \frac{\text{üzemi eredmény} + \text{értékcsökkenés}}{\text{hosszú lejáratú} + \text{rövid lejáratú kötelezettségek}}$$

$$\text{méret} = \text{árbevétel}$$

A hosszú távú likviditási helyzet mutatójának szétválasztására azért volt szükség, mert a hitellel rendelkező ügyfelek jelentős részének a mérlegében csak rövid lejáratú kötelezettség szerepelt.


A méretet nemcsak a szegmenseken keresztül, hanem változóként is figyelembe vettük a modellben úgy, hogy a 2000. évig visszatekintve az adott vállalatnak rögzítettük a historikus maximumát. A maximumérték használatával elkerüljük a túlzott ciklikusságot azzal, hogy csökkenő árbevétel esetén nem romlik jobban az ügyfél minősége annál, amit önmagában a termelékenységi mutatóban már szereplő aktuális árbevétel csökkenése okoz, így ez esetben is a TTC-modellre való törekvés előbbre való szempont volt a magyarázó erő növelésénél.

A változók kiválasztásakor elemeztük a mutatók magyarázó erejét. A magyarázó erő azt jelenti, hogy az adott mutató mentén mennyire lehet szeparálni a jó (nem defaultos) és a rossz (defaultos) ügyfeleket. Egy folytonos változó akkor szeparál jól, ha a változó mentén monoton a megfigyelt default-ráta, valamint nagy a különbség a legjobb és a legrosszabb pénzügyi mutatójú ügyfelek default-rátája között.

A modell szeparációs erejét kétféleképpen vizsgáltuk: elsőként a változók mentén besoroltuk az ügyfeleket 15 kategóriába úgy, hogy minden kategóriába azonos számú ügyfél jusson. A kategóriákon belül megnéztük a default-rátát, és amennyiben az

összefüggés nem volt monoton – ilyen csak egy-egy szomszédos kategória esetében volt megfigyelhető – ott a kategóriákat összevontuk. A hiányzó értékek egy különálló, „missing” kategóriát határoztak meg. A végső változókat a 2. ábra mutatja be, a hiányzó értékek az első vagy az utolsó kategóriákba kerültek.

2. ábra
A modell 15 kategóriára osztott pénzügyi mutatói és a kategóriákon belül megfigyelt default-rátá-átlagok



A 2. ábráról már első olvasatra is látszik, hogy a legerősebb változók az adósságfedezet és a tőkeáttétel, ahol a legalacsonyabb és a legmagasabb változókatörégiák között 8–10-szeres különbség van a default-ráták között, a legalacsonyabb magyarázó erővel látszólag a méret rendelkezik, ahol ez a különbség kevesebb, mint háromszoros. A méret azonban különösen a nagyvállalati szegmensben lesz releváns, aminek figyelembevételére a modell kalibrációja során külön kitérünk majd.

Másodsorban megmértük az egyes változók Gini-index-értékét, mely a bankok által leggyakrabban alkalmazott mérőszám a magyarázó erő mérésére. Azonban a modellbe nem a nyers változók, hanem a nemlinearitások, extrém értékek és a hiányzó értékek automatikus kezelésére elterjedt, a változókatörégiákra számolható WoE értékek kerülnek. A Weight of Evidence értékét egy katörégiára az alábbi módon kalkuláltuk:

$$WoE_i = \ln \left(\frac{\text{i. katörégiába eső nem defaultos ügyfelek aránya az összes nem defaultos ügyfeleken belül}}{\text{i. katörégiába eső defaultos ügyfelek aránya az összes defaultos ügyfeleken belül}} \right)$$

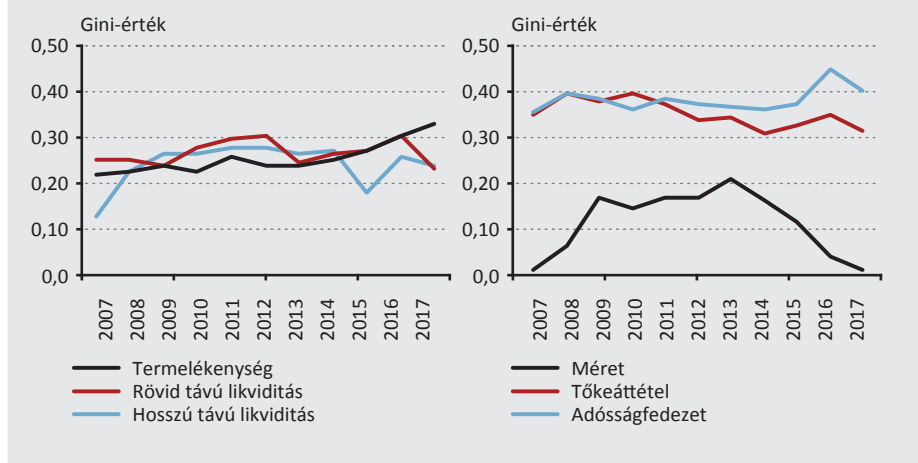
Mivel a modellben a fenti 15 katörégián számított WoE-értékeket használtuk, a Gini-index-értéket is ezen WoE-változók alapján számítottuk ki. A Ginivel jellemezhető magyarázó erő szegmensenként a modellben felhasznált pénzügyi mutatókra a 4. táblázatban mutatjuk be.

4. táblázat A modellben felhasznált pénzügyi mutatók magyarázó erejét jellemző Gini-index-értékek szegmensenként						
Szegmens	Gini-index-értékek					
	Hosszú távú likviditás	Rövid távú likviditás	Termelékenység	Tőkeáttétel	Adósságfedezet	Méret
Mikrovállalat	0,23	0,24	0,24	0,33	0,33	0,06
Kis- és középvállalat	0,24	0,38	0,29	0,45	0,46	0,08
Nagyvállalat	0,17	0,31	0,38	0,31	0,55	0,13
Teljes vállalati portfólió	0,26	0,30	0,26	0,40	0,40	0,14

Fontos kérdés az is, hogy időben mennyire tekinthetők stabilnak az egyes változók, azaz hosszú távon jó magyarázó erővel bírnak-e. Különösen azok az időszakok lényegesek, ahol nagyszámú default volt megfigyelhető. Azt, hogy a modell mennyire „válságálló”, megmutatja, hogy a nagy default-rátájú években, ami a modellezési adatbázis szerint 2009–2013 között volt, mennyire volt magas az egyes változók Gini-értéke. Azokban az években, ahol a default-ráta alacsony, kevésbé fontos

a magyarázó erő, hiszen azt a kevés számú defaultot olyan – általunk véletlennek tekintett – faktorok okozzák, melyek a modell hosszú távú teljesítményét csak kis mértékben befolyásolják negatív irányba. A 3. ábra alapján így azt is kijelenthetjük, hogy a méret, mint a legalacsonyabb magyarázó erejű változó, 2009–2013 között veszi fel a legmagasabb Gini-értékeket. Míg a méret növekedésével a vállalatok száma csökken, addig a méret változó magyarázó ereje nő, és mivel a banki kitettségek döntő részét a közép- és nagyvállalatok adják, ezért különösen fontos ennek a változónak a szerepeltetése ahhoz, hogy a megfigyelésekhez jól illeszkedő minősítő rendszert építsünk.

3. ábra
Az egyes pénzügyi mutatók magyarázó erejének időbeli változása



A mutatókat eleve úgy választottuk ki, hogy közöttük csekély átfedés van a változókhoz felhasznált mérleg- és eredményadatok között. Továbbá korrelációs elemzést is végeztünk annak megállapításához, hogy az egyes mutatóktól mennyire várhatjuk, hogy javítanak majd a megkülönböztető erőn. Ha két változó szerinti rangsor nagyon hasonló, akkor nem számítunk arra, hogy a két mutató beépítése sokat hozzáadna a modell erejéhez ahhoz képest, mintha csak az egyik változó szerepelne. Ezt a fajta kapcsolatot méri a rangkorreláció, melynek értékeit az 5. táblázatban mutatjuk be. A legnagyobb átfedés az adósságfedezet szerinti rangsornak van a tőkeáttétel és a termelékenység mutatók által meghatározott rangsorral. Az adósságfedezet és a tőkeáttétel közötti 0,55-ös korrelációs érték megfelelőnek tekinthető, figyelembe véve mindkét változó magyarázó erejét. Az adósságfedezet és a termelékenység között még ennél is magasabb, 0,59-es korrelációt mértünk, és összességében a termelékenységnek alacsony a magyarázó ereje, ezért a teljes modellen

kis hozzáadott értékre számíthatunk. Figyelembe kell azonban azt is venni, hogy ez a mutató a nagyvállalati szegmensben az egyik legjobb változó, ezért a megtartása mellett döntöttünk.

5. táblázat:
A modellben felhasznált pénzügyi mutatók közötti Spearman-féle rangkorreláció

	Hosszú távú likviditás	Rövid távú likviditás	Termelékenység	Tőkeáttétel	Adósságfedezet	Méret
Hosszú távú likviditás	1,00	-0,11	-0,01	-0,24	-0,10	0,16
Rövid távú likviditás	-0,11	1,00	-0,20	0,46	0,39	-0,14
Termelékenység	-0,01	-0,20	1,00	-0,25	-0,59	0,11
Tőkeáttétel	-0,24	0,46	-0,25	1,00	0,55	0,00
Adósságfedezet	-0,10	0,39	-0,59	0,55	1,00	0,00
Méret	0,16	-0,14	0,11	0,00	0,00	1,00

A változók kiválasztása, magyarázó erejük és korrelációs vizsgálatuk után elvégeztük a modell logisztikus regressziós illesztését. Mint azt bemutattuk, nem maguk a pénzügyi mutatók, hanem azok 15 kategóriába sorolt WoE-értékeit illesztettük magyarázó változókként a default-indikátorokhoz. A logisztikus regressziós modell illesztését SAS-szoftverben végeztük el, a Wald-teszt eredménye alapján minden változó erősen szignifikáns. A modell magyarázó ereje a Gini-együtthatóban kifejezve 0,507, mely egy tisztán pénzügyi mutatókat tartalmazó, a teljes vállalati mérettartományt lefedő modelltől nagyon jó eredménynek számít. A 0,6-ot meghaladó Gini-index-értékkel a felügyelés során szerzett tapasztalataink szerint csak olyan modellek rendelkeznek, melyek valamilyen viselkedési, vagy az éves beszámolóknál aktuálisabb pénzügyi helyzetre vonatkozó változót is felhasználnak.

A viselkedési változók és aktuális információk modellbe történő építése ugyan növelt volna a magyarázó erőt, azonban a modellt prociklikussá tette volna, amit egy tőkeszámításra alkalmazandó modell esetében el akartunk kerülni. A tőkeszámításon túl azonban vannak kockázatkezelési és kockázatmonitoring-szemponatok, melyek megkövetelik, hogy az aktuális információkat a bank nyomon kövesse. A korai beavatkozás a kockázatcsökkentés és veszteségminimalizálás egyik hatékony eszköze, emellett az értékvesztésnek is az aktuális kilátásokat kell tükröznie.

A magyarázó változók együtthatóit és szignifikanciáját a 6. táblázatban mutatjuk be.

6. táblázat**A SAS-szoftverben elvégzett logisztikus regressziós modell illesztésének eredménye és az együtthatók Wald-tesztje**

	Együttható értéke	Standard hiba	Becslés szignifikanciája (p-érték)
Tengelymetszet	-3,3181	0,0112	<0,0001
Hosszú távú likviditás	-0,5012	0,0247	<0,0001
Rövid távú likviditás	-0,6093	0,0208	<0,0001
Termelékenység	-0,1654	0,0276	<0,0001
Tőkeáttétel	-0,3739	0,0179	<0,0001
Adósságfedezet	-0,5125	0,0216	<0,0001
Méret	-0,5018	0,0411	<0,0001
Gini-érték		0,507	

A vállalat méretének növekedésével a méret változó egyre fontosabbá válik. A 15 egyenlő számú vállalatot tartalmazó méretkategória képzése során azonban a nagyvállalatok alacsony darabszáma miatt a 15 milliárd forint árbevételű vállalatok mindegyike a legnagyobb méretkategóriába kerül. Ezért a nagyvállalatok esetében a fenti modellt kiegészítettük egy folytonos méret változóval, melyet az árbevétel, illetve a mérlegfőösszeg historikus maximumaként definiáltunk, majd képeztük ennek az értéknek a természetes alapú logaritmusát. A fenti modell szerinti „score” értéket és a méret változót mint magyarázó változót használtuk a nagyvállalati logisztikus regresszióban, melynek eredményeként 0,603-os Gini-érték adódott (ld. a 7. táblázatot).

7. táblázat**Nagyvállalati szegmensen a modell mérettel való kiegészítésének eredménye, az együtthatók értéke és szignifikanciája**


Nagyvállalati méretkalibráció	Együttható értéke	Standard hiba	Becslés szignifikanciája (p-érték)
Tengelymetszet	5,2099	0,8157	<0,0001
Score (vállalati modellből)	1,1727	0,0886	<0,0001
$\ln(\max(\text{árbevétel}, \text{mérlegfőösszeg}))$	-0,3144	0,0492	<0,0001
Gini-érték		0,603	

Láttuk, hogy az egyes vállalati méretszegmenseken a magyarázó változók eltérő mértékben magyarázzák a default-esemény valószínűségét, bár mindegyik pénzügyi mutató megfelelőnek tekinthető minden mérettartományon. Ennek kezelésére kétféle megoldás kínálkozik: egyrészt már a logisztikus regressziónál különválaszthatunk volna a szegmenseket, és így szegmensenként eltérő együttható-szett adódott

volna, másrészt az egységes modell szegmensenként külön-külön is kalibrálható. Mindkét lehetőséget megvizsgálva a szegmensenkénti PD-kalibráció mellett döntöttünk, mivel így a külön logisztikus regresszióval megegyező magyarázó erő, valamint illeszkedés érhető el, miközben az egységes logisztikus regresszió egyszerűbb, robusztusabb modellt jelent. Itt csak megemlítjük, hogy ugyanezzel a változó- és együtttható-szettel jól illeszkedő modellt építettünk a felügyeleti felülvizsgálatok során a termékalapú finanszírozású, retail mikroszegmensben, pusztán a modell újrakalibrálásával. A 4. ábrán a tőkeáttételi mutató példáján szemléltetjük, hogy csak PD-kalibrációval szegmensenként is kiváló illeszkedés érhető el, és nincs szükség külön logisztikus regressziós modellekre. További modellfejlesztési lehetőség annak vizsgálata, hogy a különböző méretszegmensekben esetleg eltérő pénzügyi mutatók lehetnek-e a legjobb magyarázó faktorok, és ebben az esetben a szegmensekre akár külön modellek is fejleszthetők lennének. Az eltérő változók mentén történő külön nagyvállalati és külön középvállalati modellezésre akad példa a banki gyakorlatban is.


4. ábra

A kalibrált PD illeszkedése a default-rátákra kalibrációs szegmensenként a tőkeáttétel függvényében



A PD kalibrálása úgy történik, hogy a logisztikus regresszió eredményeként előálló, az (1) egyenlet szerinti modellezett default-ráta függvényében ábrázoltuk a tényleges default-rátát. A modellezett és a tényleges default-ráta között megfelelően megválasztott regressziós függvénykapcsolattal definiáltuk a PD-kalibrációs függvényt, melynek eredménye adta a végső, az IRB szerinti tőkekövetelmény-számítására is alkalmazható PD-paraméterek értékét. Az illesztés és a PD-kalibrációs függvények az 5. ábra grafikonjain láthatóak.


5. ábra
A PD-kalibrációs függvények illesztése az egyes vállalati szegmenseken



6. Eredmények

A vállalati benchmark-modellünk által számolt PD-k alapján elmondható, hogy a modell stabil, a historikus default-rátákhoz közeli eredményt ad (6.ábra). A becült PD-k időszora nem mutat olyan ciklikusságot, mint egy viselkedési változókat tartalmazó Point-in-Time modell, mely az éves default-ráták ingadozásait lekövetve nem képes megragadni a vállalatok hosszú távú hitelminőségét. Látszik azonban, hogy szignifikáns javulás látható a PD-idősorban, ami nemcsak a finanszírozott portfóliók javuló összetételéből és idioszinkratikus hatásokból, hanem a gazdasági konjunktúra pénzügyi mutatókra gyakorolt kedvező, tehát ciklikus hatásaiból is fakadhat.

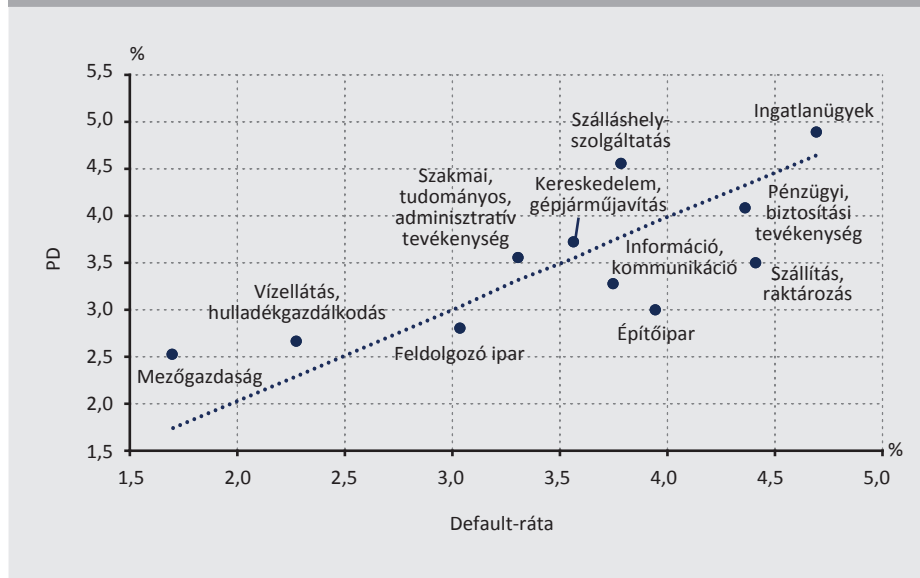
6. ábra
A historikus default-ráták és a benchmark-modell szerinti PD-k kalibráció szegmensenként bemutatva



Fontos döntési pont volt a modell fejlesztése során, hogy szerepeltessük-e az iparágat a magyarázó változók között. Úgy ítéltük, hogy 1) ha a visszamérés során az iparági átlagos default-rátákat a csak pénzügyi mutatókon alapuló modell jó közelítéssel megragadja, és 2) ha a modell az iparági kockázati sorrendet visszatükrözi, akkor nem építjük be a PD-modellbe, mert ez esetben azt mondhatjuk, hogy az iparági sajátosságok már tükröződnek a választott pénzügyi mutatókban. A 7. ábrán mutatjuk be, hogy a PD-modell eredménye jól visszaadja az iparági sajátosságokat. A mezőgazdaság a modell szerinti PD-ben is a legalacsonyabb kockázatú, az ingatlanügyek pedig a legmagasabb PD-jű szegmens, és ennek az ágazatnak volt a legnagyobb a default-rátája. Bár az építőipar és a szállítás-raktározás ágazatban a számított PD-k alatta maradnak a tényleges default-rátáknak, az eltérés mértéke és az ilyen esetek száma nem tette indokolttá az iparág változóként való figyelembevételét a modellben. Egyetlen ciklus alapján nem lehet elvárni, hogy minden iparág esetében tükröződjön a hosszú távú default-ráta, ezért el akartuk kerülni a modell túlillesztését, azaz a valóságban esetleg nem létező összefüggések modellezését.

Lehetséges azonban, hogy alapvető szektorok – pl. termelő, szolgáltató, kereskedelem – mentén különböző faktorok eltérő mértékben befolyásolják a hitelminőséget, ez azonban egy mélyebb, e cikken túlmutató további elemzést igényelne.


7. ábra
Az iparági átlagos becsült PD-értékek a megfigyelt default-ráták függvényében



Benchmark-modellünk egyik legjelentősebb eredményének tartjuk, hogy nagyon széles mérettartományon is jól alkalmazható. Nemcsak a nagy számosságú, ezért statisztikailag könnyebben modellezhető mikroszegmensen, hanem a nagyvállalati szegmensen is sikerült robusztus, jó magyarázó erejű modellt fejleszteni. A felügyeletnek nincs könnyű dolga akkor, amikor egy alacsony default-számú, esetleg az anyabank által, a külföldi bankcsoporttagok adatait is felhasználó PD-modellt kell megítélnie, azonban a modellünkhöz felhasznált magyar bankrendszeri adatok összefésülésével és a rajta kalibrált PD-moddellel már lehetővé vált a nagyvállalati PD-k kvantitatív vizsgálata is.

A 8. ábra mutatja be, hogy milyen pontos a tény default-ráta és modell szerinti PD illeszkedése a teljes mérettartományon. A legnagyobb mérettartományban (>50 milliárd forint) már olyan kevés számú vállalat és default található, hogy már egyetlen default is jelentősen el tudja mozgatni a default-arányokat. Éppen ezért ebben a sávban megfelelően konzervatívnak tartjuk a számított PD-értékeket.

8. ábra
A vállalati benchmark PD illeszkedése az átlagos tény default-rátára a teljes mérettartományon



Megjegyzés: A méretet logaritmikusan tüntettük fel, a hibásávot (pirossal jelölve) egyetlen addicionális defaulttal jelöltük ki.

A bankonként és portfóliószegmensenként visszamért eredmények azt mutatják, hogy az egyes portfóliószegmensek historikus default-rátái összhangban vannak a kalibrált PD-kkel az egyes bankok esetében is, azaz a banki kockázatkezelési sajátosságok, kvalitatív elemek nem térítik el szisztematikusan és materiálisan a hitelminőség szintjét attól a szinttől, melyet a csupán pénzügyi adatok önmagukban implikálnának.

A vállalati PD benchmark modellünk legfontosabb felügyeleti felhasználási területe a tőkekövetelmény-számítás. Egy felügyeleti benchmark PD modell fontos eszköz a belső modellel már rendelkező intézmények PD-becsléseinek ellenőrzéséhez, szükség esetén felülbírálatához, a belső modellel nem rendelkező intézményeknél pedig közvetlenül a 2. pilléres tőkekövetelmény meghatározásához. A 2019. évi felügyeleti felülvizsgálat folyamán begyűjtött nagybanki hitelanalitikákon teszteltük a benchmark-modellünket úgy is, hogy összevetettük a benchmark PD-ket a vizsgált bankok saját PD-becsléseivel, valamint megvizsgáltuk az eltéréseket a banki PD-vel számított IRB-tőkekövetelmények és a benchmark PD-kel számított IRB-tőkekövetelmények között.

Az eredményeink alapján (8. táblázat) a banki vállalati PD-becslések a 2019-es év folyamán jó összhangban voltak az e cikkben bemutatott benchmark PD-kkel, a segítségükkel kalkulálható IRB-tőkekövetelmények között pedig összességében elhanyagolható különbség adódott. Az egyes banki portfóliók méretüket tekintve 80 százalékaiban a banki PD-k és a benchmark PD-k szerinti tőkekövetelmények különbsége 10 százalékon belül volt, a maximális eltérés pedig a 20–25 százalékos sávba esett a negatív és a pozitív irányban is.

8. táblázat

A nagybankok saját, valamint a vállalati benchmark PD-k és az IRB szerinti tőkekövetelmények összehasonlítása (milliárd Ft és %)

Szegmens	Kitettség (milliárd Ft)	Intézményi PD	Benchmark PD	IRB: intézményi PD-vel kalkulált tőkekövetelmény (milliárd Ft)	IRB: benchmark PD-vel kalkulált tőkekövetelmény (milliárd Ft)
Mikrovállalat	209	3,89%	4,02%	14	15
Kis- és középvállalat	2 250	2,35%	2,72%	144	152
Nagyvállalat	2 881	1,29%	1,10%	198	189
Összesen	5 339			356	357

7. Összefoglalás

Jelen tanulmányban *Inzelt és szerzőtársai (2016)* modelljét továbbfejlesztve egy olyan vállalati benchmark PD modellt építettünk, mely a felügyeleti felülvizsgálati folyamat során tőkekövetelmény-számítási célokra megbízhatóan felhasználható. A modell magyarázó ereje kiváló, illeszkedése a megfigyelt default-rátákhoz minden mérettartományban, iparágak mentén jónak mondható, meggyőződésünk szerint a nagyvállalati szegmensen a banki modelleknél megbízhatóbb PD-t ad. A modell lehetőséget ad arra, hogy minden banki vállalati portfóliót egyenszilárdan mérhessünk. E benchmark-modell lehetővé teszi, hogy a felügyelet olyan intézmények esetében is kockázatérzékeny módon állapítsa meg a tőkeszükségletet, ahol nincsenek fejlett minősítő rendszerek, vagy e rendszerek nem megbízhatóak, így e cikk szerzői eredményesen alkalmazták a benchmark PD-eket a kisbanki tőkekövetelmények meghatározása során is.

A használat során világossá vált a modellnek néhány olyan hiányossága, mely csak egyedileg kezelhető. Vállalatcsoportok esetében mérlegelhető a csoport-/anyavállalati PD kellően konzervatív súllyal történő beépítése a végső PD-be. Holdingtársaságok és részesedésvásárlásra létrehozott cégek pénzügyi mutatói nem minden esetben tükrözik megfelelően a vállalat kockázatosságát. Ezekben az esetekben egyedi mérlegelés vezethet a PD felülbírálatához. Nagy, nemzetközi háttérű vállalatok esetében segítségre lehet az MNB rendelkezésére álló EBA benchmark PD-értékek figyelembevétele is.

A felügyeleti felülvizsgálatok és modellengedélyezések során szerzett tapasztalataink alapján tisztában vagyunk az itt bemutatott PD benchmark modell és a banki PD-modellek közötti főbb különbségekkel. A banki vállalati modellek az objektív pénzügyi mutatók mellett mindig tartalmaznak kvalitatív, úgynevezett „soft” elemeket is, például a menedzsment tapasztalatáról, az ügyfél track recordjáról, az adott vállalati piacon elfoglalt helyéről stb. A csoport/anyavállalati befolyásolás szintén része a bankok modelljeinek, mint ahogy a szakértői eltérítés, „overruling” szerepe is számottevő lehet. Ezen szakértői elemek hozzáadott értékét el nem vitatva kiemeljük, hogy a benchmark-modellünk átlagosan ad megfelelő kockázati szintet, mely egyedi esetekben felülvizsgálható. A modell kvalitatív szempontokkal történő kiegészítése akár jelentősen növelhetné a modell magyarázó erejét, ezért ez fontos fejlesztési irány lehet.

Végezetül érdemes szót ejteni a PD-modellek PiT/TTC kérdésköréről is. Az aktuális pénzügyi mutatók mindenképpen ciklikusságot visznek a PD-becslésbe. Ahhoz, hogy ciklusfüggetlenül tudjuk mérni a kockázatokat, illetve elkerülnünk a kockázatok konjunktúrában szokásos alul-, dekonjunktúrában pedig felülbecslését, mindenképpen

a modell TTC-irányba történő fejlesztésére lenne szükség. A modell „TTC-sítésére” számos megoldás kínálkozhat, akár a pénzügyi mutatók átlagolása, akár egy adott évben a változók értékeinek egymáshoz viszonyított relatív viszonya alapján, ennek vizsgálata azonban már egy másik tanulmány témája lehet.

Felhasznált irodalom

Banai Ádám – Körmendi Gyöngyi – Lang Péter – Vágó Nikolett (2016): *A magyar kis- és középvállalati szektor hitelkockázatának modellezése*. MNB-tanulmányok 123, Magyar Nemzeti Bank.

Bauer Péter – Endréz Marianna (2016): *Modelling bankruptcy using Hungarian firm-level data*. MNB Occasional Papers 122, Magyar Nemzeti Bank.

BCBS (2006): Basel Committee on Banking Supervision: *International Convergence of Capital Measurement and Capital Standards*. <http://www.bis.org/publ/bcbs128.pdf>. Letöltés ideje: 2020. március 2.

BCBS (2010): *Basel III: A global regulatory framework for more resilient banks and banking systems*. Basel Committee on Banking Supervision. https://www.bis.org/publ/bcbs189_dec2010.pdf. Letöltés ideje: 2020. március 2.

BCBS (2013): *The regulatory framework: balancing risk sensitivity, simplicity and comparability*. Discussion paper, Basel Committee on Banking Supervision. <https://www.bis.org/publ/bcbs258.pdf>. Letöltés ideje: 2020. március 2.

BCBS (2017): *High-level summary of Basel III reforms*. Basel Committee on Banking Supervision. https://www.bis.org/bcbs/publ/d424_hlsummary.pdf. Letöltés ideje: 2020. március 2.

EBA (2013): *Report on the comparability of supervisory rules and practices*. European Banking Authority. <https://eba.europa.eu/sites/default/documents/files/documents/10180/15947/aab59482-8c84-44b7-8d5f-8a588eb7276e/20131217%20Report%20on%20the%20comparability%20of%20supervisory%20rules%20and%20practices.pdf?retry=1>. Letöltés ideje: 2020. március 2.

EBA (2015): *EBA Report Results from the 2014 Low Default Portfolio (LDP) Exercise*. European Banking Authority. <https://eba.europa.eu/sites/default/documents/files/documents/10180/950548/b3adc4f7-653d-408d-b950-da2e4229e294/EBA%20results%20from%20the%202014%20Low%20Default%20portfolio%20%28LDP%29%20exercise.pdf?retry=1>. Letöltés ideje: 2020. március 6.

EBA (2016): *Final Draft Regulatory Technical Standards: on the specification of the assessment methodology for competent authorities regarding compliance of an institution with the requirements to use the IRB Approach in accordance with Articles 144(2), 173(3) and 180(3) (b) of Regulation (EU) No 575/2013*. European Banking Authority. <https://eba.europa.eu/sites/default/documents/files/documents/10180/1525916/e8373cbc-cc4b-4dd9-83b5-93c9657a39f0/Final%20Draft%20RTS%20on%20Assessment%20Methodology%20for%20IRB.pdf>. Letöltés ideje: 2020. március 6.

EBA (2017a): *Guidelines on PD estimation, LGD estimation and the treatment of defaulted exposures*. European Banking Authority. [https://eba.europa.eu/sites/default/documents/files/documents/10180/2033363/6b062012-45d6-4655-af04-801d26493ed0/Guidelines%20on%20PD%20and%20LGD%20estimation%20\(EBA-GL-2017-16\).pdf](https://eba.europa.eu/sites/default/documents/files/documents/10180/2033363/6b062012-45d6-4655-af04-801d26493ed0/Guidelines%20on%20PD%20and%20LGD%20estimation%20(EBA-GL-2017-16).pdf). Letöltés ideje: 2020. március 6.

EBA (2017b): *EBA Report Results from the 2016 High Default Portfolios (HDP) Exercise*. European Banking Authority. <https://eba.europa.eu/sites/default/documents/files/documents/10180/15947/7d246d06-4fca-4662-8a8e-71106008c4c8/EBA%20Report%20results%20from%20the%202016%20high%20default%20portfolio%20exercise%20-%20March%202017.pdf?retry=1>. Letöltés ideje: 2020. március 6.

EBA (2017c): *EBA Report Results from the 2017 Low Default Portfolios (LDP) Exercise*. European Banking Authority. <https://eba.europa.eu/sites/default/documents/files/documents/10180/15947/8dd027a7-08d9-490a-87d3-b5cd0ea9c9bf/EBA%20Report%20results%20from%20the%202017%20LDP%20Credit%20Risk%20benchmarking.pdf?retry=1>. Letöltés ideje: 2020. március 6.

EBA (2019): *EBA Report Results from the 2018 Low and High Default Portfolios Exercise*. European Banking Authority. <https://eba.europa.eu/sites/default/documents/files/documents/10180/2087449/431db2b7-559a-4a64-b3e8-0451edaebfef/EBA%20Report%20results%20from%20the%202018%20Credit%20Risk%20Benchmarking%20Report.pdf?retry=1>. Letöltés ideje: 2020. március 6.

EBA (2020): *EBA Report Results from the 2019 Low-Default and High-Default Portfolios Exercise*. European Banking Authority. https://eba.europa.eu/sites/default/documents/files/document_library/Publications/Reports/2020/EBA%20Report%20-%20Results%20from%20the%202019%20Credit%20Risk%20Benchmarking%20Exercise.pdf. Letöltés ideje: 2020. március 6.

ECB (2017): *Guide for Targeted Review of Internal Models*. European Central Bank. https://www.bankingsupervision.europa.eu/ecb/pub/pdf/trim_guide.en.pdf. Letöltés ideje: 2020. március 2.

- ECB (2019): *ECB guide to internal models*. European Central Bank. https://www.bankingsupervision.europa.eu/ecb/pub/pdf/ssm.guidetointernalmodels_consolidated_201910~97fd49fb08.en.pdf. Letöltés ideje: 2020. március 2.
- Imre Balázs (2008): *Bázel II definíciókon alapuló nemfizetés-előrejelzési modellek magyarországi vállalati mintán (2002–2006)*. PhD-értekezés, Miskolci Egyetem.
- Inzelt György – Szappanos Gábor – Armai Zsolt (2016): *Felügyelés robusztus kockázati monitoring alkalmazásával – ciklusfüggetlen magyar vállalati minősítő rendszer*. Hitelintézeti Szemle, 15(3): 51–78. <https://hitelintezetiszemle.mnb.hu/letoltes/inzelt-gyorgy-szappanos-gabor-armai-zsolt.pdf>
- Kristóf Tamás – Virág Miklós (2019): *A csődelőrejelzés fejlődéstörténete Magyarországon*. Vezetéstudomány/Budapest Management Review, 50(12): 62–73. <https://doi.org/10.14267/VEZTUD.2019.12.06>
- Madar László (2014): *Scoring rendszerek hatásai a gazdasági tőkeszámítás során alkalmazott portfóliómodellek eredményeire*. PhD-értekezés, Kaposvári Egyetem.
- MNB (2020): *A tőke megfelelés belső értékelési folyamata (ICAAP), a likviditás megfelelőségének belső értékelési folyamata (ILAAP) és felügyeleti felülvizsgálatuk, valamint az üzleti modell elemzés (BMA)*. Magyar Nemzeti Bank. <https://www.mnb.hu/letoltes/icaap-ilaap-bma-kezikonyv-2019-final.docx>. Letöltés ideje: 2020. március 6.