

Bankruptcy prediction with financial ratios in the SME sector

GERGELY FEJÉR-KIRÁLY

The bankruptcy and financial distress prediction research has evolved substantially after the new BASEL agreement and due to its importance in corporate finance. However, bankruptcy prediction studies focus mostly on big companies. The prediction of bankruptcy and financial distress is important in the SME sector because of its impact on local, regional and national economies. This article completes the bankruptcy prediction research from Romania, using an SME data sample from Harghita county for the period 2008–2014. The article also compares the logistic regression model (LR) with the neural network model (NN) in the prediction accuracy, showing that both can predict the financial distress in the SME sector, but the neural network model outperforms in accuracy the logistic regression model. The SMEs from Harghita county use mainly short term financing in their business cycle and one of the main factors that cause financial distress and bankruptcy in the SME sector is the circular debt.

Keywords: failure prediction, financial distress, bankruptcy, financial ratios, SME.

JEL code: G33.

Csődelőrejelzés a KKV-szektorban pénzügyi mutatók segítségével

FEJÉR-KIRÁLY GERGELY¹

A vállalati csőd és fizetéseképtelenség előrejelzésének kutatása jelentős fejlődésen ment keresztül az új bázeli tőkekegyezményt követően, ugyanakkor a vállalati pénzügyekben is egyre fontosabb szerepet kapott. A vállalati csődkutatás legnagyobb része a nagyvállalatokra fókuszál, bár a csőd és fizetéseképtelenség kutatása a KKV-k esetében is fontos, tekintettel a szektor helyi, regionális és országos gazdaságban kifejtett hatására. Jelen tanulmány a romániai csőd és fizetéseképtelenség kutatását egészíti ki egy 2008–2014 közötti Hargita megyei KKV-adatmintán végzett kutatással. A tanulmányban összehasonlításra kerülnek a logisztikus regresszió (LR) és a mesterséges neurális háló (NN) modellek találati értékei és ezek alkalmazhatósága is. Az eredmények alapján megállapítható, hogy a logisztikus regresszió és a neurális hálómódel egyaránt alkalmas a KKV-szektorbeli csőd előrejelzésére, ugyanakkor a vállalati csőd kialakulásának előrejelzésében a neurális háló nagyobb találati értékkel bír. Megállapítható, hogy a Hargita megyei KKV-k főleg a rövid távú finanszírozást alkalmazzák üzleti tevékenységük során, illetve hogy a csőd kialakulását nagymértékben a vállalatok egymás közötti tartozása befolyásolja. Mivel a megyei vállalati hitelállomány jelentősen elmarad az országos értékektől, a vállalatok adóssági helyzetét jellemző pénzügyi mutatók kevésbé alkalmasak a csőd vagy fizetéseképtelenség tanulmányozására.

Kulcsszavak: fizetéseképtelenség, csőd, csődelőrejelzés, pénzügyi mutatók, KKV-szektor.

JEL kód: G33.

Bevezető

A pénztőke szabad áramlása és korlátolt léte arra készíti a befektetőket, hogy a pénzt minimális kockázat mellett fektessék be. A befektetéseket érő kockázatok elkerülése miatt a kihelyezett tőke folyamatos ellenőrzés alatt áll. A vissza nem fizetés kockázata nagyobb gazdasági és pénzügyi válságok idején (Constand–Yazdipour 2011). A működésből származó kockázatok, gazdasági sokkhatások gyakran a csőd szélére sodorják a vállalatokat, befektetéseket, így jelentős költséget okoznak a tőke tulajdonosainak és a társadalomnak egyaránt.

A vállalati csőd költséges jelenség a gazdasági szereplők számára. A hitelezők elvesztik pénzüket, a vállalatot felszámolási költségek terhelik, az alkalmazottak nem, vagy csak részben kapják meg béreiket. A tulajdonosok érteken aluli

¹ Egyetemi tanársegéd, Sapientia EMTE, e-mail: fejergergely@yahoo.co.uk.

összegeket kapnak vissza, vagy egyáltalán nem kapnak semmit. Egy nagyobb vállalat esetében a csőd hatással lehet a beszállítókra is, a csőd a beszállítók egy részét is magával húzhatja vagy pénzügyi válság szélére sodorhatja. Ez az összefonódás és a kereskedelmi tartozás vezethet csoportos, iparágon belüli csődhöz is, ami az állami költségvetés számára egyrészt jövedelemkiesést, másrészt pótlólagos társadalombiztosítási költségeket jelenthet (Altman–Sabato 2005).

A fentebb említett okok hatására a vállalati pénzügyi kutatások terén az elmúlt években egyre nagyobb figyelmet kapott a vállalati pénzügyi modellezés, a vállalati csőd és fizetésképtelenség kutatása. A tanulmányok nagy része azonban bankok és nagyvállalatok csőd kutatásával foglalkozik, főleg fejlett országok adatait véve alapul. Lízal és Schwarz (2012), illetve Karas és Režňáková (2013) arra hívják fel a figyelmet, hogy kevés a közép-kelet-európai térségen belül a csődelőrejelző empirikus kutatás. A KKV-k fizetésképtelenség-előrejelzésének modellezése 2005-ig hiányosnak tekinthető (Altman–Sabato 2005). Ennek oka többek között a II. bázeli egyezmény 2005-től való alkalmazása, melynek hatályba lépésekor számos kritika fogalmazódott meg a kormányzatok és KKV-érdekvédelmi szervezetek részéről, mivel a magas tőke költség negatívan érinti ezen vállalatokat. Altman és Sabato (2005), illetve Berger (2006) is foglalkozott a bázeli egyezmény KKV-szektorra gyakorolt hatásával. A KKV-szektor hitelezés szempontjából kockázatosabbnak tekinthető (Altman–Sabato 2005), mivel a gazdasági változásoknak, sokkhatásoknak jobban ki vannak téve, mint a nagyvállalatok, ugyanakkor a KKV-hitelezés erős hatással van a bankok eredményességére is (Kolari et al. 2006; Berger 2006).

Jelen tanulmány célja, hogy hozzájáruljon a romániai KKV-k csőd kutatásához. A kutatás annak a lehetőségét vizsgálja, hogy Hargita megye szintjén létrehozható-e olyan modell, amely pénzügyi mutatók alapján jelezze előre a KKV-k csődbe jutását.

Szakirodalmi áttekintés

A csődelőrejelzés folyamatos átalakuláson, fejlődésen ment keresztül. Az informatikai technológia és a szakértői rendszerek fejlődésével egyre összetettebb modellek alakultak és alakulnak ki, de nincs egy általánosan elfogadott modell (Constand–Yazdipour 2011). Bellovary és társai (2007) a tanulmányokat két csoportba osztják aszerint, hogy miként határozzák meg a csőd fogalmát. Az első csoportba tartoznak azon cikkek, amelyek a csődöt jogi értelemben kezelik

(a vállalat ellen már jogi úton elindult a csőd eljárás, átszervezés vagy felszámolás). A második csoportba azon tanulmányok tartoznak, amelyek a csődöt pénzügyi stressznek tekintik, azaz a vállalatok fizetéseképtelenségét értik a csőd fogalma alatt (a vállalat nem tud adósainak fizetni).

A szakértők a csődkutatás első mérföldkövét Altmanhoz kötik: ő volt az első, aki felismerte, hogy egyetlen változó nem elégséges a csőd pontos becsléséhez. Altman (1968) 33 vállalatpár (fizetőképessé és fizetéseképtelen) 1946–1964 közötti pénzügyi mutatóit vizsgálta többváltozós diszkriminanciaelemzés² segítségével. Modellje számos tanulmányban szolgál összehasonlítási alapul (Bellovary et al. 2007). Meg kell jegyezni azonban, hogy Fitzpatrick még Altman előtt hasonlított össze 20-20 vállalat (jól működő és csődbe jutott vállalatok) mutatóit, és arra a következtetésre jutott, hogy az eladósodottsági, likviditási, jövedelmezőségi és forgási sebesség mutatószámok a jól működő vállalatok esetében magasabbak, mint a csődbe jutott vállalatoké (Fitzpatrick 1934). Ugyanakkor Smith és Winakor (1935) vizsgálta először a két csoportba tartozó vállalatok pénzügyi mutatóit páronként.

Altmant követően a kutatók számos diszkriminanciaanalízisen alapuló modellt alkottak, megváltoztatva a modellt alkotó mutatókat. Mások iparági átlagok korrekciójával, piaci érték vagy nagy adatbázisok alkalmazásával új változatokat dolgoztak ki (Deakin 1972; Blum 1974; Fulmer et al. 1984).

Az 1980-as évektől kezdődően új modellcsalád jelent meg a csődelőrejelzésben, a logisztikus regresszióelemzés. A modell Ohlson nevéhez fűződik, aki 105 csődbe ment és 2058 működő társaság 1970–1976 közötti adatait elemezve negatív kapcsolatot mutatott ki a vállalat mérete és fizetőképessége között (Ohlson 1980).

Az 1990-es években gyors fejlődésnek indult a számítógépes technika, ami a mesterséges intelligencia és szakértői rendszerek fejlődését is elősegítette. Ennek köszönhetően egy újabb modellcsalád született, a neurális hálók. A neurális hálók alkalmazása Messier és Hansen (1988) nevéhez fűződik, őket többen követették: Raghupathi et al. (1993), Coats–Fant (1992) és Altman et al. (1994). A neurális hálózatok segítségével is készíthető klasszifikációs elemzés. A hálózatok felépítése több réteg segítségével történik (Virág–Kristóf 2005): bemeneti, köztes és kimeneti réteg. A bemeneti réteg a vállalatok pénzügyi jellemzőit tartalmazza, a kimeneti réteg csak egy neuronból áll, a rétegek közötti kapcsolatot a neuronok fontossági sorrend szerint súlyozzák.

² Multivariate discriminant analysis (MDA).

A neurális hálózatok mellett más mesterséges intelligenciát felhasználó módszerek is születtek a csődelőrejelzés területén: hibrid modellek, amelyek az MDA és a neuronhálós modelleket kombinálják (Lee et al. 1996), generikus algoritmusok (Vareto 1998), illetve a rough teszt elmélet alapján végzett kutatások (Dimitras et al. 1999). A rough teszt módszer alkalmasnak bizonyult pénzügyi információs adattáblák magyarázatára azzal, hogy több megfogalmazott pénzügyi célt képes megmagyarázni értékelt pénzügyi változók segítségével (Dimitras et al. 1999). A neurális hálózatok a nem parametrikus modellek közé tartoznak. A nem parametrikus modellek csoportjába tartoznak a Bayesian-, hazard-, huzzy- és genetikus algoritmusmodellek, és a Data Envelopment Analysis (DEA). A mesterséges intelligenciát alkalmazó tanulmányok szakirodalmi áttekintésével Perez (2006), Ravi–Ravi (2007), Verikas et al. (2010) és Kirkos (2015) foglalkozott. Perez (2006) cikkében 30 tanulmányt és az azokban alkalmazott neurális háló modellek problémáit tárgyalja, Ravi–Ravi (2007) 1968–2005 között több modellesalád modelljeit vizsgálja, Verikas és társai (2010) pedig a számítási technikák javítására tettek próbát, melynek segítségével hibrid modellek alkothatóak.

A Bellovary-cikk (Bellovary et al. 2007) egy összefoglaló tanulmány a csőd-kutatás területén. A szerzők 165 tanulmányt vizsgáltak 1966 és 2004 között, ebből 43 cikk két vagy ennél több modellt hasonlított össze. A modellekben gyakran előforduló pénzügyi mutatók között szerepel a ROA, az általános likviditási mutató, az eszközökre vetített forgótőke és az árbevétel-arányos eszközök értéke.

Xu és Zhang (2009) kísérletet tett a statisztikai modellek és az opcióárazási modellek összehasonlítására. Az adatokat a japán tőzsdén jegyzett 3510 vállalati adaton tesztelték. Végső következtetésük, hogy a japán vállalatok esetében az opcióárazási modell jobb, mint a statisztikai modellek, ugyanakkor a két modell kombinációjával a csődelőrejelzés pontosabb. Gupta és társai (2014) a logisztikus regresszió módosított változatát alkalmazták a KKV-szektorra, amely figyelembe veszi az idő hatását is. A tanulmány az Egyesült Királyságból származó 385 733 egészséges és 8162 fizetéképtelen KKV-t vizsgálta 2000 és 2009 között. A vállalati pénzügyi mutatók mellett más, nem pénzügyi mutatókat is alkalmaztak dummy változókként. A szerzők a vállalati mintát felosztották mikro-, kis- és közepes vállalkozásokra, mivel kutatásuk célja az volt, hogy megvizsgálják a vállalati méret hatását a fizetéképtelenség valószínűségére. A szerzők a modell találati értékének meghatározásához a ROC görbe alatti területet vették összehasonlítási alapul. Mindhárom kategória esetében a találati érték magas volt, a ROC értéke

74-75% között mozgott, és ugyanarra a következtetésre jutottak, mint Altman és társai (2010), éspedig hogy a méret csak a mikrovállalatok esetében volt hatással a fizetéképtelenség valószínűségére, a többi esetben viszont nem.

Brîndescu és Goleț (2013) Temes megyében végeztek vizsgálatot, amelynek a célja annak a megállapítása volt, hogy mekkora pontossággal készíthető vállalati csődelőrejelzés logisztikus regresszió segítségével a hivatalosan elérhető mérlegadatokból.³ A vizsgálat mintáját összesen 4327, 2008 és 2012 között tevékenkedő vállalat képezte, ebből 266 jutott csődbe. A felhasznált független változók száma 11 volt. A szerzők egy öt változóból és konstansból álló modellt alkottak. Az öt változó (5%-os szignifikanciaszint mellett): a befektetett eszközök forgása, a követelések forgási ideje, a befektetett eszközök és a mérlegfőösszeg aránya, a saját tőke és mérlegfőösszeg aránya, illetve a saját tőke és befektetett eszközök különbsége. A modell szétválasztó értéke (cut value) 0,071 volt. A találati érték a nem csődös vállalati csoport esetében 67,6%, míg a csődös csoport esetében 68% volt a tesztelő mintán.

Goleț (2014) tanulmányában többfajta statisztikai modell tesztelését végezte el a 2008–2012-es évekre. A tanulmány célja az alkalmazott modellcsaládok, logit- és probitmodellek csődelőrejelző találati értékének tesztelése romániai vállalati mintákon. A modell felépítéséhez összesen nyolc vállalati pénzügyi mutatót alkalmazott, a kezdeti minta 26 860 vállalatot tartalmazott. A statisztikai eljárást megelőző tisztítást követően a végső felhasznált minta 5908 vállalatból állt, ebből közel 6% (354 vállalat) a csődbement csoporthoz tartozott. A tanulmány végkövetkeztetése az volt, hogy a modellek jelentős eltérést nem mutattak a pontossági találat szempontjából. Az átlag AUROC-érték 0,7244 volt. Minden modell esetében a saját vagyion aránya és a befektetett eszközök aránya bírt a legnagyobb hatással a csőd bekövetkezésének esélyére, ugyanakkor a csődbe jutás tekintetében a magas működőtőke-szükséglet jellemző a minta esetében.

Cimpoeru (2014) tanulmánya egy összehasonlító elemzés Altman és Taffler modelljeinek egy általa készített logisztikus modell találati arányával. A tanulmányban használt adatminta kismintás volt, a megfigyelések száma 105 vállalatot ölelt fel (75 nem csődös és 30 csődbe ment vállalat). Véleményem szerint a vizsgálat szempontjából az elemek száma nem elégséges egy logisztikus regresz-

³ Romániában a hivatalos mérlegadatokhoz való szabad hozzáférés csak a fontosabb mérleg és eredménykimutatás adataira vonatkozik. Valójában ezekből még likviditási mutató sem számolható, mivel a tartozásokat nem különítik el rövid és hosszú távú tartozásra.

szíóelemzés elvégzéséhez. A felhasznált pénzügyi mutatók esetében (összesen 14 változót használt) klasszifikációs módszerrel öt csoportot alakított ki. A találati arány 87,2%-os volt, és négy változó került be a végső modellbe. A szerzőnek sikerült igazolnia, még ha kismintás futtatással is, hogy a csődelőrejelző modellek függenek az adott országtól és annak gazdasági helyzetétől, ebből kifolyólag a nemzetközi modellek alkalmazása nem minden esetben megfelelő.

Slavici és társai (2015) egy optimalizált neurális hálózati modell segítségével vizsgálta a csőd valószínűségét 55 kelet-európai vállalat 1994–1998 közötti pénzügyi mutatóit felhasználva (49 vállalat adatai a tanulómintában, míg a többi 6 vállalat a tesztmintában szerepelt). A neurális hálózat felépítése a következő volt: a bemeneti réteg 18 pénzügyi mutatót tartalmazott. A próbafuttatások alkalmával tesztelésre került egy, két és három rejtett rétegű neurális háló. Tekintettel arra, hogy a minta kismintának is alig minősíthető, a modell becsült találati értéke elérte a 98%-ot. A szerzők szerint a legnagyobb találati értéket elérő modell felépítése három rejtett réteget tartalmazott.

Módszertan

A vállalati minta kialakításánál a romániai csődeljárást szabályozó alaptörvényt (a 2014. évi 85. törvényt) vettem alapul, amely 2014 júniusában lépett hatályba. Ennek értelmében egy vállalat akkor tekinthető fizetéképtelennek, ha a vagyoni helyzete nem teszi lehetővé az adósságai törlesztését. A vállalati mintában szereplő vállalatok esetében jogi úton elkezdték a végső felszámolási eljárást.

A tanulmányban alkalmazott modellek kiválasztásában feltétel volt, hogy alkalmazhatóak legyenek az SPSS segítségével. A kutatás során használt statisztikai módszerek a logisztikus regresszió és a neurális háló modellek voltak. Jelen tanulmányban a Hargita megyei adatmintából számított pénzügyi mutatók többváltozós statisztikai módszerrel kialakított modell segítségével csoportosítottam a nem csődös és a csődbe jutott vállalatokat. A nem csődös vállalatokat 0-val, a csődbe jutott vállalatokat 1-gyel jelöltem.

A logisztikus regresszió egy nem lineáris klasszifikációs eljárás, amely nem feltételezi a független változók folytonosságát és normalitását, ugyanakkor választ ad arra, hogy mitől és miképpen függ egy vállalati csőd bekövetkezése (Hajdu 2003).

A logisztikus regresszió az eredményváltozó két egymást kölcsönösen kizáró értékének bekövetkezési esélyeit modellezi több magyarázó változó segítségével.

Az y valószínűségi változó esetén jelölje $y = 1$ a csődbe ment vállalatot és $y = 0$ az egészséges vállalatot. Ekkor a csőd $P(y=1)$ valószínűségét több magyarázó változó (x_1, x_2, \dots, x_n) mellett az alábbi lineáris regressziós egyenlettel becsülhetnénk:

$$P(y=1) = \beta_0 + \beta_1 \cdot x_1 + \beta_2 \cdot x_2 + \dots + \beta_n \cdot x_n \quad (1)$$

A lineáris regresszióval becsült érték azonban nem esik minden esetben a $[0,1]$ intervallumba, mint a valószínűség értéke, hanem akár mekkora lehet, és ez gondot jelent. Olyan transzformációra van tehát szükségünk, amely egyértelmű megfeleltetést létesít a $[0, 1]$ és a $(-\infty, \infty)$ intervallumok között, ez a logit transzformáció:

$$\text{logit}(P) = \ln(P/(1 - P)) \quad (2)$$

Ha a csőd valószínűségét P -vel jelöltük, akkor a fizetőképessége $1 - P$, ezek arányának a becslésére (amely akár mekkora lehet) már jó a lineáris formula:

$$\frac{P(y=1)}{1-P(y=1)} = \beta_0 + \beta_1 \cdot x_1 + \beta_2 \cdot x_2 + \dots + \beta_n \cdot x_n \quad (3)$$

Az egyenletben a $P/(1 - P)$ hányadost esélynek nevezzük, s mint látható, az esély logaritmusa nem más, mint a logit, és az már becsülhető a magyarázó változók kombinációjával:

$$\ln\left(\frac{P(y=1)}{1-P(y=1)}\right) = \beta_0 + \beta_1 \cdot x_1 + \beta_2 \cdot x_2 + \dots + \beta_n \cdot x_n \quad (4)$$

A (4) egyenletet a logaritmus definícióját felhasználva az alábbi formában írhatjuk fel:

$$\frac{P(y=1)}{1-P(y=1)} = e^{\beta_0 + \beta_1 \cdot x_1 + \beta_2 \cdot x_2 + \dots + \beta_n \cdot x_n} \quad (5)$$

Ebben a formában a β_n koefficiens egységnyi változása e^{β_n} -szeres változást idéz elő az esélyben minden más változó változatlanlansága mellett. Az (5) egyenletből átrendezéssel meghatározható $y=1$ bekövetkezésének valószínűsége:

$$P(y=1) = \frac{e^{\beta_0 + \beta_1 \cdot x_1 + \beta_2 \cdot x_2 + \dots + \beta_n \cdot x_n}}{1 + e^{\beta_0 + \beta_1 \cdot x_1 + \beta_2 \cdot x_2 + \dots + \beta_n \cdot x_n}} \quad (6)$$

A neurális hálókat sikeresen alkalmazzák a vállalati, banki csőd és fizetéseképtelenség előrejelzésénél, alkalmazásuk jelentősen megnövekedett az 1990-es évektől kezdődően (Balcean–Ooghe 2004). A bemeneti rétegben található a vállalati pénzügyi mutatók és más változók, amelyek kapcsolatba hozhatók a fizetéseképtelenség, csőd bekövetkezésével (makrogazdasági és makropénzügyi mu-

tatók, egyéb nem pénzügyi mutatók). Kimeneti rétegeként csak egy réteg létezik, a vállalat fizetőképes vagy fizetéseképtelen csoportba való sorolása. A neurális háló erőssége, hogy mintákat ismer fel és ezeket képes csoportosítani, azonban egyik hiányossága, hogy az eredményváltozók nehezen értelmezhetők.

Az adatállomány két vállalati csoportból tevődik össze: csődbe jutott és nem csődös vállalatok. Hargita megyében a vizsgált időszakban (2008–2014) összesen 1472 fizetéseképtelen vállalat volt. A kutatásom során ebből az 1472 vállalatból 588 (39,95%) vállalatot csődbe jutottnak azonosítottam a cégbírósági bejegyzések alapján. Ugyanakkor a vállalatok kiválasztásánál figyelembe vettem azt is, hogy a csődbe jutásuk évét megelőző két évben rendelkezzenek teljes pénzügyi jelentéssel (mérleggel és eredménykimutatással).⁴ Ezt követően kizártam azon társaságokat, amelyek a csődöt megelőző két évben 0 árbevétellel vagy 0 eszközértékkel rendelkeztek. A vizsgálat a már működő vállalatokra terjedt ki, a három évnél fiatalabb vállalatok esetében más tényezők nagyobb hatással lehetnek a csőd bekövetkezésének valószínűségére. Elméleti modellek esetében (Jovanovic 1982; Pakes–Ericsson 1998) az újonnan belépő vállalatok részben ismerik a piaci környezetet, azonban képességeiket, hatékonyságukat csak a működésük során ismerik meg behatóbban. Véleményem szerint az első évek a tanulás időszaka, ami alatt vagy fejlődni tudnak, vagy megbuknak, ebben az esetben a fizetéseképtelenség, a csőd kialakulásának okai között akár vezetői hibák vagy a piac helytelen megítélése is húzódhat.

Ezt követően kizártam azon vállalkozásokat is, amelyek mérlegfőösszeg-értéke a csődeljárást megelőző évben nem érte el a 100 ezer eurót, tekintettel arra, hogy ezt az értékhatárt tartottam alkalmasnak a nem aktív vállalatok kiszűrésére.

A végső adatállomány 1075 vállalatot tartalmazott (1. táblázat).

1. táblázat. A minta összetétele

Kategória	darab	%-ban
Nem csődös vállalatok száma	965	89,77%
Csődös vállalatok száma	110	10,23%
Teljes minta	1075	100,00%

Forrás: saját kutatás

A tanulmány során 40 pénzügyi mutatót használtam, ezen változókat a 2008–2014-es időszak pénzügyi jelentéseiből határoztam meg (lásd a mellékletet).

⁴ Országos szinten a pénzügyi fegyelem hasonló a megyei adatokhoz (COFACE 2015): 2010-ben a fizetéseképtelen társaságok 40,21%-a tett le teljes pénzügyi jelentést, 2014-ben ez az érték 49,46% volt.

Egyes mutatók esetében több számítási módszert is alkalmaztam, például a ROA esetében több változatot is teszteltem: EBIT, EBITD, adóval és kamatköltséggel korrigált eredmény.

A pénzügyi mutatókat Brealey és társai (2011) öt fő csoportba sorolják. Az általam használt felosztásban (jövedelmezőségi, likviditási, cash-flow és tőkeátvételi mutatók) nem szerepel a piaci mutatók csoportja, tekintettel arra, hogy a tanulmány adatmintáját a tőzsdén nem jegyzett vállalatok képezték.

A kiválasztott mutatók esetében figyelembe vettem a témában született kutatások eredményeit (Belovary et al. 2007). Az adatmintát tisztítani kellett a kiugró értékek miatt, mivel torzítják a modell eredményességét. A szakirodalomban javasolt szélsőérték-csonkolást alkalmaztam (felső és alsó 5-5%-os csonkolással). A csődbe jutott vállalati csoport esetében a kiugró értékek főleg az értékek alsó tartományát érintették, míg a nem csődös vállalatok esetében ez fordítva volt. A kutatásban azokat a pénzügyi mutatókat hagytam meg, amelyek átlagértékei a két csoport (nem csődös és csődbe jutott vállalatok) esetében lényeges eltérést mutattak. Azt is figyelembe vettem, hogy a változók szórása kellőképpen nagy legyen, így az adott mutató segítségével a két csoport jobban elkülöníthető.

Az eredményváltozó bináris, 0-val a nem csődös vállalatokat jelöltem, 1-gyel a csődbe jutott társaságokat.

A logisztikus regresszió esetében a változók kiválasztása lépésenként történt (stepwise eljárás), figyelembe véve a kiválasztás irányát. A backward módszer lényege, hogy a kiválasztott változók sokaságából indul ki, és egyenkénti kiléptetéssel csökkenti a modellben lévő változók számát. Minden lépésben újraszámolja a regressziós együtthatókat, így határozva meg az optimális független változókból álló modellt. A forward módszer a modell felépítését a konstanssal indítja, majd egyenként viszi be a változókat, és az optimális független változókból álló modellt tartja meg. Az enter módszer a megadott változókat egyszerre szerepelteti a modellben (Kovács 2011). A modell beléptetési kritériumai 5%, a kiléptetési kritérium 10% valószínűségi érték mellett került meghatározásra. A teljes mintát 70%-ban tanulási és 30%-ban tesztelőmintára osztottam. Fontos, hogy a tanulási minta esetében ahhoz, hogy többváltozós statisztikai elemzést alkalmazzunk, a csődös csoport 50 megfigyelésnél többet kell tartalmazzon (Engelman et al. 2003), jelen esetben ez a feltétel teljesült. A választóvonal értéke (cut value) 0,5, azonban ezt a modell találati értékének maximalizálása érdekében folyamatosan teszteltem, változtattam. A csőd kutatás során az a fontos, hogy a találati érték a

legnagyobb legyen, figyelembe véve az első- és másodfajú hibákat is (Ooghe-Spaenjers 2010).

A neurális háló modellek esetében a felosztás teljes mértékben megegyezett a logisztikus regresszió esetében alkalmazottal, hogy a találati értékek összehasonlíthatók legyenek. A próbaftuttatások során a háló tervezésénél egy és két köztes réteget is figyelembe vettem eltérő neuronszámmal, végül a legnagyobb találati értékkel rendelkező modellt került kiválasztásra. A köztes rétegek és a kimeneti réteg neuronjainak aktiválási függvénye szigmoid formájú volt. A tanítás kötegelt tanítással történt.⁵

A csőd és fizetéképtelenség modellek értékeléséhez gyakran alkalmazott módszer a klasszifikációs táblázat, illetve a ROC-görbe alatti érték (Kovács 2011). A klasszifikációs táblázat a becsült és megfigyelt állapotot veti össze, így lehetőség van az első- és másodfajú hiba meghatározására is. A ROC-görbe a modell megkülönböztető képességének grafikus megjelenítése, és azt mutatja meg, hogy a kapott valószínűségi érték mennyire jelzi pontosan a vállalat két ismert csoportba való tartozását. Egy modell pontossága a görbe alatti terület nagyságával mérhető (AUROC – area under ROC). Az ideális modell AUROC-értéke 100%; az a jó, ha a modell ROC-görbéje minél távolabb helyezkedik el a referenciaegyenestől, azaz minél nagyobb legyen a ROC-görbe alatti terület nagysága, közelítsen a 100%-hoz.

Egy másik, gyakorlatban alkalmazott mérőszám a találati érték pontosságának megítélésében a Gini-koefficiens, amely az AUROC értékéből könnyen kiszámítható (Imreh 2008):

$$\text{GINI}=2 \cdot \text{AUROC}-1 \quad (7)$$

A koefficiens 0 és 1 közötti értéket vehet fel. Az ideális helyzet az, amikor a koefficiens értéke 1, vagyis a modell megkülönböztető ereje tökéletes.

Eredmények

Főbb pénzügyi mutatók alakulása

A tesztelések elvégzése előtt megvizsgáltam a főbb pénzügyi mutatók mentén a két vállalati csoportot, tekintettel arra, hogy egy alaphelyzethez képest a csőd jelei már egy évvel a bekövetkezést megelőzően megmutatkoznak.

A vállalatok esetében gyakran felhozott vizsgálati terület a fizetéképtelen-

⁵ A kötegelt tanítás azt jelenti, hogy a súlyok korrekcióját csak a teljes lefutás után korrigáljuk.

ség vagy csőd modellezésénél a vállalat mérete. A vállalati méret két mutatóval érzékelhető a legjobban: az árbevétel nagysága és a vállalat mérlegfőösszege. A mérlegfőösszeg értékeit vizsgálva a két minta esetében megfigyelhető, hogy a csődbe jutott vállalatok mérlegfőösszege két évvel a csődöt megelőzően átlagban 7,54%-ban növekedett, míg a nem csődös vállalatok esetében az átlagos változás ennél jóval magasabb volt (65%). A mintában szereplő vállalatok mérlegfőösszegeinek értékeit a 2. táblázat tartalmazza.

2. táblázat. A mintában szereplő vállalatok mérlegfőösszegeinek értékei

Kategória	Elemzszám	Átlag (lej)	Medián (lej)	Minimum (lej)	Maximum (lej)
Nem csődös	965	3 121 704,59	1 232 287	451 584	78 643 221
Csődös	110	4 027 809,55	1 418 914	460 153	49 748 422
Teljes minta	1075	3 214 422,30	1 241 056	451 584	78 643 221

Forrás: saját kutatás

Ahogy várható volt, a fizetésektelen csoport esetében a mérlegfőösszeg csökkenése gyakoribb (50,9%), mint a fizetőképes vállalatok esetében (24,5%), de nem jelenthető ki egyértelműen, hogy a fizetésektelen vállalatok mérlegfőösszege csökkent a pénzügyi nehézséget megelőző időszakban (3. táblázat).

3. táblázat. A mérlegfőösszeg alapadatai a két minta esetében

Vállalati csoport	Mérlegfőösszeg n-2 év (lej, átlagérték)	Mérlegfőösszeg n-1 év (lej, átlagérték)	Változás (%, átlagérték)	Csökkenő/növekvő (% a teljes csoportból az n-1 évben)
Csődös	4 065 414	4 027 810	7,54%	50,90%
Nem csődös	2 827 227	3 121 705	65,00%	24,50%

Forrás: saját kutatás

A vállalati tevékenység alapvető mutatója a teljes nettó árbevétel. Egy vállalat kiadásait az árbevételből, vagy hitel esetében ennek terhére tudja fedezni. A csődbe jutott csoport esetében az árbevétel alakulása átlagban 6,3%-kal csökkent, ezzel szemben a nem csődös vállalatok árbevétele átlag 114%-kal növekedett (4. táblázat).

A csődbe jutott vállalatok 70,9%-ának csökkent az árbevétele a csődöt megelőző időszakban, míg a nem csődös vállalatoknak csupán 25,9%-ában csökkent az árbevétel. Az adatokat vizsgálva elmondható, hogy a csődbe jutott vállalatok rossz pénzügyi helyzetéhez az árbevétel negatív alakulása jelentősen hozzájárult.

4. táblázat. Az árbevétel alapadatai a két minta esetében

Vállalati csoport	Árbevétel n–2 év (lej, átlagérték)	Árbevétel n–1 év (lej, átlagérték)	Változás (%, átlagérték)	Csökkenő/növekvő (% a teljes csoportból az n–1 évben)
Csődös	4 072 474	3 314 114	-6,30%	70,90%
Nem csődös	3 605 199	4 073 272	114,00%	25,90%

Forrás: saját kutatás

A továbbiakban kérdésként merül fel, hogy hány százalékot tett ki a teljes árbevételből a vevői követelések aránya a két vállalati minta esetében. Ebből az értékből jól látható, hogy az eladott áru vagy szolgáltatás esetében a vállalatoknak mennyit sikerült behajtani, illetve a be nem hajtott vevői követelés lehet-e magyarázó változó ebben az esetben. Az adatokat vizsgálva megállapítható, hogy a csődöt megelőző második évben az átlagos vevői követelés aránya az árbevételből 47,37% volt, míg az egészséges vállalatok esetében a vevői követelés 21,59%-ot tett ki a teljes árbevételből. A helyzet a csődbe jutott vállalatok esetében egy évvel a csődöt megelőzően romlott (az arány 62,22%-ra emelkedett), míg az egészséges vállalatok esetében ez előző időszakhoz képest 1,38 százalékpontot csökkent, 20,21%-ra.

Ezzel párhuzamosan érdemes megvizsgálni a két csoport esetében a pénzállomány fedezeti értékét. Ezt a mutatót az esedékes költségek bevételezett jövedelemmel való fedezeteként kell érteni, a kiszámolt változó segítségével megtudjuk, hogy az átlagos bevétel mennyiben fedi az átlagos kiadásokat. Minél kisebb ez a mutató, annál nagyobb a likviditási gond egy vállalatnál. Amennyiben az érték egység alatti, akkor szükséges a növekvő működő tőke finanszírozása. A minta esetében a csődbe jutott vállalati csoport átlagértéke 0,85 volt, míg az egészséges vállalatok esetében 1,06. A mutató értelmezésénél érdemes a nettó eredményt is bevonnunk az elemzésbe. Amennyiben az eredmény pozitív és a pénzállomány fedezeti értéke egység alatti, akkor a vállalatról megállapítható, hogy az éves eredménye nem materializálódott. A csődbe jutott 110 vállalatból 75 esetben a mutató egységnyi fölötti volt, ebből a 75 vállalatból 30 vállalatnál volt az éves nettó eredmény pozitív (a minta 27,27%-a), ezen vállalatok esetében az eredmény nem alakult át pénzzé.

A likviditási rátát vizsgálva megállapítható, hogy mindkét vállalati csoport esetében a mutató normális értéket vett fel két évvel az eseményt megelőzően (5. táblázat). Az egészséges vállalatok esetében az érték túl magas volt (3,29). Megvizsgálva a követelések arányát a forgóeszközökben, elmondható, hogy a

nem csődös vállalatok esetében a működőtőke-gazdálkodás nem tekinthető feltétlenül jónak a magas értékeivel, mivel jelentős összeg szerepel vevői követelésként. A likviditási mutatókat és a vevői követelés arányát a forgóeszközökben vizsgálva megállapítható, hogy ez a pénzügyi mutatócsoport nem bír magyarázó erővel a csődbe jutás előrejelzését tekintve.

5. táblázat. Likviditási mutatók átlagértékei

	Likviditási ráta		Likviditási gyorsráta		Pénzhányad		Vevői követelés / Forgóeszközök	
	n-2	n-1	n-2	n-1	n-2	n-1	n-2	n-1
Csődös	1,41	1,07	0,84	0,67	0,14	0,10	44,76%	47,06%
Nem csődös	3,29	2,72	2,06	1,79	1,05	0,71	44,06%	47,82%

Forrás: saját számítások

A csődbe jutott vállalatok likviditási rátája csökkent a csődöt megelőző évben (1,41-es értékről 1,07-re), érezhető volt számukra, hogy nehézségekkel küszködnek, a likviditási gyorsráta már az alsó határt súrolta.⁶

Egy másik nagyon fontos mutatószám-csoport a fizetéseképtelenség, illetve csődelőrejelzés esetében az adóssági mutatók. A megyei adatokat vizsgálva megállapítható, hogy az országos értékekhez képest a megyei vállalati szféra kevésbé finanszírozza tevékenységét közép- és hosszú távú hitelekkel. Az adatok egyváltozós vizsgálata során érzékelhető volt ez a tény, hisz számos vállalat mérlegében a hosszú távú tartozások értéke alacsony volt. Megvizsgálva a Román Nemzeti Bank adatait (BNR 2016), ez megerősítést nyert. Az országos vállalati hitelállomány nagyságában a Hargita megyei vállalati szektor elhanyagolható részt képvisel és a 2008-as időszakot követően folyamatosan csökkent: a megyében a csökkenés átlag 4,17% volt a 2009–2015 közötti időszakban, míg az országos érték ugyanebben az időszakban ingadozott (az ingadozás átlaga 1,93%). Ennek eredményeként a vállalati hitelállomány aránya az országosból 0,80%-ról 0,56%-ra csökkent 2009–2015 között. Az okok között a vállalkozások vezetőinek kockázatkerülő magatartása húzódnak meg a gazdasági válságot követően, hiszen a devizahitelek aránya 2009–2015 között lényegesen alacsonyabb, mint az országos értékek, ugyanakkor felmerül a fedezet hiánya és a gyenge tőkeerő, ami pótlólagos kockázati felárat jelent a vállalati hitelkamatláb esetében.

⁶ Borszéki (2000) szerint a likviditási gyorsráta értéke 1 és 0,8 között jónak minősíthető.

A logisztikus regresszióval előállított modell eredményei

Az elsődleges tesztelések során a modellek pontossága 58,2% és 75,8% között mozgott a csődbe jutott vállalatok találati aránya esetében.

A továbbiakban a végső logisztikus regresszióval kialakított modellt és annak jellemzőit ismertetem. Meg kell jegyezni, hogy a futtatások során az árbevétel növekedése a különböző modellek változói között többször is szerepelt. A próbafuttatások során a ROA-mutatók közül végül az a verzió volt jobb, amelyik esetében az eredményt korrigáltam az adó és adómegtakarítás mértékével. Azon modellek, amelyben a ROA-változó korrigált formáit alkalmaztam, a találati arány a tesztmintánál a nem csődös vállalati csoport esetében 63%-66,7% között mozgott. Az EBITDA értékével számolt ROA találati értéke 66,7%-os volt. Ezek alapján megállapítható, hogy eltérő tőkeszerkezetű vállalatok statisztikai modellezésénél a ROA-mutató esetében a vállalat eredményét érdemes korrigálni, mivel így a találati arány javítható.

A próbafuttatások során a modell változói között többször is megjelent az Altman-modellben is alkalmazott nettó árbevétel/mérlegfőösszeg vagy nettó árbevétel/átlagolt mérlegfőösszeg, azonban ennek a mutatónak az előjele ellentétes volt a várt előjellel. Az ellentétes előjel csak akkor nyert volna értelmet, amennyiben a vállalati árbevétel jelentős része követelésként szerepel a csődbe jutott vállalati mintában, ugyanis ebben az esetben a vállalatok nem termelnek elég pénzt az árbevételből, így fizetési problémák merülnek fel a tevékenységük során. A teljes minta vizsgálata során ez a feltételezés megerősítést nyert, mivel a csődös csoport esetében a változó átlagértéke 0,66 volt, míg a nem csődös vállalatok esetében ez az érték 0,18. A végső modellbe a követelés aránya az árbevételből változó mégsem került be, mivel a találati arány a csőbe jutott vállalatok esetében alacsonyabb volt, mint a végső modellé (a tesztelő minta találati értéke rosszabb volt, mint a végső modellé).

A végső logisztikus regressziós modellbe öt változó került be, ezek közül az adómegtakarítással korrigált vagyonarányos EBIT bizonyult a legnagyobb hatásúnak a vállalati csődre. Bellovary és társai (2007) szerint a ROA-mutató a leggyakoribb magyarázó változó a csőd és fizetésképtelenség előrejelzésében. A cash flow aránya az árbevételből mutató is jelentős mértékben magyarázta a vállalati csőd bekövetkezését: míg a csődbe jutott társaságok esetében a cash flow negatív értéket vett fel a csődbe jutást megelőző évben, addig az egészséges vállalatok esetében a cash flow pozitív volt és az árbevételből átlagosan 10% feletti arányt képviselt. Ez az elmélettel is megegyezik, mivel az a

vállalat, amelyik negatív cash flow-val rendelkezik, fizetési gondokkal küzd. A végső csődelőrejelző modellben eladósodottsági mutató is szerepelt, az összes tartozás aránya a nettó árbevételből magyarázó változónak bizonyult. A csődbe ment csoport esetében a tartozások értéke 2,5-szöröse volt az árbevételnek, míg az egészséges vállalatok esetében a tartozások összes értéke nem érte el az árbevétel felét sem.

A modell magyarázó erejét meghatározó tesztstatisztikák alapján megállapítható, hogy a modell illeszkedése jó (6. táblázat). A Nagelkerke R^2 értéke szerint az öt pénzügyi mutató 68,3%-ban magyarázza a fizetési képzetlenséget.

6. táblázat. A logit modell illeszkedése (Cox-Snell R^2 , Nagelkerke R^2)

lépés	- 2 Log likelihood	Cox-Snell R^2	Nagelkerke R^2
1	195,822	0,328	0,683

Forrás: saját kutatás, SPSS programmal végzett számítások

A Hosmer–Lemeshow-teszt szerint a modell jól illeszkedik (7. táblázat). Az eloszlás szignifikanciaszintje alapján a H_0 hipotézist nem utasíthatjuk el, mivel a megfigyelt és a modell által becsült értékek között nincs különbség.

7. táblázat. A logit modell illeszkedése (Hosmer–Lemeshow-teszt)

lépés	Chi-square	szabadságfok	szignifikancia
1	5,950	8	0,653

Forrás: saját kutatás, SPSS programmal végzett számítások

A klasszifikációs táblázatot vizsgálva (8. táblázat) elmondható, hogy a modell találati aránya a tanulási minta esetében 95,0%, a tesztelőminta esetében 96,5% volt 0,5-ös választóvonal (cut value) esetében.

8. táblázat. A logit modell klasszifikációs táblája

Cut value = 0,5		Előre jelzett					
		Tanulóminta			Tesztelőminta		
		nem csődös	csődös	találati arány %	nem csődös	csődös	találati arány %
Megfigyelt	nem csődös	681	6	99,10	275	3	98,90
	csődös	32	45	58,40	8	25	75,80
Teljes minta				95,00			96,50

Forrás: saját kutatás, SPSS programmal végzett számítások

A választóvonal értékének változtatásával a modell találati aránya maximalizálható. A gyakorlatban felmerül az a kérdés, hogy mit maximalizáljunk. Egy hitelintézet részére az első- és másodfajú hiba is költséggel jár. Az elsőfajú hiba figyelmen kívül hagyása a pénzének elvesztéséhez vezet, míg a másodfajú hiba esetében olyan ügyfeleket utasít vissza, akik képesek visszafizetni a kölcsönt. A jelen tanulmányban a cut value értékének megválasztásában a találati értéket vettem figyelembe, vagyis azt, hogy a modellnek minél nagyobb találati értéke legyen. Jelen esetben a 0,5-ös és 0,45-ös érték volt az, amelynél a modell találati értéke maximális volt (9. táblázat). A két választóérték közötti egyetlen különbség a tanulóminta esetében volt tapasztalható a csődbe jutott találati aránynál, ahol az eltérés 3,9 százalékpont volt. A többi választóvonal-értékre a modell teljes találati aránya romlott.

9. táblázat. A cut value különböző értékei és a találati arány

Cut value	Tanulóminta			Tesztelőminta		
	Nem csődös	Csődös	Teljes	Nem csődös	Csődös	Teljes
0,55	99,30%	58,40%	95,20%	98,90%	72,70%	96,10%
0,50	99,10%	58,40%	95,00%	98,90%	75,80%	96,50%
0,45	98,80%	62,30%	95,20%	98,90%	75,80%	96,50%
0,40	98,40%	62,30%	94,80%	98,60%	75,80%	96,10%
0,35	98,00%	66,20%	94,20%	97,80%	75,80%	95,50%

Forrás: saját kutatás, SPSS programmal végzett számítások

A logisztikus regresszió esetében a változók együtthatója egyben a változó hatásának a súlyát is tükrözi. A végső logisztikus regressziós modellben az első változó (x1) az adó és adómegettarítással korrigált EBIT-tel számolt ROA-mutató volt. A ROA-mutató növekedésével csökken a csődbe jutás esélye. A második változó (x2) az árbevétel alapú pénzáramlás. Az árbevétel egységnyi növekedése 0,302-szeresével csökkenti a fizetéseképtelenség kialakulásának esélyét (x3), míg a modell többi változójának növekedése, a kereskedelmi tartozás forgási ideje (x4) és a tartozás aránya az árbevételből (x5) növeli a csődbe jutás esélyét (10. táblázat).

A logisztikus regresszió futtatása során érdekes módon a likviditási mutatók nem bizonyultak jónak, azaz a változók a modellben csak 10%-nál nagyobb szignifikanciaszint mellett voltak elfogadhatók. Ugyanakkor az eladósodottsági mutatók esetében azon mutatók, amelyek külön kezelték a rövid és hosszú távú kötelezettségeket, nem bírtak elégséges magyarázó erővel. A legjobb adósságot tükröző mutatónak az árbevételben kifejezett összes kötelezettség aránya bizonyult.

10. táblázat. A logisztikus regressziós modell paraméterei

Változók	Beta regressziós együttható	Standard hiba	Wald	Sig.	Exp(B)
x1	-21,134	6,717	9,899	0,002	0,000
x2	-15,835	4,365	13,158	0,000	0,000
x3	-1,197	0,421	8,099	0,004	0,302
x4	0,002	0,001	8,977	0,003	1,002
x5	1,880	0,423	19,799	0,000	6,556
konstans	-1,946	0,445	19,149	0,000	0,143

Forrás: saját kutatás, SPSS programmal végzett számítások

A modell végső egyenlete:

$$P(\text{csőd}) = \frac{e^{-1,946 - 21,134 \cdot x_1 - 15,835 \cdot x_2 - 1,197 \cdot x_3 + 0,002 \cdot x_4 + 1,880 \cdot x_5}}{1 + e^{-1,946 - 21,134 \cdot x_1 - 15,835 \cdot x_2 - 1,197 \cdot x_3 + 0,002 \cdot x_4 + 1,880 \cdot x_5}} \quad (8)$$

A 11. táblázatban a csődbe jutott és egészséges vállalati csoportok végső modelljében szereplő pénzügyi mutatók átlagértékei láthatók. Az eszközarányos adómegettarítással korrigált EBIT értékeit vizsgálva láthatjuk, hogy a csődbe jutott vállalatok esetében a negatív EBIT volt a jellemző a csődöt megelőző évben. Az egészséges vállalati csoport esetében az átlagérték jelentős (közel 12%), ami azt mutatja, hogy Hargita megyében a vállalatok eszközeiket nyereségesen tudták működtetni és közel 12%-os vagyonarányos EBIT-et értek el. A kereskedelmi tartozások forgási idejét vizsgálva az egészséges vállalatok esetében a 164 napos érték magasnak minősíthető, még abban az esetben is, ha a számla kiállítását követően általánosan elfogadott szabály, hogy 15-30 napos türelmi időszakot is megadnak az ügyfeleknek. A csődbe jutott vállalatokat vizsgálva az is megfogalmazható, hogy többségében a tartozások kifizetésének ideje miatt indult el a csőd-eljárás. Ehhez társult a felhalmozott kötelezettségek értéke is, hiszen a csődbe ment társaságok esetében jelentős a tartozás aránya az árbevételből, a vállalatok a csődöt megelőző évben nem tudtak annyi árbevételt előteremteni, amivel tartozásaikat fedezni tudják. Tudva azt, hogy a csődbe jutott vállalatok esetében az összes tartozásban jelentős a rövid távú kötelezettségek aránya, megfogalmazható az is, hogy a Hargita megyei KKV-k megpróbálják a működőtőke-finanszírozást áthárítani a beszállítóikra. Ez a KKV-k esetében egy gyakori megoldás, ami azonban veszélyekkel jár. A követelések, illetve tartozások forgási ideje és az ezekre való hatás jelentősen befolyásolja a vállalat működőtőke-szintjét, működő-

tőke-költségét, ugyanakkor hatással van a kereskedelmi ügyfelek megtartására is. Például ha egy vállalat túl szigorú (rövid) követelési időt határoz meg, az hatással lehet az ügyfeleire, mivel ezek érdeke, hogy minél később fizessenek. Hasonló megállapítást fogalmaztak meg Altman és társai (2010) is.

11. táblázat. A logisztikus regressziós modellben szereplő változók átlagértékei

Változó	Átlagos értékek	Csődös	Nem csődös
x1	ROA – %	-4,78%	11,73%
x2	CF/Nettó Árbevétel – %	-3,84%	11,93%
x3	Árbevétel növekedése – %	-13,62%	50%
x4	Kereskedelmi tartozások forgási ideje – nap	744,80	164,09
x5	Tartozás/Árbevétel	2,61	0,47

Forrás: saját kutatás, SPSS programmal végzett számítások

A csődbe jutott vállalatokat az árbevétel csökkenése jellemezte, ugyanakkor az összes tartozás aránya jelentősen meghaladta az árbevétel szintjét, amiből arra is lehet következtetni, hogy a csődbe jutott társaságok nem termeltek elég árbevételt ahhoz, hogy tartozásaikat ki tudják egyenlíteni, ugyanakkor az árbevétel döntő része követelésként az ügyfeleknél maradt. Erre a modellezés során derült fény, amikor a futtatások során a nettó árbevétel aránya a mérlegfőösszegben (az Altman-modellben is használt mutató) a várakozásokhoz képest ellentétes előjelet (negatív értéket) vett fel. Ezt a megállapítást az is alátámasztja, hogy a csődbe jutott csoport esetében a követelések aránya az árbevételben átlagosan 0,66 volt, míg a fizetőképes vállalatok esetében 0,18, vagyis a fizetésektelen csoportban lévő vállalatok esetében az árbevétel jelentős hányada az ügyfeleknél volt.

A neurális hálóval előállított modellek eredményei

A neuronhálóval készített végső modell kialakítása hosszabb időbe telt, mint a logisztikus regresszióé, csak többszöri futtatás után sikerült a végső modellt kialakítani. A cél többek között az volt, hogy bizonyosságot szerezzek arra a megállapításra, amelyet a szakirodalom is állít, miszerint a neuronhálók becslése jobb találati arányt ér el a többváltozós statisztikai elemzésekkel szemben.

Az adatállomány ebben az esetben is felosztásra került 70%-ban tanuló- és 30%-ban tesztelőmintára. A felosztás teljes mértékben megegyezett a logisztikus regresszió esetében alkalmazottal. A próbafuttatások során a háló tervezésénél

egy és két köztes réteget is figyelembe vettem eltérő neuronszámmal, a legjobb modellnek a két köztes rétegből álló háló bizonyult. A végső modell felépítése a következő volt: bemeneti réteg 38 vállalati mutató, a két köztes réteg rendre hét, illetve öt neuront tartalmazott, a végső kimeneti réteg két neuronból állt.

A 12. táblázat azon neuronháló-felépítéseket tartalmazza, amelyek a tesztelés során találati arány szempontjából jónak bizonyultak. A bemeneti pénzügyi mutató esetében a ROA-mutató több változatát külön teszteltem, ezért szerepel a végső modell esetében bemeneti értéként a 20 neuron száma.

12. táblázat. A neuronhálók felépítése és a találati arány

Neuronháló felépítése	Tanulóminta			Tesztelóminta		
	nem csődös	csődös	teljes	nem csődös	csődös	teljes
20-3-2	99,70%	70,10%	96,70%	99,60%	72,70%	96,80%
20-5-2	99,40%	72,70%	96,70%	98,20%	72,70%	95,50%
20-7-2	99,40%	63,60%	95,80%	99,60%	72,70%	96,80%
20-5-3-2	99,90%	67,50%	96,60%	99,60%	66,70%	96,10%
20-7-5-2	99,60%	63,60%	95,90%	99,60%	75,80%	97,10%

Forrás: saját kutatás, SPSS programmal végzett számítások

A futtatások során a neurális hálómódellek döntő többségében a fizetésképtelenség elmélete által meghatározott mutatók jöttek ki, mint legnagyobb fontossággal bíró változók. A legnagyobb fontossággal bíró változó minden esetben a teljes tartozás aránya az árbevételből pénzügyi mutató volt. A változó, függetlenül a háló felépítésétől, minden esetben ezt hozta ki a legrelevánsabbnak. A rétegek közötti aktiválási függvényben kapott együttható előjele is megfelelő volt, a pozitív érték növelte a megfigyelés fizetésképtelenségbe való besorolását. Az egyrétegű modellekben a cash flow/árbevétel mutató is gyakran szerepelt.

13. táblázat. A végső neuronmodell változóinak fontossága a modellben

Független változó	Relatív fontosság
Tartozás/Árbevétel	1,00
Kereskedelmi tartozások forgása	0,83
Cash flow/Mérlegfőösszeg	0,65
Követelések forgása	0,61
ROA-korrigált	0,61
Készletek forgása	0,52

Forrás: saját kutatás, SPSS programmal végzett számítások

A modellek futtatása során az árbevétel növekedésének relatív fontossága 0,1 alatti volt, ugyanakkor likviditási mutatók sem kerültek be azon modellekbe, ahol a találati arány elég magas lett volna. A mérlegfőösszeg és az árbevétel nagysága változók relatív fontossága elhanyagolható volt a neurális hálómodellek esetében.

A logisztikus regresszió modell és a neurális hálómodell találati értékeinek összehasonlítása

A végső modellek eredményeit a 14. táblázat tartalmazza. Az összehasonlítás érdekében a ROC-érték és a Gini-koefficiens értékei is szerepelnek a táblázatban, továbbá a modellekhez tartozó I. és II. fajú hiba találati értékei. A modellek esetében a választóvonal (cut value) a 0,5-ös érték volt.

14. táblázat. A végső modellek találati értékei

	Logisztikus regressziómodell		Neurális hálómodell	
	tanulóminta	tesztelőminta	tanulóminta	tesztelőminta
Teljes minta	95,00%	96,50%	95,90%	97,10%
ROC értéke	0,954		0,964	
Gini-koefficiens	0,908		0,928	
I. fajú hiba	41,60%	24,20%	36,40%	24,20%
II. fajú hiba	0,90%	1,10%	0,40%	0,40%

Forrás: saját kutatás, SPSS programmal végzett számítások

A táblázat eredményeit vizsgálva megállapítható, hogy a neurális hálómodell találati értéke magasabb, ezt a ROC és Gini-koefficiens értékei is alátámasztják. A két modell találati értékeit vizsgálva a nem csődös vállalatok helyes besorolásánál észlelhető eltérés, míg a csődös vállalatok besorolásának találati értéke azonos.

Következtetések

A vállalati csőd és fizetésképtelenség modellezése egyre fontosabbá válik a hitelezőknek, a gazdasági döntéshozóknak és a kereskedelmi partnereknek. A vállalati fizetésképtelenség Közép-Kelet-Európában még mindig kevésbé kutatott, Romániában ez a terület az adatok hiánya miatt kiegészítésre szorul. A csőd kutatás jelentős része a nagyvállalati minták tesztelésével foglalkozik, míg a kis- és közepes vállalatok csödbe jutásának és fizetésképtelenségének tanulmányozása háttérbe szorul.

A vállalati csőd és fizetéképtelenség kutatások jelentős része azzal foglalkozik, hogy melyek azok a pénzügyi mutatók, amelyek segítségével a lehető legnagyobb találati értékkel bíró modellek állíthatók elő (Altman–Hotchkiss 2006). A hazai kutatások közül Brindescu és Goleţ (2013) tanulmánya tekinthető nagymintás vizsgálatnak. Az általuk felhasznált Temes megyei adatállomány segítségével készült végső modell öt változót tartalmazott, ebből a vevőállomány forgása változó, a jelen kutatáshoz hasonlóan, szintén szerepelt a végső modellben. A szerzők kiemelik a kis- és közepes vállalatok esetében a működő tőke fontosságát a fizetéképtelenség előrejelzésében.

A jelen kutatás eredményeként megfogalmazható, hogy a Hargita megyei KKV-k csődelőrejelzésében a működő tőkéhez kapcsolható pénzügyi mutatóknak jelentős szerepük van. A csődös vállalatokat az árbevétel lassulása jellemezte a csődöt megelőző időszakban, míg az egészséges vállalatok esetében jelentős növekedés volt tapasztalható. Az árbevétel szempontjából ugyanakkor azt is fontos megvizsgálni, hogy mekkora arányban sikerül ezt pénzzé konvertálni. A vizsgált mintán az volt tapasztalható, hogy a jól teljesítő vállalati minta követeléseinek aránya a teljes árbevételből 21,59%-ot tett ki, míg a csődbe jutott társaságok esetében ez az érték 47,37% volt. A csődbe jutást megelőző évben az értékek romlottak a rosszul teljesítő vállalatok esetében (62,22%-ra nőtt a követelések aránya).

A csőd számos esetben a rossz pénzügyi döntések, illetve a túlzott eladósodottság miatt következik be, de a Hargita megyei vállalatokra ez nem volt jellemző: a megyében a vállalati hitelek aránya elhanyagolható, ami azt jelenti, hogy a vállalatok döntő többsége rövid távú finanszírozást alkalmaz. Sok vállalatnak nincs elég garanciája, eszköze a kölcsön fedezetére. A minta tőkeszerkezetét vizsgálva megállapítható, hogy a tartozásoknak közel háromnegyede mindkét vállalati csoportban rövid távú tartozás volt. Borszéki (2008) szerint a kereskedelmi hitel és más rövid lejáratú források magas aránya a vállalatok közötti tartozások növekedésének és a fizetőképesség romlásának a következménye, ez a Hargita megyei vállalatokra is igaz, különös tekintettel a csődbe ment társaságokra.

A csőd előrejelzésében nem tekinthetőek fontos változóknak a likviditási mutatók és a hosszú távú adósságot jellemző pénzügyi mutatók. A vállalat méretét jellemző mutatók nem voltak szignifikánsak a modellalkotás során, vagy relatív fontosságuk alacsony volt más pénzügyi mutatókhoz képest a neurális hálómodellek esetében, ami annak is tulajdonítható, hogy Hargita megye vállalati szektora méretét tekintve homogénnek tekinthető.

A logisztikus regresszió és neurális háló modellek találati eredményeit vizsgálva megállapítható, hogy a neurális hálómodell találati értéke magasabb, ezt a ROC és Gini-koefficiens értékei is alátámasztják. A két modell találati értékeit vizsgálva a nem csődös vállalatok helyes besorolásánál észlelhető eltérés, míg a csődös vállalatok besorolásának találati értéke azonos.

A jövőben fontosnak tartom olyan fizetésképtelenné vált vállalatok tanulmányozását, amelyek utólag sikeres átszervezésen estek át, és a fizetésképtelenségi eljárást követő harmadik évben is működőképesek. Ennek kapcsán több kutatandó kérdés vethető fel: milyen pénzügyi mutatók jellemzők a túlélő vállalatokra, milyen pénzügyi változások tapasztalhatók a sikeresen túlélő és végleg csődbe ment vállalatok között, illetve melyek lehetnek azon jellemzők, amelyek a csőd bekövetkezését felgyorsítják. Meggyőződésem, hogy a Hargita megyében tevékenykedő vállalatok esetében a döntéseket nem előre megtervezett stratégiák mentén hozzák, ugyanakkor hiányzik a pénzügyi tervezés. Felmerül a kérdés, hogy a pénzügyi tervezés hiánya vagy létezése (dummy változóként) mennyiben befolyásolja a csőd valószínűségének bekövetkezését?

Irodalomjegyzék

Altman, E. I. 1968. Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy. *Journal of Finance* 23(4), 589–606.

Altman, E. I.–Hotchkiss, E. 2006. *Corporate Financial Distress and Bankruptcy*. 3rd edition. Hoboken, NJ: Wiley.

Altman, E. I.–Sabato, G. 2005. Effects of the new Basel capital accord on bank capital requirements for SMEs. *Journal of Financial Services Research* 28(1–3), 15–42.

Altman, E. I.–Sabato, G.–Wilson, N. 2010. The value of non-financial information in SME risk management. *The Journal of Credit Risk* 6(2), 1–44.

Altman, E. I.–Marco, G.–Varetto, F. 1994. Corporate distress diagnosis: comparison using linear discriminant analysis and neural networks (the Italian experience). *Journal of Banking and Finance* 18, 505–529.

Balcean, S.–Ooghe, H. 2004. Alternative methodologies in studies of business failure: do they produce better results than the classic statistic methods? *Vlerick Leuven Ghent Working Paper Series* 2004(16), 1–40.

Bellovary, J.–Giacomino, D.–Akers, M. 2007. A review of bankruptcy prediction studies: 1930–present. *Journal of Finance Education* 33, 1–42.

Berger, A. N. 2006. Potential Competitive Effects of Basel II on banks in SME credit markets in the United States. *Journal of Financial Services Research* 29, 5–36.

Blum, M. 1974. Failing company discriminant analysis. *Journal of Accounting Research* 12(1), 1–25.

BNR 2016. <http://bnr.ro/Credite-si-depozite-in-profil-teritorial-3171.aspx>, letöltve: 2016.09.20.

Borszéki, É. 2000. *Pénzügytan I. Egyetemi jegyzet*. Gödöllő: Szent István Egyetem.

Borszéki, É. 2008. A jövedelmezőség és a tőkeszerkezet összefüggései a vállalkozásoknál. *Bulletin of the Szent István University* Special Issue II, 391–401.

Brealey, R. A.–Myers, S. C.–Allen, F. 2011. *Principles of corporate finance. 10th edition*. New York, NY: McGraw-Hill/Irvin.

Brîndescu, D.–Golet, I. 2013. Prediction of corporate bankruptcy in Romania through the use of logistic regression. *The Annals of the University of Oradea. Economic Sciences* XXII(July), 976–986.

Cimpoeru, S. 2014. Scoring functions and bankruptcy prediction models – case study for Romanian companies. *Procedia Economics and Finance* 10, 217–226.

Coats, P.–Fant, L. 1992. A neural network approach to forecasting financial distress. *The Journal of Business Forecasting Methods and Systems* 10(4), 9–12.

COFACE 2015. *Studiul insolvențelor semestrul I, 2015*. <http://www.coface.ro/Stiri-Publicatii/Publicatii/Studiul-Insolventelor-Semestrul-1-2015>, letöltve: 2016.09.20.

Constand, L. R.–Yazdipour, R. 2011. Firm failure prediction models: a critique and a review of recent developments. In: *Advances in Entrepreneurial Finance: With Applications from Behavioral Finance and Economics*. New York, NY: Springer, 185–204.

Deakin, E. B. 1972. A discriminant analysis of predictors of failure. *Journal of Accounting Research* 10(1), 167–179.

Dimitras, A. I.–Slowinski, R. S.–Zoupounidis, C. 1999. Business failure prediction using rough sets. *European Journal of Operation Research* 114(2), 263–280.

Engelman, B.–Hayden, E.–Tasche, D. 2003. *Measuring the discriminant power of rating systems. Discussion Paper Series no. 2*. Frankfurt: Banking and Financing Supervision, Deutsche Bundesbank.

Fitzpatrick, P. 1934. Transitional stages of business failure. *The Accounting Review* 9(4), 337–340.

Fulmer, J. G.–Moon, J.–Gavin, T.–Erwin, M. 1984. A bankruptcy classification model for small firms. *Journal of Commercial Bank Lending* 66(11), 25–37.

Golet, I. 2014. Symmetric and asymmetric binary choice models for corporate bankruptcy. *Procedia – Social and Behavioral Sciences* 124, 282–291.

Gupta, J.–Gregoriou, A.–Healy, J. 2014. Forecasting bankruptcy for SMEs using hazard function: To what extent does size matter? *Review of Quantitative Finance and Accountings* 45(4), 1–25.

Hajdu, O. 2003. *Többváltozós statisztikai számítások*. Budapest: KSH.

Imreh, B. 2008. *BÁZEL II. definíciókon alapuló nemfizetés-előrejelzési modellek Magyarországi vállalati mintán (2002–2006)*. PhD-tézis. Miskolc: Miskolci Egyetem.

Jovanovic, B. 1982. Selection and the evolution of industry. *Econometrica* 50(3), 649–670.

Karas, M.–Režňáková, M. 2013. Bankruptcy prediction model of industrial enterprises in the Czech Republic. *International Journal of Mathematical Models and Methods in Applied Sciences* 5(7), 519–531.

Kirkos, E. 2015. Assessing methodologies for intelligent bankruptcy prediction. *Artificial Intelligence Review* 43, 83–123.

Kolari, J. W.–Charles, O.–Shin, H. G. 2006. Assessing the profitability and riskiness of small businesses lenders in the banking industry. *Journal of Entrepreneurial Finance* 11(2), 1–26.

Kovács, E. 2011. *Pénzügyi adatok statisztikai elemzése*. Budapest: Tanszék Kft.

Lee, K. C.–Han, I.–Kwon, Y. 1996. Hybrid neural network models for bankruptcy predictions. *Decision Support Systems* 18(1), 63–72.

Lizal, L.–Schwarz, J. 2012. *Financial distress: Firms before and after the 2008 crisis*. http://www.finnov-fp7.eu/sites/default/files/FINNOV_DP4.5.pdf, letöltve: 2016.03.17.

Messier, J. R. W.–Hansen, J. 1988. Inducing rules for expert system development: An example using default and bankruptcy data. *Management Science* 34(12), 1403–1415.

Ohlson, J. 1980. Financial ratios and the probabilistic prediction of bankruptcy. *Journal of Accounting Research* 18(1), 109–131.

Ooghe, H.–Spaenjers, C. 2010. A note on performance measures for business failure prediction models. *Applied Economics Letters* 17, 67–70.

Pakes, A.–Ericsson, R. 1998. Empirical implications of alternative models of firm dynamics. *Journal of Economic Theory* 79(1), 1–45.

Perez, M. 2006. Artificial Neural Network and bankruptcy forecasting: a state of the art. *Neural Computing and Applications* 15(2), 154–163.

Raghupathi, W.–Schakade, L.–Raju, B. 1993. A neural network approach to bankruptcy prediction. In: Trippi, R.–Turban, E. (eds.) *Neural Network in Finance and Investing*. Chicago, IL: Probus Publishing Co.

Ravi, K. P.–Ravi, V. 2007. Bankruptcy prediction in firms and banks via statistical and intelligent techniques – a review. *European Journal of Operation Research* 180, 1–28.

Slavici, T.–Maris, S.–Pirtea, M. 2015. Usage of artificial neural networks for optimal bankruptcy forecasting. Case study: European small manufacturing enterprises. *Quality and Quantity* 50(1), 385–398.

Smith, R.–Winakor, A. 1935. Changes in financial structure of Unsuccessful Industrial Corporations. *Bureau of Business Research Bulletin* 51.

Vareto, F. 1998. Genetic algorithms applications in the analysis of insolvency risk. *Journal of Banking and Finance* 22, 1421–1439.

Verikas, A.–Kalsyte, Z.–Bacauskiene, M.–Gelzinis, A. 2010. Hybrid and ensemble-based soft computing techniques in bankruptcy prediction: a survey. *Soft Computing* 14, 995–1010.

Virág, M.–Kristóf, T. 2005. Az első hazai csődmodell újraszámítása neurális hálók segítségével. *Közgazdasági Szemle* 52, 144–162.

Xu, M.–Zhang, C. 2009. Bankruptcy prediction: the case of Japanese listed companies. *Review of Accounting Studies* 14, 534–558.

Melléklet. A számítások során felhasznált változók képletei és alapadatai

Változó	Változó megnevezése	Változó kiszámítása	Csődös (n=110)		Nem csődös (n=965)	
			átlag	szórás	átlag	szórás
x1	ROA	Adózott eredmény/ Eszközök összesen	-,0640	,1434	,1067	,0957
x2	Vagyonarányos EBIT	EBIT/Eszközök összesen	-,0425	,1450	,1393	,1121
x3	Vagyonarányos EBIT	(EBIT-adó- adómegettakarítás)/ Eszközök összesen	-,0478	,1412	,1173	,0953
x4	Vagyonarányos EBITDA	EBITDA/Eszközök összesen	-,0075	,1363	,1896	,1197
x5	Eszközarányos üzleti eredmény	Üzemi eredmény/ Eszközök összesen	-,0290	,1247	,1402	,1159
x6	ROS	Adózott eredmény/Nettó árbevétel	-,1486	,3343	,0763	,0719
x7	Árbevétel-arányos üzemi eredmény	Üzemi eredmény/Nettó árbevétel	-,0694	,2387	,1005	,0851
x8	Árbevétel-arányos EBIT	EBIT/Nettó árbevétel	-,0879	,2670	,1009	,0853
x9	Árbevétel-arányos EBITDA	EBITDA/Nettó árbevétel	,0047	,2228	,1438	,1049
x10	Forgótőke-arányos árbevétel	Nettó árbevétel/Átlagolt nettó forgótőke	,5913	13,9657	4,1762	19,4541
x11	Nettó haszonkulcs	(EBIT-adófizetés)/Nettó árbevétel	-,0946	,2737	,0866	,0728
x12	Eszközarányos forgótőke	Forgótőke/ Mérlegfőösszeg	-,0766	,3506	,1927	,3035
x13	Eszközarányos árbevétel	Nettó árbevétel/Eszközök összesen	,9479	,8574	1,6550	,9822
x14	Forgó- és idegentőke aránya	(Forgóeszközök-Rövid távú tartozások)/ Kötelezettségek összesen	-,0175	,3907	,7578	1,3026
x15	Likviditási ráta	Forgóeszközök/Rövid távú tartozások	1,0978	,7288	2,4132	2,4532

Változó	Változó megnevezése	Változó kiszámítása	Csődös (n=110)		Nem csődös (n=965)	
			átlag	szórás	átlag	szórás
x16	Likviditási gyorsráta	(Forgóeszközök- Készletek)/ Kötelezettségek összesen	,5907	,5395	1,5162	1,6755
x17	Készpénz-likviditás	Pénzeszközök/Rövid lejáratú kötelezettségek	,0883	,1636	,4878	,8122
x18	Forgótőke lekötése	Készletek/ (Forgóeszközök-Rövid lejáratú kötelezettségek)	-,0404	3,5500	,7126	1,6052
x19	Idegen tőke és összes eszközök aránya	Összes kötelezettség/ Eszközök összesen	,9203	,3301	,5645	,2671
x20	Saját vagyon aránya	Saját tőke/Eszközök összesen	,0575	,3183	,4130	,2689
x21	Hosszú távú eladósodottság	Hosszú távú kötelezettség/(Saját tőke+Hosszú távú kötelezettség)	,2800	,5561	,2232	,2879
x22	Rövid lejáratú kötelezettségek aránya	Rövid lejáratú kötelezettségek/ Források összesen	,7445	,3896	,4305	,2629
x23	Tartozások lefedettsége	Saját tőke/Tartozások összesen	,2202	,5323	1,6265	2,3403
x24	Árbevétel-arányos cash flow	Cash flow/Nettó árbevétel	-,0384	,2483	,1193	,0912
x25	Dinamikus jövédelmzőségi ráta	Cash flow/Eszközök összesen	-,0252	,1335	,1581	,1068
x26	Idegentőke-arányos cash flow	Cash flow/ Kötelezettségek	-,0095	,1163	,5172	,6836
x27	Működési cash flow és nettó árbevétel aránya	Működési cash flow/ Nettó árbevétel	,0389	,5163	,0869	,1481
x28	Működési cash flow és mérlegfőösszeg aránya	Működési cash flow/ Eszközök összesen	,0277	,1794	,1112	,1666
x29	Működési cash flow és tartozások aránya	Működési cash flow/ Tartozások összesen	,0321	,2117	,3148	,4989

Változó	Változó megnevezése	Változó kiszámítása	Csődös (n=110)		Nem csődös (n=965)	
			átlag	szórás	átlag	szórás
x30	Mérlegfőösszeg nagysága	$\ln(\text{Eszközök összesen})$	14,4599	1,1003	14,2226	,9266
x31	Nettó árbevétel nagysága	$\ln(\text{Nettó árbevétel})$	13,9421	1,4383	14,5508	,9283
x32	Árbevétel növekedési üteme	$(\text{Nettó árbevétel}_{n+1} - \text{Nettó árbevétel}_n) / \text{Nettó árbevétel}_n$	-,1362	,5151	,5020	,9688
x33	Szállítói tartozás és rövid távú tartozás aránya	Szállítói tartozás/Rövid távú tartozás	,5308	,3511	,5304	,3255
x34	Vevői követelés aránya a mérlegfőösszegeből	Vevői követelés/Eszközök összesen	,2493	,2476	,2140	,1959
x35	Készletek forgási ideje	$(\text{Készletek átlagolt állománya} / \text{ELÁBÉ}) * 365$	600,21	942,56	92,47	93,65
x36	Követelések forgási ideje	$(\text{Átlagolt kereskedelmi követelés} / \text{Árbevétel}) * 365$	193,6716	216,4700	60,1636	55,2440
x37	Kereskedelmi tartozások forgási ideje	$(\text{Kereskedelmi tartozások átlagos állománya} / \text{ELÁBÉ}) * 365$	744,80	1066,40	164,08	222,70
x38	Pénzkonverzió-ciklus	Készletek forgási ideje + Vevői követelések forgási ideje – Kereskedelmi tartozások ideje	16,25	892,90	135,80	239,57
x39	Tartozások és nettó árbevétel aránya	Tartozások/Nettó árbevétel	2,6058	3,3449	,4653	,3691
x40	Pénzállomány fedezeti rátája	$[(\text{Árbevétel} - \Delta \text{Követelések} + \Delta \text{Passzív időbeli elhatárolás}) / 365] / [(\text{Működési költség} + \text{Pénzügyi költség} - \text{Amortizáció}) / 365]$,8512	,3563	1,0612	,1647