

## Felszámolások előrejelzésének vizsgálata Csongrád megyei vállalkozások esetén

BAREITH TIBOR – KOROSZCZNÉ PAVLIN RITA – KÖVÉR GYÖRGY

### Bevezetés

*„A felszámolási eljárás olyan eljárás, amelynek célja, hogy a fizetéseképtelen adós jogutód nélküli megszüntetése során a hitelezők e törvényben meghatározott módon kielégítést nyerjenek.”<sup>1</sup>*

Napjainkban a felszámolási eljárások száma jelentősen megnövekedett, a növekedést a 2008-ban kirobbant gazdasági világválság indította hazánkban. Beszédesebb adat, hogy Magyarországon 2007-ben a felszámolások száma országosan nem érte el a 10.000-et, 2012-ben ez a száma több, mint 22.000 volt, ami a legmagasabb értéknek számít jelenleg. Az adatok is azt bizonyítják, hogy a felszámolások előrejelzésére szükség van, akár a banki szektoron kívül is. A felszámolások előrejelzésére a pénzügyi szektorban feltétlenül szükség van, akkor hajlandóak hitelezni, ha a hitelezett összeget a kamatokkal együtt a hitelfelvevő vissza tudja fizetni.<sup>2</sup> Amennyiben a bank úgy gondolja, hogy a cég múltbéli beszámolója alapján nem képes eleget tenni fizetési kötelezettségeinek, úgy a hitelkérelmet megtagadja. A bankok által használt úgynevezett csőd előrejelzési modellek titkosak, nem hozzáférhetőek. Azt azonban biztosan tudjuk, hogy a pénzügyi mutatókon, illetve statisztikai módszertanon alapulnak, annak ellenére, hogy a nemzetközi kutatásokban számos alkalommal, az adatbányászati módszerekkel jobb eredményeket értek el. A szakirodalom a legtöbb esetben tőzsdei cégeket vagy bankok adatait használja előrejelző modellek építésére. E tanulmány keretében a magyarországi kis- és középvállalati szektorra fókuszálunk és a szakirodalomban több ízben bizonyított adatbányászati módszertannal készítettük a modellünket, amelyet a Csongrád megyei vállalatokon teszteltünk. Az adatbányászati eszközök közül a neurális hálókra esett a választásunk.

<sup>1</sup> 1991. évi XLIX. törvény, I. fejezet, 1. § 3. bekezdés

<sup>2</sup> IMRE 2008.

## Szakirodalmi áttekintés

A szakirodalom áttekintésében a különböző korszakok a felhasznált módszertanoknak köszönhetően elkülönülnek. A kezdetekben egyváltozós statisztikai módszereket használtak, majd következtek a többváltozós statisztikai módszerek, s végül, ami a legújabbnak számít, az adatbányászati algoritmusok használata.

A felszámolások előrejelzésével az 1930-as években kezdtek el foglalkozni, ekkor arra lettek figyelmesek, hogy a felszámolt és a normál működésű vállalatok beszámolóiból képzett különböző pénzügyi mutatók nagy eltéréseket mutatnak. Fitzpatrick, az eladósodottsági, likviditási, jövedelmezőségi és forgási sebesség mutatószámokat találta kedvezőtlenebbeknek a csődbe jutott vállalkozások esetében.<sup>3</sup>

Az 1960-as évektől jelent meg a többváltozós statisztikai módszerek alkalmazása a csődelőrejelzésben. Az első igazi csődmodell Edward I. Altman nevéhez fűződik, aki először használt többváltozós diszkriminancia analízist, arra vonatkozóan, hogy elkülönítse a vállalatokat fizetőképességük alapján.<sup>4</sup> Összesen 66 vállalatot vizsgált, amelyek közül 33 csődbe ment. Összesen 22 pénzügyi mutatószámot vizsgált, melyek 5 csoportba oszthatók: likviditási, megtérülési, tőkeáttételi, eszköz-megfeleléségi és eszköz-kihasználtsági mutatócsoportok. Ez a modell tekinthető a csődelőrejelzés atyjának, népszerű néven az Altman féle Z-modell.<sup>5</sup>

A Z-modellnek 95%-os besorolási pontossága volt a csődöt megelőző évben, a csőd előtt 2 évvel a modell 72%-ban sorolta be a vállalatokat aszerint, hogy csőd következik vagy pedig túlélő vállalattal van dolgunk.

Az 1980-as években publikálták az első logisztikus regresszióval készült előrejelzési modellt, amely Ohlson nevéhez fűződik. Az új módszertanon kívül még az is érdekes volt Ohlson vizsgálatában, hogy nem körülbelül fele-fele arányban tartalmazott az adatbázis csődöt jelentett és túlélő vállalatokat. A mintájában összesen 2163 vállalat volt található és ezek közül csupán 105 volt, amely csődöt jelentett. Ezzel próbálta a szerző érzékeltetni, hogy több a túlélő ipari nagyvállalat az Egyesült Államokban, mint a csődbe ment.

Ohlson modellje 82,9% besorolási pontosságot mutatott fel, amely szignifikáns különbséget nem mutatott a diszkriminancia elemzésekhez képest, ezért is születtek főként olyan publikációk csődelőrejelzés témakörben,

---

<sup>3</sup> KRISTÓF 2005, 841–863.

<sup>4</sup> ALTMAN 1968, 589–609.

<sup>5</sup> IMRE 2008.

amelyek mind a diszkriminancia analízist, mind a logisztikus regressziót is tartalmazták.<sup>6</sup>

Az 1980-as évek közepétől alkalmazták először az adatbányászati algoritmusokat a csődelőrejelzési modellek építésére. Először a döntési fákkal kísérleteztek, de ezek végül nem terjedtek el. Azonban 1990-ben megjelent Odom és Sharda cikke, ahol mesterségek neurális háló alapú csődmodellt készítettek. A szerzők Altman Z-modelljének változóit felhasználva más mintán tesztelték a neurális hálók teljesítményét és az új módszertan segítségével hiba nélkül sikerült a vállalatokat besorolni.<sup>7</sup> Coats és Fant is Altman modelljének a változóival dolgozva alkották meg a neurális háló alapú csődmodelljüket, amelynek eredményei szintén felülmúlták a diszkriminancia analízis és logisztikus regresszió eredményeit.<sup>8</sup>

A mesterséges intelligencia megjelenése a csődmodellezésben üdítően hatott a csődmodellek fejlődésére. Az esetek többségében a neurális hálók jobb eredményeket hoztak a statisztikai módszereknél, mint a diszkriminancia analízis vagy a logisztikus regresszió. Az új módszertannal való munka során a kutatók szinte minden esetben elvégezték az összehasonlítást a korábban alkalmazott módszerekkel.

Magyarországot tekintve az 1990-es évek után beszélhetünk csődmodellezésről, mivel mindenképpen szükség volt arra, hogy elfogadják és bevezessék a csődtörvényt. Ebben a témában a legjelentősebb publikációk Virág Miklós és Kristóf Tamás nevéhez fűződnek, akik külön-külön és együtt is sokat foglalkoztak a csődelőrejelzéssel.

A neurális hálókkal történő csődelőrejelzés szintén Virág és Kristóf nevéhez fűződik, akik egy korábban megalkotott modelljüket – amely diszkriminancia analízissel és logisztikus regresszióval készült – tesztelték neurális hálókkal. A besorolási pontosságuk nekik is magasabb lett az új módszertannal, amely összhangban volt a nemzetközi kutatásokkal is.<sup>9</sup>

A tanulmány fő kérdése, hogy a képzett pénzügyi mutatók képesek-e elkülöníteni a működő és a felszámolt vállalatokat a Csongrád megyei régióban?

---

<sup>6</sup> OHLSON 1980, 109–131.

<sup>7</sup> ODOM – SHARDA 1990, 163–167.

<sup>8</sup> IMRE 2008.

<sup>9</sup> VIRÁG – KRISTÓF 2005, 144–162.

## Anyag és módszer

A felhasznált adatbázisunk tartalmazza Magyarország valamennyi gazdasági társasának közzétett, nyilvános beszámolóját 2002-2012 közötti időszakban. Továbbá van lehetőségünk székhely, telephely, tevékenység, tulajdonosok szerinti szűrésre és külön adattáblán szerepelnek a felszámolás és végelszámolás alá eső vállalkozások is. A cégek egy anonim kóddal rendelkeznek, így lehetőség van rá, hogy az adattábláink összekötésével különböző komplex szűréseket végezzünk.

A jelenlegi tanulmányhoz a Csongrád megyei vállalatokat vizsgáltuk, méretüket tekintve kis- és középvállalatnak azokat tekintettük, amelyek mérlegfőösszege 10 és 250 millió forint közé esik. Szükséges volt egy saját beosztási formát kialakítanunk, mert az adatbázisunk nem tartalmazta a dolgozói létszámot. Ennek hiányában a törvény szerinti besorolást nem volt lehetőségünk alkalmazni. Továbbá jogi forma szerint is bontottuk az adatbázist, ennek következtében csak a Korlátolt felelősségű vállalatok maradhattak a vizsgált vállalatok között.

Ezek a feltételek nem számottevően, de szűkítették a vizsgálandó vállalkozások körét, azonban ami leginkább ritkította a vállalkozásokat, az a feltétel volt, hogy csak olyan vállalatokat kívántunk vizsgálni, amelyek legalább 3 teljes évet működtek, mind a normál működés és mind a felszámolt működés esetén. Ezt azért tartottuk fontosnak, mert azokkal a vállalkozásokkal szerettünk volna foglalkozni, amelyeknek a tulajdonosai nem kényszerből vállalkoztak, hanem valamit létre szerettek volna hozni. Nem a fejlődésre képtelen, „roncsgazdaságot” kívántuk elemezni.

A kutatás során pénzügyi mutatókkal kerestük a különbséget a felszámolt és a normál működésű vállalkozások között. A mutatók kiküszöbölik azt a problémát, hogy az infláció okozta torzításokkal foglalkozunk, így a különböző évek adatai összehasonlíthatóvá válnak.

A megfelelő mutatók kiválasztása alapozza meg a tanulmány sikerességét, ez tekinthető az egyik legfontosabb mozzanatnak a kutatás során. Használhatjuk a jól megszokott általános mutatókat, amelyekkel a tankönyvekben és a különböző szakirodalomokban számtalanszor találkozhattunk és emellé lehetőségünk nyílik új mutatókat is képezni, amelyeket fontosnak találunk a felszámolhatóság becslésére. A saját mutatókkal kiemeltnek kell foglalkoznunk és azokat kellőképpen át kell gondolnunk, mielőtt bevonnánk a modellalkotásba. A tankönyvekből vett mutatók is hordoznak veszélyt magukban, nem lehetünk kényelmesek, az

adatainkat feltétlenül szükséges átböngészniük és keresniük kell olyan eltéréseket, amelyek felboríthatják a várakozásainkat. Egy ilyen esetre lehet példa a széles körben alkalmazott ROE mutató, az  $\frac{\text{Adózott eredmény}}{\text{Saját tőke}}$ .

Megalapozott várakozásunk lehet, hogy a felszámolt vállalkozások esetében az adózott eredmény veszteséget mutat, és ha elosztjuk a saját tőkével, akkor negatív értéket kapunk. Az adataink átböngészése után viszont azt tapasztalhatjuk, hogy a saját tőke sok esetben negatív és nem csak a felszámolt vállalkozásoknál. Ezzel el is érkeztünk egy komoly problémához, mivel ha két negatív értéket osztunk egymással, akkor az eredmény pozitív lesz, így a modell nem tud különbséget tenni a nyereséges és veszteséges vállalatok között.

Az általunk meghatározott méretkategóriában a vállalkozások egyszerűsített éves beszámolót készítenek. Ennek a legnagyobb hátránya, hogy nem tudunk olyan fontos információkat kinyerni, mint a vevő és szállító állomány. Sajnos az eredménykimutatáson belül a pénzügyi műveletek eredménye sor nincs megbontva pénzügyi műveletek bevételeire és pénzügyi műveletek kiadásaira, továbbá arról se volt információnk, hogy az árbevétel mekkora része származik a belföldi és külföldi értékesítésből.

A mutatóképzés során kiemelt figyelemre van szükség, nem járhatunk el jóhiszeműen és nem eshetünk abba a csapdába sem, hogy automatikusan veszünk át korábbi kutatásokban felhasznált mutatókat. A mutató választásnak összhangban kell lennie az adatbázisunkkal, hogy olyan információkat nyerhessünk ki, amelyeket előzőleg megfogalmaztunk.

Az *1. táblázatban* láthatóak azok a pénzügyi mutatók, amelyek a szakirodalomban is megtalálhatóak, valamint olyan mutatók is, amelyeket mi tartottunk fontosnak a felszámolások vizsgálatához.

### *Módszertan*

„Az adatbányászat egy olyan döntéstámogatását szolgáló folyamat, mely érvényes, hasznos, és előzőleg nem ismert, tömör információt tár fel nagy adathalmazból”.<sup>10</sup> Az adatbányászat kifejezés az angol *data mining* fordításából származik. Az angol kifejezés az aranymosásra utalt, ahol a homok megfelelő technikával való átszűrésével kinyerhetjük az aranyat.<sup>11</sup>

---

<sup>10</sup> ABONYI 2006.

<sup>11</sup> FAJSZI 2010.

<b>Mutató neve</b>	<b>Képlet</b>	<b>rövidítése</b>
Likviditási gyorsráta	$\frac{\text{Forgóeszközök} - \text{Készletek}}{\text{Rövid lejáratú kötelezettségek}}$	l_gy
Nettó forgótőke aránya	$\frac{\text{Forgóeszközök} - \text{Rövid lejáratú kötelezettségek}}{\text{Rövid lejáratú kötelezettség}}$	nft_a
Eszközarányos nyereség (ROA)	$\frac{\text{Adózott eredmény}}{\text{Összes eszköz}}$	roa
Árbevétel arányos nyereség (ROS)	$\frac{\text{Adózott eredmény}}{\text{Éves nettó árbevétel}}$	ros
Tárgyi eszközök aránya	$\frac{\text{Tárgyi eszközök}}{\text{Befektett eszközök}}$	te_a
Pénzügyi műveletek eredménye/Kötelezettsége	$\frac{\text{Pénzügyi műveletek eredménye}}{\text{Kötelezettségek}}$	pui_kot
Saját vagyon aránya	$\frac{\text{Saját tőke}}{\text{Mérlegfőösszeg}}$	sva
Rövid lejáratú kötelezettség aránya	$\frac{\text{Rövid lejáratú kötelezettségek}}{\text{Kötelezettségek}}$	rlk_a
Forgó eszközök aránya	$\frac{\text{Forgóeszközök}}{\text{Összes eszköz}}$	fe_a
Befektetett eszközök fedezete	$\frac{\text{Saját tőke} + \text{Hosszú lejáratú kötelezettségek}}{\text{Befektetett eszközök}}$	be_fed

### 1. táblázat: Felhasznált pénzügyi mutatók

A kutatás során a neurális hálók kapták a főszerepet, mivel a szakirodalom alapján az adatbányászati eszközök közül a neurális hálók eredményei a legmegbízhatóbbak. A neurális hálók alapjai az emberi agyig nyúlnak vissza és annak a működését próbálják utánozni. A mesterséges neurális háló neuronokból és azok kapcsolataiból áll. A neuronok kapcsolatban állnak egymással, és ahogyan az emberi agy, a mesterséges neuronok is képesek tanulni.<sup>12</sup>

A neurális hálókat rétegekre lehet bontani, három különböző réteget különböztethetünk meg: 1.) bemeneti réteg, 2.) rejtett réteg, 3.) kimeneti réteg.


Az adatfeldolgozás során a kialakított modell egy rejtett réteget tartalmaz. A különböző rétegek más-más feladatokat látnak el. A dolgozat példáján keresztül kerül bemutatása az alábbiakban a rétegek szerepe.

<sup>12</sup> HORVÁTH 1998.

- **Bemeneti réteg:** A bemeneti réteg neuronjai tartalmazzák a pénzügyi mutatókat.
- **Rejtett réteg:** Idetartoznak azok a neuronok, amelyek a „munkát”, a feldolgozást végzik. Ezek a neuronok mind a bemeneti réteg neuronjaihoz és a kimeneti réteg neuronjaihoz csatlakoznak. A rejtett rétegben a neuronok számát mi határozhatjuk meg.
- **Kimeneti réteg:** Az itt található neuronok hordozzák azt az információt, hogy a vállalkozást normál működésűnek vagy felszámoltnak sorolta-e az algoritmus.

A rejtett rétegen belül nem csak a neuronok számát van lehetőségünk meghatározni, hanem a rejtett rétegek számát is.

### Egyszerű neurális háló



**1. ábra: Egyszerű neurális háló**  
(Saját szerkesztés az R program alapján.)

Az 1. ábrán egy egyszerű neurális háló látható, a bemeneti rétegnél 3 neuron: mutató1(I1), mutató2(I2) és mutató3(I3). A rejtett rétegek száma 1 és 5 neuront(H1...H5) tartalmaz. Látható, hogy minden bemeneti neuron

csatlakozik a rejtett neuronokhoz és a rejtett neuronok csatlakoznak egymáshoz a B1 neuronon keresztül. A kimeneti két neuron esetében az O1 a normál vállalkozásokat jelöli, az O2 pedig a felszámoltakat. Itt is láthatóak a kapcsolatok egymással(B2) és a rejtett réteg neuronjaival is.

Az adatbázisunk tartalmaz normál működésű vállalatokat és felszámolt vállalatokat is. Mielőtt a neurális hálót futtatnánk, pontosan tudjuk, hogy mely vállalkozások felszámoltak. A célunk az, hogy a neurális háló minél pontosabban leírja a valóságot. A besorolási pontosság mérésére szolgál a Kappa-statisztika, amelyet Cohen fejlesztett ki. A Kappa-statisztika nem csak a neurális háló osztályozásának a pontosságára szolgál, több területen is használják. Cohen szerint a Kappa-statisztikának az az előnye, hogy figyelembe veszi a véletlen találgatást és kiküszöböli azt.<sup>13</sup> A Kappa-statisztika értéke 0 és 1 között változhat, 1 esetén a modellünk tökéletesen osztályoz, 0 esetén pedig valamennyi esetben tévesen sorolta be az eseteinket. A kappa mutató esetében nincs egységes nézet arra vonatkozóan, hogy mekkora, az az érték, amit elfogadhatónak találhatunk, de amennyiben a kappa 0,6–0,7 feletti, elégedettek lehetünk.

Az egyszerű neurális háló ábrán (*1. ábra*) a neuronokat összekötő vonalak vastagsága eltérő. Minél vastagabb a vonal, annál erősebb a pozitív kapcsolat a neuronok között és minél vékonyabb, annál erősebb a negatív kapcsolat. A modell kialakítása közben a súlyok folyamatosan változnak és így alakulnak ki ezek a fontossági kapcsolatok. A relatív fontosságot Garson és Goh dolgozta ki az 1990-es évek első felében.<sup>14</sup> Az inputadatok relatív fontossága az outputváltozók értékének becslésében úgy kerül meghatározásra, hogy egyidejűleg az összes olyan kapcsolathoz rendelt súlyt figyelembe veszi az algoritmus. Ezeket a súlyokat ábrázolva kapjuk meg a relatív fontosságot bemutató ábrát. A Marcus W. Beck által továbbfejlesztett relatív fontosság meghatározása esetén a bemeneti neuronok standardizáláson esnek át, -1 és +1 közötti értéket vesznek fel (*2. ábra*).<sup>15</sup>

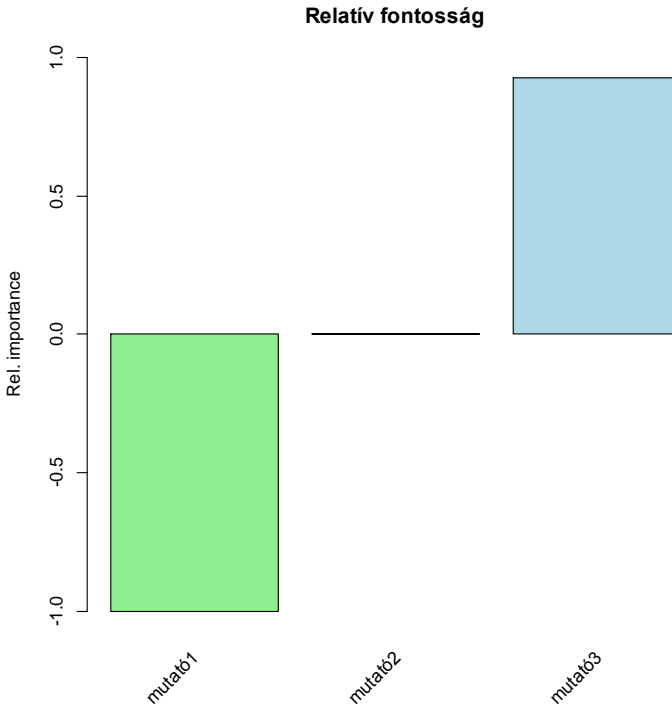
---

<sup>13</sup> COHEN 1960, 37–46.

<sup>14</sup> BECK 2013; <https://beckmw.wordpress.com/2013/08/12/variable-importance-in-neural-networks/> (2014.03.10.).

<sup>15</sup> BECK 2013; <https://beckmw.wordpress.com/2013/10/07/sensitivity-analysis-for-neural-networks/> (2014.03.10.).






**2. ábra: Relatív fontosság**  
(Saját szerkesztés az R program alapján.)

A korábbi példát folytatva láthatjuk a relatív fontosságot ábrázolva. Amennyiben a relatív fontosság minél közelebb esik valamely szélsőértékhez (-1;+1), akkor annál nagyobb magyarázó erővel rendelkezik az adott változó. A relatív fontosság 0 közeli értéke arra enged következtetni, hogy a változónak nincs osztályozási képessége.

Az ábra értelmezése a példánkon úgy néz ki, hogy a mutató3 és a mutató1 változó sokkal nagyobb magyarázó erővel rendelkezik, mint a 0 relatív fontossággal bíró mutató2.

A relatív fontosságon kívül az érzékenységvizsgálat is segítségünkre lehet, hogy értelmezzük a neurális háló eredményeit. Az érzékenységvizsgálat „ceteris paribus” elven működik. Kiválasztunk egy változót és azt a változót vizsgáljuk annak tükrében, miközben a többi változót állandó szinten tartjuk. A vizsgálat során 6 állandó szintet határoztunk meg, a minimum, 20., 40., 60., 80. kvantilis és a maximum.



**3. ábra: Érzékenység vizsgálat**  
(Saját szerkesztés az R program alapján.)


A 3. ábra első ránézésre nagyon zsúfoltnak tűnik és észrevehetjük, hogy tükrözve is van. példánkat folytatva a mutató3 érzékenységvizsgálatát elemezzük. Koncentráljunk az ábra alsó részére. Az x tengelyen láthatjuk, hogy a mutató3 milyen értékeket vehet fel, az y tengelyen pedig azt tudjuk meghatározni, hogy a modell normál működésűnek vagy inkább felszámoltnak sorolná-e a vállalatokat. Amennyiben az y tengelyen 0,5 fölé esnek a vonalak, akkor felszámoltnak tekinti az érzékenységvizsgálat a vállalatokat. A színes vonalak szemléltetik a mutató3 alakulását. A színek alapján határozhatjuk meg, hogy a mutató1 és a mutató2 milyen szinten lett rögzítve, 0 a minimum 1 a

maximum és közte a kvantilisok láthatóak az ábra jobb oldalán. A lila vonal esetében a maradék mutatókat maximumon vesszük és a mutató3 értékét változtatjuk, akkor azt láthatjuk, hogy ha a mutató értéke -2,5 (y tengely), akkor billen át az x tengelyen a vonal 0,5 fölé és sorolja a vállalatokat felszámoltnak.

## Eredmények

Az előző fejezetben bemutatott korlátozó feltételek mellett a 2002–2012-ig tartó időszakban Csongrád megyében mindösszesen 2284 normál működésű és 199 felszámolt vállalkozás maradt az adatbázisban.

Ezen az összesen 2483 vállalkozáson teszteltük a neurális hálót, hogy milyen pontossággal sikerült a vállalkozásokat visszaosztani normál működésűek vagy felszámoltnak.




**4. ábra: Csongrád megye neurális háló 2002–2012 időszakban**  
(Saját szerkesztés az R program alapján.)

Az 1. ábrán lévő neurális háléhoz képest egy jóval bonyolultabb neurális háló látható a 4. ábrán. A bementeni oldalon már 30 pénzügyi mutató látható, pontosabban 10 mutató, csak valamennyi le lett képezve 3 évre visszamenőleg

is. A közbenső rétegben 15 neuront láthatunk, amelyek végül a szokásos két kimeneti neuronhoz kapcsolódnak.

A 4. ábráról sok információt nem tudunk leolvasni, ahhoz hogy közelebbi képet kapjunk a neurális hálóban lezajló folyamatokról, vizsgáljuk meg a relatív fontosságot.



**5. ábra: Csongrád megye neurális háló 2002–2012 időszak mutatóinak relatív fontossága**  
(Saját szerkesztés az R program alapján.)

A relatív fontosság ábra (5. ábra) jobb oldaláról 3 mutató, bal oldaláról 2 mutató emelhető ki, amely fontosabb a modellalkotás szempontjából.

Amennyiben az Árbevétel arányos nyereség a felszámolás előtti évben (ros3), minél magasabb, annál nagyobb a valószínűsége, hogy az adott vállalatot normál működésűnek sorolja az algoritmus. A Saját vagyon arány a

felszámolás előtt 1 évvel (sva3) értelmezése megegyezik az előzőével, tehát minél tőkeerősebb egy vállalkozás, annál nagyobb valószínűséggel normal működésű. A Forgó eszközök aránya is a felszámolás előtt 1 évvel fontos (fe\_a3), ami alapján elmondható, hogy minél nagyobb arányban vannak az eszközök között a forgóeszközök, annál kisebb a valószínűsége, hogy a neurális háló felszámoltak sorolja az adott vállalkozást.

A Saját vagyon aránya a felszámolás előtt 3 évvel (sva1) minél alacsonyabb, annál nagyobb a valószínűsége, hogy az adott vállalkozást felszámoltak sorolja a modell. Valamint az Eszközarányos nyereség a felszámolás előtt 1 évvel (roa3) minél kisebb értéket vesz fel, annál nagyobb a valószínűsége, hogy a vállalatot felszámoltak sorolja az algoritmus. A modell besorolási pontosságát a 2. táblázat szemlélteti.

	normál (db)	felszámolt (db)
normál (db)	2284	0
felszámolt (db)	14	185
Kappa	0,96	

**2. táblázat: A neurális háló besorolási pontossága**

A 2. táblázatban az átlókra érdemes figyelni: a bal felső sarokból induló átlóban láthatjuk azokat az eseteket, amikor a modellünk helyesen osztályozott, tehát normált normálba, felszámoltat felszámoltba sorolt vissza. Az ellentétes átlóban pedig azok az esetek láthatóak, amikor hibázott a modellünk. Látható, hogy mindössze 14 alkalommal hibázott a modellünk, felszámolt vállalatokat normálnak sorolt be. Ennek hátterében olyan dolgok lehetnek, amelyeket nem lehet kiolvasni a pénzügyi beszámolókból, nem mérhetőek ezek a történések, így a modellalkotásnál sem lehet ezeket figyelembe venni.


A kapa értéke 0,96, ami rendkívül jónak mondható, mivel a határérték 0,6–0,7.

A 6. ábrán az érzékenységvizsgálatra egy konkrét példa látható, a Saját vagyon aránya mutatóval. Amennyiben az ábra alsó felére koncentrálnak láthatjuk, hogy nagyon sokáig 0 a mutató értéke, majd ahogy fokozatosan csökken úgy a világoskék vonal – ami azt jelenti, hogy az összes többi (29 mutató) 60%-os értéken van rögzítve és a saját vagyon aránya mutatót csak a felszámolás előtt 1 évvel vizsgáljuk – hirtelen nőni kezd, majd ahogy az y tengelyen 0,5 fölé kerül, onnan sorolja a modell a vállalkozásokat

felszámoltnak. A 60%-os rögzítés esetén ez azt jelenti, ha a Saját vagyron aránya a felszámolás előtt 1 évvel eléri a körülbelül -0,3-as értéket, akkor az algoritmus felszámoltnak sorolja a vállalkozásokat. Ez érthető is, hiszen a saját tőke ebben az esetben negatív.

### Következtetések

A célkitűzésben megfogalmazott kérdésre egyértelműen lehet válaszolni: a képzett pénzügyi mutatóknak szinte tökéletesen sikerült elkülöníteniük a normál működésű és a felszámolt vállalatokat. A vizsgált időszakban a Csongrád megyei vállalkozások közül mindösszesen 14 alkalommal tévedett a neurális háló, ami kifejezetten jó eredménynek tekinthető.



**6. ábra: A Saját vagyron aránya mutató a felszámolás előtt 1 évvel érzékenységvizsgálata**

(Saját szerkesztés az R program alapján.)

A modellalkotás szempontjából a legtöbb releváns mutató a felszámolás előtti közvetlen időszakból származik, ami azt jelenti, hogy gyors beavatkozásra van szükség, ha a modell „megbélyegez” egy vállalatot, nincs sok idő a változtatásra.

## Összefoglalás

A tanulmányban a Csongrád megyében működő normál és a már felszámolt vállalatokat vizsgáltuk a nyilvános, bárki által hozzáférhető beszámolók alapján. Az adatbázis, amellyel dolgoztunk, tartalmazza a magyarországi gazdasági társaságok éves beszámolóit a 2002 és 2012 közötti időszakból. Összesen 10 pénzügyi mutatót képeztünk 3 évre visszamenőleg, amelyekkel kerestük a különbséget a felszámolt és a normál működésű vállalkozások között. A modellalkotás során nem a statisztikai eszközöket használtuk, hanem a szakirodalmi eredmények alapján is a legjobban teljesítő mesterséges neurális hálókat.

A modellalkotás eredményeképpen sikerült egy olyan neurális hálót létrehozni, ahol a bementeni oldalon valamennyi pénzügyi mutató szerepel, a közbenső rétegben 15 neuront használtunk. A besorolási pontosság kiváló lett, a normál működésű vállalatokat valamennyi esetben sikerült pontosan besorolni, a felszámoltak esetében pedig 199 vállalat közül csupán 14 esetben tévedett a modellünk. A kitűzött célt sikerült teljesíteni, a képzett pénzügyi mutatókkal sikerült elkülöníteni a felszámolt és a normál működési vállalatokat.

## Irodalom

ABONYI 2006: = Abonyi J.: *Adatbányászat a hatékonyság eszköze*. Budapest: ComputerBooks Kiadói Kft., 2006.

ALTMAN 1968 = Altman, E. I.: Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy. *Journal of Finance*. Vol. 23. (1968) 589–609.

<http://onlinelibrary.wiley.com/doi/10.1111/j.1540-6261.1968.tb00843.x/full> (2013.11.12.)

BECK. 2013a = Beck, W. M.: Variable importance in neural networks [WEB log message] Retrieved from: <https://beckmw.wordpress.com/2013/08/12/variable-importance-in-neural-networks/>

- BECK. 2013b = Beck, W. M.: Sensitivity analysis for neural [WEB log message]. Retrieved from: <https://beckmw.wordpress.com/2013/10/07/sensitivity-analysis-for-neural-networks/>
- COHEN 1960 = Cohen, J.: A coefficient of agreement for nominal scales. *Educational and Psychological Measurement*. Vol. 20. (1960) 37–46.  
<http://www.garfield.library.upenn.edu/classics1986/A1986AXF2600001.pdf> (2014.02.25.)
- FAJSZI ET AL. 2010 = Fajsi et al.: *Üzleti haszon az adatok mélyén*. Budapest: Alinea Kiadó, 2010.
- HORVÁTH 1998 = Horváth G.: *Neurális hálózatok és műszaki alkalmazásai*. Budapest: Műegyetemi Kiadó, 1998.
- IMRE 2008 = Imre B.: *Bázel II definíciókon alapuló nemfizetés-előrejelzési modellek magyarországi vállalati mintán (2002–2006)*. (PhD értekezés) Miskolc: Miskolci Egyetem, 2008.  
[http://www.gei.uni-miskolc.hu/phd/teziszfuzetek/imre\\_phd.pdf](http://www.gei.uni-miskolc.hu/phd/teziszfuzetek/imre_phd.pdf) (2013.10.08.)
- KRISTÓF 2005 = Kristóf T.: A csődelőrejelzés sokváltozós statisztikai módszerei és empirikus vizsgálata. *Statisztikai Szemle* 83. évf. 9. sz. (2005) 841–863.
- ODOM. – SHARDA 1990 = Odom, M. D. – Sharda, R.: A Neural Network Model for Bankruptcy Prediction. *IJCNN International Joint Conference on Neural Networks*. Vol. 2. (1990) 163–167.  
[https://www.google.hu/url?sa=t&rct=j&q=&esrc=s&source=web&cd=2&cad=rja&uact=8&ved=0CEIQFjAB&url=http%3A%2F%2Fwww.researchgate.net%2Fpublication%2F222494559\\_Artificial\\_neural\\_networks\\_in\\_bankruptcy\\_prediction\\_General\\_framework\\_and\\_cross-validation\\_analysis%2Ffile%2F72e7e521761f62845a.pdf&ei=Uxp1U6mvErg4QTJ2YDoBQ&usg=AFQjCNEZ4IT9Eg8cUjXXQUVHn5TGGPiyVw&sig2=Ci0bOR4jRt4k8ORKEBYQmw](https://www.google.hu/url?sa=t&rct=j&q=&esrc=s&source=web&cd=2&cad=rja&uact=8&ved=0CEIQFjAB&url=http%3A%2F%2Fwww.researchgate.net%2Fpublication%2F222494559_Artificial_neural_networks_in_bankruptcy_prediction_General_framework_and_cross-validation_analysis%2Ffile%2F72e7e521761f62845a.pdf&ei=Uxp1U6mvErg4QTJ2YDoBQ&usg=AFQjCNEZ4IT9Eg8cUjXXQUVHn5TGGPiyVw&sig2=Ci0bOR4jRt4k8ORKEBYQmw) (2014.01.18.)
- OHLSON 1980 = Ohlson, J. A.: Financial Ratios and the Probabilistic Prediction of Bankruptcy. *Journal of Accounting Research*. Vol. 18. (1980) 109–131.  
<http://teaching.ust.hk/~ismt551/project2/Ohlson.pdf> (2014.02.25.)



VIRÁG – KRISTÓF 2005 = Virág M. – Kristóf T.: Az első hazai csődmodell újraszámítása neurális hálók segítségével. *Közgazdasági Szemle* 52. évf. (2005) 144–162.

## **Liquidations Examination among Csongrád County Enterprises**

TIBOR BAREITH – RITA KOROSZCZÉ PAVLIN – GYÖRGY KÖVÉR

This study aims to explore enterprises in the Csongrád county predictability liquidation. This topic is not has going back domestic literature because of the lack of legal enviroment (Bankruptcy Act, 1991). Internationally, data mining from the 1980s appeared in bankruptcy modelling as a new methodology.

The database that was available options offered use of data mining tools. The article focuses on the Csongrád county of a limited company.

The data set includes the companies' financial statement and profit and loss statement from 2012 back 10 years. These were developed using the range of indicators that help enterprises separating. In the study, the data mining techniques of neural networks are used to predict the liquidations.

The study result will be developed model that in time may be able to draw the attention close state of winding active for the Csongrád county companies.