

Vállalatok tudatos működési elemei adatbányászati módszerek tükrében²

Az adatbányászati eszközök folyamatos fejlődésével egyre pontosabb és mélyebb ismeretekre teszünk szert az üzleti élet egyik alapvető építőkövének tekinthető üzleti tervezés folyamataival és hálózati összefüggéseivel kapcsolatosan. Az adatbányászat során minták nyerhetők ki, amelyek alapösszefüggések elemzéséhez adnak segítséget. A leginkább elfogadott elemzési módszerek a hibrid adatbányászati modellek és eszközök, ezen belül is az emberi agy működését modellező mesterséges neurális hálózatok, amelyek utat nyithatnak a mélyebb összefüggések feltárásához és megértéséhez.

Az adatbányászat segítségével tudatosságmodell állítható fel, amely a vállalatok mozgását, működését, döntési mechanizmusát értékeli és elemzi.³

Kulcsszavak: tudatosságmodell, üzleti tervezés, adatbányászat, mesterséges intelligencia, pénzügyi instrumentumok

Journal of Economic Literature (JEL) kód: C3, C6, F20, F23, F24

Bevezetés

Az adatbányászat a fejlett intelligens üzleti elemzések és döntéshozatali eszközök egyik legfontosabb jelenlegi paradigmája (Amania–Fadlalla 2017). Olyan multidiszciplináris megközelítés, amely különböző technikákat alkalmaz a statisztika, a gépi tanulás, az adatbázisok területén. Az adatbányászat egyik speciális ága, amely a pénzügyi mérle-

1 Elnök, Hozzáadott Érték Gazdaságkutató és Fejlesztési Intézet; e-mail: laskaiandras@gmail.com.

2 DOI: http://dx.doi.org/10.31570/Prosp_2018_02_4

3 Ezúton is köszönetet szeretnék mondani professzor dr. Sándorné Kriszt Éva egyetemi tanár asszonynak az inspirációért és jelen cikk megjelenéséhez nyújtott segítségével, valamint professor emerita dr. Solt Katalin egyetemi tanár asszonynak ugyancsak a cikk megjelenéséhez nyújtott segítségével. Jelen cikk Laskai András: Az üzleti terv pénzügyi instrumentumai nemzetközi perspektívában a tudatosság tükrében című PhD-értekezése vonatkozó fejezeteinek átdolgozott, aktualizált változata.

gek, illetve beszámolók és azok származtatott mutatószámainak összefüggéseit vizsgálja. Ebben a módszerben az adatbányászat az adatok újszerű és végső soron értelmezhető mintáinak azonosítását nyújtja (Pujari 2001). Az adatbányászat lehetővé teszi a szervezetek számára, hogy könnyebben azonosíthassák a teljesítménymutatók közötti statisztikai kapcsolatokat (Ittner–Larcker 2001). Ezzel összefüggésben meghatározható a hibrid adatbányászati eszközökkel egy adott vállalati csoport tudatos működése. A tudatos működés feltérképezésével a kutatások egyre közelebb kerülhetnek az *Egyesített Mező*⁴ feltérképezéséhez.

A szakirodalmi háttér bemutatása

Az általános szakirodalmi háttér bemutatása az eljárások, módszerek, pénzügyi instrumentumok elemzésében

A mérlegelemzések, beszámolók, pénzügyi elemzések informatikai vizsgálata az 1960-as évektől kezdődött, a számítógépes könyvvizsgálati szabványok kutatása pedig az 1990-es években, elsősorban a szabványokra, a specifikációkra összpontosítva (Zhang–Wang–Zhang 2011).

A számvitel területén több mint három évtizede intelligens alkalmazásokat alkalmaznak (Baldwin 2006), és az egyik legkorábbi üzleti diszciplína volt az adatbányászat

4 Az intelligencia megalapozása, fejlesztése (nem biológiai úton történő születése), a GNR, a mesterséges intelligencia eljövetele, az emberi és gépi tudatosság egybecsúszása (Kurzweil 2005, 2012, 2013) a mindezt átfogó keretrendszer megértése nélkül nem lehetséges. A keretrendszer az Egyesített Mező, a tudatosság jelenti, amely egyben kvantumtér. A tudatos tapasztalatok alapjánál található egyesített tudatmező felfedezése tette lehetővé azt a felismerést, hogy a tudat egyesített mezeje és az elméleti fizikában ismert Egyesített Mező azonosak. Az Egyesített Mező, a tudatosság első módszertani megfogalmazója a védikus hagyományokat felelevenítő Maharishi Mahesh Yogi volt. Az Egyesített Mező, tudatosság nem az emberi idegrendszer működésének köszönheti a létét. Az emberi idegrendszer csupán összetettséget biztosít az anyag szintjén, mely visszatükrözi, minőséggel és egyéniséggel ruházza fel az emberi tudatot, lehetőséget nyújtva ezzel az egyéni tapasztalatok megjelenésére (Hagelin 1987). Az Egyesített Mező, tudatosság az élet lényegi magva, az emberi értelem szerint objektív módon, egyéni tapasztalatok fényében nem lehet semmilyen módon jellemezni. Ez az egységes mező, amely kifejezi és áthatja az egész megnyilvánult jelenségvilágot (Hagelin 1987). A kvantumgazdaság, mint az Egyesített Mező, tudatosság egyik részlemele, a kvantumfizika módszereit alkalmazza a közgazdaságtan, az üzleti tudományok területére (Laskai 2018). A pénzügyi folyamatok nagyon sok tekintetben paralel modellezhetők a kvantumfolyamatokkal. (Shubik 1999; Haven 2002; Baaquie 2007; Haven–Khrennikov 2013; Orrell 2016; Orell–Chlupaty 2016; Colin 2017). A kvantumgazdaság korai propagálója, Asghar Qadir szerint, mint a kvantummechanikában lévő részecskék, az egyén mint entitás a Hilbert-térben egy pontnak tekinthető (Asghar 1978). Aerts továbbítte Asghar gondolatmenetét, és az epsilon-modellel arra a megállapításra jutott, hogy az emberi döntéshozatal számos aspektusa, beleértve a gazdasági döntésekben részt vevőket is, egyfajta kvantumlogikát követ (Aerts–Aerts 1994). Alapvetően a gazdasági döntések (emberi döntések) események a számviteli beszámolóknak (Helfert 2011; Virág–Kristóf–Varsányi 2013) ennek a végtelenített tudatosságnak az egyik rendszerszinű végpontjai (Laskai 2018, 2019a, 2019b).

hasznosítása érdekében, hogy feltárják a rendszer kockázatát és komplexitását. Számos kutatás készült a számviteli adatbányászati alkalmazásokkal kapcsolatosan, azonban jelentős részük egy adott számviteli területre vagy adatbányászati technikára koncentrált (Coakley–Brown 2000; Yang 2006; Calderon–Cheh 2002; Wang 2010; Ngai 2011).

Az adatbányászat ezekben az esetekben az algoritmusok alkalmazását és **az adatokból származó minták kivonását jelentette, amely lehetővé tette az implicit minták és a tudás automatikus feltárását nagy mennyiségű adatból** (Jiawei–Kamber 2006). Az adatbányászat segít a szervezeteknek abban, hogy a meglévő adatbázisukban elérhető legfontosabb információkra és ismeretekre összpontosítsanak.

Az adatbányászatnak három fő célja van: leírás, előrejelzés és előírás (*description, prediction, prescription*). Mivel a leírás az adatok leírására szolgáló emberi értelmezhető mintákra összpontosít, a becslés magában foglalja az adatbázisban lévő változók vagy mezők használatát az érdeklődésre számot tartó egyéb változók ismeretlen vagy jövőbeni értékeinek előrejelzésére (Fayyad 1996). A leíró adatbányászat lehetővé teszi a felhasználók számára, hogy azonosítsák az adatok mintáit és tendenciáit, és felfedezzék a problémákat vagy a lehetőségeket. Másrészt a prediktív adatbányászat elemzi a múltat, és a jövőre irányulóan tesz előrejelzéseket. A prediktív adatbányászat elsősorban a jövőorientált döntéshozatalt jelenti. Végezetül az előíró adatbányászat optimalizálási technikákat alkalmaz a legjobb alternatívák azonosítása érdekében, amelyek minimalizálják vagy maximalizálják az objektív funkciókat. A prediktív adatbányászatban a matematikai és statisztikai technikák kombinálódnak. Optimalizálással olyan döntések születhetnek, amelyek figyelembe veszik az adatok bizonytalanságát is (Evans 2013). A számviteli jelentés két legfontosabb perspektívájának (*retrospektív, prospektív*) és az adatbányászat három fő céljának egymás mellé állításával hat kombináció alakul ki. Logikailag mindössze négy ilyen kombináció valósítható meg: (1) leíró adatbányászat visszamenőleges jelentéskészítés során, (2) előíró adatbányászat visszamenőleges jelentéskészítés során, (3) előíró adatbányászat a leendő jelentésekben, és (4) prediktív adatbányászat a leendő jelentésekben. A retrospektív-leíró alkalmazások az adatok megértésére koncentrálnak. Az alkalmazási területek által használt legfontosabb adatbányászati feladatok közé tartozik a feltárás, csoportosítás, összehasonlító elemzés, vizualizálás, szegmentálás és mintafelismerés (Amanía–Fadlalla 2017).

A legjelentősebb adatbányászati technikák a mesterséges neurális hálózatok, az esetalapú érvelés, a genetikai algoritmusok, a döntési fák, az egyesülési szabályok, a regresszió, az önszervező térképek, a k-legközelebbi szomszéd módszer, a Bayes-féle analízis és a fuzzy analízis (Amanía–Fadlalla 2017).

Dattilo és társai (2002) szerint az adatbányászat területén önállóan használt technika a neurális hálózatok és a klaszterezés. Egyetlen adatbányászati technika azonban nem elegendő az adott adatkészletből történő tudás kinyeréséhez, **így a hibrid adatbányászati megközelítések a javasolt, elfogadott és gyakran használt technikák, amelyek egy adott adatbányászati eljárást együttműködően támogatnak.** A különböző osztályozási technikák – például a döntési fák indukciója – és a klaszterezés kombinálásával megfelelő és intuitív adatleírást lehet létrehozni (Dattilo–Greco–Masciari–Pontieri 2000).

Ezen adatbányászati technikák mindegyike különleges célt, problémát és üzleti igényt szolgál ki. Az adatbányászat alkalmazásáról a pénzügyek, illetve számviteli alkalmazásokkal kapcsolatosan külön összefoglaló tanulmányok jelentek meg. A nagy összefoglaló munkák kategorizálják, összehasonlítják és összefoglalják a különböző adatbányászati módszereket, az algoritmusokat és a teljesítménymérést (így pl. Yang [2006], Wang [2010], Ngai és társai [2011] munkái), míg más nagyobb összefoglaló munkák (Coakley–Brown [2000]; Calderon–Cheh [2002]) a pénzügyi adatbányászatot elemzik a neurális programozási módszereken keresztül.

Speciális adatbányászati eljárások, módszerek a pénzügyi instrumentumok elemzésében

Dattilo és társai a mérlegadatok elemzéséhez egy a különböző adatbányászati és osztályozási technikák kombinált felhasználásával megvalósított *DMTool* nevű rendszert készítettek (Dattilo et al. 2000). A rendszerük architektúráját és fő funkcionális szempontjait az olasz vállalatok mérlegeinek osztályozási és adatleírási folyamatának egészére terjesztették ki. Ez a modell integrált környezetet biztosított az adatok kezeléséhez és osztályozásához, valamint az eredmények elemzéséhez. Alapvetően klaszterezési és döntési faindukciós algoritmust használtak (uo.).

A felhasználók a grafikus felhasználói felület segítségével léptek kapcsolatba a rendszerrel, amely lehetővé tette az eredeti adatok egyszerű feldolgozását a forrásadatbázisban. A rendszer több „archívumot” kezelt: a forrásadatbázist, a céladatbázist, amely egy adott feladathoz manipulált adatokat tartalmazott, valamint egy harmadik adatbázist, amely az adatokból származó modelleket tárolta. Az utolsó archívumban fontos információkat tároltak a modell leírásával és osztályozásával kapcsolatban. A rendszer fő moduljai a következők voltak: céladatkezelő modul, amely az eredeti adatok egy részhalmazának (céladatok) kiválasztására szolgált és az osztálykezelő modul, amely egyszerű és rugalmas funkciókat kínált az osztályok meghatározásához (Dattilo et al. 2000).

A fő adatbányászati komponens az indukciós modul volt, amely lehetővé tette egy új osztályozási modell létrehozását. Az indukció magja a döntési fák indukálására szolgáló algoritmus volt. A művelet eredményeként létrejött mátrix lehetővé tette, hogy meghatározásra kerüljenek a hibás osztályozások (Dattilo et al. 2000).

Dattilo és társai (2000) az olasz vállalatok mérlegeinek pénzügyi elemzésében olyan alkalmazást használtak, amelyben ötvözik a különböző osztályozási technikákat, a döntési fák indítását és a klaszterezési technikát (Dattilo et al. 2000). Olyan adatszerkezetet hoztak létre, amely az összes olasz vállalat mérlegeit tartalmazta. A legérdekesebb adatok egy táblázatban voltak tárolva, amely éves lebontásban 520 000 adatot és 27 elemet (attribútumot) tartalmazott (például eszközöket, forgalmat, nyereséget, adósságot). Először az „adatjai” megszüntetése érdekében: (1) csak az 1998-as adatokat tárolták (az előző évek hiányos információi miatt); (2) december 31-én lezárt mérlegeket (az egészségesség miatt); (3) külön-külön elemezték a különféle szegmensbe tartozó vállalatokat (Dattilo et al. 2000).

Dattilo és társai (2000) az adatokat normalizálták, a reálértékeket 106 tényezővel skálázták, addig, míg a százalékértékek *csonkultak*. A kiválasztott iparági szegmensre 3000 párhuzamosot, attribútumot hoztak létre. Az adatbányászati technikákat a következő módon kombinálták: a mérleg elemzéséhez először a standard osztályozási technikákat alkalmazták, majd a döntési fák indítását és a Bayes-féle klaszterezést az osztályok meghatározására. Az osztályok meghatározásához a javasolt kritériumok attribútumának megoszlása az alábbiak szerint történt: 1. osztály: Eszközök <5; 2. osztály: 5 <Eszközök <10; 3. osztály: 10 <Eszközök <22; 4. osztály: 22 <Eszközök <38; 5. osztály: 38 <Eszközök <63; 6. osztály: 63 <Eszközök <140 és 7. osztály: Eszközök > 140 (Dattilo et al. 2000).

Egy másik megoldás szerint párhuzamos szimulációs programot állítottak össze egyetlen vállalat számára a mérleg logikája alapján. Li Zhang és társai (2011) munkájának alapvető célja a mérlegellenőrzések keresztmetszetében a nagyvállalati csoportok rendszerellenőrzésében felmerülő problémák feltárása volt. A szokatlan adatok kiszűrését, az adatok elemzését a korrelációs analízis szabályaival, kombinált adatbányászati módszerekkel, statisztikai modellek segítségével végezték (Zhang–Wang–Zhang 2011).

A vizsgálat több mint 500 vállalat párhuzamos szimulációjával valósult meg. Az eredmény alapján a kiszűrt kockázati tényező-elemek: a befektetett eszközök, a folyamatban levő építés, az egyéb kötelezettségek, a követelés és készlet számviteli tételek és számlák voltak (Zhang–Wang–Zhang 2011).

A párhuzamos szimulációs VBA alapú rendszert úgy alakították ki, hogy a vállalatok beszámolójának beadása után a rendszer automatikusan egy újabb mérleget, be-

számolót generált, meghatározva a kockázatokat. A minimum- és maximumértékek és az eredeti és a generált beszámoló összehasonlítása alapján mutatta ki a különbségeket *fetch logika* szerint, alkalmazva a különböző eljárásokban a regresszióanalízis módszereit (Zhang–Wang–Zhang 2011).

Számos kutató vizsgálta az adatbányászat alkalmazását a számvitelben. Mindazonáltal mindegyik kutató a tágabb témakör speciális aspektusára összpontosított, és egyikünk sem tudott egy használható átfogó áttekintést adni (Zhang–Wang–Zhang 2011).

Foltin és Garceau az egyik korai tanulmányában bemutatta a szakértői rendszerek és a neurális hálózatok közötti különbségeket és a neurális hálózatok alkalmazásának jövőjét a könyvelésben (Foltin–Garceau 1996).

Coakley és Brown a neurális hálózatok számviteli és pénzügyi modellezési kérdéseivel foglalkoztak (Coakley–Brown 2000), Calderon és Cheh a jövőbeli ideghálózati kutatásokról szóló könyvvizsgálati és kockázatértékelési ütemtervet készített (Calderon–Cheh 2002), Koskivaara pedig felülvizsgálta a neurális hálózatok használatát a könyvvizsgálatban, elsősorban az analitikai felülvizsgálati eljárásokra tekintettel (Koskivaara 2004a).

Gray és Debreceny taxonómiát vezettek be az adatok bányászatának a pénzügyi kimutatások auditálásával összefüggő csalás felderítésével kapcsolatosan (Gray–Debreceny 2014).

A pénzügyi teljesítményelemzés során a méret és a szektor homogenitását figyelembe véve Hofmann és Lampe a logisztikai szolgáltatók mérlegstruktúrájára klaszterezést alkalmaztak (Hofmann–Lampe 2013).

Eklund és társai önorganizáló térképeket használtak fel egy pénzügyi teljesítmény-mutató modell kialakításához (Eklund 2008).

A szakirodalmi elemzések szerint az adatbányászati eszközök 82%-a prediktív, 11%-a leíró és 7%-a előíró jellegű. **A szakirodalom elemzése azt mutatja, hogy a neurális hálózatok a legszélesebb körben alkalmazott adatelemzési módszer.** Az alkalmazások majdnem fele (47%) ezt az elemzési technikát használta. Az ideghálózatok ilyen dominanciája az ideghálózatok természetéből fakadhat, mint általános problémamegoldó technika, amelyet minden adatbányászati típusban, feladat és üzleti probléma során alkalmaznak. A regresszió az alkalmazások 20%-át adta. Mögötte szerepel 14%-ban a döntési fák, támogató vektoros gépek és genetikai algoritmusok, melyeket az alkalmazások 11%-a használt. Más kevésbé széles körben alkalmazott technikák közé tartoznak: önszerveződő térképek, k-legközelebbi szomszéd módszer, diszkriminanciaelemzés, társulási szabályok, esetalapú érvelés, klaszterezés.

A pénzügyi számviteli alkalmazások elsősorban a pénzügyi teljesítményt és az elemzést vizsgálták. Az adatbányászat egyik legkorábbi alkalmazása ezen a területen Callen és társai munkája (1996), amelyben egy ideghálózati modellt építettek a negyedéves számviteli bevételek előrejelzésére. Ez a munka összehasonlította a neurális hálózatokat a lineáris idősor-előrejelző modellekkel, és beszámolt arról, hogy a lineáris idősoros modellek jobb negyedéves jövedelem-előrejelzéseket eredményeztek, mint egy mesterséges neurális hálózati modell. Azonban Callen és munkatársai (1996) kísérletének *replikálhatósága* nehéz volt az idegi hálózati modell pontos meghatározásának hiánya miatt (Callen 1996).

Back és társai (2001) önszerveződő térképeket használtak, összehasonlítva a számszerű adatokból nyert vállalati teljesítményt és az éves beszámolókból levont szöveget (uo.).

Hasonlóképpen, de elsősorban a jövőre összpontosítva, Kloptchenko és társai (2004), valamint Magnusson és társai (2005) adatbányászati technikákat használtak a pénzügyi beszámolók mennyiségi és minőségi tartalmának elemzésére a jövőbeli pénzügyi teljesítmény megjósolásához. Mindketten arra a következtetésre jutottak, hogy míg a szöveges tartalom jobban tájékoztatja a vállalatokat a jövőbeli teljesítményről, a mennyiségi tartalom a múltbeli teljesítmény vizsgálatára irányult (Kloptchenko 2004; Magnusson 2005).

A pénzügyi számvitel adatbányászata elsősorban a pénzügyi teljesítményre és az arányelemzésre összpontosított, mint például a negyedéves számviteli bevételek előrejelzésére, a numerikus és a szöveges adatok összehasonlítására, a teljesítmény mérésére, a pénzügyi teljesítmény értékelésére, az éves jelentések kockázati tényezőinek azonosítására, a számviteli adatok mintázatainak vizualizálására, a pénzügyi jelentések alapjául szolgáló könyvelési adatok minőségi értékelésére. Ezek az alkalmazások elsősorban a leírásra és a predikcióra összpontosítottak. A neurális hálózatok és a szövegbányászat ezen alkalmazásainak típusai a legelterjedtebb technikának bizonyultak. Az üzleti életben a kutatók az adatbányászat alkalmazásának három fő területére összpontosítottak: a *i*) pénzügyi életképességre, az *ii*) üzleti kudarcra és a *iii*) jó üzletmenet folytatására: *i*) az adatbányászati elemzés tekintetében a legjelentősebb – a *pénzügyi életképesség* vizsgálatát elemző – Etheridge és társai munkája (Etheridge et al. 2000); *ii*) az *üzleti kudarcot* Ahn és társai; Chakraborty és Sharma; Chi és Tang; Huang és társai; Youn és Gu; Benhayoun és társai; Chen; Chen és társai; Li és társai dolgozták fel adatbányászati szempontól (Ahn et al. 2000; Chakraborty–Sharma 2007; Chi–Tang 2005; Huang et al. 2008; Youn–Gu 2010; Benhayoun et al. 2013; Chen et al. 2013; Li et al. 2013); *iii*) az *előrejelzések, megelőzések és kudarcok* feldolgozását Alam és társai; Tung és társai; Boyacioglu és társai; Quek és társai adatbányászatiilag végezték el. Ezeknek a kutató-

soknak a közös jellemzője, hogy szinte mindegyikük hibrid adatbányászati modellezési megközelítést alkalmazott. A legfontosabb megállapítások egy részét az jelentette, hogy a teljes hibaarány-mutató figyelembevétele, a neurális hálózat a pénzügyi életképesség előrejelzésének legmegbízhatóbb eszközeként jelent meg. Chen (2013) beszámolt arról, hogy a különböző neurális hálózatok tanulási technikái különböző előrejelzési pontossággal rendelkeznek az időhorizonton. Tang és Chi 2005-ben vizsgálták a hálózati architektúra, a változó szelekció, a mintakeverék-képzés és a tesztelés részhalmazait, a neurális hálózati modellek tanulási és előrejelzési képességét (Alam et al. 2000; Tung et al. 2004; Boyacioglu et al. 2009; Quek et al. 2009; Chen et al. 2013; Chi–Tang 2005).

A vállalatok folyamatos működésének megítéléséhez, a várakozáson alapuló minősítés előrejelzéséhez Peel a logisztikus regressziót alkalmazta, és megállapította, hogy a magas átértékelés, az alacsony nyereségesség és az alacsony tulajdoni koncentráció következetesen összefüggésbe hozható a könyvvizsgáló azon döntésével, hogy folyamatosan foglalkozik a minősítéssel (Peel 1989).

Koh és Tan, Lenard és társai, Koh és Low a logisztikus regressziót, valamint a neurális hálózatokat és döntési fákat alkalmazták a cégek folyamatos működésének megjósolására (Koh–Tan 1999; Lenard et al. 1995; Koh–Low 2004).

Koh és Low a döntési fa fölényét jelezték előrejelző modellként a neurális hálózatok és a logisztikus regresszió ellenében (Koh–Low 2004).

Lenard és társai kidolgozták a fuzzy klaszterezésre és egy statisztikai modell hibrid modelljére a vállalati üzleti értékelési modellt (Lenard et al. 1995).

Martens és társai konstruáltak egy hatékony, folyamatosan működő, prediktív rendszert támogató vektoros gépet, szabályalapú osztályozók bevonásával (Martens et al. 2008).

Shirata és Sakagami a pénzügyi beszámolóknak közzétett nem pénzügyi (kvalitatív) információk elemzésével a szöveges bányászatot használták a „megfontolt” és a „nem megfontolt” vállalatok közötti különbség tisztázására (Shirata–Sakagami 2008).

Doumpos és társai kifejlesztettek egy támogató vektor gépmodellt, amely ötvözi a nyilvánosan elérhető pénzügyi információkat és a hitelkockázat-mutatókat az ellenőrzési jelentésekben szereplő képesítések magyarázatával. A legfontosabb következtetés, amivel szembesültek, hogy a lineáris és nemlineáris támogató vektoros gépek, modellek képesek megkülönböztetni a képzett és nem minősített pénzügyi kimutatásokat időfüggvény-tekintet nélkül (Doumpos et al. 2005).

Spathis a logisztikus regressziót és a rendes legkisebb négyzetek regresszióját használta fel annak tesztelésére, hogy a pénzügyi és nem pénzügyi információk kombinációi milyen mértékben használhatók fel arra, hogy megkülönböztessék a minősített

vagy nem minősített könyvvizsgálói jelentés eredményeit. A minősítési döntéshez olyan pénzügyi információk társultak, mint a pénzügyi nehézségek és a nem pénzügyi információk (mint például a peres eljárás) (Spathis 2003).

Salterio esetalapú érvelést használt annak vizsgálata során, hogy a precedensek és az ügyfél preferált számviteli politikája befolyásolja-e a könyvvizsgálói számviteli politika döntéseit (Salterio 1996).

Kirkos és társai (2007a), valamint Gaganis és társai (2007a, 2007b) az adatbányászat felhasználására összpontosítottak a minősített könyvvizsgálói jelentések azonosítására. Pontosabban, Murugan Anandarajan és Asokan A. Anandarajan (1999) összehasonlították a neurális hálózatok, a szakértői rendszerek és a többszörös diszkriminancia-analízis prediktív képességét abból a szempontból, hogy milyen típusú (módosított vagy visszautasított) folyamatos üzleti jelentést kell kiadni (Anandarajan–Anandarajan 1999).

A jövedelemgazdálkodás előrejelzésének területén Tsai és Chiou (2009) olyan neurális hálózatokat és döntésifa-modelleket fejlesztettek ki, amelyeket a befektetők a jövedelemkezelés szintjének előrejelzésével és a bevételek felfelé vagy lefelé irányításával használnak (Tsai–Chiou 2009).

Tsai és Chiou (2009) eredményei azt mutatták, hogy az adatbányászati technikák használata jelentősen javította a jövedelemkezelés előrejelzését és a generált döntési szabályokat, amelyek segítenek a jövedelemkezelés kimutatásában (Tsai–Chiou 2009).

Másrészről Ezazi és társai (2013) megvizsgálták a különböző adatbányászati technikák hasznosságát a jövedelemkezelés előrejelzésében, megkérdőjelezve a linearitás feltevését az eredményelszámolási folyamat modellezésében. Arra a következtetésre jutottak, hogy a jövedelemkezelés előrejelzésére vonatkozó nemlineáris megközelítés hatékonyabb, mint egy lineáris megközelítés (Ezazi et al. 2013).

A jövedelemkezelés kimutatására összpontosítva Hoglund a különböző adatbányászati technikák teljesítményét értékelte (Hoglund 2012). Az eredmények azt mutatták, hogy a genetikai algoritmusok magasabb rendűek, mint más csoportosítási módszerek. Az idősoros becslésre vonatkozó adatok tekintetében Hoglund úgy találta, hogy a fuzzy lineáris regressziós alapú modell felülmúlja a regressziós alapú modelleket a szimulált jövedelemkezelés kimutatásában (Hoglund 2013).

Song és társai (2013) megvizsgálták a jövedelemkezelés és az eszközök hűtlen kezelése közötti kapcsolatot, és megállapították, hogy az eszközök hűtlen használata jelentősen pozitív kapcsolatban áll a diszkrecionális felhalmozódással (Song et al. 2013).

Carlos Leon (2017) tanulmányában a kolumbiai bankok 2000–2014-es havi 25 számla mérlegadataira mesterséges neurálishálózat-felismerési módszert alkalmazott

annak megvizsgálására, hogy lehetséges-e azok pontos minősítése. Az eredmények azt mutatták, hogy a választott módszer képes a mintapénztárak mérleg fő jellemzőinek megtanulására és nagy pontossággal történő besorolására. Az eredmények megerősítették a kutatókat, hogy a mérlegek egyediek és reprezentatívak minden egyes bank számára, és hogy egy mesterséges neurális hálózat képes ezt felismerni (Leon 2017).

Neves és társai modelleljárásukhoz genetikai algoritmust alkalmaztak. A 2008-as és 2009-es évekre vonatkozó likviditás- (pénzügyi helyzet), jövedelmezőség- (gazdasági helyzet) és adósság- (tőke struktúra) mérlegadatokat használtak a bevont állományokban. A tanulmányukban adaptációs függvényt használtak annak megvizsgálására, hogy a likviditás, a nyereségesség és az adósság indexek mindegyikének aránya jelentősen javult-e a bázisétől a következőig. A program ezután összehasonlította ezt az eredményt a korábban létrehozott indexmintával annak megállapítására, hogy van-e javulás, vagy stabil maradt-e, vagy akár bármely elemzett index csökkent-e (Neves et al. 2011).

Steve Yang és Randy Cogill a mérlegek elemzéséhez klaszterezési módszereket alkalmaztak. Vizsgálták a költségmódosításokat és mérték a változások következményeit. Rendszerszintű algoritmust használtak a pénzügyi kimutatások tulajdonságsorának megalkotásához. A kiválasztott vállalatok klaszterezésére a *Ward-módszert* alkalmazták. 2010-ben a vállalatok 90%-át a megfelelő csoportokba csoportosították. 2011-ben összességében összesen nyolc céget találtak, amelyek nem voltak összhangban az iparágukkal (Yang–Cogill 2013). A klaszterezési módszer feltáró eszköznek bizonyult, amely lehetővé tette az elemzők számára, hogy vizuálisan vizsgálják meg a mintákat több változó alapján. Vizsgálatuk alapján egy pontosabb statisztikai osztályozási szabályt lehet kidolgozni a képzési adatlap figyelembevételével. Következtetésük szerint, ha egy vállalat egy bizonyos iparághoz tartozik és mégis egy másik iparágba sorolható, akkor ezt a vállalatot kiemelkedőnek tekintették, és különös figyelmet fordítottak az ok magyarázatára. A tanulmány legfontosabb megállapítása, hogy megerősíti azt a hipotézist, miszerint a mérlegen belüli szerkezeti eltérés kimutatható a grafikon metrikájával (Yang-Cogill 2013).

Ballarin és társai tanulmánya szerint az egyik legfontosabb probléma, amelyet fel kell oldani, hogy a mérlegtételek hogyan kapcsolódnak a cég sikeréhez. A tanulmány olyan idegi osztályozót ír le, amelynek fő feladata a vállalat mérlegtételekkel kapcsolatos lehetőségeinek leírása. A legfontosabb olasz textil ipari vállalatok legutóbbi három évének mérlegtételét használták fel az elemzésükhöz. *Visszaforgatási algoritmust* alkalmaztak a tanulási és tesztelési esetek konvergenciájának végrehajtására. Egy szimulált esetekre épülő osztályozási rendszert alkalmaztak ahhoz, hogy meghatározzák, milyen

pénzügyi profilra van szüksége a vállalkozásnak ahhoz, hogy versenyképes legyen. Ez a módszertan fontos információkkal szolgált arra vonatkozóan, mit kell megtennie a vállalatnak annak érdekében, hogy növelje versenyképességét (Ballarin et al. 1995).

A pénzügyi stratégiai elemzés olyan eszköz, amely segítséget nyújt a vállalatok eredményeinek optimalizálásához. A stratégiai tervezési módszertan a céges eredmények elemzéséből indul ki, és megpróbálja előre megjósolni a vállalat jövőbeni viselkedését. Tekintettel arra, hogy ez nem ad egyértelmű választ, ezért neurális osztályozók használatával határozták meg, hogyan lehet maximalizálni az előre meghatározott pénzügyi tételeket (Ballarin et al. 1995). A modell lényege, hogy egy olyan osztályozási rendszer valósult meg, amelynek elsődleges feladata egy sikeres vállalat gazdasági profiljának azonosítása és ennek inverz oldala. N év adatait használták az $N + 1$ év pénzügyi éveinek egy részhalmazára vonatkozó gazdasági viselkedés előrejelzésére. Az alkalmazott modell hasonló a *multivariáns diszkriminanciaanalízis* során alkalmazottakhoz. Ennek a technikának a legkritikusabb pontjai, amelyek minden alkalmazásproblémában felmerültek: *i*) az elemzéshez felhasznált tételek kiválasztása; *ii*) a vállalati minta osztályozása során elkövetett hibamennyiség (a besorolási hiba értéke közvetlenül arányos a becslési idő növekedésével); *iii*) a társadalmi és gazdasági feltételek, amelyek mellett a vállalkozásnak működnie kell.

Azt tapasztalták, hogy az idegi osztályozó könnyen megkerüli mindhárom korlátot. Először is megvizsgálták a vállalat elemzésére rendelkezésre álló összes elemet, anélkül, hogy figyelembe vették volna az adott elem *a priori* jelentőségét vagy fontosságát. Másodszor, egy neurális osztályozó minősítési teljesítményét vezették be a vállalat gazdasági teljesítményének azonosításához (Ballarin et al. 1995). Az adatokat a CERVED- (az olasz kereskedelmi kamarák informatikai szolgáltatója) adatbázisokból nyerték ki. Megvizsgálták az 50 legfontosabb ruházati-textilipari vállalkozást az 1991-es, 1993-as időszakra vonatkozóan (Ballarin et al. 1995).

Minden mérlegben figyelembe vették a következő elemeket:

1. nettó értékesítés,
2. munkaerőköltség,
3. kereskedelmi eredmények,
4. ROE,
5. saját tőke,
6. harmadik személyek eszközei,
7. bruttó állóeszközök,
8. nettó állóeszközök,

9. bruttó eszközök,
10. nettó eszközök,
11. pénzeszközök,
12. értékhelyesbítések értékei,
13. strukturális különbség.

Az 1991-es és 1992-es évekre ezen elemeknek az értékeit jósolták meg *i)* a ROE-ra vonatkozóan, *ii)* a nettó árbevétel növekedését (vagy csökkenését), *iii)* a kereskedelmi eredmények növekedését (vagy csökkenését) (Ballarin et al. 1995).

A neurális hálózat felépítéséhez három különböző idegi osztályozót használtak. Mindhárom rendszer 1–14 bemeneti tétellel rendelkezett. Minden osztályozó esetében a hálózati kimenet a cég sikerének mércéje lett. Három neurális osztályozót építettek ki, mindegyiknek egy kimeneti neuronja lett. Ez a neuron csak két értéket vett fel – 0 vagy 1, a sikertől függően (0 = nem sikeres, 1 = sikeres) (Ballarin et al. 1995).

150 mérlegtételt dolgoztak fel, és egy többrétegű, teljes összeköttetésű *feed-forward* hálózatot használtak egy *sigmoid aktiválási funkcióval*. A tanulási fázis egy algoritmus segítségével került kifejlesztésre, és az általánosított *delta szabályt* és a *gradiens szabályt* használták. A tanulási fájl 70, míg a tesztfájl 80 esetet tartalmazott. A három kifejlesztett hálózat, osztályozási rendszer: a ROE, a nettó árbevétel-változás és a kereskedelmi eredmények összevont teljesítményük változását mutatták (Ballarin et al. 1995). A lineáris korrelációs mátrixot a *k* és *h* elemek között adták meg. A lineáris korrelációs analízis a várt módon kölcsönös kapcsolatot mutatott, amelynek értékei a 70% és 95% közötti értékek között voltak. A lineárisan független változók a következő bemeneti változók lettek: kereskedelmi eredmények, ROE, saját tőke, értékhelyesbítés (Ballarin et al. 1995).

Miután meghatározták, hogy mely változók voltak lineárisan függetlenek, az összes lehetséges mintát úgy állították elő, hogy a független változók által elért értékeket és a nettó értékesítési tétel által feltételezhető értékeket kombinálták, így 648 darab lehetséges profilt nyertek. Ezt a fájlt *szimulált esetfájlnak* nevezték el. Bemutattak minden olyan esetet, amely sem a tanulási fájlban, sem az érvényesítési fájlban nem volt megtalálható. A 648 szimulált esethez társítottak egy fix ad hoc profilt, amely megfelelt az eljárás során felhasznált esetek átlagának. Ezért a 648 szimulált eset mindegyikéhez a következő profilt társítottak: 1. osztály – kategória (6,12), nettó állóeszközök – 1. osztály – harmadik osztályú eszközök – 2. osztály – tartomány (25,60), bruttó állóeszköz – (30,60), nettó eszközök – 1. osztály – tartomány (30,60), pénzeszközök – 1. osztály – tartomány (30,60), süllyedő alapok – 1. osztály – tartomány (3,6) (Ballarin et al. 1995).

Az osztályozó felépítése és a helyes osztályozási teljesítmény ellenőrzése után a szimulált eseteket a rendszer feldolgozta. A három hálózat külön-külön történő használatával az alábbi eredményekhez jutottak a 648 szimulált esetben:

1. hálózat: ROE-analízis, output = [0,8, 1] 368 esetben (57%);
2. hálózat: nettó eladási különbség analízis, output = [0,8, 1] 213 esetben (33%);
3. hálózat: kereskedelmi eredménykülönbség analízis, kimenet = [0,8,1] 368 esetben (57%) (BALLARIN et al. 1995).

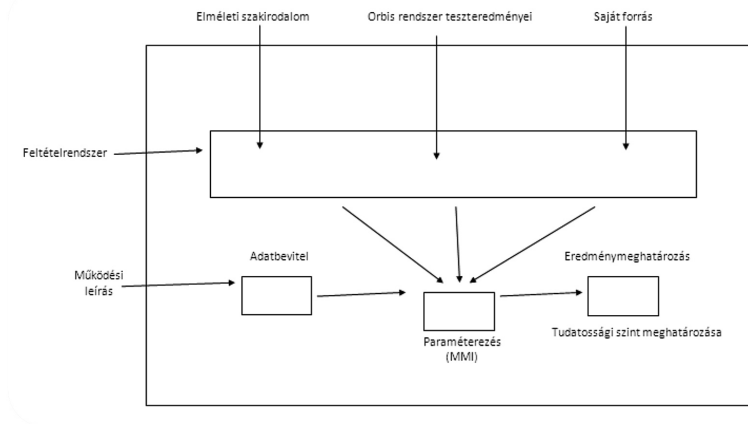
Végkövetkeztetésként arra jutottak, hogy *i*) a ROE-értéket növelő cégek koncentrálnak a korábbi év független tételeire, *ii*) ha a cégnek a korábban meghatározott független tételértékekkel kell rendelkeznie, akkor jó esélye lesz a ROE növelésére is, *iii*) egy vállalat növelni fogja a nettó árbevételét és a kereskedelmi eredményeit, ha a mérleg független tételek értékeit fogja felvenni, *iv*) a társadalmi-gazdasági környezet változásaira vonatkozóan nincs egyetlen módszer sem, amely a vállalkozás sikerének meghatározását adná, *v*) a ROE növekedését vállalati sikerként értékelték, de ezt nem tekintették előfeltételének, különösen a nettóárbevétel és a kereskedelmi eredmények összegének növekedését (Ballarin et al. 1995).

R. H. Berry és S. Nix tanulmányuk középpontjába a pénzügyi kimutatásokban használt regressziószámítást és az arányszámszámítást állították. Elemzésük alapja a Microexstat által nyújtott vállalati pénzügyi adatbázis adatai, mely adatbázis több mint 2500 brit vállalatból több mint 50 iparági besorolást tartalmazott. Négy egymást követő évben a sörfőzésre vonatkozó adatokat kivonták a Microexstatból, hogy megvizsgálhassák az eredmények stabilitását (Berry–Nix 1991). A regressziós analízis csak egy esetben azonosította az arányanalízis szigorúan arányos feltételezését. Ez az egyetlen eset, amikor a regressziós megközelítés különböző információkat szolgáltat az arányelemzéshez. Az analízis céljára szolgáló mutatószám kiválasztásához ideális esetben az elemzés kezdeti szakaszaiból kell kiindulni. **Kutatásuk szerint nem létezik egy alternatív, általában megfelelő egyszerű modell a kérdés megválaszolásához (uo.).**

A tudatosság modelljének felállítása és általános leírása

A modell 3 alapvető felületre különül el (1. ábra). Az első az adatbekérő felület. Itt kell megadni az értékeléshez az adatokat. Az adatbekérő felület alaptulajdonsága, hogy az adatokat 10 éves periódusban kell megadni. Ettől eltérő adatmegadás nem tudatos vállalati állapotot eredményez az értékelésben.

1. ábra: A tudatosság MMI-modellje



Forrás: saját forrás, saját szerkesztés

Az adatok bevitele után az adatok az értékelőmodulba kerülnek, amely külön rejtett felületen jelenik meg, ez a második felület, a modell „mesterséges intelligenciája”⁵ (a továbbiakban: MMI). Az adatokat az MMI összefüggéseiben értékeli. Az értékelőmodul 3 értékelési tartományba csatornázza az adatokat: *i*) nem tudatos vállalati viselkedésbe, *ii*) kevésbé tudatos viselkedésbe, és *iii*) tudatos vállalati viselkedésbe. A harmadik felület külön meg is jelenik eredményként. A bevitt adatokat az értékelőmodul először tudatossági sorrendbe helyezi, ezt szövegesen értékeli, és másodsorban számszerűen is alátámasztja az értékelést.

Az MMI-modell alapjául szolgáló feltételrendszert *i*) az elméleti szakirodalom megállapításainak absztrakciói és paraméterezései, *ii*) az Orbis⁶ rendszer teszteredményei és *iii*) az általam feltárt összefüggések alkotják. Az Orbis rendszer által használt innovációsminőség-meghatározást tovább adatvizualizáltam. Az adatok vizuális szegmentációjához 3 szoftvert használtam. A Power BI Desktopot, a Tableau 10.4 és a QlikSilk programot. Az adatok megjeleníthetősége tekintetében a Power BI Desktop bizonyult a leghasználhatóbbnak, ezért az általa megjelenített vizualizációt használtam fel.

5 Első körben a modellezéshez alapvetően *számító algoritmusokat* használtam fel. A modell e pontja helyettesíthető önmagától tanuló, érzékelő, előrejelző intelligenciával. Az ehhez kapcsolódó MMI-fejlesztés a Hozzáadott Érték Gazdaságkutató és Fejlesztési Intézetben folyik.

6 Kutatásom adatbázisát az Orbis Bureau van Dijk nemzetközi üzleti adatbázisának 2017. júliusi (a továbbiakban: Orbis) változata adta.

Az adatok alábbi formuláját használtam tesztelésre mind a két típusú adathalmazra.

1. egyenlet: Innovációs adatok aggregációja

$$|B| = \begin{bmatrix} \left\| \begin{matrix} V_1 & j_1 \\ I_1 & k_1 \end{matrix} \right\| & \left\| \begin{matrix} V_1 & j_2 \\ I_1 & k_2 \end{matrix} \right\| & \left\| \begin{matrix} V_1 & j_3 \\ I_1 & k_3 \end{matrix} \right\| & \dots & \left\| \begin{matrix} V_1 & j_m \\ I_1 & k_m \end{matrix} \right\| \\ \left\| \begin{matrix} V_2 & j_1 \\ I_2 & k_1 \end{matrix} \right\| & \left\| \begin{matrix} V_2 & j_2 \\ I_2 & k_2 \end{matrix} \right\| & \left\| \begin{matrix} V_2 & j_3 \\ I_2 & k_3 \end{matrix} \right\| & \dots & \left\| \begin{matrix} V_2 & j_m \\ I_2 & k_m \end{matrix} \right\| \\ \left\| \begin{matrix} V_3 & j_1 \\ I_3 & k_1 \end{matrix} \right\| & \left\| \begin{matrix} V_3 & j_2 \\ I_3 & k_2 \end{matrix} \right\| & \left\| \begin{matrix} V_3 & j_3 \\ I_3 & k_3 \end{matrix} \right\| & \dots & \left\| \begin{matrix} V_3 & j_m \\ I_3 & k_m \end{matrix} \right\| \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \left\| \begin{matrix} V_m & j_1 \\ I_m & k_1 \end{matrix} \right\| & \left\| \begin{matrix} V_m & j_2 \\ I_m & k_2 \end{matrix} \right\| & \left\| \begin{matrix} V_m & j_3 \\ I_m & k_3 \end{matrix} \right\| & \dots & \left\| \begin{matrix} V_m & j_m \\ I_m & k_m \end{matrix} \right\| \end{bmatrix}$$

ahol:

$|B|$ Innovációs mutatók adathalmaza

$V_{(i)}$ Nemzetközi vállalat (1–1000)

$I_{(i)}$ Minőségi változó (1–21)

$j_{(i)}$ Minőségi változó éves értéke (1–10)

$k_{(i)}$ Minőségi változó negyedéves értéke (1–10)

Forrás: saját forrás, saját szerkesztés

A k-közép klaszterezés adatvizualizációja mind a kettő tekintetében az innovációs portfóliót (Innovation strength – Portfolio value max) jelenítette meg elsőlegesként. Ezért a tudatosság modelljében ezt az értéket építem be az innovációt megjelenítő és minőséget meghatározó elemként.

Az Orbis rendszerből az adathalmazokat szétvágtam származtatott és nem származtatott, illetve éves és negyedéves adathalmazokra. Minden adatot faktoráltam, főkomponens-analízisnek vettem alá, majd klasztereztem. Elsődlegesen az adott faktort meghatározó elemeket vettem figyelembe, és elsődlegesen azokat szűrtem, amelyek 100 százalékban minden elemhalmazt tartalmaztak.

Különkiemeltem azokat az elemeket, amelyeket meghatározónak tekintettem, amelyeket a tudatosságmodellben elsődlegesen felhasználtam. Mind az információtechnológia, mind a egyes vállalatok tekintetében az alábbi 3 elem vált elsődlegesen a modellbe bevonható elemmé: Operating revenue (Turnover), Shareholders funds, Total assets. A nem származtatott részben az önálló faktorelemek vagy azok részei legalább 75%-ban: Cash flow, Shareholders funds per employee, Profit per employee, Total assets per

employee, Operating revenue per employee, Working capital per employee, Number of employees Year.

A származtatott mutatóknál a meghatározó elemek: Profit margin, EBITDA margin, Gross margin, P/L for period net income. A származtatott részben az önálló faktorelemek vagy azok részei legalább 75%-ban: ROE using P/L before tax, Net assets turnover Quarter, Solvency ratio (Asset based), ROCE using net income, ROA using net income.

Összességben az alábbi faktorokat különítettem el és csatornáztam be a későbbi elemzésekhez.

A **nem származtatott** elemek tekintetében:

1. FAKTOR

Operating revenue (Turnover),
Shareholders funds,
Total assets.

Cash flow (legalább 75%-ban mint a 100%-os faktorelemek [1. faktorban])

2. FAKTOR

Shareholders funds per employee (legalább 75%-ban mint a 100%-os faktorelemek [4, 2, 4 faktorban, ezért önálló faktornak vettem]).

3. FAKTOR

Profit per employee (legalább 75%-ban mint a 100%-os faktorelemek [2, 2, 3 faktorban, ezért önálló faktornak vettem]).

4. FAKTOR

Total assets per employee (legalább 75%-ban, mint a 100%-os faktorelemek [2, 4, 2, 2 faktorban, ezért önálló faktornak vettem]).

5. FAKTOR

Operating revenue per employee (legalább 75%-ban, mint a 100%-os faktorelemek [2, 2, 2, 3 faktorban, ezért önálló faktornak vettem]).

6. FAKTOR

Working capital per employee (legalább 75%-ban, mint a 100%-os faktorelemek [2, 4, 2 faktorban, ezért önálló faktornak vettem]).

7. FAKTOR

Number of employees Year (legalább 75%-ban, mint a 100%-os faktorelemek [3, 1, 1, 1 faktorban, ezért önálló faktornak vettem]).

A származtatott mutatók tekintetében:

1. FAKTOR

Profit margin,
EBITDA margin,
Gross margin.

2. FAKTOR

Net assets turnover (legalább 75%-ban, mint a 100%-os faktorelemek [1,2,1,3 faktorban ezért önálló faktornak vettem]).

3. FAKTOR

Solvency ratio (Asset based) (legalább 75%-ban, mint a 100%-os faktorelemek [3,1,1 faktorban ezért önálló faktornak vettem]).

4. FAKTOR

ROCE using Net income (legalább 75%-ban, mint a 100%-os faktorelemek [2,1,1 faktorban ezért önálló faktornak vettem]).

5. FAKTOR

ROA using Net income (legalább 75%-ban, mint a 100%-os faktorelemek [1,1,1 faktorban ezért önálló faktornak vettem]).

Az Orbis rendszerből nyert faktorokat az 1000 db számú elemszámhoz viszonyítottan határoztam meg, amelyeket a modellen belüli belső értékeként kezeltem.

A származtatott és nem származtatott mutatókból kinyert faktorokat az alábbiak szerint jellemezhetjük: *Profit per employee* – az egy alkalmazottra jutó nyereség egy olyan számveteli arány, amely a vállalat nyereségét méretének arányában fejezi ki, figyelembe véve a foglalkoztatottak számát. Az egy alkalmazottra jutó profit a társaság profitjának és az alkalmazottak számának hányadosa. Ez a szám megmutatja, hogy a vállalat mennyire profitábilis. Elméletileg minél nagyobb az egy munkavállalónkénti profit, annál tudatosabb a vállalat. Általában az ugyanabban az iparágban működő vállalatok össze-

hasonlítására használják. Ez azért van így, mert egyes vállalkozások ágazatainak több alkalmazottra van szükségük a bevételeikhez és nyereségükhöz, mint más ágazatoknak. Lowell Bryan szerint ez egy olyan mutató, amely azt a nyereséget mutatja meg, amellyel a vállalat munkavállalói tehetségük alapján a tőkét nyereséggé alakítják (Bryan 2017).

A *Total assets per employee* az egy alkalmazottra jutó eszköz. Az összes eszköz értékének és az alkalmazottak számának hányadosával írható fel. Mivel a vállalatok évente jelentik az alkalmazottak számát, ez a mutató csak évente egyszer jelenik meg az összesített kimutatásban.

Az egy alkalmazottra jutó bevétel (*Operating revenue per employee*) egy olyan arány, amelyet a vállalat bevétele alapján kell kiszámítani, az adott létszám hányadosaként. Akkor a leghasznosabb, ha az ugyanazon iparág többi vállalatával történik az összehasonlítás. Ideális esetben a vállalat a legmagasabb bevételt munkavállalónként kívánja elérni, mert ez a nagyobb termelékenységet és a vállalat erőforrásainak hatékony felhasználását jelzi.

Working capital per employee – az a mutatószám, amely kifejezi az alkalmazottak arányát a vállalat dolgozói tőkeösszegének arányában. A forgóeszközök és az alkalmazottak számának hányadosaként írható fel. Általában minél magasabb ez az arány, annál tudatosabb a vállalat. Ez azért van, mert ez azt jelenti, hogy több működő tőke biztosított egy alkalmazottra.

Number of employees – minél nagyobb az érték, annál tudatosabb a vállalat (1000 fős átlaghoz mérve vagy a bevitt adatokhoz képest).

Profit margin – a haszonkulcs a nettó bevétel és a nettó árbevétel (bevétel) hányadosaként határozható meg. Minél nagyobb, annál tudatosabb a vállalat.

EBITDA margin – az EBITDA és a bevételek százalékban kifejezett aránya. Az EBITDA ráta a vállalat működési jövedelmezőségének értékelését jelenti a teljes bevétel százalékában kifejezve. Az EBITDA margin a mutatónak az árbevételhez mért arányát fejezi ki, és a működés hatékonyságára utal. Minél nagyobb az érték, annál tudatosabb a vállalat. A bruttó árres a vállalat összes nettó árbevételének és a bruttó árrestőmeg hányadosaként kifejezett százalékos érték. Minél nagyobb ez az érték, annál tudatosabb a vállalat.

Net assets turnover – eszközérték. A vállalat értékesítéseinek vagy bevételeinek értékét méri a vagyona értékéhez viszonyítva. Az értékesítés és az átlagos összes eszköz értékének hányadosaként határozható meg.

Solvency ratio (Asset based) – szolvenciaarány. A szavatolótőke-mutató kulcsfontosságú mutatója a vállalkozás azon képességének mérésére, hogy teljesítse adósságát és egyéb kötelezettségeit. A szavatolótőke-mutató azt jelzi, hogy a vállalat cash flow-ja

elegendő-e a rövid és hosszú lejáratú kötelezettségek teljesítéséhez. Minél alacsonyabb a vállalat fizetőképességi mutatója, annál nagyobb az esélye, hogy az adóssághelyettesítést alapértelmezettnek fogja tekinteni. A szavatoló tőke értéke megmutatja, hogy egy esetleges csőd vagy felszámolás esetén mekkora vagyont áll rendelkezésre a hitelezők, betétesek kifizetésére.

A megtérülő tőke megtérülése (ROCE) olyan pénzügyi arány, amely méri a vállalat nyereségességét és a tőkebefektetés hatékonyságát. A ROCE értéke a kamat és az adó (EBIT), valamint a tőkebefektetés előtti eredményhányadosból akkumulálódik.

ROA using net income, azaz eszközök megtérülése az a mutató, amely jelzi, hogy a vállalat nyeresége-e az összes eszközhöz viszonyítva. Azt mutatja meg, hogy a vállalat milyen hatékonyan tartja eszközeinek bevételszerzését. Az eszközök megtérülése százalékban jelenik meg, és kiszámítása a nettó bevétel és az összes eszköz értékének hányadosaként történik. Minél magasabb a mutató értéke, annál nagyobb hozamot ér el a társaság az eszközeinek működtetésével. A mutató értékének tükröznie kell az adott tevékenység üzleti kockázatát, tehát egy kockázatosabb tevékenységet folytató vállalkozásnál hosszabb távon a ROA értékének magasabbnak kell lennie.

Az elméleti szakirodalomban lefektetett tudatossági peremfeltételek nagy részben megegyeznek az elemzéseim eredményeivel. Az elméleti szakirodalmi megállapításokat az empirikus vizsgálatok visszaigazolták. A fontos tudatossági peremfeltételek, amelyek mind a két halmazban szerepelnek: munkavállalók száma, bruttó árres, bevételi értékek, likviditás, szolvencia.

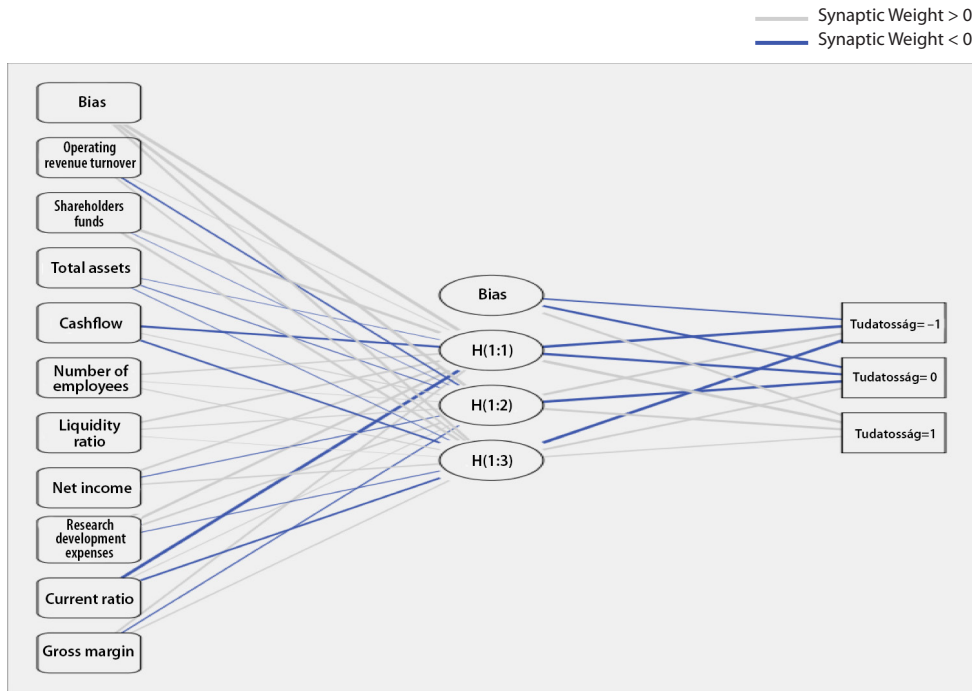
Következtetések

A tudatosság modelljének értékelése és tesztelése

A neurális modellezés során 40 vállalat elemeit teszteltem 10 minőségi változó megadásával. A tudatossági szinteket (1 = tudatos, 0 = kevésbé tudatos, -1 = nem tudatos) értékszint beállításával határoztam meg.

Az eredmények között az alábbi automatikusan generált MLP architektúrát kaptam, amelyben látható, hogy a bemeneti rétegben egy-egy elem felel meg a három kvantitatív független változónak, egy pedig a „Bias” torzításokat igyekezett csökkenteni. A rejtett rétegben négy feldolgozó elem található, a kimeneti rétegben egy-egy elem felel meg a független tudatosság „target” változó három lehetséges értékének.

2. ábra: INfoalldt 7 tudatosságmodell neurálisháló-eredményei



Hidden layer activation function: Hyperbolic tangent
 Output layer activation function: Softmax

Forrás: saját készítés, saját forrás

A *Model Summary* táblázat mutatja, hogy a Training és Testing során jól működik a modell: a Cross Entropy Error kicsi (a Training mintára: 0,010, a Testingre 0,012), és a téves besorolások aránya (Percent Incorrect Predictions) 0%. A *Classification* táblázat mutatja, hogy a modell a Training során minden elemet helyesen azonosított, és hasonló azonosítást végzett a Testing során. Az azonosítások eredményei az adateditorban is megjelentek (1. táblázat).

7 Az INfoalldt jelentése: az Orbis NAICS 2012 statisztikai kódrendszer szerinti 51 kódjelzésű információtechnológiai vállalatokat jelenti, magába foglalja alapvetően az adatszolgáltatási, a telekommunikációs, az internet- és a szoftveripari vállalatokat.

1. táblázat: INfoalldt tudatosságmodell összefoglaló táblázata

Model Summary

Training	Cross Entropy Error	,010
	Percent Incorrect Predictions	0,0%
	Stopping Rule Used	1 consecutive step(s) with no decrease in error ^a
	Training Time	0:00:00,00
Testing	Cross Entropy Error	,012
	Percent Incorrect Predictions	0,0%

Dependent Variable: A tudatosság szintjei

^a Error computations are based on the testing sample.

Classification

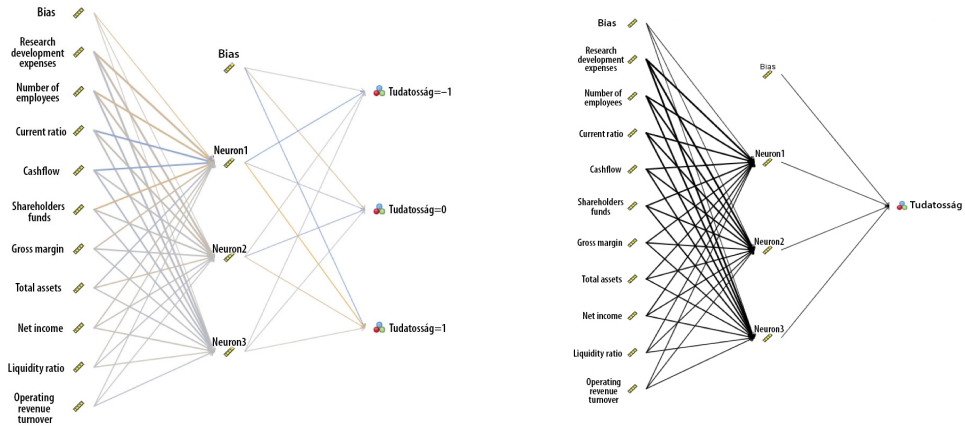
SAMPLE	OBSERVED	PREDICTED			
		nem tudatos	kevésbé tudatos	tudatos	Percent Correct
Training	nem tudatos	4	0	0	100,0%
	kevésbé tudatos	0	1	0	100,0%
	tudatos	0	0	27	100,0%
	Overall Percent	12,5%	3,1%	84,4%	100,0%
Testing	nem tudatos	0	0	0	0,0%
	kevésbé tudatos	0	0	0	0,0%
	tudatos	0	0	9	100,0%
	Overall Percent	0,0%	0,0%	100,0%	100,0%

Dependent Variable: A tudatosság szintjei

Forrás: saját forrás, saját szerkesztés

A 3. ábra az összefüggések mélyebb, árnyaltabb rétegeit mutatja be. A Classification táblázat Overall Percent Correct értéke 97,6%, és a modell illeszkedésére 100%-os illeszkedési mutatót hozott. A Predictor Importance mutató az innovációnál volt a legnagyobb. Összességében a Modell Summary 95,8%-os eredményt mutatott.

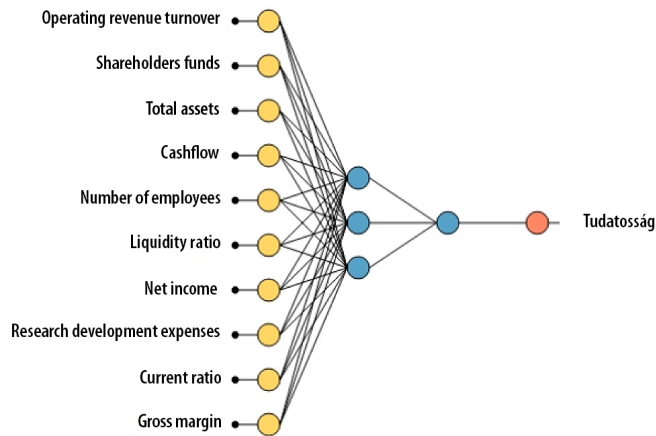
3. ábra: A tudatosságmodell neurális háló általi megjelenítése fekete-fehér színben (INfoalldt)



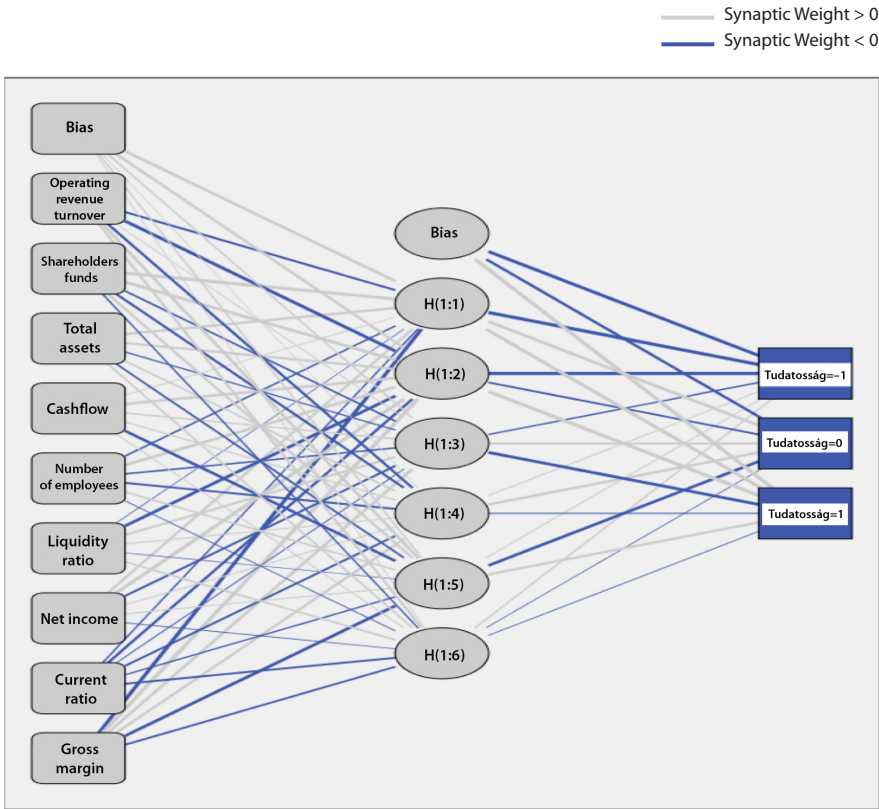
Forrás: saját forrás, saját szerkesztés

A tudatosságmodell hálózati architektúrájának grafikus ábrázolását mutatja a lenti ábra, amely egy skálázó réteget, neurális hálózatot és valószínűségi réteget tartalmaz. A világos körök reprezentálják a neuronokat, a sötétebb körök a perceptron neuronjait, a végső körök pedig a valószínűségi neuronokat. A bemenetek száma 10, a kimenetek száma pedig 1. A rejtett neuronok száma által képviselt komplexitás 3.

4. ábra: A tudatosságmodell neurális háló általi megjelenítése fekete-fehér színben (INfoalldt 2)



Forrás: saját forrás, saját szerkesztés

5. ábra: NAICS2012⁸ tudatosságmodell neurálisháló-eredményei

Hidden layer activation function: Hyperbolic tangent
Output layer activation function: Softmax

Forrás: saját forrás, saját szerkesztés

Az Infoalldt eredményéhez hasonló, a egyes vállalatokra vonatkozóan az alábbi automatikusan generált MLP architektúrát kaptam, amelyben látható, hogy a bemeneti rétegben egy-egy elem felel meg a három kvantitatív független változónak, egy pedig a „Bias” torzításokat igyekezett csökkenteni. A rejtett rétegben hat feldolgozóelem található, a kimeneti rétegben egy-egy elem felel meg a független tudatosság „target” változó három lehetséges értékének.

8 NAICS2012 jelentése: az Orbis rendszer szerint az ún. ipari szegmentálás nélküli, vegyes vállalati adathalmaz.

A Model Summary táblázat mutatja, hogy a Training és Testing során jól működik a modell: Cross Entropy Error kicsi (a Training mintára: 1,467, a Testingre 0,353), és a téves besorolások aránya (Percent Incorrect Predictions) 0%. Az alábbi Classification táblázat mutatja, hogy a modell a Training során minden elemet helyesen azonosított, és a Testing során hasonló azonosítást végzett a modell. Az azonosítások eredményei az adat editorban is megjelentek (2. táblázat).

2. táblázat: NAICS2012 tudatosság modell összefoglaló táblázata

Model Summary

Training	Cross Entropy Error	1,467
	Percent Incorrect Predictions	0,0%
	Stopping Rule Used	1 consecutive step(s) with no decrease in error ^a
	Training Time	0:00:00,06
Testing	Cross Entropy Error	,353
	Percent Incorrect Predictions	0,0%

Dependent Variable: Tudatosság szintjei

^a Error computations are based on the testing sample

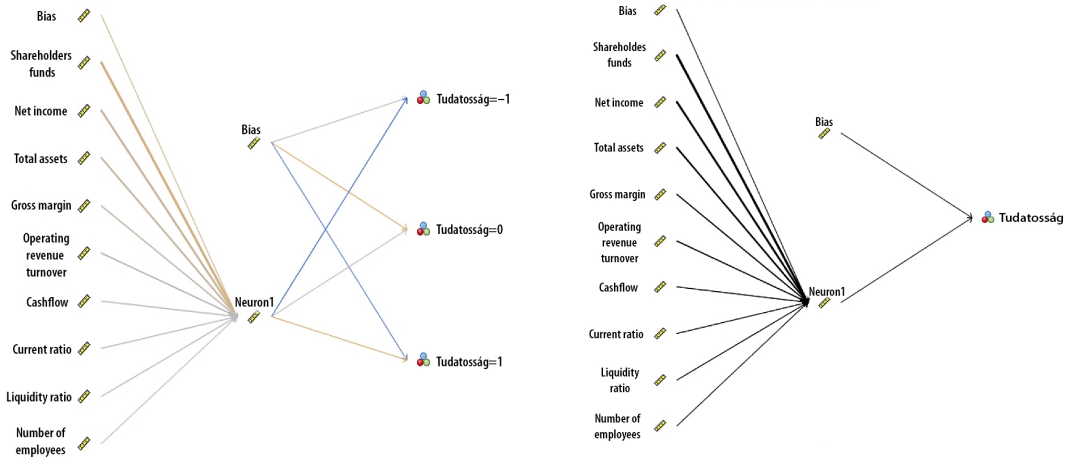
Classification

SAMPLE	OBSERVED	PREDICTED			
		nem tudatos	kevésbé tudatos	tudatos	Percent Correct
Training	nem tudatos	8	0	0	100,0%
	kevésbé tudatos	0	1	0	100,0%
	tudatos	0	0	22	100,0%
	Overall Percent	25,8%	3,2%	71,0%	100,0%
Testing	nem tudatos	4	0	0	100,0%
	kevésbé tudatos	0	0	0	0,0%
	tudatos	0	0	9	100,0%
	Overall Percent	44,4%	0,0%	55,6%	100,0%

Dependent Variable: Tudatosság szintjei

A Classification táblázat Overall Percent Correct értéke 95% és a modell illeszkedésére 100%-os illeszkedési mutatót hozott. A Predictor Importance mutató a tudatossághoz viszonyítva az innovációé a legnagyobb. Összességében a Modell Summary 95,6% eredményt mutatott.

6. ábra. A tudatosság modell neurális háló általi megjelenítése NAICS2012



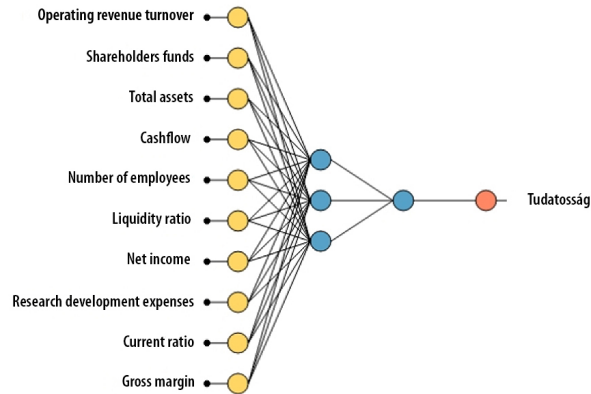
A tudatosságmodell hálózati architektúrájának vegyes vállalatokra vonatkozó grafikus ábrázolását mutatja a lenti ábra, amely egy skálázó réteget, neurális hálózatot és valószínűségi réteget tartalmaz. A világos körök reprezentálják a neuronokat, a sötétebb körök a perceptron neuronjait, a végső körök a valószínűségi neuronokat. A bemenetek száma 10, a kimenetek száma pedig 1. A rejtett neuronok száma által képviselt komplexitás 3.

A modellezésem célja a tudatosságmodell igazolása, amelyet a neurális hálózati összefüggések vállalati szegmentációtól függetlenül igazoltak.

Önmagában a tudatosságmodell eredetileg színekkel, mintázatokkal jelzi az egyes részeredményeket, így a kék szín a nem tudatos, a sárga a kevésbé tudatos és a zöld a tudatos jellemzőket. A modell utolsó sorában szerepel az összesített eredmény. A tudatosságmodell által kapott eredmények azt mutatták, hogy összesítve éves adatok összehasonlításában az INfoalldt tekintetében a tudatos vállalatok száma 238 db, a kevésbé tudatosaké 1 db, a nem tudatos vállalatoké 701 db. A NAICS2012 tekintetében ugyancsak éves adatok összehasonlításában a tudatos vállalat mintázatát hordozza a modell alapján 495 db vállalat, a kevésbé tudatos mintázatát 120 db és a nem tudatos mintázatát 385 db. A két elkülöníthető mintacsoportban, az információtechnológiai vállalatok modell eredmé-

nyében és a vegyes tevékenységű vállalatok modell eredményében éves és negyedéves átlagolás tekintetében is fontos tényező a tudatosság, amit hasonló mintázat is mutat.

7. ábra: A tudatosságmodell neurális háló általi megjelenítése NAICS2012 (2)



Forrás: Saját forrás, saját szerkesztés

Az eredmények hasznosíthatósága és a jövőbeli kutatási irányok

A dolgozat áttekintést adott az alapvető tudatosság rendszeréről, jellemzőiről a pénzügyi instrumentumok szemszögéből. A dolgozat kísérletet tett az alapösszefüggések megtalálására, feltárására. A jelen dolgozatban taglalt kutatási terület széles kutatási lehetőséget nyújt a kutatók számára. Az elsődleges cél az *Egyesített Mezőhöz* való csatlakozás feltérképezése, amellyel a gazdaság mélyebb aspektusait, összefüggéseit is megismerhetjük.

Dolgozatom elsődlegesen a *nem mély tanulást* elősegítő neurális háló alkalmazására irányult, a modellek felismerésére és az összefüggések megjelenítésére. A modell még pontosabb működését *mély tanulást* elősegítő neurális háló alkalmazásával lehet erősíteni, így az alapelvek szerint más független adatrendszerekben is adaptálhatóvá válhat.

A tudatosság általam felvázolt modell típusa a legalapvetőbb összetevőket és azok összefüggéseit használja. A meghatározó, lényeges elemek figyelembevételével építettem fel a modellt. A rendszer tovább finomítható mesterséges intelligenciát használó programelemekkel.

A modell, illetve az alkalmazott szelektálási rendszer a gazdaság minden területén használható és továbbfejleszhető vállalati csoporttípustól függetlenül.

Irodalomjegyzék

- Aerts, D. – Aerts, S. (1994): Applications of quantum statistics in psychological studies of decision processes. *Foundations of Science*, 1, 85–97. 1995/96. sz. https://doi.org/10.1007/978-94-015-8816-4_11.
- Ahn, B. S. – Cho, S. S. – Kim, C. Y. (2000): The integrated methodology of rough set theory and artificial neural network for business failure prediction. *Expert Systems with Applications*, 2(18), 65–74. [https://doi.org/10.1016/s0957-4174\(99\)00053-6](https://doi.org/10.1016/s0957-4174(99)00053-6).
- Alam, P. – Booth, D. – Lee, K. – Thordarson, T. (2000): The use of fuzzy clustering algorithm and self-organizing neural networks for identifying potentially failing banks: An experimental study. *Expert Systems with Applications*, 3(18), 185–199. [https://doi.org/10.1016/s0957-4174\(99\)00061-5](https://doi.org/10.1016/s0957-4174(99)00061-5).
- Amania, F. A. – Fadlalla, A. M. (2017): Data mining applications in accounting: A review of the literature and organizing framework. *International Journal of Accounting Information Systems*, 24, 32–58. <https://doi.org/10.1016/j.accinf.2016.12.004>.
- Anandarajan, M. – Anandarajan, A. (1999): A comparison of machine learning techniques with a qualitative response model for auditor's going concern reporting. *Expert Systems with Applications*, 4(16), 385–392. [https://doi.org/10.1016/s0957-4174\(99\)00014-7](https://doi.org/10.1016/s0957-4174(99)00014-7).
- Baaquie, B. E. (2007): *Quantum Finance: Path Integrals and Hamiltonians for Options and Interest Rates*. Cambridge University Press.
- Back B. – Toivonen, J. – Vanharanta, H. – Visa, A. (2001): Comparing numerical data and text information from annual reports using self-organizing maps. *International Journal of Accounting Information Systems*, 4(2), 249–269. [https://doi.org/10.1016/s1467-0895\(01\)00018-5](https://doi.org/10.1016/s1467-0895(01)00018-5).
- Ballarin, A. – Gervasi, S. – Cannat, V. – Liudaki, S. (1995): Company Financial Strategic Analysis Using Neural Classifiers. Computational Intelligence for Financial Engineering. IEEE. <https://doi.org/10.1109/cifer.1995.495264>.
- Berry, R. H. – Nix, S. (1991): Regression analysis v. ratios in the cross-section analysis of financial statements. *Accounting and Business Research*, 21(82), 107–117. <https://doi.org/10.1080/00014788.1991.9729823>.
- Benhayoun, N. – Chairi, I. – El Gonnouni, A. – Lyhyaoui, A. (2013): Financial intelligence in prediction of firm's creditworthiness risk: Evidence from support vector machine approach. *Procedia Economics and Finance*, 5, 103–112. [https://doi.org/10.1016/s2212-5671\(13\)00015-4](https://doi.org/10.1016/s2212-5671(13)00015-4).

- Boyacioglu, M. A. – Kara, Y. – Baykan, O. K. (2009): Predicting bank financial failures using neural networks, support vector machines and multivariate statistical methods: A comparative analysis in the sample of savings deposit insurance fund (SDIF) transferred banks in Turkey. *Expert Systems with Applications*, 2(36), 3355–3366. <https://doi.org/10.1016/j.eswa.2008.01.003>.
- Calderon, T. G. – Cheh, J. J. (2002): A roadmap for future neural networks research in auditing and risk assessment. *International Journal of Accounting Information Systems*, 4(3), 203–236. [https://doi.org/10.1016/s1467-0895\(02\)00068-4](https://doi.org/10.1016/s1467-0895(02)00068-4).
- Callen, J. L. – Kwan, C. C. – Yip, P. C. – Yuan, Y. (1996): Neural network forecasting of quarterly accounting earnings. *International Journal of Forecasting*, 4(12), 475–482. [https://doi.org/10.1016/s0169-2070\(96\)00706-6](https://doi.org/10.1016/s0169-2070(96)00706-6).
- Chakraborty, S. – Sharma, S. K. (2007): Prediction of corporate financial health by artificial neural network. *International Journal of Electronic Finance*, 4(1), 442–159. <https://doi.org/10.1504/ijef.2007.012898>.
- Chen, Y. – Zhang, L. – Zhang, L. (2013): Financial distress prediction for Chinese listed manufacturing companies. *Procedia Computer Science*, 17, 678–686. <https://doi.org/10.1016/j.procs.2013.05.088>.
- Chi, L. C – Tang, T. C. (2005): Neural networks analysis in business failure prediction of Chinese importers: A between-countries approach. *Expert Systems with Applications*, 2(29), 244–255. <https://doi.org/10.1016/j.eswa.2005.03.003>.
- Coakley, J. R. – Brown, C. E. (2000): Artificial neural networks in accounting and finance: Modeling issues. *International Journal of Intelligent Systems in Accounting, Finance & Management*, 2(9), 119–144. [https://doi.org/10.1002/1099-1174\(200006\)9:2<119::aid-isaf182>3.0.co;2-y](https://doi.org/10.1002/1099-1174(200006)9:2<119::aid-isaf182>3.0.co;2-y).
- Dattilo G. – Greco, S. Masciari, E. – Pontieri, L. (2000): A hybrid technique for data mining on balance-sheet data. In Kambayashi, Y. – Mohania, M. – Tjoa, A. M. (eds.): *Data Warehousing and Knowledge Discovery Second International Conference*. London: Springer, 419–425. https://doi.org/10.1007/3-540-44466-1_42.
- Doumpos, M. – Gaganis, C. – Pasiouras, F. (2005): Explaining qualifications in audit reports using a support vector machine methodology. *Intelligent Systems in Accounting, Finance and Management*, 4(13), 197–215. <https://doi.org/10.1002/isaf.268>.
- Eklund, T. – Back, B. – Vanharanta, H. – Visa, A. (2008): A face validation of a SOM-based financial benchmarking model. *Journal of Emerging Technologies in Accounting*, 1(5), sz. 109–127. <https://doi.org/10.2308/jeta.2008.5.1.109>.

- Etheridge, H. L. – Sriram, R. S. – Hsu, H. Y. (2000): A comparison of selected artificial neural networks that help auditors evaluate client financial viability. *Decision Sciences*, 2(31), 531–550. <https://doi.org/10.1111/j.1540-5915.2000.tb01633.x>.
- Evans, J. R. (2013): *Business Analytics: Methods, Models, and Decisions*. Boston: Prentice-Hall.
- Ezazi, M. E. – Ghotbi, F. S. – Ghotbi, S. F. (2013): Predicting earning management using RBF, ICA, and SVM in firms listed in Tehran security exchange. *Asian Journal of Management Research*, 1(4), 208–220. <https://doi.org/10.5958/2249-7307.2014.00938.4>.
- Fayyad, U. P. – Shapiro, G. – Smyth, P. (1996): From data mining to knowledge discovery in databases. *AI Magazine*, 3(17), 37.
- Foltin, C. – Garceau, L. (1996): Beyond expert systems: Neural networks in accounting. *National Public Accountant*, 6(41), 26–32.
- Gray, G. L. – Debreceny, R. S. (2014): A taxonomy to guide research on the application of data mining to fraud detection in financial statement audits. *International Journal of Accounting Information System*, 4(15), 357–380.
- Hagelin, J. S. (1987): Is consciousness the unified field? A field theorist's perspective. *Modern Science and Vedic Science*, 1, 29–87.
- Han, J. – Kamber, M. (2006): *Data Mining: Concepts and Techniques*. Second Edition. Elsevier, 67–68.
- Haven, E. (2002): *A discussion on embedding the Black-Scholes option pricing model in a quantum physics setting*. *Physica A: Statistical Mechanics and its Applications*. Physica A. 304. 507–524. <https://doi.org/10.1016/j.accinf.2014.05.006>.
- Haven, E. E. – Khrennikov, A. (2013): *Quantum Social Science*. Cambridge University Press.
- Helfert, E. A. (2001): *Financial Analysis: Tools and Techniques. A Guide for Managers*. McGraw and Hill.
- Hofmann, E. – Lampe, K. (2013): Financial statement analysis of logistics service providers: ways of enhancing performance. *International Journal of Physical Distribution and Logistics Management*, 4(43), 4. <https://doi.org/10.1108/ijpdlm-08-2012-0229>.
- Hoglund, H. (2012): Detecting earnings management with neural networks. *Expert Systems with Applications*, 10(39), 9564–9570. <https://doi.org/10.1016/j.eswa.2012.02.096>.

- Hoglund, H. (2013): Fuzzy linear regression-based detection of earnings management. *Expert Systems with Applications*, 15(40), 6166–6172. <https://doi.org/10.1016/j.eswa.2013.05.046>.
- Huang, S. M. – Tsai, C. F. – Yen, D. C. – Cheng, Y. L. (2008): A hybrid financial analysis model for business failure prediction. *Expert Systems with Applications*, 3(35), 1034–1040. <https://doi.org/10.1016/j.eswa.2007.08.040>.
- Ittner, C. D. – Larcker, D. F. (2001): Assessing empirical research in managerial accounting: A value-based management perspective. *Journal of Accounting and Economics*, 1(32), 349–410. [https://doi.org/10.1016/s0165-4101\(01\)00026-x](https://doi.org/10.1016/s0165-4101(01)00026-x).
- Kloptchenko, A. – Eklund, T. – Karlsson, J. – Back, B. – Vanharanta, H. – Visa, A. (2004): Combining data and text mining techniques for analyzing financial reports. *Intelligent Systems in Accounting, Finance and Management*, 1(12), 29–41. <https://doi.org/10.1002/isaf.239>.
- Koh, H. C. – Tan, S. S. (1999): A neural network approach to the prediction of going concern status. *Accounting and Business Research*, 3(29), 211–216. <https://doi.org/10.1080/00014788.1999.9729581>.
- Koh, H. C. – Low, C. K. (2004): Going concern prediction using data mining techniques. *Managerial Auditing Journal*, 3(19), 462–476. <https://doi.org/10.1108/02686900410524436>.
- Koskivaara, E. (2004a): Artificial neural networks in analytical review procedures. *Managerial Auditing Journal*, 2(19), 191–223. <https://doi.org/10.1108/02686900410517821>.
- Kurzweil, R. (2005): *How to Create a Mind. The Secret of Human Thought Revealed*. New York: Viking.
- Kurzweil, R. (2013): *A szingularitás küszöbén*. Ad Astra Kiadó.
- Kurzweil, R. – Steadman, R. (2012): *Virtually Human. The Promise-and the Peril- of Digital Immortality*. New York: St. Martin's Press,
- Laskai András (2018): Az üzleti terv pénzügyi instrumentumai nemzetközi perspektívában a tudatosság tükrében. PhD-értekezés. Soproni Egyetem. Lámfalussy János Közgazdaságtudományi Kar. Széchenyi István Gazdálkodás- és Szervezéstudományok Doktori Iskola.
- Laskai, András (2019a): Consciousness and the International Business Planning. *International Journal of Science and Business*, 1(3), 1–6. <https://doi.org/10.5281/zenodo.2528383>.

- Laskai, András (2019b): Consciousness system approaches and the financial instruments. *International Journal of Science and Business*, 1(3), 7–16. <https://doi.org/10.5281/zenodo.2528355>.
- Lenard, M. J. – Alam, P. – Madey, G. R. (1995): The application of neural networks and a qualitative response model to the auditor's going concern uncertainty decision. *Decision Sciences*, 2(26), 209–227. <https://doi.org/10.1111/j.1540-5915.1995.tb01426.x>.
- Leon, C. (2017): Whose balance sheet is this? Neural networks for banks' pattern recognition. *Wilmott*, 91, 34–47. <https://doi.org/10.1002/wilm.10619>.
- Li, H. – Sun, J. – Li, J. C. – Yan, X. Y. (2013): Forecasting business failure using two-stage ensemble of multivariate discriminant analysis and logistic regression. *Expert Systems with Applications*, 5(30), 385–397. <https://doi.org/10.1111/j.1468-0394.2012.00642.x>.
- Magnusson, C. – Arppe, A. – Eklund, T. – Back, B. – Vanharanta, H. – Visa, A. (2005): The language of quarterly reports as an indicator of change in the company's financial status. *Information and Management*, 4(42), 561–574. <https://doi.org/10.1016/j.im.2004.02.008>.
- Martens, D. – Bruynseels, L. – Baesens, B. – Willekens, M. – Vanthienen, J. (2008): Predicting going concern opinion with data mining. *Decision Support Systems*, 4(45), 765–777. <https://doi.org/10.1016/j.dss.2008.01.003>.
- Neves, C. M. M. – Silva, V. R. M. – Barros, G. A. B. – Lopes, R. V. V. (2011): A variation of the genetic algorithm of Holland to support analysis of balance sheet and income statement for the fiscal year. *Information Technology and Artificial Intelligence*, 2, 331. <https://doi.org/10.1109/itaic.2011.6030338>.
- Ngai, E. W. T. – Hu, Y. – Wong, Y. H. – Chen, Y. – Sun, X. (2011): The application of data mining techniques in financial fraud detection: a classification framework and an academic review of literature. *Decision Support Systems*, 3(50), 559–569. <https://doi.org/10.1016/j.dss.2010.08.006>.
- Orrell, D. (2016): A quantum theory of money and value. *Economic Thought*, 2(5), 19–28. <https://doi.org/10.2139/ssrn.2624371>.
- Orrell, D. – Chlupatý, R. (2016): *The Evolution of Money*. Columbia University Press, 171–175.
- Peel, M. J. (1989): The going-concern qualification debate: Some UK evidence. *British Accounting Review*, 4(21), 329–350. [https://doi.org/10.1016/0890-8389\(89\)90032-2](https://doi.org/10.1016/0890-8389(89)90032-2).
- Pujari, A. K. (2001): *Data Mining Techniques*. Universities Press.

- Quek, C. – Zhou, R. W. – Lee, C. H. (2009): A novel fuzzy neural approach to data reconstruction and failure prediction. *Intelligent Systems in Accounting, Finance and Management*, 1/2(16), 165–187. <https://doi.org/10.1002/isaf.299>.
- Salterio, S. (1996): The effects of precedents and client position on auditors' financial accounting policy judgment. *Accounting, Organizations & Society*, 5(21), 467–486. [https://doi.org/10.1016/0361-3682\(95\)00041-0](https://doi.org/10.1016/0361-3682(95)00041-0).
- Shirata, C. Y. – Sakagami, M. (2008): An analysis of the Going Concern Assumption: text mining from Japanese financial reports. *Journal of Emerging Technologies in Accounting*, 1(5), 1–16. <https://doi.org/10.2308/jeta.2008.5.1.1>.
- Shubik, M. (1999): Quantum economics, uncertainty and the optimal grid size. *Economics Letters*, 3(64), 277–278. [https://doi.org/10.1016/s0165-1765\(99\)00095-6](https://doi.org/10.1016/s0165-1765(99)00095-6).
- Song, D. B. – Lee, H. Y. – Cho, E. J. (2013): The association between earnings management and asset misappropriation. *Managerial Auditing Journal*, 6(28), 542–567. <https://doi.org/10.1108/02686901311329919>.
- Spathis, C. T. (2003): Audit qualification, firm litigation, and financial information: An empirical analysis in Greece. *International Journal of Auditing*, 1, 71–85. <https://doi.org/10.1111/1099-1123.00006>.
- Teese, C. (2017): *Money and Quantum Physics*. News Weekly.
- Tsai, C.F.-Chiou, Y.J., (2009): Earnings management prediction: A pilot study of combining neural networks and decision trees. *Expert Systems with Applications*, 3(36), 7183–7191. <https://doi.org/10.1016/j.eswa.2008.09.025>.
- Tsaih, R. H. – Lin, W. Y. – Huang, S. Y. (2009): Exploring fraudulent financial reporting with GHSOM. Proceeding of Pacific Asia Workshop (PAISI). Intelligence and Security Informatics, 31–41. https://doi.org/10.1007/978-3-642-01393-5_5.
- Tung, W. L. – Quek, C. – Cheng, P. (2004): GenSo-EWS: A novel neural-fuzzy based early warning system for predicting bank failures. *Neural Network*, 4(17), 567–588. <https://doi.org/10.1016/j.neunet.2003.11.006>.
- Zhang, L. – Wang, L. – Zhang, J. (2011): A computer auditing model of the balance sheet parallel simulation based on data mining. In *Modeling Risk Management for Resources and Environment in China*. Springer-Verlag Berlin Heidelberg, 567–576. https://doi.org/10.1007/978-3-642-18387-4_62.
- Yang, J. G. S. (2006): Data mining techniques for auditing attest function and fraud detection. *Journal of Forensic Investigative Accounting*, 1(1), 4–10.
- Yang, S. – Cogill, R. (2013): Balance Sheet Outlier Detection using a Graph Similarity Algorithm. 2013 IEEE Conference on Computational Intelligence for Financial Engineering & Economics. 1–8. <https://doi.org/10.1109/cifer.2013.6611709>.

- Yang, J. – Zhang, Y. – Au, K. – Xue, H. (2011): *Prior experiences and social class as moderators of planning-performance relationship in China's new business ventures*. National Science Foundation of China, 1–40. <https://doi.org/10.1002/sej.1155>.
- Youn, H. – Gu, Z. (2010): Predicting Korean lodging firm failures: an artificial neural network model along with a logistic regression model. *International Journal Hospital Management*, 1(29), 120–127. <https://doi.org/10.1016/j.ijhm.2009.06.007>.
- Virág Miklós – Kristóf Tamás – Fiáth Attila – Varsányi Judit (2013): *Pénzügyi elemzés, csődelőrejelzés, válságkezelés*. Kossuth Kiadó.
- Wang, S. (2010): A comprehensive survey of data mining-based accounting-fraud detection research. Proceeding of the International IEEE Conference on Intelligent Computation Technology and Automation. <https://doi.org/10.1109/icicta.2010.831>.