
Modele de previziune a riscului de faliment pe baza rețelelor neuronale artificiale

Doina PRODAN-PALADE,
Universitatea „Alexandru Ioan Cuza”, Iași, România,
E-mail: doina_prodan_palade@bau.edu.ro

Rezumat

Obiectivul cercetării este de a studia capacitatea rețelelor neuronale artificiale de a previziona riscul ca o companie să întâmpine dificultăți financiare. Am previzionat riscul de faliment prin utilizarea indicatorilor financiari asociați (rata de lichiditate globală și rata de solvabilitate globală), apelând la două modele de rețele neuronale artificiale, bazate pe algoritmul de propagare inversă a erorii. Modelele propuse au fost implementate și testate cu aplicația PyBrain, utilizând un număr de 55 de companii listate la Bursa de Valori București, în perioada 2010-2014. După un total de 19.944 iterații pentru fiecare fază de învățare, cei doi algoritmi au devenit convergenți, iar erorile obținute pe parcursul testării au atins ținta fixată. Rezultatele empirice au arătat că modelele bazate pe rețele neuronale artificiale sunt eficiente și fiabile în ceea ce privește detectarea riscului de faliment. Rețelele neuronale artificiale sunt foarte utile în analiza economică, atunci când implementarea unor funcții care descriu în mod adecvat relația dintre variabilele economice este dificilă, din cauza complexității datelor. Utilizarea metodei rețelelor neuronale în previzionarea riscului de faliment este mai puțin întâlnită în România. Intenția prezentului studiu este de a compensa acest deficit al literaturii de specialitate. În opinia noastră, lucrarea poate trezi interesul nu doar al companiilor listate la bursa de valori, dar și al investitorilor, acționarilor și băncilor.

Cuvinte-cheie: Rețele neuronale artificiale, propagare inversă a erorii, risc de faliment, rată de lichiditate globală, rată de solvabilitate globală.

Clasificare JEL: M41, C53, G33

Vă rugăm să citați acest articol astfel:

Prodan-Palade, D. (2017), Bankruptcy risk prediction models based on artificial neural networks, *Audit Financiar*, vol. XV, no. 3(147)/2017, pp. 418-429,
DOI: 10.20869/AUDITF/2017/147/418

Link permanent pentru acest document:

<http://dx.doi.org/10.20869/AUDITF/2017/147/418>
Data primirii articolului: 15.07.2016
Data revizuirii: 13.12.2016
Data acceptării: 20.12.2016

Introducere

Previzionarea exactă a riscului financiar reprezintă un factor cheie al competitivității întreprinderilor, în mediul dinamic al pieței internaționale. Globalizarea piețelor financiare a condus la reducerea timpului de răspuns și de decizie al decidenților politici (Aydin și Cavdar, 2015). Între timp, interconexiunile între instituțiile financiare amplifică consecințele crizelor economice (Glasserman și Young, 2013). Ca rezultat, există o cerere ridicată pentru previzionarea cu exactitate a dificultăților financiare ale firmelor, respectiv a riscului de faliment. Modelele exacte de previziune sprijină puterea politică în a lua deciziile corecte și a diminua riscul în afaceri (Airinei și Berta, 2012). Criza financiară recentă a accentuat slăbiciunea modelelor statistice tradiționale. În cazul în care există diferențe semnificative între profiturile previzionate și cele auditate, credibilitatea companiilor în fața investitorilor și a tuturor părților interesate se va diminua (Bunget ș.a., 2014). Analiza datelor poate fi realizată prin diferite tehnici, cum ar fi statistica descriptivă, analiza regresiei, data mining, algoritmi de logică fuzzy sau modelele bazate pe rețele neuronale.

1. Literatura de specialitate pe tema utilizării în afaceri a rețelelor neuronale artificiale

Într-o economie sănătoasă cererea pentru o distribuție adecvată a resurselor pe piețele financiare este ridicată. La ora actuală, firmele reprezintă sisteme complexe, mediul economic se află într-o foarte rapidă schimbare, iar funcțiile manageriale nu mai pot fi îndeplinite de o singură persoană. Timpul pe care managerii îl au la dispoziție pentru a lua decizii este mai scurt, iar evaluarea companiilor a devenit o problemă foarte dificilă, care se bazează pe o analiză calitativă și orientată spre riscuri. Obținerea unor rezultate exacte este condiționată de existența datelor contabile adecvate (Bunget, 2009), inclusiv a unor variabile calitative, cum ar fi indicatorii politici și de mediu, anomaliile de calendar și ciclurile de afaceri (Tjung ș.a., 2012), precum și de utilizarea unor metode statistice potrivite (Vallini ș.a., 2009). Lucrările de cercetare au arătat că rețelele neuronale artificiale sunt în măsură să previzioneze performanța financiară a companiilor cu un nivel înalt de precizie.

Salama și Omar (2014) au dezvoltat și au testat un model bazat pe rețele neuronale artificiale cu propagare inversă a erorii, capabil să detecteze și să previzioneze raportarea financiară frauduloasă. Shang, Huang, Yang și Zhou (2015) au studiat avertizarea de risc financiar pentru companiile de pe piața întreprinderilor în creștere (en. Growth Enterprises Market – GEM), aparținând industriilor emergente strategice chineze (en. Chinese Strategic Emerging Industries – SEI). Aceștia au utilizat modelul de regresie pas cu pas și modelul bazat pe rețele neuronale cu propagare inversă a erorii (Backpropagation neural network – BPNN). Rezultatele empirice au arătat faptul că modelul BPNN oferă o previziune mai exactă a riscului financiar decât modelul bazat pe regresie. Aceștia au demonstrat că precizia rețelelor neuronale și a altor metode de inteligență artificială (IA) este superioară preciziei metodelor statistice tradiționale. În comparație cu alte modele de previzionare a prețurilor pe bursă, studiile empirice au arătat că performanța rețelelor neuronale artificiale este cea mai ridicată (Ardebili ș.a., 2015).

În încercarea de a descoperi tipare complexe de date prin utilizarea analizei discriminante multiple (MDA) și a rețelelor neuronale artificiale, Coats și Fant (1993) au constatat că abordarea bazată pe rețele neuronale este mai exactă și mai eficace decât MDA. Yildiz și Yezegel (2010) au realizat o analiză fundamentală a strategiei comerciale pe baza unui eșantion de firme tranzacționate la bursa de valori din New York (NYSE), la cea americană (AMEX) și pe NASDAQ. Studiul a demonstrat că rețelele neuronale au capacitatea de a previziona rentabilitatea viitoare a titlurilor NYSE/AMEX/NASDAQ pentru perioada 1990-2005.

Modelele statistice tradiționale sunt valide doar sub rezerva unor prezumții restrictive, cum ar fi liniaritatea, distribuția normală a datelor și independența variabilelor predictor (Alborzi ș.a., 2013; Yildiz și Yezegel, 2010). Ca rezultat, acestea nu reflectă cu precizie procesele și mediul economic. De asemenea, nu sunt capabile să învețe inductiv de la alte date, în mod dinamic, precizia previziunii fiind astfel afectată în mod semnificativ (Khademolqorani și Farimah, 2015).

Ahangar, Yahyazadehfar și Pournaghshband (2010) estimează prețul acțiunilor companiilor listate pe Tehran Stock Exchange utilizând regresia liniară și metoda RNA. Comparând performanțele celor doi algoritmi, rezultatele empirice au arătat că rețelele neuronale artificiale sunt mai eficiente decât modelul regresiei

liniare. Hu, Yi-Chung și Lin (2012) au utilizat un eșantion de prețuri zilnice ale petrolului din Brent, West Texas Intermediate (WTI), Dubai și International Petroleum Exchange (IPE), din perioada 1990 – 2005 și au testat precizia previziunii rețelelor neuronale artificiale cu privire la livrările la termen de țitei brut. Pe parcursul testelor empirice au fost utilizate rețeaua neuronală recurentă Elman (ERNN), rețeaua neuronală recurentă fuzzy (RFNN) și perceptronul multistrat (MLP). Rezultatele au demonstrat că RFNN are capacitatea de previziune cea mai ridicată, iar MLP cea mai slabă. În plus, studiul a arătat că abilitatea de previziune a rețelelor neuronale artificiale crește odată cu creșterea timpului de instruire.

2. Rețele neuronale cu propagare inversă

Creierul uman este înzestrat la naștere cu capacitatea de a procesa informații și de a realiza activități complexe, cum ar fi controlul motricității, recunoașterea tiparelor, interacțiunea cu mediul și abilitatea de a învăța din experiență, fiind construit din neuroni care transformă datele de intrare în date de ieșire. Inteligența artificială (AI) memorează cunoștințe, fiind capabilă să le utilizeze pentru a rezolva probleme, precum și să învețe din experiență. În acest scop, inteligența artificială utilizează un limbaj construit din simboluri, care reprezintă un sprijin în procesul de căutare a soluțiilor și rezolvare a problemelor date. Expresiile semantice utilizate în IA sunt complexe, bazate pe sintaxă și reguli, similar limbii naturale.

Ca parte a IA, rețelele neuronale sunt sisteme care utilizează metode de aproximare bazate pe procesul de învățare. Calculul neuronal este o disciplină care încearcă să simuleze funcționarea creierului uman prin utilizarea de sisteme informatice (Aydin, 2015) și algoritmi, precum și combinând cunoștințe din diferite discipline, cum ar fi biologie, chimie, fizică, matematică și economie. O trăsătură importantă a acestor rețele este faptul că sunt capabile să se auto-organizeze și, prin aceasta, să rezolve probleme, fără a avea nevoie de implementarea unor programe cu algoritmi puternici. Au nevoie în schimb de o fază de instruire pentru construirea cunoștințelor, utilizând seturi de date specifice.

După memorarea cunoștințelor, printr-un proces de „gândire” care imită raționamentul uman, rețelele sunt

capabile să rezolve probleme foarte complexe. Astfel, pornind de la un set de instruire care conține numeroase exemple, introduse ca date de intrare, rețelele neuronale creează un model specific, bazat pe problema dată. Alte abordări sunt sistemele neuro-fuzzy și modelele hibride bazate pe rețele genetice, fuzzy sau neuronale (Pradhan ș.a., 2011). Acestea se bazează pe procesul de estompare – accentuare aplicat datelor de intrare și datelor de ieșire ale rețelei neuronale și aduc raționamentul artificial mai aproape de cel uman.

Datorită universalității lor, domeniile de aplicare a rețelelor neuronale sunt foarte diverse, de la științele naturii, industrie, agricultură, arte, până la divertisment. Cu ajutorul rețelelor neuronale, analizele și previziunile destinate managementului companiilor și piețelor de capital pot fi realizate cu un nivel înalt de precizie. Printre cele mai frecvent utilizate aplicații se numără procesarea limbajului natural, procesarea imaginilor, recunoașterea tiparelor, interpretarea grafologică, robotica și modelarea în economie și finanțe.

În afaceri, problemele cu grad ridicat de dificultate pot fi rezolvate de experți, respectiv de profesioniști cu experiență vastă. Rețelele Neuronale Artificiale (RNA) pot la rândul lor acumula experiență după efectuarea unor procese de învățare iterative, fiind capabile să rezolve probleme extrem de complexe din mediul economic, fără a apela la cunoștințele specialiștilor.

3. Principii de bază ale calculului neuronal

Calculul neuronal se bazează pe modele matematice preluate din neurobiologie și au trei componente:

- Unitățile de calcul;
- Straturile compuse din unități de calcul;
- Regulile de schimbare a intensității conexiunilor între unitățile de calcul.

Conceptul de calcul neuronal a fost lansat în anul 1943 în lucrarea “A Logical Calculus of Ideas Immanent in Nervous Activity”, publicat de profesorii McCulloch și Pitts. În 1969, Minsky și Papert au prezentat modelul neuronal compus din straturi de neuroni care transmit informația de la intrare la ieșire prin conexiuni similare celor sinaptice. Cel mai important pas în dezvoltarea rețelelor neuronale este implementarea învățării prin metoda propagării inverse a erorii, descoperită de

Werbos în 1974 și încă utilizată. În funcție de modul de conectare a neuronilor, rețelele pot fi clasificate în trei tipuri: cu conexiune directă, cu propagare inversă (PI) și recurente. Rețelele cu propagare inversă sunt utilizate în numeroase aplicații. Acestea utilizează o arhitectură neuronală multistratificată, care are cel puțin un strat ascuns de neuroni și aplică algoritmi de minimizare a erorii funcției. Funcția de activare a straturilor ascunse este o funcție logistică de forma (Enăchescu, 2009):

$$f(x) = 1 / (1 + e^{-x})$$

Numărul nodurilor din stratul ascuns poate fi determinat utilizând metoda încercării și a erorii, sau prin metoda formulei. Cele mai frecvent utilizate formule sunt următoarele (Shang ș.a., 2015):

$$m = \sqrt{nl}$$

$$m = \log_2 n$$

$$m = \sqrt{n+1} + a; a = \text{constant}, a \in [0,1]$$

Unde:

- m = număr de noduri în stratul ascuns
- n = număr de noduri în stratul de intrare
- l = număr de noduri în stratul de ieșire

Rețelele neuronale pot fi utilizate pentru previziune, clasificare, conceptualizare, filtrarea datelor și asociere. Pentru a realiza evaluarea modelului, setul de date este de regulă divizat în trei seturi: setul de instruire, setul de validare și setul de testare (Badea, 2013). Precizia previziunilor RNA depinde de o serie de factori, cu impact semnificativ asupra performanței acestora, între care selecția variabilelor de intrare, arhitectura rețelei și volumul de date utilizate pentru etapa de instruire (Walczak, 2001). Spre deosebire de alte metode de programare, rețeaua neuronală artificială are capacitatea de a învăța. Într-un proces neuronal, învățarea se realizează în două faze. Prima fază este destinată instruirii și acumulării de cunoștințe. În următoarea fază sunt realizate modificări funcționale ale nodurilor rețelei neuronale, care conduc la modificarea structurii interne. Un neuron sau un nod are mai multe semnale de intrare și produce un singur semnal de ieșire, fiecărei intrări fiindu-i atribuită o anumită pondere sinaptică.

Pe parcursul procesului de învățare, neuronii modifică ponderea variabilelor de intrare, în funcție de erorile dintre outputul țintă și outputul previzionat al rețelei. Pe baza ponderilor conexiunilor neuronale, algoritmul

sintetizează un model specific de rezolvare a problemei. Prin acest mecanism, rețelele neuronale sunt capabile să îndeplinească sarcini complexe, pentru care implementarea unor algoritmi clasici de procesare ar fi foarte dificilă.

În structura clasică a unui tip de rețele cu propagare inversă (PI), neuronii sunt conectați în straturi multiple. Primul strat recepționează valorile de intrare, ultimul strat furnizează valorile de ieșire, iar între cele două pot exista unul sau mai multe straturi ascunse. Fiecărui element de calcul dintr-o rețea neuronală îi este atribuită o combinație de valori de intrare care se transformă într-o valoare de ieșire, pe baza cunoștințelor memorate anterior. Pe parcursul procesului instruire-învățare, rețeaua recepționează un număr ridicat de valori de intrare și ajustează ponderile folosind mecanismul PI. Pe baza valorilor de intrare, rețeaua de neuroni artificiali identifică anumite tipare și conexiuni și obține o valoare de ieșire care va fi comparată cu anumite valori cunoscute, numite valori țintă. Erorile calculate ca diferență între valorile de ieșire ale rețelei și valorile țintă sunt transmise înapoi, prin straturile ascunse ale rețelei. Procesul se repetă până când diferența între valoarea de ieșire a rețelei și valoarea țintă atinge un nivel minim, stabilit în prealabil.

Un dezavantaj al acestor sisteme este intervalul de timp necesar pentru a încărca și a memora cunoștințele. O altă problemă constă în volumul ridicat de informație de intrare necesar pentru procesul de învățare (Kaastra și Boyd, 1996). Pentru a furniza o soluție adecvată, sistemul ar trebui să primească detalii complete legate de respectiva sarcină. Întrucât volumul ridicat de date care trebuie procesate consumă timp și resurse, în prezent cercetătorii caută să dezvolte noi sisteme de instruire, capabile să opereze eficient cu un volum mai mic de cunoștințe inițiale.

4. Studiu empiric de utilizare a rețelelor neuronale pentru previzionarea riscului de faliment

Lucrarea propune două modele RNA supervizate, bazate pe metoda propagării inverse a erorii, destinate previzionării riscului de faliment prin

utilizarea unor indicatori financiari asociați. Procesul de învățare este supervizat, pe baza unui eșantion de valori de intrare și valori de ieșire. Învățarea supervizată include un proces de corectare a erorilor, învățarea folosind un critic (reinforcement learning), învățarea stohastică și convergența erorilor (Salama și Omar, 2014). Conceptul de convergență a erorilor înseamnă că diferențele între valorile țintă și valorile de ieșire calculate trebuie minimizate. În acest scop, algoritmul modifică ponderile și creează modelul adecvat. Modelele de rețele neuronale previzionează riscul de faliment pe baza analizei unor evenimente trecute din activitatea companiei (Prodan-Palade, 2016).

România este o țară emergentă, care are o piață dinamică și oferă numeroase oportunități mediului economic internațional, alături de un număr mai ridicat de riscuri decât alte piețe dezvoltate. În ultimii 26 de ani, țara noastră a cunoscut numeroase transformări, în procesul de tranziție de la o economie centralizată la una de piață. În ceea ce privește mediul de afaceri dinamic, în conformitate cu datele furnizate de Oficiul Național al Registrului Comerțului, la data de 31 decembrie 2015 în România existau 773.781 persoane juridice active. În cursul aceluiași an, 10.269 de entități au intrat în insolvență, acestea reprezentând 1,33% din numărul total de entități active, mai puțin cu 50,38% decât în cursul perioadei precedente, în timp ce 2,29%, respectiv 17.698 de entități și-au suspendat activitatea, numărul acestora reprezentând o creștere de 12,10%, în comparație cu anul 2014.

O mare parte a entităților listate la Bursa de Valori București (BVB) se află în primul stadiu de dezvoltare și au nevoie de investiții substanțiale, creditele bancare reprezentând una dintre cele mai importante surse de finanțare a companiilor românești. Problema lichidității și a capacității de rambursare a datoriilor este esențială pentru analiza echilibrului financiar al acestor companii. Din acest motiv, considerăm necesară construirea unor cunoștințe fundamentale și formalizarea unor modele de previziune pentru lichiditatea și solvabilitatea entităților, pe baza conceptului rețelelor neuronale.

Studiul nostru propune două modele de previziune, unul proiectat pentru previzionarea ratei lichidității globale, iar cel de-al doilea pentru previzionarea ratei solvabilității globale. Cele două rate sunt considerate

indicatori principali de analiză ai stabilității financiare ai unei entități. Rata lichidității globale este exprimată prin rata activelor imobilizate, rata autonomiei financiare globale, testul acid (rata lichidității curente), rata disponibilităților și rata profitului. Rata solvabilității globale este exprimată prin rata activelor imobilizate, rata autonomiei financiare globale și rata lichidității globale (Prodan-Palade, 2016).

Eșantionul este format din 55 de entități din sectorul productiv, listate la BVB în perioada 2010-2014. Informațiile contabile utilizate pentru determinarea indicatorilor financiari au fost extrase din raportările anuale ale companiilor, publicate pe site-ul bursei.

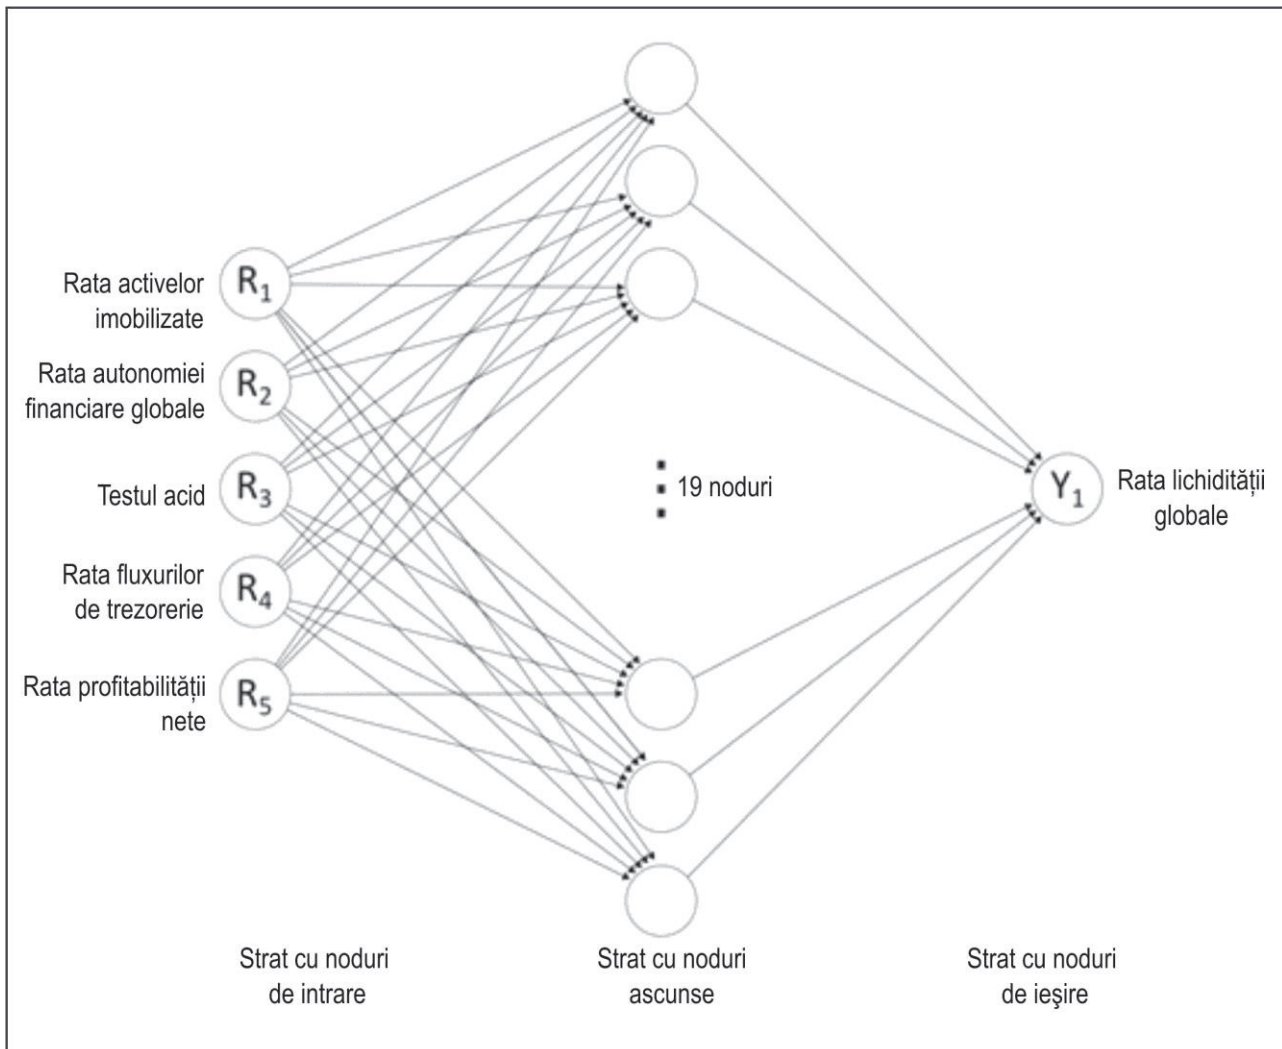
Aplicația are trei faze de lucru: instruirea, testarea și previzionarea. Pe parcursul fazei de instruire rețeaua învață, pe baza informațiilor furnizate ca valori de intrare, și identifică un anumit model. Pentru prima fază, am utilizat date contabile de intrare din exercițiile financiare 2010-2013. Previziunea și testarea preciziei algoritmului au fost realizate prin utilizarea datelor contabile ale anului 2014.

4.1. Construirea unui model de rețea neuronală pentru previzionarea ratei lichidității globale

Conceptul de lichiditate exprimă capacitatea companiei de a-și achita datoriile pe termen scurt, arătând gradul de acoperire a datoriilor pe termen scurt din active curente. Valorile acceptabile ale acestui indicator diferă de la un sector industrial la altul, literatura de specialitate recomandând în general o valoare mai mare decât 1. Pe de altă parte, există cazuri în care o rată a lichidității globale (lichiditate curentă) prea ridicată, de exemplu mai mare decât 2, poate indica prezența unor stocuri și creanțe care consumă resurse financiare semnificative, reprezentând un semnal negativ pentru companie. Astfel, în modelul de previziune a ratei lichidității globale am considerat util să includem testul acid (rata lichidității rapide), care ține cont de nivelul stocurilor entității. Arhitectura acestei RNA este prezentată în **Figura nr. 1**. Modelul propus este format din:

- 5 neuroni în stratul 1 (stratul de intrare);
- 19 neuroni în stratul 2 (stratul ascuns);
- 1 neuron în stratul 3 (stratul de ieșire).

Figura nr. 1. Modelul de rețea neuronală pentru previziunea ratei lichidității globale



Sursa: prelucrare proprie

unde:

- R_1 (Rata activelor imobilizate) = active imobilizate/activ total
- R_2 (Rata autonomiei financiare globale) = capital propriu/ total capitaluri proprii și datorii
- R_3 (Testul acid sau Rata lichidității rapide) = (active curente – stocuri)/datorii curente
- R_4 (Rata fluxurilor de trezorerie) = fluxuri de trezorerie nete/datorii curente

- R_5 (Rata profitabilității nete) = profit net/cifra de afaceri netă
- Y_1 (Rata lichidității globale sau Rata lichidității curente) = active curente/datorii curente.

Considerând:

- R_i ; $i = \overline{1,5}$, neuronii de intrare;
- H_j ; $j = \overline{1,19}$, neuronii ascunși;
- Y_1 , neuronul de ieșire;

- W_{ji}^k ; $i = \overline{1,5}$; $j = \overline{1,19}$, $k = \overline{2,3}$, ponderea interconexiunilor între neuronul i , localizat în stratul cu numărul $k-1$ și neuronul j , localizat în stratul k ;
- f_k ; $k = \overline{2,3}$, funcția de activare corespunzătoare stratului k , $k = \overline{2,3}$, rețeaua neuronală funcționează după cum urmează:

Pentru stratul 1 (intrare), vectorul de intrare este $R = (R_1, R_2, R_3, R_4, R_5)$

Pentru stratul 2 (ascuns): $H_j = f(\sum_{i=1}^5 R_i w_{ji}^2)$; $j = \overline{1, 19}$


Pentru stratul 3 (ieșire): $Y_1 = f(\sum_{j=1}^{19} H_j w_{1j}^3)$

Numărul de noduri ascunse depinde de complexitatea modelului. După cum se arată în figura 1, intrările în sistem includ ratele R1, R2, R3, R4 și R5 cărora, după procesul de construire a modelului, li se atribuie ponderi diferite. Fiecărei rate îi este repartizat un nod în rețea. Fiecare din cele 19 noduri ale stratului ascuns este conectat cu toate nodurile de intrare și ieșire. Stratul de ieșire conține un singur nod (Y1), reprezentat de rata lichidității globale.

Primul pas în construcția modelului este perioada de instruire, care reprezintă procesul de învățare, când ponderile au valori optime. Modelul nostru utilizează un proces de învățare supervizată, întrucât se bazează pe o pereche de date de instruire formată dintr-un vector de intrare (R1, R2, R3, R4, R5) și o valoare de ieșire vizată Y_1 . Metoda de învățare utilizată în model este propagarea inversă a erorii. Obiectivul algoritmului este de a identifica funcția adecvată, care poate furniza valoarea de ieșire corectă, pe baza vectorului de intrare. Perioada de instruire a rețelei încearcă să acumuleze cunoștințe despre modelul studiat. Pe parcursul perioadei de instruire, algoritmul determină ponderea fiecărui nod și tipul de relație – directă sau inversă – dintre acestea. Pe durata memorării cunoștințelor, rețeaua încearcă să minimizeze erorile determinate ca diferență între valorile furnizate de model și valorile țintă, modificând ponderile. Considerate împreună, seturile de valori de intrare, care constă în valorile unui număr de cinci indicatori financiari, pentru anii 2010, 2011, 2012 și 2013, reprezintă informația utilizată de rețeaua neuronală pentru a-și modifica structura.

Rezultatul testului (vezi Figura nr. 2) confirmă precizia și capacitatea de previziune a modelului proiectat.

Figura nr. 2. Rata lichidității generale, comparație între valoarea previzionată de modelul neuronal și valoarea țintă



Sursa: prelucrare proprie în Excel și PyBrain

Pentru a implementa modelul propus, am utilizat aplicația gratuită PyBrain, realizată în limbajul de programare Python. Valoarea erorii de instruire este fixată la 0,0001,

cu o rată de învățare de 0,05 și un număr total de 19.944 iterații în faza de învățare. Urmând cunoștințele memorate, am testat modelul cu baza de date adecvată,

comparând valorile previzionate pentru anul 2014 cu valorile țintă ale rețelei neuronale. Procesul s-a repetat, utilizând neuroni din straturile ascunse. S-a constatat că algoritmul a generat un model exact, care poate fi utilizat în analiza bazată pe previziune.

4.2. Construirea unui model de rețea neuronală pentru previzionarea ratei solvabilității globale

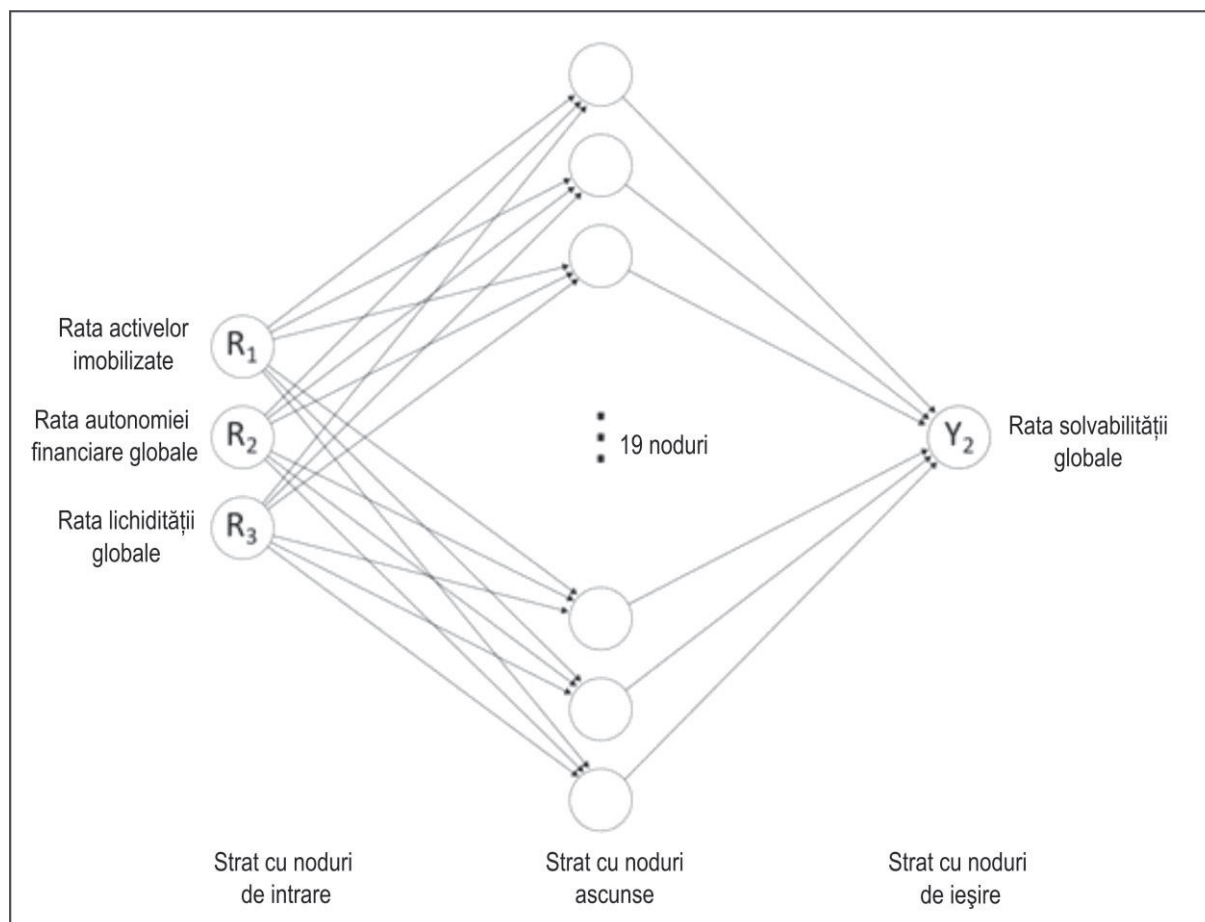
Solvabilitatea unei entități reprezintă capacitatea acesteia de a-și achita la scadență datoriile pe termen lung, precum și dobânda asociată acestora. În aplicația

noastră, am construit o rețea neuronală pentru a previziona rata solvabilității globale (vezi **Figura nr. 3**).

Unde:

- R1 (Rata activelor imobilizate) = active imobilizate/activ total
- R2 (Rata autonomiei financiare globale) = capital propriu/datorii totale
- R3 (Rata lichidității globale) = active curente/datorii curente
- Y2 (Rata solvabilității globale) = activ total/datorii totale

Figura nr. 3. Modelul de rețea neuronală pentru previzionarea ratei solvabilității globale



Sursa: proiecție proprie


După cum se arată în **Figura nr. 4**, există 23 de noduri, trei noduri de intrare, o ieșire corespunzătoare ratei

solvabilității generale Y1 și 19 noduri ascunse (Prodan-Palade, 2016). Intrările în sistem includ ratele R1, R2,

R3. Pentru fiecare dintre acestea, în rețea există un nod. Pe parcursul procesului de construcție a modelului,

acestora le sunt atribuite diferite ponderi.

Figura nr. 4. Rata solvabilității, comparație generală între valoarea previzionată de modelul neuronal și țintă




Sursa: prelucrare proprie în Excel și PyBrain

O trăsătură importantă a rețelelor neuronale constă în convergența erorilor, respectiv minimizarea diferențelor între vectorul de ieșire al modelului, obținut prin învățare, și vectorul țintă, care conține un set de valori determinate a priori. În situația în care valorile de intrare


nu pot explica valorile de ieșire țintă, respectiv între acestea nu există o corelație, rețeaua nu poate construi modelul neuronal, iar erorile înregistrate nu sunt convergente. Rețeaua noastră este convergentă și erorile ating un minim local (vezi **Figurile nr. 5 și 6**).

Figura nr. 5. Evoluția erorilor înregistrate pe parcursul celor 19.944 pași de învățare



Sursa: prelucrare proprie în Excel și PyBrain

Figura nr. 6. Evoluția deplasării erorilor medii pe parcursul celor 19.944 pași de învățare



Sursa: prelucrare proprie în Excel și PyBrain

Concluzii și perspective ale utilizării rețelelor neuronale în economie

Obiectivul cercetării noastre a fost de a dezvolta două rețele neuronale cu propagare inversă a erorii, o tehnică utilizată pe scară largă, pentru a previziona ratele de lichiditate și solvabilitate globală ale unei entități. Am testat precizia fiecărui model, prin compararea valorilor de ieșire ale modelului de previziune cu un set de valori țintă, preluate din situațiile financiare auditate ale entităților listate pe BVB. Noutatea cercetării constă în faptul că ne-am bazat pe un eșantion de entități românești, iar pentru investigația noastră am utilizat cele mai recente informații financiar-contabile disponibile pentru perioada 2010-2014. Cu ajutorul instrumentelor pe care le-am menționat, am construit rețelele neuronale apelând la o combinație de indicatori financiari, selectați pe baza literaturii de specialitate și a raționamentului propriu. Cercetarea se justifică prin cererea tot mai ridicată de implementare a unor algoritmi de performanță capabili să furnizeze o previziune corectă a evoluției firmelor pe piețele actuale în continuă creștere. Precizia previziunilor este impresionantă, dovedind încă o dată faptul că simbioza între tehnologia informației și informația financiară produce valoare pentru o entitate și constituie elementul de bază al managementului modern.

Dat fiind spectrul larg de factori care influențează activitatea unei firme, previzionarea evoluției acesteia este un proces dificil. Pentru a obține rezultate fiabile, analiștii sunt nevoiți să utilizeze modele complexe și un volum ridicat de date. Dacă rezultatele previzionate diferă în mod semnificativ de valorile înregistrate în raportările anuale, acestea se vor transforma într-un impediment în procesul de management, riscurile cresc, iar entitatea își pierde credibilitatea în fața investitorilor. Din acest motiv, analiza și previzionarea activității joacă un rol foarte important, influențând relația companiei cu părțile interesate. Toate aceste elemente reprezintă argumente în favoarea dezvoltării unor metodologii moderne și eficiente de analiză și previziune a riscului de faliment.

În lucrările de cercetare, riscul financiar este definit de diferiți indicatori, în funcție de contextul investigației. Din perspectiva băncilor, acesta poate însemna incapacitatea entității de a-și achita datoriile la scadență, în timp ce din perspectiva burselor, companiile care înregistrează pierderi sau prezintă un capital propriu negativ pentru trei exerciții financiare consecutive prezintă un risc financiar ridicat (Shang, 2015). În același timp, furnizorii iau decizii pe baza lichidității, solvabilității și continuității activității entității, urmărind de regulă un orizont de timp mai redus decât creditorii financiari. Din punct de vedere al guvernantei corporative, diminuarea riscului implică îmbunătățirea lichidității și a solvabilității, precum și luarea celor mai

bune decizii, pentru a asigura autonomia financiară și o poziție competitivă favorabilă pe piață. Din acest motiv, considerăm că previzionarea acestor indicatori, respectiv a ratelor de lichiditate și solvabilitate globală, este adecvată. O evaluare corectă a riscurilor impune analiza și interpretarea aspectelor semnificative legate de activitatea comercială a entității, precum și capacitatea de a previziona orice evenimente viitoare neprevăzute care ar putea avea loc. Un exemplu în acest sens este activitatea de finanțare, care reprezintă o parte importantă a procesului de investire și dezvoltare, precum și o componentă esențială a politicii economice a unei companii. Deciziile de finanțare trebuie să se bazeze pe informații furnizate de analiza economică și financiară. Dacă o entitate dispune de mai multe alternative de finanțare, managerul va trebui să aleagă cea mai bună opțiune care răspunde necesităților comerciale, în conformitate cu activitatea sa specifică și cu strategiile pe termen lung. Dat fiind faptul că resursele financiare pe termen lung fac parte din capitalul permanent al unei entități și sunt direct legate de mecanismele financiare pe termen lung ale entității, alegerea celei mai eficiente variante este rezultatul unui proces de revizuire detaliat.

Tehnicile convenționale de previzionare a riscului au anumite deficiențe. De exemplu, în ceea ce privește funcția Z, nu există nicio bază teoretică a dependenței strict liniare a variabilelor utilizate în modelul de regresie. Aplicarea logicii fuzzy, care funcționează cu valori logice zero și unu, oferă o precizie superioară a algoritmilor de previziune, însă necesită cunoștințe avansate și experiență din partea practicienilor. Rețelele neuronale învață independent, însă au nevoie de experiență bazată pe exemple furnizate la intrare, fără a se specifica anumite funcții de modelare și fără a recurge la experiența specialiștilor.

Lucrările de cercetare publicate în domeniu arată că o rețea neuronală bine instruită este capabilă să

previzioneze riscul financiar cu un nivel înalt de precizie, înregistrând o performanță superioară celei prezentate de algoritmi de regresie liniară multivariată (Coats și Fant, 1993; Shang ș.a., 2015). Acestea pot fi approximate adecvat prin funcții non-liniare, utilizând neuroni plasați în straturile ascunse și ponderând legăturile dintre noduri. Rețelele neuronale oferă soluții valoroase la problemele complexe ale activităților companiei, fiind un instrument extrem de valoros pentru burse, investitori, manageri și finanțiști.

Ca cercetare viitoare, ne-am propus să utilizăm rețelele neuronale pentru a detecta fraudă din raportările financiare. Modelul pe care îl recomandăm pentru lucrări viitoare ar trebui să utilizeze valori ale unor anumite rate financiare previzionate de rețeaua neuronală, care pot fi comparate cu valori țintă preluate din raportări anuale și rapoarte de audit. Eventualele discrepanțe semnificative pot reprezenta un indiciu al raportării frauduloase, oferind auditorilor posibilitatea de a intensifica controlul unor asemenea elemente. Metoda propagării inverse a erorii, utilizată în prezenta lucrare, poate fi înlocuită cu alte metode (Enăchescu, 2009). În același timp, pentru previzionarea riscului de faliment va trebui să avem în vedere alte variabile financiare și non-financiare legate de guvernarea entității.

Ar trebui să menționăm anumite limite ale cercetării: eșantionul a fost compus din doar 55 de entități, care au fost analizate pe parcursul unei perioade scurte de timp. Eficiența rețelelor neuronale crește proporțional cu volumul datelor de intrare. Ar putea fi, de asemenea, interesant un studiu asupra tuturor entităților românești, inclusiv asupra celor care nu sunt listate la Bursa de Valori București. Pentru a oferi o privire de ansamblu asupra companiilor românești, menționăm faptul că, la data de 31 decembrie 2015 în România erau înregistrate 773.781 firme active. Un studiu comprehensiv, bazat pe un eșantion format din toate aceste entități, ar fi deosebit de interesant pentru mediul economic din țara noastră.

BIBLIOGRAFIE

1. Ahangar, A.G., Yahyazadehfar, M. și Pournaghshband, H. (2010), The comparison of methods artificial neural network with linear regression using specific variables for prediction stock price in Tehran Stock Exchange, *International Journal of Computer Science and Information Security*, vol. 7, nr. 2, pp. 38-46.
2. Airinei, D. și Berta, D. (2012), Semantic business intelligence - a new generation of business intelligence, *Informatică Economică*, vol. 16, nr. 2, pp. 72-80.
3. Alborzi, M., Roodposhti, F.R. și Sabet, S. (2013), Using neural networks for forecasting operation

- cash flows, *Interdisciplinary Journal of Contemporary Research in Business*, vol. 4, nr. 9, pp. 1165-1173.
4. Ardebili, M.A., Hashemi, M., Shahabi, A. și Barough, M.H. (2015), Optimized selection of stock portfolio by using the fuzzy artificial neural networks web model, ARIMA and Markowitz Model in Tehran Stock Exchange, *European Online Journal of Natural and Social Sciences*, vol. 4, nr. 1, pp. 831-844.
 5. Aydin, A.D. și Cavdar, S.C. (2015), Prediction of financial crisis with artificial neural network: An empirical analysis on Turkey, *International Journal of Financial Research*, vol. 6, nr. 4, pp. 36, DOI 10.5430/ijfr.v6n4p36.
 6. Badea (Stroie), M.L. (2013), Supporting management decisions by using artificial neural network for exchange rate prediction, *Accounting and Management Information Systems*, vol. 12, nr. 4, pp. 578-594.
 7. Bunget, O.C. (2009), Etică și audit intern: Problematika whistleblowing-ului, *Audit Financiar*, vol. 7, nr. 9, pp. 43-51.
 8. Bunget, O.C., Bliidișel, R.G., Dumitrescu, A.C. și Demian, R. (2014), Reacția auditorului financiar la provocările crizei economico-financiare, *Audit Financiar*, vol. 12, nr. 6, pp. 3-11.
 9. Coats, P.K. și Fant, L.F. (1993), Recognizing financial distress patterns using a neural network tool, *Financial Management, Periodicals Archive Online*, vol. 22, nr. 3, pp. 142-155, DOI 10.2307/3665934.
 10. Enăchescu, C. (2009), *Calculul neuronal*, Editura „Casa Cărții de Știință”, Cluj-Napoca.
 11. Glasserman, P. și Young, H.P. (2013), How likely is contagion in financial networks? *Discussion Paper Series, University of Oxford, Department of Economics*, DOI 10.2139/ssrn.2642423.
 12. Hu, J.W.-S., Yi-Chung, H. și Wen Lin, R.R. (2012). Applying neural networks to prices prediction of crude oil futures, *Mathematical Problems in Engineering*, vol. 2012, pp. 1-12, DOI 10.1155/2012/959040.
 13. Kaastra, I. și Boyd, M. (1996), Designing a neural network for forecasting financial and economic time series, *Neurocomputing*, vol. 10, nr. 3, pp. 215-236, DOI 10.1016/0925-2312(95)00039-9.
 14. Khademolqorani, S., Ali, Z.H. și Farimah, M.R. (2015), A hybrid analysis approach to improve financial distress forecasting: Empirical evidence from Iran, *Mathematical Problems in Engineering*, vol. 2015, pp. 1-9, DOI 10.1155/2015/178197.
 15. Pradhan, R., Pathak, K.K. și Singh, V.P. (2011), Application of neural network in prediction of financial viability, *International Journal of Soft Computing and Engineering (IJSCE)*, vol. 1, nr. 2, pp. 41-45.
 16. Prodan-Palade, D. (2016), Corporate governance between performance and non-performance validated through accounting, *PhD Thesis*, Alexandru Ioan Cuza University, Romania.
 17. Salama, A.S. și Omar, A.A. (2014), A back propagation artificial neural network based model for detecting and predicting fraudulent financial reporting, *International Journal of Computer Applications*, vol. 106, nr. 2, DOI 10.5120/18489-9521.
 18. Shang, H., Huang, J., Yang, J. și Zhou, D. (2015), Predicting financial risk of Chinese listed companies in strategic emerging industries with BP neural network, *Advances in Information Sciences and Service Sciences*, vol. 7, nr. 4, pp. 43-58.
 19. Tjung, L.C., Kwon, O. și Tseng, K.C. (2012), Comparison study on neural network and ordinary least squares model to stocks' prices forecasting, *Academy of Information and Management Sciences Journal*, vol. 15, no. 1, pp. 1-35.
 20. Vallini, C., Ciampi, F. și Gordini, D.N. (2009), Using artificial neural networks analysis for small enterprise default prediction modeling: statistical evidence from Italian firms. *2009 Oxford Business and Economics Conference Program*, ISBN: 978-0-9742114-1-1.
 21. Walczak, S. (2001), An empirical analysis of data requirements for financial forecasting with neural networks, *Journal of Management Information Systems*, vol. 17, nr. 4, pp. 203-222, DOI 10.1080/07421222.2001.11045659.
 22. Yildiz, B. și Yezegel, A. (2010), Fundamental Analysis with Artificial Neural Network, *The International Journal of Business and Finance Research*, vol. 4, nr. 1, pp. 149-158.