

## APLICAREA REȚELELOR DE NEURONI ARTIFICIALI ÎN PROGNOZAREA RATINGULUI TITLURILOR DE VALOARE

*Asist. princ. dr. Natalia MARINOVA,  
Academia de Economie „Dmitri Ţenov”  
din Sviștov*

Articolul dat studiază aplicarea rețelelor de neuroni artificiali în soluționarea problemelor clasificate. Scopul lucrării este de a deduce cele mai importante sfere economice, în care acestea pot fi utilizate cu succes și de a arăta posibilitățile rețelelor în cauză pentru o predicție relativ exactă a ratingului de titluri de valoare emise. Pentru a atinge aceste obiective, a fost studiată literatura de specialitate cu privire la problemele existente și analiza dovezilor empirice din studiile diversilor autori.

**Cuvinte-cheie:** inteligență artificială, rețele neuronale artificiale, prognozarea ratingului titlurilor de valoare.

**JEL:** C88, L86

### Introducere

#### 1. Rețelele neuronale artificiale – o tendință promițătoare în utilizarea sistemelor cu inteligență artificială

De mii de ani, omul a visat la crearea mașinilor care să-l poată înlocui în diverse activități. Datorită apariției și dezvoltării direcției științifice de inteligență artificială, astăzi asistăm la realizarea unui număr impunător din aceste doleanțe.

Intențiile oamenilor de știință de a combina tehnica și performanțele sistemelor informatice cu conștiința umană s-a manifestat odată cu apariția primelor calculatoare electronice, la mijlocul anilor '50 ai secolului XX. Formarea modelării logico-simbolice de inteligență a creat domenii noi, cum ar fi programarea euristică și inteligența mașinilor și a pus începutul ideii de a crea sisteme informatice, care funcționează în analogie cu creierul uman – așa-numitele sisteme cu inteligență artificială. În ultimul deceniu, inteligența artificială și sistemele bazate pe această inovație s-au dezvoltat destul de intens: ritmurile sunt comparabile, ca importanță, cu revoluția informațională cauzată de lumea de pe Internet.

După Conferința de la Dortmund din 1956, care este considerată primul forum științific la care s-a introdus conceptul de inteligență artificială, dezvoltarea direcției științifice se caracterizează prin apariția a două abordări radical diferite în reprezentarea obiectelor în acest tip de sisteme informatice – abordarea simbolică și numerică.

Abordarea simbolică se referă la așa-numita „inteligență artificială clasică”, bazată pe conceptele de „simboluri” și „căutare”, introduse de oamenii de știință Allen Newell și Herbert Simon. Conform teoriei lor, sistemele cu inteligență artificială funcționează în baza

## ARTIFICIAL NEURAL NETWORK APPLICATIONS IN BOND RATING PREDICTIONS

*Head Assistant, PhD Natalia MARINOVA  
D. A. Tsenov Academy of Economics,  
Svishtov, Bulgaria*

*This paper explores the use of artificial neural network applications in resolving complicated classification problems. The main target is to outline the most important economic areas where they can successfully be applied and to reveal their capabilities for relatively correct predictions of an emitted bond's rating. To achieve these goals we have investigated the specialist literature dedicated to the existing problems and have analysed some empirical data from different author's works.*

**Key words:** artificial intelligence, artificial neural networks, bond rating predictions.

**JEL:** C88, L86

### Introduction

#### 1. Artificial neural networks – a trend in artificial intelligence systems applications

For thousands of years, humanity has dreamed of creating machines which could be able to replace them in the performance of different human activities. Due to the emergence and development of the scientific strand of artificial intelligence, today, we are witnesses as to how some of these dreams may come true.

The ambitions of scientists to link data processing and the performances of informatics systems with human conscience began at the time of the emergence of the first computers in the middle of the 50's of the 20th century. The approach of logic-symbolic modelling of intelligence created such strands as heuristic programming and machine intelligence, and started ideas for establishing computer systems that worked analogically like the human brain – so-called artificial intelligence (AI) systems. During the last decade, AI and the systems created on the basis of this innovation have developed intensively at such a pace it is comparable in scope with the information revolution provoked by the global network, the Internet.

After the conference in Dartmouth in 1956 (which is well known as the first scientific forum on AI) the development of the scientific strand has been characterized by the appearance of two different approaches to presenting objects in these types of information systems – symbolic and numeric.

The symbolic approach relates to the so called ‘classical artificial intelligence’, on the basis of which, the terms of “symbols” and “search” were introduced by the scientists Allen Newell and Herbert Simon. According to their theory, AI systems work with symbolic-modelled knowledge, and as the first

cunoștințelor simbolic-modelate, iar primele aplicații ale inteligenței date le-au constituit sistemele-expert.

În cadrul abordării numerice, în inteligența artificială, sunt gestionate cunoștințele, implicit reprezentative, care nu au o formă verbală, dar sunt folosite inconștient și, de multe ori, intuitiv. Principalii reprezentanți ai acestei tendințe sunt rețelele neuronale artificiale, algoritmi genetici și sistemele de simulare. Toate acestea sunt programe sau surse tehnice, proiectate pentru a simula anumite funcții ale creierului uman.

Rețelele neuronale artificiale sunt un model electronic relativ „brut” al structurii creierului uman, în care informațiile sunt stocate ca „probe” (modelul reflectă realitatea). Abordarea metodelor de salvare și repartizare a informației, în forma modelului, servește ca un nou instrument de prelucrare a datelor pe calculator – aceasta nu include programarea tradițională, ci crearea de rețele masive paralele, instruite în rezolvarea problemelor specifice. [4]

Într-o formă mai generală, rețelele neuronale artificiale pot fi descrise ca o rețea paralelă de elemente simple adaptate – neuroni, care interacționează cu lumea reală din jur similar sistemului nervos biologic [2]. Din punct de vedere al ingineriei, ea reprezintă un sistem foarte dinamic, cu o topologie regizată grafic, care poate procesa informații prin schimbarea de stare ca răspuns la o intrare constantă sau puls [3]. Funcționarea corectă a acestui tip de rețea depinde de ordonarea fluxului de neuroni, de alegerea funcției activate și conexiunile ponderate între neuroni.

În prezent, utilizarea rețelelor neuronale artificiale poate fi divizată în trei direcții:

1. Pentru a simula comportamentul inteligent pe baza cunoștințelor acumulate în neuroștiințe și psihologie matematică;
2. Ca elemente încorporate, la nivel de hardware sau software controlere, în diferite aplicații industriale, în special, la tipurile de vehicule robotizate în producție și ingineria de proiectare;
3. Ca mijloc de prelucrare a datelor economice empirice.

Obiectivele specifice [1], care pot fi atinse prin utilizarea rețelelor neuronale artificiale, se referă la administrarea investițiilor, managementul financiar, prognoza piețelor financiare și a primelor de asigurare, de analiză a prețului de bunuri, pe de o parte, și analiza de risc a creditării, prognozarea comportamentului forței de muncă și modelarea macroeconomică, pe de altă parte.

Punerea în aplicare a rețelelor neuronale artificiale moderne se reflectă în dezvoltarea diferitelor hardware acceleratoare și neuroprocese speciale, puse în aplicare pe bază de cristale de specialitate și de lucru în conformitate cu principiile logicii parțiale.

Producătorii globali creează rețele neuronale artificiale în formă de aplicații software cu următoarele caracteristici:

applications of AI strand expert systems.

When applying the numeric approach in AI, knowledge that is represented indirectly, and which does not possess a verbal form and is used unconsciously - having an intuitive character - is processed. The main representatives of this strand are artificial neural networks, genetic algorithms and simulation systems. All these are in hardware or software form, and are developed to aim for a simulation of specific functions of the human brain.

Artificial neural networks are relatively “raw” electronic models of the human brain’s structure, the information in which is stored as “patterns” (models reflecting reality). The approach of storing and recognizing information in the form of models is a new tool in computing – it does not include traditional programming, but the creation of massive parallel networks which are trained to resolve specific problems [4].

In short, an artificial neural network could be described as a neuron network of simple adaptive elements connected in parallel, which interacts with objects in the real environment, analogically to the biological nervous system [2]. From an engineering point of view, it is a strongly distributed dynamic system with the topology of a directed graph which is able to process information through changing its status by replying to a constant or pulse input signal. [3]. Correct function of such types of networks depends on the neurons arranged within them, the selection of an activating function and the weight connections between the neurons.

Nowadays the application of artificial neural networks could be outlined in the following three ways:

1. As means of modelling intelligent behaviour on the basis of accumulated knowledge in neurobiology and mathematical psychology;
2. As components embedded like hardware or software in controllers in various industrial solutions, mostly in robotic production and as a means of engineering project development;
3. As a means of empirical economic data processing.

The specific tasks [1] which could be achieved by the assistance of artificial neural networks refer to: investment management, finance management, financial markets forecasting, insurance premium forecasting, predicting available stock prices on the one hand, and, on the other hand, risk analyses in crediting, work force behaviour prediction, macro-economic modelling, etc.

The hardware realization of contemporary artificial neural networks is expressed via the development of various hardware accelerators and specialized neuro-processors made using special crystals and operating according to the principles of fuzzy logic.

1. Procesarea limbilor – există multe aplicații pentru a converti textul în discurs și vorbirea în text. Unele programe au potențialul de a proteja vocea (de recunoaștere a vocii), de a traduce în limbi diferite, de a verifica greșelile de ortografie etc.
2. Recunoașterea caracterelor – aceste aplicații pot fi folosite de către diferite instituții financiare pentru colectarea informației de la formularul completat și înscrierea în baza de date.
3. Recunoașterea modelelor – astfel de sisteme sunt utilizate pe larg în evaluarea costurilor monedelor valoroase și controlul asupra calității produselor. În sfera protecției, se cer aplicații de detectare a obiectelor specifice.
4. Procesarea semnalelor – prima rețea neuronală artificială ADALINE a fost creată ca un supliment la metodele de reducere a zgomotului în liniile telefonice. Iar Odin Corporation a stabilit un program de prelucrare a gazelor emantate de motoarele autovehiculelor.
5. Prelucrarea datelor – în domeniul finanțelor. Rețele neuronale artificiale sunt folosite la evaluarea riscului de credit, atunci când se acordă împrumuturi, carduri de credit și în precizarea ratingului de credit al titlurilor de valoare.
6. Servocontrolul – controlul sistemelor complexe este una dintre cele mai promițătoare aplicații ale rețelelor neuronale artificiale. În vederea dezvoltării unui astfel de sistem, pentru un proces specific, este necesară configurarea manuală a formulelor care guvernează procesele.

#### Material și metodă.

#### 2. Utilizarea rețelelor neuronale artificiale pentru a prezice evaluarea titlurilor de valoare

În ultimii ani, producătorii de rețele neuronale artificiale, au depus eforturi pentru a implementa principiile logicii fuzzy în aplicațiile lor. Există o tendință în dezvoltarea de neuroni neclari (neuroni vagi), care nu oferă un simplu răspuns de „da” sau „nu”. Astfel de sisteme hibride funcționează, de obicei, cu neuroni convenționali și neclari care pot efectua anumite studii, comparând informațiile și corectând erorile comice.

Logica fuzzy, rețelele neuronale artificiale și algoritmi genetici sunt cele trei componente principale ale așa-numitului calcul moale (soft computing). Noțiunea, explicată mai popular, este înțeleasă ca fiind un set de metodologii care lucrează sinergic și oferă oportunități de prelucrare flexibilă a informației pentru a permite rezolvarea situațiilor din viața reală. Tehnicile soft computing pot fi folosite cu succes pentru rezolvarea problemelor multidimensionale și, anume, sarcinilor care au un număr relativ mare de variabile de intrare, așa, de exemplu, este problema titlurilor de valoare de prognoză nominală, ceea ce constituie o sarcină de clasificare tipic

Global producers create artificial neural networks as software applications with the following characteristics:

1. Language processing – there are many existing applications capable of converting text into speech and vice versa. Some programs have the capabilities of voice protection (speech recognition), different language translations, spelling, etc.
2. Symbol recognition – such applications can be used by different financial organizations for information collection from completed forms that have been saved in a database.
3. Pattern recognition – such systems are used massively in the value evaluation of precious coins and in quality control. In the area of defence, some applications are implemented for the location of specific objects.
4. Signal processing – the first artificial neural network, ADALINE, was created as a noise reduction application for telephone lines. On the other hand, the Odin Corporation has created a program for monitoring the exhaust of engines of different motor vehicles.
5. Data processing – in the financial field, artificial neural networks are used in credit risk rating when granting loans, credit card approvals and bond credit ratings.
6. Servo control – complicated systems control is one of the most promising strands of artificial neural network applications. In order to develop such a system for a specific process, one needs to manually set up the formulas which manage the processes. In the oil industry, artificial neural networks are already used for refining process improvement, and in NASA they are used for controlling and manoeuvring the space shuttles.

#### Material and method

#### 2. The use of artificial neural networks for bond credit rating predictions

During recent years, the vendors of artificial neural networks have attempted to embed the principles of fuzzy logic in their applications. A trend can be observed toward fuzzy neuron development, which does not give simple answers such as “yes/no”. Such hybrid systems (working both with common and fuzzy neurons) will be able to be trained through a comparison of information and correcting any errors found within.

Fuzzy logic, artificial neural networks and genetic algorithms are the three main components of so-called soft computing methodologies. The term can popularly be explained as a sum of methodologies which work synergistically and present possibilities for flexible information processing that can deal with real situations in life. The techniques of soft computing

multidimensională și dificil de rezolvat cu ajutorul programelor de calculator tradiționale.

După cum știți, titlurile de valoare emise pot fi cumpărate și vândute sau date cu împrumut, fiind oferite guvernelor sau investitorilor marilor companii. În prealabil, la primirea împrumuturilor prin intermediul titlurilor de valoare, este necesar să le fie evaluată bonitatea pe baza situațiilor financiare (bilanțul și conturile de venituri) și așteptările, în ceea ce privește dezvoltarea lor economică viitoare. Cei mai mulți investitori nu au resursele necesare pentru a efectua o astfel de cercetare dificilă și care necesită mult timp, astfel, încât aceștia recurg la serviciile agențiilor de rating.

Ratingul de credit al societății sau guvernului îl constituie o măsură de risc, în cadrul căreia se estimează dacă clientul respectiv este în stare să plătească contribuțiile, sau titlurile de valoare cumpărate vor fi returnate. Diverse agenții de rating (Standard & Poor, Moody, Fitch, Duff & Phelps și colab.) iau în considerare atât efectele cantitative – rentabilitatea companiei și valoarea datoriei restante, cât și factorii calitativi – aptitudinile de management și previziunile economice pentru organizație. Analizat fiind dintr-o perspectivă holistică, ratingul respectiv este rezumat, în evaluare alfabetică, de la A – cea mai înaltă clasă de rating, gradul maxim de siguranță, la „B” – unde sunt clasate persoanele ce au întârzieri emitente sau neîndeplinirea obligațiilor contractuale.

Deoarece activitățile agențiilor de rating acoperă o mulțime de momente confidențiale, mulți cercetători au încercat să formuleze abordări alternative la prognozarea evaluării titlurilor de valoare.

Ultimele lucrări s-au concentrat pe utilizarea diferitelor metode statistice, prin analiza de regresie liniară [8] și analiza discriminantelor liniare [14]. Ulterior, metodologia de tehnici convenționale de analiză statistică a fost criticată de mulți oameni de știință și a devenit cunoscută și aprobată prin ideea că, în rezolvarea unor probleme complexe de clasificare, ar trebui să se aplice rețele neuronale artificiale, seturi fuzzy și sisteme-expert [7].

Un exemplu practic de rezolvare a problemei de prognoză a ratingului de credit al titlurilor de valoare, prin utilizarea unei metodologii artificiale a rețelelor neuronale, este prezentată în articolul omului de știință indian J. Sethuraman [16], în care acesta descrie relația dintre situația financiară a societății și a ratingului de credit atribuit. Scopul lucrării – de a investiga în ce măsură acest lucru va determina analiza expertă de agenția de rating.

J. Sethuraman construiește o rețea neuronală artificială, cu 45 de variabile de intrare, care sunt mapate într-un set de 15 clase discrete, se exclud reciproc din ratinguri și pot fi atribuite titlurilor de valoare. Un număr mare de variabile poate acoperi cât mai mulți, posibili, parametri financiari ai companiei, datorită căreia, o rețea neuronală artificială fără supraveghere poate „învăța”

could be applied successfully in resolving multi-dimensional problems, i.e. tasks which possess a relatively great number of input variables. One instance is the task of bond rating prediction, which is a typical multi-dimensional task and is hard to solve via traditional computational programs.

As is well-known, the emission of bonds is a free trading loan granted by investors for other companies or governments. The buyers of bonds have to make an evaluation of the credibility of the loan-receiving organization based on its financial statements (the balance sheet and income accounts) and expectations for its future economic development. Most of the investors do not have enough time to make such a time consuming and difficult investigation and therefore use the services of rating agencies.

The assessment of a given company or government credibility is a measure of the risk that it will be able to pay the instalments for the granted loan and to buy back the emitted bonds. The various rating agencies (Standard & Poor's, Moody's, Fitch, Duff & Phelps and others) measure the influence both of quantitative (the profitability of the company and the volume of the outstanding debt) and qualitative (managerial skills, economic forecasts for organizational development) factors. The overall analysis is summarized using a letter rating: from A – the highest rating having maximum security, to „B” – the emitter slows down or allows their obligations to become overdue.

Due to the fact that the activities of rating agencies cover many confidential points, many researchers have tried to formulate alternative approaches for bond rating predictions.

In earlier works, they have concentrated on various statistical methods used for analyses such as linear regression [8], and linear discriminates [14]. Later on, the methodology of conventional techniques for statistical analyses was criticized by many scientists and, as a result, the idea of applying artificial neural networks to solving complicated classification tasks, fuzzy sets and expert systems was put forwards [7].

A practical example of solving the task of forecasting bond credit ratings through the use of the methodology of artificial neural networks can be found in the paper by the Indian scientist Sethuraman [16], where he describes the rate between the financial statement of a given company and the credit rating assigned to it. The goal of his work was to explore how this evaluation is influenced by expert analyses performed by a credit agency.

J. Sethuraman constructed an artificial neural network with 45 input variables, which matches a set of 15 discrete and mutually exclusive classes of ratings, to which bonds could be associated. The large number of variables permitted the use of possibly more company financial parameters, so that the artificial neural network could be able to non-observably “learn” the

relația dintre date. Pentru a instrui rețeaua, autorul utilizează mai mulți algoritmi:

1. Abordarea bazată pe o rețea neuronală – o rețea de Kohonen sau hărți cu auto-organizare [9], [11], [12] și [13];
2. Tehnica de cluster pe baza neclarității – instrumente neclare [6];
3. Sistemul de neuron-fuzzy – rețele Kohonen neclare [17].

**Variabilele de intrare, alimentate la o rețea neuronală artificială, includ metrici financiare care descriu dimensiunea companiei, rentabilitatea, lichiditatea, obligațiile, data înființării, iar alte date sunt prezentate în tabelul 1.**

data dependencies. The author used several algorithms for training the network:

1. An approach based on neural networks – a Kohonen network or self-organizing map; [9], [11], [12], [13];
2. A cluster technique based on fuzziness and fuzzy means [6];
3. A neuro-fuzzy system – a fuzzy Kohonen [17].

**The input variables sent to the artificial neural network included financial metrics describing the size of the company, profitability, liquidity, obligations, foundation date, etc., as shown in table 1.**

*Tabelul 1 / Table 1*

**Intrare variabile în modelul Sethuraman / Input variables in Sethuraman's model**

Raportul dintre profit pe dividende și mărimea vânzărilor / Ratio of value of profit before dividends/value of sales	Raportul dintre valoarea medie a creanței și valoarea medie a activelor circulante / Ratio of average value of debtors claims /average value of current assets
Raportul dintre venitul înainte de impozitare și mărimea vânzărilor / Ratio of value of profit before taxes/size of sales	Raportul dintre valoarea medie a capitalului de lucru și valoarea tuturor activelor / Ratio of average value of turnover capital /value of all assets
Raportul dintre profitul de dividende și valoarea medie a capitalului angajat / Ratio of value of profit before dividends /average value of the borrowed capital	Raportul dintre valoarea medie a capitalului de lucru și mărimea vânzărilor / Ratio of average value of turnover capital /value of sales
Raportul dintre venitul înainte de impozitare și rata dobânzii la titlurile de valoare / Ratio of value of profit before taxes/value of interests rate of bonds	Raportul dintre mărimea datoriilor pe termen lung și valoarea netă a companiei / Ratio of amount of long term loans/net value of the company
Raportul dintre profitul după impozitare și valoarea tuturor activelor / Ratio of value of profit after the taxes/value of all assets	Raportul dintre valoarea creditelor și a valorii nete a companiei / Ratio amount of all loans/net value of the company
Raportul dintre valoarea vânzărilor și valoarea tuturor activelor / Ratio of value of sales/value of all assets	Raportul dintre valoarea creditelor și valoarea tuturor activelor / Ratio of amount of all loans /value of all assets
Raportul dintre valoarea vânzărilor și valoarea activelor circulante / Ratio of value of sales/value of current assets	Raportul (venituri din exploatare – ratele dobânzilor la titlurile de valoare) și valoarea tuturor activelor / Ratio of (operative profit – bonds interest rate)/value of all assets
Raportul dintre valoarea vânzărilor și valoarea capitalului angajat / Ratio of value of sales/ value of the borrowed capital	Raportul dintre valoarea veniturilor totale și a valorii nete a companiei / Ratio of value of income /net value of the company
Raportul dintre valoarea netă a companiei și valoarea tuturor datoriilor / Ratio of net value of the company / value of all liabilities	Raportul dintre profitul operațional și valoarea tuturor activelor / Ratio of operative profit /value of all assets
Raportul dintre valoarea rezervelor și valoarea tuturor activelor / Ratio of value of reserves/ value of all assets	Raportul dintre valoarea profitului operațional și valoarea capitalului angajat / Ratio of operative profit /value of capital employed
Durata medie în zile de plăți către creditori / Average time in days for payments to creditors	Raportul dintre valoarea profitului operațional și vânzări / Ratio of operative profit /value of sales
Durata medie în zile de creanțe / Average time in days for claims to debtors	Raportul dintre veniturile în termeni de bani și vânzări / Ratio of cash value of the profit /value of sales
Raportul dintre durata medie de plăți către creditori în zile și lungime medie de creanțe, în zile / Ratio of average time in days for payments to creditors/ average time in days for claims to debtors	Raportul dintre veniturile în termeni de bani și valoarea tuturor creditelor / Ratio of cash value of the profit /value of all loans
Raportul dintre valoarea medie de inventar și valoarea medie a activelor circulante / Ratio of average value of stock/average value of current assets	Raportul dintre veniturile în termeni monetari și valoarea capitalului angajat / Ratio of cash value of the profit /value of capital employed

Raportul dintre valoarea medie a stocurilor și mărimea vânzărilor / Ratio of average value of stock/ value of sales	Raportul dintre valoarea medie stocată în active în numerar și costul mediu al activelor circulante / Ratio of average of the saved cash means/average value of the current assets
Raportul dintre valoarea medie a stocurilor și valoarea medie a capitalului de lucru / Ratio of average value of stock /average value of turnover capital	Raportul dintre valoarea medie stocată în termeni monetari și valoarea activelor circulante / Ratio of average of the saved cash means /value of FMCG assets
Raportul dintre valoarea medie de inventar și valoarea medie a activelor totale / Ratio of average value of stock /average value of the common assets	Raportul dintre activele curente și vânzări / Ratio of value of current assets /value of sales
Raportul dintre valoarea medie a stocurilor și valoarea medie zilnică a costurilor de producție / Ratio of average value of stock /average value for daily production costs	Raportul dintre activele curente și valoarea tuturor activelor / Ratio of value of current assets /value of all assets
Suma totală a activelor / Total value of assets	Raportul dintre activele curente și valoarea datoriilor curente / Ratio of value of current assets /value of current liabilities
Mărimea vânzărilor / Value of sales	Raportul costurilor activelor circulante rapid și activelor totale / Ratio of FMCG assets /value of common assets
Data înființării companiei / Foundation date of company	Raportul costurilor activelor circulante rapid și a datoriilor curente / Ratio of FMCG assets /value of current liabilities
Raportul dintre valoarea costurilor de publicitate, distribuție și marketing, și valoarea vânzărilor / Ratio of advertisements, distribution and marketing costs value/value of sales	Raportul dintre veniturile în termeni monetari și valoarea (plăților curente pentru pasivele pe termen lung + ratele dobânzilor la titlurile de valoare) / Ratio of cash value of the profits /value of (current payments on long term liabilities + bond interest rate)
Raportul dintre cantitatea (costul total al materiei prime + energie + costuri indirecte + tarif de plată pe oră + alte cheltuieli de exploatare) și valoarea vânzărilor / Ratio of value of (common cots for raw materials +energy +indirect cots +wages + other operative costs) / value of sales	

Toate variabilele de intrare trebuie să fie prezentate într-un formular standard normalizat. Pentru a măsura acuratețea prognozei, autorul calculează numărul de cazuri clasificate corect și incorect, folosind ratingurile de credit pe termen lung cu privire la instrumentele de datorie ale diverselor companii de producție, datele companiilor indiene CRISIL. Din tot setul de antrenare, care conține 170 de intrări din toate clasele de rating, a fost selectat un set de testare din 33 de intrări, acoperind toate clasele de rating. Datorită complexității problemei, e necesar ca scara de evaluări să fie redusă la șase clase principale.

Pentru a compara ratingul titlurilor de valoare din setul de testare, specializat după cei trei algoritmi de mai sus, cu indicatorii de date ai agenției CRISIL, autorul folosește două tehnici: **Tehnica de reducere a dimensiunii** eșantionului prin componentele principale și **Tehnica de reducere a numărului de variabile** prin utilizarea regresiei liniare multiple. Rezultatele obținute sunt prezentate în tabelul 2.

Rezultatele obținute ne permit să tragem următoarele concluzii:

1. Cea mai apropiată coincidență cu previziunile agențiilor de rating o demonstrează utilizarea algoritmului-neuronal fuzzy.

All input variables were represented in a normalized standard form. In order to measure the accuracy of the forecast, the author calculated the number of correctly or incorrectly classified cases, using the credit ratings for the long term debt instruments of different production companies as given by the Indian credit agency, CRISIL. From whole training set, which contained 170 records about all classes of ratings, a test set of 33 records was selected, covering all classes of ratings. Due to the complexity of the problem, it was necessary for the scale of the rating assessments to be reduced to 6 main classes.

In order to be able to compare the bond ratings from the test set trained through the three algorithms cited above with the indicators provided by the CRISIL agency, the author applied two techniques: **a technique for reducing the dimension of the sample** through an analysis of the principle components and **a technique for reducing the number of variables** through the use of multiple linear regression. The results are summarized in table 2.

From the results, we can derive the following conclusions:

1. The closest correspondence to the forecasts by rating agencies is provided by the use of neural-fuzzy algorithm.

Tabelul 2/Table 2

Exactitatea previziunilor în modelele Sethuraman / Prediction accuracy in Sethuraman's model

Algoritm / Training algorithm	Tehnica de reducere a dimensiunii eșantionului / A technique for reducing the dimension of the sample		Tehnica de reducere a numărului de variabile / A technique for reducing the number of variables	
	Procentul de cazuri în care ratingul prevăzut coincide exact cu valorile specificate de către agenție / Percentage of cases where the predicted rating coincides exactly with the one provided by the agency	Procentul de cazuri în care ratingul prevăzut este cu un grad mai mic decât cel precizat de agenție / Percentage of cases where the predicted rating is one class below the one provided by the agency	Procentul de cazuri în care ratingul prevăzut coincide exact cu valorile specificate de către agenție / Percentage of cases where the predicted rating coincides exactly with the one provided by the agency	Procentul de cazuri în care ratingul prevăzut este cu un grad mai mic decât cel specificat de agenție / Percentage of cases where the predicted rating is one class below the one provided by the agency
Harta auto-organizării / Self-organizing map	33%	79%	52%	76%
Mijloace mobile / Fuzzy means	47%	79%	55%	81%
Rețeaua instabilă a lui Kohonen / Fuzzy Kohonen network	51%	80%	62%	80%
Regresia liniară / Linear regression	45%	76%	48%	76%

2. Utilizarea tehnologiei de reducere a numărului de variabile, înregistrează rezultate mai bune. Și ambele tehnici pot fi folosite cu succes în formarea rețelei neclare Kohonen.

Un alt exemplu practic de utilizare a metodelor de calcul soft computing, în precizarea ratingului titlurilor de valoare, e discutat în articolul autorilor, Perkins și Brabazon [15], care au inventat un model de rețele neuronale artificiale compuse din perceptroni cu multe straturi. Un fapt special în studiul celor doi autori este că au folosit un algoritm genetic, pentru a automatiza procesul de selecție a variabilelor de intrare, alimentate la intrarea rețelei neuronale.

Combinând avantajele ambelor concepte, autorii au proiectat o rețea neuronală artificială creată de perceptroni multistratificați hibridi, care încearcă să dovedească două lucruri: 1) eficiența modelului pentru delimitarea titlurilor de valoare cu reiting investițional și ratingul non-investițional; 2) capacitatea modelului de a prezice, cu exactitate, clasa de rating a titlurilor de valoare de clasa A, BBB, BB și B.

Avem dat eșantionul de studiat din 667 de companii nefinanciare cu instrumente de îndatorare pe termen lung, pentru a obține estimări ale agențiilor de rating de la A la B. Pentru studiul rețelei alege de 20 de variabile financiare majore (dimensiunea companiei, rentabilitatea, istoria de rentabilitate, modificările activelor totale în ultimii trei ani etc.), mărimile claselor

2. The use of a technique for reducing the number of variables provides better results. Both techniques could be applied for training fuzzy Kohonen networks.

Another practical example of soft computing methods, used to predict bond ratings, can be found in an article written by Perkins and Brabazon [15], who developed a model of an artificial neural network composed by multi-layer perceptions. The specifics of the research by both authors are that they applied a genetic algorithm in order to automate the selection process of input variables fed to the neural network.

By combining the advantages of both concepts, the authors established an artificial neural network composed of hybrid multi-layer perceptions, with which they tried to prove two points: 1) the usefulness of the model in distinguishing bonds with investment and no-investment ratings; 2) the capability of the model to predict exactly the rating class of bonds for the classes: A, BBB, BB and B.

A sample of 667 non-financial companies with long-term debt instruments which received evaluations from rating companies from AAA to D was examined. For network training 20 main financial variables were selected (the size of the company, profitability, history of profitability, change in common assets during the last three years, etc.), of which the values for the particular rating

individuale de rating sunt diferite pentru fiecare companie.

Exanșionul generat aleatoriu de 50 de genotipuri binare este responsabil de structura perceptronilor individuali și de setul de variabile de intrare (Fiecare genotip descrie 23-bit șiruri de caractere binare, în cazul în care primii 14 biți indică dacă această variabilă este de intrare, iar restul, se folosesc pentru un anumit nivel ascuns în nodurile rețelelor neuronale cu funcția de activare). Rețelele neuronale artificiale sunt instruite de trei ori pe algoritmul înotarcerii răspândirii greșelilor (back-propagare).

Ca urmare, rețelele neuronale arată 83.08% de exactitate intra-Group și 81.43% exactitate extra-Group, în clasificarea binară a titlurilor de valoare cu rating investițional și neinvestițional, separate în șapte seturi de grupuri de date. Tabelul 3 prezintă exactitatea studiului prognozei ratingului a titlurilor de valoare, clasificate în patru clase separate.

classes are different for every company.

A sample of 50 binary genotypes, every one of which was responsible for the structure of the specific perceptions and the set of input variables, was generated randomly (every genotype is described using a 23-bit binary string, in which the first 14 bits show if a given input variable is used, and the rest of them show if there is a hidden level within the neural network's nodes and the type of activating function. The artificial neural network was trained three times through the back propagation algorithm.

As a result, the neural network gave 83.08% internal group accuracy in the binary classification of the selected bonds with an investment or non-investment rating, isolated in 7 groups of data. In Table 3 below, the accuracy of the prediction of bond ratings is shown, differentiated in the fourth classification groups:

Tabelul 3 / Table 3

**Exactitatea prognozei în modelul Perkins și Brabazon / Prediction accuracy for Perkins and Brabazon's model**

Valoarea curentă / Current value \ Valoarea prognozată / Predicted value	A	BBB	BB	B	Total
A	34.29%	48.57%	11.43%	5.71%	100%
BBB	14.29%	68.57%	17.14%	0.0%	100%
BB	2.86%	28.57%	40.0%	28.57%	100%
B	2.86%	8.57%	34.29%	54.29%	100%

Modelul construit reprezintă 48.75% din exactitatea medie prognozată. Pentru a studia mai precis rezultatele, autorii calculează, în continuare, ce procent din ratingurile prezise coincid cu cele actuale. În așa mod, se ating 92,5% ale exactității de clasificare, arătând prezența unei discrepante relativ slabe între cele două tipuri de variabile.

**Concluzie**

Rețelele neuronale artificiale constituie o tehnologie promițătoare, deoarece acestea pot recunoaște informațiile într-o mare bază de date, modele, tipare și prelucrează informațiile necesare, datorită capacității lor de a învăța. Ele sunt folosite pentru a rezolva o serie de probleme economice: selectarea mărfurilor, producția de proiecte de marketing, aprobarea de credite, verificarea și respingerea cardurilor de credit, controlul asupra proceselor de lucru etc.

Deosebit de interesantă este aplicarea rețelelor neuronale artificiale în cadrul mecanismelor de piață din domeniul finanțelor, în estimarea ratingului titlurilor de valoare corporative. Utilizarea unui sistem hibrid-neural neclar și rețelelor create de perceptroni multistratificați poate recunoaște modele și pe baza abordării deductive de a lua decizii în baza cunoștințelor umane colectate. În

The model provides a 48.75% average accuracy of forecast. In order to perform research that is more accurate, the authors additionally calculated what percentage of the predicted bond rating assessments coincided with those that were current. In this way a 92.5% classification accuracy was achieved that showed relatively weak discrepancy between both types of values.

**Conclusion**

Artificial neural networks are a prospective technology, because they can recognize information in large databases using patterns and templates and can process the desired information due to their capabilities of being able to learn. They can be applied in resolving a number of economic problems – the selection of goods, marketing project preparation, the approval of loans, checking and rejecting credit cards, working process control, etc.

Their application in the field of market mechanisms, finance and predicting the rating of corporate bonds is quite interesting. The use of hybrid neuro-fuzzy systems and networks built from multi-layer perceptions permits pattern recognition and deductions based on accumulated human



poftă utilizării informațiilor financiare despre companiile din diverse sectoare ale economiei, aceste modele sugerează posibilitatea de a distinge diferitele clase de ratinguri ale titlurilor de valoare și a genera valori precise, apropiate semnificativ de valoarea determinată de agențiile de rating.

knowledge. Nevertheless, by using financial data on companies from different sectors of the economy, these models have demonstrated the capabilities for distinguishing various bond rating classes and generating prediction values which are significantly closer to those of rating agencies.

#### Bibliografie / Bibliography:

1. ATANASOV, T., *Inteligența sistemelor computeriale*, Știința și economia, IU Varna, 2005. ISBN 954-21-0245-3.
2. ГАЛУШКИН, А. И. *Нейронных сетей. Основы теории*. Москва, «Горячая линия – телеком», 2010. 496 с.
3. ЗЛОБИН, В. К., РУЧКИН, В. Н. *Нейросети и нейрокомпьютеры*. «БХВ-Петербург», Санкт-Петербург, 2011. стр. 45. ISBN 978-5-9775-0718-9.
4. ПОПОВ, Э. В. *Искусственный интеллект*. // Системы общения и экспертные системы: Справочник. Москва, Радио и связь, 1990.
5. A Tutorial on Speech Understanding Systems. // *Speech Recognition: Invited Papers of the IEEE Symposium*, New York: Academic Press, 1975, p. 3-54.
6. BEZDEK, J. C., PAL, S. K. *Fuzzy models for pattern recognition*. New York: IEEE Press, 1992.
7. CHAVEESUK, R., SRIVAREE-RATANA, C., & Smith, A.E. (1999). *Alternative neural network approaches to corporate bond rating*. // *Journal of Engineering Valuation and Cost Analysis*, 2(2), pp. 117-131.
8. EVERITT, B. S., DUNN, G. *Applied multivariate data analysis* (2nd edition). Arnold, 2001.
9. HASSOUN, M. H. *Fundamentals of artificial neural networks*. Cambridge, MA: MIT Press, 1995.
10. HOLLAND, J. *Adaptation in natural and artificial systems*. 1975, Ann Arbor: University of Michigan Press.
11. KOHONEN, T. *Self-organization and associative memory* (3rd ed.). Berlin, Heidelberg; New York: Springer Verlag, 1989;
12. KOHONEN, T., *Self-organized Formation of Topologically Correct Feature Maps*. // *Biological Cybernetics*, 43, 1982.
13. KOHONEN, T. *Self-organizing Maps*. Berlin, Springer-Verlag, 1997.
14. MADDALA, G. S. *Econometrics*. McGraw Hill, 1997.
15. PERKINS, R., BRABAZON, A. *Predicting Credit Ratings with a GA-MLP Hybrid*. // *Artificial Neural Networks in Real-Life Applications*. Idea Group Inc., 2006. ISBN 1-59140-902-0. pp. 220-237.
16. SETHURAMAN, J. *Soft Computing Approach for Bond Rating Prediction*. // *Artificial Neural Networks in Real-Life Applications*. Idea Group Inc., 2006. ISBN 1-59140-902-0. pp. 202-219.
17. TSAO, E. C., BEZDEK, J. C., PAL, N.R. *Fuzzy Kohonen clustering networks*. *Pattern Recognition*, 27(5), 1994. pp. 757-764.