



**MINISTERUL EDUCAȚIEI NAȚIONALE**  
**UNIVERSITATEA „VALAHIA” din TÂRGOVIȘTE**  
**IOSUD – ȘCOALA DOCTORALĂ DE ȘTIINȚE ECONOMICE ȘI UMANISTE**

---



# **REZUMATUL TEZEI DE DOCTORAT**

## **ÎMBUNĂTĂȚIREA DECIZIEI MANAGERIALE LA NIVELUL SOCIETĂȚILOR DESCHISE PRIN MODELAREA PREDICTIVĂ ÎN TIMP REAL**

**CONDUCĂTOR DE DOCTORAT:**  
**Prof. univ. dr. Marius PETRESCU**

**DOCTORAND:**  
**MIHAI C. Mădălina (CUC)**

**TÂRGOVIȘTE**  
**Anul 2017**

---

## CUPRINS REZUMAT TEZA

Cuprinsul tezei de doctorat .....	4
Cuvinte cheie .....	5
Introducere și contextul actual...	6
Actualitatea temei de cercetare .....	7
Interesul temei de cercetare.....	8
Obiectivele cercetării.....	8
Ipotezele cercetării .....	9
Structura tezei.....	10
Concluzii .....	20
Contribuții personale .....	22
Dezvoltări ulterioare.....	23

## CUPRINS

<b>1. INTRODUCERE .....</b>	<b>4</b>
1.1. Introducere și contextul actual .....	4
1.2. Actualitatea temei de cercetare .....	5
1.3. Interesul temei de cercetare .....	6
1.4. Obiectivele cercetării .....	8
1.5. Ipotezele cercetării .....	9
1.6. Structura tezei .....	9
1.7. Contribuții proprii .....	22
<b>2. CAPITOLUL I. AGENȚI ȘI SISTEME DE AGENȚI.....</b>	<b>24</b>
2.1. Agenți și sisteme de agenți.....	24
2.2. Agenți inteligenți.....	28
2.3. Standardele FIPA pentru agenți inteligenți .....	31
2.4. Platforma JADE .....	37
2.5. Sisteme multi-agent .....	44
2.6. Concluzii .....	46
<b>3. CAPITOLUL al II-lea. TEHNICI DE INTELIGENȚĂ COMPUTAȚIONALĂ....</b>	<b>47</b>
3.1. Conceptul de inteligență .....	47
3.2. Rețele Neuronale sau Neuronale .....	51
3.3. Modelul neuronului artificial .....	54
3.4. Arhitecturi ale rețelelor neuronale. ....	60
3.5. Învățarea (antrenarea) Rețelelor Neuronale .....	64
3.6. Componentele unei rețele neuronale .....	67
3.7. Perceptronul .....	69
3.8. Concluzii .....	75
<b>4. CAPITOLUL al III-lea. MANAGEMENTUL RISCULUI DE TRANZACȚIONARE PE PIEȚELE FINANCIARE ȘI DE CAPITAL .....</b>	<b>78</b>
4.1. Noțiuni privind managementul riscului.....	78
4.2. Randamentul și riscul activelor financiare .....	80
4.3. Fapte stilizate ale randamentelor activelor financiare.....	84
4.4. Definiția Valorii la Risc (VaR). Concepte teoretice ale metodologiei VaR .....	86
4.5. Clasificarea modelelor VaR și compararea acestora .....	88
4.6. Modelul LN-VaR și modele pentru estimarea volatilității: MA, EWMA, GARCH .....	89
4.7. Simularea Monte Carlo, simularea istorică și tehnica bootstrapping .....	93
4.8. Modelele hibride BRW și HW .....	94
4.9. Agregarea măsurii VaR pentru un portofoliu de acțiuni .....	96
4.10. Concluzii .....	97

<b>5. CAPITOLUL al IV-lea. APLICAȚII PRIVIND MANAGEMENTUL RISCULUI DE TRANZACȚIONARE PE PIEȚELE FINANCIARE ȘI DE CAPITAL .....</b>	<b>98</b>
5.1. Aplicația 1: Managementul riscului de tranzacționare bazat pe modelarea și predicția prețului .....	98
5.1.1. Tehnici de predicție a prețurilor bazate pe inteligența computațională .....	101
5.1.2. Estimarea unui model de tip NARX al pretului acțiunilor, bazat pe antrenarea unei rețele neuronale (modelare și studii de caz pentru societățile TEL, TNG, SNN, SNG, ATB ).....	102
5.2. Aplicația 2: Managementul riscului de tranzacționare bazat pe modelarea și predicția volatilității.....	159
5.2.1. Modelarea și predicția volatilității.....	160
5.2.2. Riscul de portofoliu: analiza valorii la risc (VaR) .....	171
5.2.3. Simularea randamentelor portofoliului cu ajutorul FHS .....	177
5.3. Rezultate obținute .....	177
5.4. Concluzii .....	179
<b>6. CAPITOLUL al V-lea. IMPLEMENTAREA SISTEMULUI DE AGENȚI PENTRU MINIMIZAREA RISCULUI TRANZACȚIONAL .....</b>	<b>180</b>
6.1. Parametrii și caracteristicile sistemului de agenți proiectat. ....	180
6.2. Arhitectura sistemului de agenți proiectat. ....	183
6.3. Concluzii .....	202
<b>7. CONCLUZII, CONTRIBUȚII PERSONALE ȘI DEZVOLTĂRI ULTERIOARE .....</b>	<b>205</b>
7.1. Concluzii .....	205
7.2. Contribuții personale .....	208
7.3. Dezvoltări ulterioare.....	208
<b>BIBLIOGRAFIE .....</b>	<b>210</b>
<b>LISTĂ FIGURI .....</b>	<b>218</b>
<b>ANEXE .....</b>	<b>223</b>

---

## CUVINTE CHEIE

- simularea unor modele economice clasice
- instrumente de colectare, structurare și actualizare a datelor
- analiză, simulare și evaluare a rezultatelor în baza unor modele
- portofolii
- instrumente de fundamentare și asistare a deciziei,
- sistem de asistare a deciziei în timp real,
- analiza riscului de tranzacționare
- managementul riscului
- predicții în timp real
- agent inteligent
- sistem de agenți specializați
- modelarea bazată pe agenți
- rețea neuronală
- eficiența și efectivitatea
- ponderilor sinaptice
- rețea neuronală stratificată
- antrenarea unei rețele neuronale
- riscurile financiare și de capital
- valoarea la risc (VaR)
- modelul de medie mobilă cu ponderi constante (MA)
- modelul de medie mobilă cu ponderi exponențiale (EWMA)
- volatilitatea factorului de risc
- simularea istorică
- tehnica bootstrapping
- agregarea măsurii VaR
- corelațiilor factorilor de risc
- matricelor de varianță-covarianță
- predicția nivelurilor prețurilor
- perceptronii multistrat
- rezidualii filtrați
- reziduurile standardizate
- funcția de autocorelație

---

## 1. INTRODUCERE ȘI CONTEXTUL ACTUAL

Una din provocările ultimilor 20 de ani a fost „Programul de Privatizare în masă - 1995”, program în urma căruia au rezultat societăți comerciale cu capital privat, mixt sau de stat, la rândul lor acestea fiind „închise” sau „deschise”.

Evoluția acestora pe perioada amintită a fost diferită de la caz la caz, în funcție de obiectul de activitate al fiecăreia și de tipul de acționariat.

Dacă pentru societățile cu capital majoritar privat regulile managementului aplicate în vederea realizării obiectivului uzual de maximizare a profitului și de minimizare a pierderilor au condus către o evoluție predictibilă a acestora, bazată pe măsurabilitatea impactului mediului intern, extern, internațional etc., urmată de planuri de măsuri realizate în baza simulării unor modele economice clasice, validate în cadrul economiilor specifice țărilor dezvoltate, în cazul societăților cu capital majoritar de stat fie ele închise sau deschise lucrurile nu au avut o astfel de dezvoltare.

Impactul disruptiv al factorului politic și în consecință al celui social, lipsa unor metrici de măsurare a eficienței manageriale, inclusiv pentru factorii economici, tehnologici și nu în ultimul rând ecologici, nu au permis dezvoltarea unor modele care să permită crearea și evoluția unor instrumente de fundamentare și suport decizional specifice economiilor dezvoltate.

Dacă în primul caz, al societăților private, managementul strategic a putut beneficia de instrumente de colectare, structurare și actualizare a datelor, de analiză, simulare și evaluare a rezultatelor în baza unor modele verificate, adaptate foarte puțin sau deloc societății românești, lucru ce a permis realizarea, urmărirea și evaluarea, în baza unor indicatori (PKI), a unor planuri strategice, în cel de-al doilea caz, managementul societăților cu capital de stat sau majoritar de stat, închise sau deschise a fost puternic perturbat atât de impactul factorului politic, corelat cu consecința firească a divergenței acțiunilor sociale, cât și de lipsa unor instrumente de colectare structurare și actualizare a datelor specifice acestora care să fie folosite în antrenarea și simularea unor modele construite pe specificul fiecărei entități, modelele clasice folosite în cazul societăților comerciale cu capital privat, importate din alte economii nefiind aplicabile direct.

În toate aceste cazuri, strategiile de dezvoltare au avut la bază sau monopolul activității la nivel național sau pe cel al distribuției, aceștia fiind principalii factori ai dezvoltării acestor societăți pe termen lung. În alte situații, în care acest avantaj a fost pierdut, societățile au falimentat sau sunt în insolvență, managementul fiind cauza principală, mai puțin factorii

---

externi. Sunt cunoscute cazurile Combinatului de Oțeluri Speciale Târgoviște, Electroputere Craiova, Fabrica de Osii și Boghiuri Balș care, odată ce au pierdut poziția de monopol, au intrat fie în faliment, fie în insolvență.

## **2. ACTUALITATEA TEMEI DE CERCETARE**

Privind către societățile închise cu capital de stat cele mai importante și ne referim la: CNTEE TRANSELECTRICA S.A. (TEL), SNTGN TRANSGAZ S.A. (TGN), SOCIETATEA NAȚIONALĂ NUCLEARELECTRICA S.A. (SNN), S.N.G.N. ROMGAZ S.A. (SNG) și ANTIBIOTICE S.A. (ATB), vom constata că principalii indicatori de măsurare a performanțelor au fost reprezentați de cei sociali (reducerea disponibilizării angajaților, angajări nejustificate în anii electorali). Singurii indicatori economico-financieri au fost reprezentați de reducerea pierderilor, nefiind niciodată pusă problema profitului.

Altfel au stat însă lucrurile pentru societățile deschise cu capital de stat. Prin „Programul de Privatizare în masă - 1995” s-a creat o masă mare de acționari dispusă să-și vândă acțiunile, lucru ce a avut ca și consecință imediată o mare volatilitate a acțiunilor emise, urmată de concentrarea acționariatului, cu întreg arsenalul de urmări: volatilitatea pieței atât pe volume cât și pe preț, posibilitatea perturbării pieței motivată de slaba ei capitalizare, toate acestea putând genera preluări ostile și închideri strategice ale jucătorilor mari de profil.

Managementul acestor societăți, la data respectivă, era unul autoritar, bazat în mare parte pe conducere psihologică. Acest tip de conducere era lipsit de componenta de suport decizional, menită să asiste managementul în calibrarea acțiunilor sale ca și răspuns la reacția pieței. Lipsa suportului decizional, corelată cu lipsa de educație a acționarilor, în mare parte muncitori ce au primit acțiuni la societățile unde au fost angajați, au reprezentat factori care, corelați cu tehnicile de analiză de sentiment și de difuzare a unor mesaje specifice influențării comportamentului acestora, au permis achiziții speculative ale marilor pachete de acțiuni, neurmărite întotdeauna de cea mai bună evoluție pentru societăți.

Referindu-ne la ultimele evoluții ale portofoliilor acestora și ținând cont că urmează să fie deschise prin listarea la bursă și alte societăți naționale de importanță strategică, apare necesitatea creării unor instrumente de fundamentare și asistare a deciziei, de urmărire a procesului de acumulare de capital prin vânzarea de acțiuni, privite ca parte a sistemelor de fundamentare și suport a deciziei manageriale la nivelul societăților deschise cu capital de stat.

Observând aceste societăți, este lesne de constatat că nu multe au un astfel de sistem de fundamentare și asistare a deciziei manageriale. În prezent, funcțiile acestor sisteme constau, cel mult, în marea majoritate, în colectare statică de date, măsurare a unor indicatori clasici,

---

alertare și un set de măsuri de avarie în cazul depășirii indicatorilor critici de funcționare. Este aproape inexistentă o metodologie de creare a unor indicatori care să fie rezultatul aplicării unor metrici pe elemente ale spațiului dat de mulțimea simulărilor unor modele convergente, stabile și controlabile, iar acest lucru se întâmplă din lipsa elementelor argument, adică simulările modelelor, cauzate de lipsa unor modele specific construite.

Plecând de la premisa necesității construcției unui sistem de asistare a deciziei specific fiecărei societăți naționale și nu unul general, customizat pentru fiecare, ca urmare a evoluțiilor ce vor avea loc în urma listării acestor societăți închise cu capital de stat, apare necesitatea existenței unui subsistem de asistare a deciziei manageriale pe segmentul de tranzacționare a propriilor acțiuni, cu agregarea datelor la nivel sectorial și apoi național, bazat pe analiza tehnică clasică, completată cu mecanisme de identificare, colectare, structurare și actualizare a datelor, cu mecanisme de analiză a principalilor indicatori referitori la preț și volatilitate.

## 2. INTERESUL TEMEI DE CERCETARE

În contextul actual al creșterii exponențiale a cantităților de date și a puterii de calcul, al apariției cloud computingului ca urmare a necesității scăderii cheltuielilor cu infrastructura, concomitent cu definirea serviciilor de platformă (PaaS), a serviciilor software (SaaS) și a serviciilor de infrastructură (IaaS) se generează posibilitatea folosirii agenților inteligenți în identificarea, colectarea, structurarea și actualizarea datelor în baze de date, nucleul subsistemului de asistare a deciziei de tranzacționare fiind reprezentat de instrumente specifice de analiza riscului de tranzacționare, instrumente ce vor opera pe aceste baze de date.

Managementul riscului pe componenta de tranzacționare va presupune analiza mai multor riscuri: **de capital, de piață, de lichiditate, de insolvență, de afaceri, de credit, operațional sau de finanțare.**

## 3. Obiectivele cercetării

**3.1. Obiectivul general** al lucrării de cercetare este reprezentat de crearea unui sistem de analiză în timp real, în vederea minimizării riscurilor de tranzacționare, ce se adaptează zilnic, permițând luarea celei mai bune decizii manageriale pe baza unor predicții în timp real, pentru societățile cu capital de stat sau majoritar de stat. Acest sistem are la bază un sistem de agenți, unii dintre ei agenți inteligenți, a căror învățare este bazată pe rețele neuronale.

### 3.2. Obiectivele specifice ale cercetării sunt:

OS.1 Studiul și construcția unei baze de date cu informațiile de tranzacționare pentru societățile de stat sau majoritar de stat, folosind sisteme de agenți specializați.



---

OS.2 Studiul aplicabilității și construcția unei rețele neuronale ca model de predicție a prețului societăților analizate.

OS.3. Conceptualizarea unui agent inteligent generic, bazat pe o rețea neuronală și a unui sistem de agenți, aplicabil unui sistem de tranzacționare a societăților cu capital de stat sau majoritar de stat.

OS.4. Crearea unui model de predicție individual, pentru fiecare societate, prin antrenarea și specializarea agentului inteligent generic pe un set de date de antrenament obținut din baza de date actualizată.

Modelul astfel generat se recrează zilnic, antrenându-se cu datele zilei curente, adăugate la datele istorice dintr-un interval predefinit. (Datele zilei curente actualizează înrările rețelei neuronale din ziua precedentă, se culeg între orele 10.00 - 18.00, agentul inteligent se antrenează împreună cu noua rețea neuronală între orele 20.00 - 23.30, acesta generând un nou model ce se aplică zilei următoare începând cu ora 10.00, ora de deschidere a tranzacțiilor.)

#### **4. IPOTEZELE CERCETĂRII CE SE VOR VALIDA PRIN PREZENTA CERCETARE**

**I.1. Există cel puțin un sistem de agenți specializați, ce realizează identificarea, colectarea, structurarea și actualizarea datelor, organizate într-o bază de date consistentă, peste care se poate aplica un sistem de fundamentare și asistare a deciziei manageriale, pentru oricare societate cu capital integral sau majoritar de stat.**

**I.2. Oricare ar fi societatea cu capital de stat, există cel puțin un agent inteligent, construit pe baza unei rețele neuronale, care, pe baza datelor colectate de sistemul de agenți de la I.1., creează modelul predictiv specific societății de stat și generează predicții, în timp real, privind evoluția volatilității și a prețului acțiunilor acesteia în vederea fundamentării deciziei manageriale în timp real, pentru minimizarea riscului tranzacțional.**

Demersul științific poziționează aria cercetării în zona de interferență a mai multor domenii interdisciplinare: managementul riscului, modelarea riscului de tranzacționare completată de adăugarea noțiunilor de agenți, sisteme de agenți, platforme de dezvoltare și implementare a agenților, sisteme de rețele neuronale aplicabile, antrenarea modelelor bazate pe rețele neuronale și în final predicția – toate acestea văzute ca subsistem de asistare a deciziei ce va fi folosită de managementul acestor societăți în vederea reducerii riscului tranzacțional.

Modelele ce se doresc a fi construite sunt bazate pe rețele neuronale integrate într-o platformă de agenți, parte din ei având capacitate de învățare (antrenare).

---

## 5. STRUCTURA TEZEI DE DOCTORAT

Pentru îndeplinirea demersului propus lucrarea a fost structurată în cinci capitole și o anexă, conținând modulele de agenți descrise și folosite. Descrierea fiecărui capitol este data mai jos.

În **capitolul I - „SISTEME DE AGENȚI”**, sunt definite noțiunile de agenți, agenți inteligenți și sistemele de agenți. Deși termenul de agent poate avea semnificații diferite în funcție de context, în lucrarea de față agentul este definit ca fiind o componentă software capabilă să îndeplinească sarcini specifice, în medii în schimbare. În majoritatea cazurilor, agentul are un grad semnificativ de autonomie și este dotat cu capacitatea de a determina sau alege modul în care sarcinile ce îi sunt impuse pot fi îndeplinite.

Alegerea agenților în demersul științific a fost bazată pe faptul că aceștia oferă o metodă generală și fiabilă de concepere a aplicațiilor, bazată pe elemente distincte și autonome, capabile de comunicare.

Pentru realizarea acestui deziderat, au fost concepute noi tehnici și au fost dezvoltați și implementați noi algoritmi capabili să asigure interconectarea agenților, comunicarea cu și între aceștia, standardizarea acțiunilor pe care agenții le pot îndeplini.

Pe de altă parte, tehnologiile nou apărute și aplicate stau la baza unui număr mare de modele ce permit simularea unor procese complexe, existente în realitate. Modelele bazate pe agenți produc rezultate rapide și directe. Modelarea bazată pe agenți oferă posibilitatea de a urmări conexiunile dintre diverse componente ale sistemului și de a identifica posibile interacțiuni care sunt în general greu detectabile într-un sistem clasic de modelare. Prin modificările aduse unui număr mic de agenți pot fi testate diferite ipoteze și poate fi urmărită modalitatea de adaptare a modelului global la situațiile specifice.

În general, agenții au abilitatea de a rezolva probleme care nu au putut fi rezolvate până în acest moment, fie pentru că nici o tehnologie existentă nu putea fi folosită pentru a rezolva problema, fie pentru că soluția a fost considerată prea scumpă, dificilă sau consumatoare de timp și resurse.

Pentru a măsura performanțele unui agent în rezolvarea unei probleme au fost stabilite atât teoretic cât și practic *eficiența* și *efectivitatea*. Eficiența se referă la viteza cu care se obține soluția, precizia soluției, consumul de resurse și câștigul obținut din rezolvarea problemei. Efectivitatea se referă la capacitatea agentului de a rezolva problema. Testele trebuie să fie eficiente și să acopere toată gama de situații.

Comunicarea între agenți se realizează folosind *protocoalele de comunicație sau limbajele de comunicare agent*, ambele având avantaje și dezavantaje.

---

Baza pentru evoluția limbajului se găsește în comunicarea umană, limbajul agent fiind format din gramatici și vocabulare, la fel ca orice limbaj uman (Bussink, 2004).

Dificultatea de a gestiona cu precizie coordonarea și comunicarea crește odată cu dimensiunea software-lui bazat pe agenți care urmează să fie dezvoltat.

Elementul de inovare specific societății cunoașterii pentru nivelul 4.0 este agentul inteligent, agentul care are capacitate de învățare. Înzestrarea agenților cu capacitate de învățare este utilă în rezolvarea de probleme, dirijarea unor acțiuni complexe sau controlul sistemelor care utilizează medii dinamice.

Prin învățare agentul devine independent și nu mai depinde de restricțiile stabilite prin creare. Pentru definirea noțiunii de învățare a agenților se pleacă de la definiția lui Minsky: *„Învățarea constă în modificări esențiale privind modul de descriere a cunoștințelor și de elaborare a deciziilor în timpul vieții unui agent”*. Învățarea duce la modificări comportamentale adaptive ale agenților.

Un agent reține în procesul de învățare cunoștințele necesare în baza sa de cunoștințe. În bazele de cunoștințe declarative și în sistemele expert, adăugarea de cunoștințe este mai ușoară, în timp ce în cele reprezentate procedural sau în rețelele neuronale acest lucru este mult mai dificil.

În timpul învățării, un agent poate elimina cunoștințele care nu îi sunt necesare sau sunt eronate, fapt care duce la creșterea vitezei și a capacității de memorare. Eliminarea se face ușor din bazele de cunoștințe declarative și dificil din cele procedurale.

Coordonarea este un proces absolut obligatoriu atunci când se urmărește ca sistemul de agenți să aibă coerență și omogenitate în acțiunile comune. Coordonarea agenților aduce o serie întreagă de avantaje. Problema coordonării nu este în mod necesar o caracteristică a sistemelor mulți-agent.

Odată cu apariția tehnologiilor de calcul distribuit, rezolvarea problemelor de coordonare a devenit vitală în multe domenii și reprezintă în continuare o problemă deschisă.

**În capitolul al II-lea - „TEHNICI DE INTELIGENȚĂ COMPUTAȚIONALĂ”**, sunt descrise metode utilizate în abordarea problemelor ce nu pot fi rezolvate prin tehnici tradiționale sau atunci când informațiile aflate la îndemână nu sunt suficiente pentru a construi un model pe baza căruia să se poată dezvolta un algoritm cu ajutorul căruia problema să își găsească soluția.

O definiție unanim acceptată a termenului de „intelență”, necesară cercetării în inteligența artificială și în inteligența computațională nu există în acest moment. În general, majoritatea definițiilor presupun inteligența ca fiind capacitatea de rezolvare a problemelor

---

dicile. Cu toate acestea, această definiție generează întrebări asupra a cine decide gradul de dificultate al problematicii soluționabile.

După definiție, orice sistem inteligent trebuie să facă în mod constant alegeri într-un spațiu de alternative strâns legate de alocarea resurselor disponibile într-un anumit scop. Organismele biologice satisfac condiția de inteligență ca rezultat al competiției dintre ele pentru resursele disponibile. Scopul principal al organismelor vii este supraviețuirea, iar selecția naturală elimină soluțiile nepotrivite în realizarea acestui scop. Din acest punct de vedere, soluția nepotrivită este aceea care nu generează un comportament adecvat al ființei în raport cu mediul în care există.

Pe de altă parte, inteligența nu se limitează la organismele biologice și la lupta lor pentru supraviețuire. Ea este proprietatea fundamentală a decidenților. Chellapilla și Fogel arată că inteligența este *„capacitatea unui sistem de a-și adapta comportamentul pentru a îndeplini obiectivele sale într-o gamă de medii și procesului de viață însăși”*.

Rețelele Neuronale utilizate în domeniul Inteligenței Computaționale au ca model creierul, respectiv încearcă să simuleze funcționarea sistemului nervos uman.

Rețelele Neuronale Artificiale (*Artificial Neural Network - ANN*) sunt sisteme de procesare a informației ce au la bază elemente interconectate simple (neuroni), care procesează în paralel informația. La fel ca în cazul sistemelor biologice, funcția rețelei este stabilită de conexiunile elementelor ce o compun. Ponderile legăturilor dintre neuroni sunt cele care stochează informația acumulată în rețea. Instruirea rețelei este realizată prin ajustarea conform unor algoritmi a acestor ponderi.

Ca și sistemele biologice, Rețelele Neuronale învață din exemple. Ele sunt configurate printr-un proces de învățare pentru aplicații specifice precum recunoașterea modelelor sau clasificare. Învățarea în sistemele biologice implică ajustarea conexiunilor sinaptice care există între neuroni. Rețelele neuronale au fost aplicate unui număr din ce în ce mai mare de probleme din lumea reală, probleme de o complexitate considerabilă. Principalul lor avantaj este aplicabilitatea în rezolvarea problemelor prea complexe pentru tehnologiile convenționale, probleme care nu au o rezolvare algoritmică sau pentru care rezolvarea algoritmică este foarte costisitoare.

Puterea de calcul a unei rețele neuronale derivă, în primul rând, din structura masivă, paralel distribuită și, în al doilea rând, din capacitatea sa de a învăța și de a generaliza. Generalizarea se referă la producția de valori de ieșire raționale pentru valori de intrare ce nu au fost întâlnite în timpul antrenamentului de învățare. Aceste două capacități de prelucrare a informațiilor fac posibilă găsirea de soluții aproximativ bune pentru probleme complexe, dificil

---

de rezolvat. Cu toate acestea, în practică, rețelele neuronale nu oferă întotdeauna soluții pentru probleme particulare. De obicei, este de preferat integrarea acestora în sisteme mai complexe, unde, cu ajutorul lor, se vor rezolva doar o parte din sarcini, respectiv cele ce beneficiază de caracteristicile lor intrinseci.

Rețelele neuronale artificiale încearcă să simuleze procesele ce au loc în creier, fiecare nod fiind o unitate de procesare. Rețelele neuronale învață din experiență și sunt utile în găsirea relațiilor necunoscute dintre un set de date de intrare și un rezultat. Rețelele neuronale încearcă să detecteze modele în datele de intrare, generalizează relațiile descoperite și furnizează predicții. Rețelele neuronale au fost în special remarcate pentru capacitatea lor de a furniza predicții pentru procese complexe.

Antrenarea unei rețele presupune introducerea ca date de intrare a unor seturi de date istorice, proces ce are ca rezultat modificarea ponderilor conexiunilor din rețea și obținerea anumitor valori de ieșire. Antrenarea continuă până ce rețeaua neuronală produce valori rezultat care se potrivesc (cu un nivel de acuratețe specificat) cu valorile cunoscute sau până când sunt satisfăcute alte criterii de oprire. Procesul de reajustare a ponderilor este important pentru creșterea preciziei unui model.

Numărul de intrări și ieșiri ale unei rețele, numărul de straturi ascunse și nodurile aflate pe acestea, precum și algoritmi de ponderare pentru conexiunile dintre noduri determină complexitatea unei rețele neuronale și capacitatea ei de generalizare.

Proiectarea unei rețele neuronale pentru rezolvarea unei probleme specifice presupune luarea unor decizii raportat la alegerea parametrilor ce definesc rețeaua. Deoarece spațiul soluțiilor asociat cu fiecare problemă nu este cunoscut, este obligatorie testarea mai multor arhitecturi de rețea pentru a se obține o combinație potrivită scopului.

**În capitolul al III-lea, denumit MANAGEMENTUL RISCULUI DE TRANZACȚIONARE PE PIETELE FINANCIARE ȘI DE CAPITAL”, am descris** noțiunile privind managementul riscului aferente tranzacționării acțiunilor. Riscurile financiare și de capital reprezintă o categorie importantă de riscuri. Pe măsură ce crește volatilitatea randamentelor, crește și incertitudinea cu privire la randamentele viitoare (ecartul negativ față de randamentul anticipat poate să devină substanțial).

Am realizat în acest capitol **clasificarea modelelor de analiză a valorii la risc și compararea acestora, cu descrierea modelelor folosite ulterior pentru fiecare societate analizată. Modelul de Medie Mobilă cu Ponderi Constante (MA)** este cel mai simplu mod de a estima volatilitatea viitoare a factorului de risc, care nu este decât abaterea standard istorică obișnuită. **Modelul de Medie Mobilă cu Ponderi Exponențiale (EWMA)** este conform

---

Linsmeier și Person (1996) „o metodă îmbunătățită pentru estimarea volatilității viitoare a factorilor de risc”. Acest model acordă ponderi mai mari datelor recente și ponderi mai mici datelor din trecutul îndepărtat. Ponderile acordate observațiilor istorice mai îndepărtate descresc exponențial de la ponderea inițială la zero, cu o rata determinată prin intermediul factorului de descreștere (parametrului de netezire).

**Modelul GARCH** este metoda cea mai completă din punct de vedere tehnic și modelează volatilitatea factorului de risc în mod explicit.

**Modelul HS-VaR**, spre deosebire de modelul LN, nu necesită estimarea parametrilor distribuției factorului de risc, ci presupune că volatilitatea factorilor de risc este constantă în timp și măsoară VaR direct din date.

Simularea istorică presupune colectarea valorilor de piață în orizontul de timp pentru care se calculează VaR și observarea modificărilor acestora. Spre deosebire de metoda Monte Carlo, ce utilizează scenarii ipotetice, simularea istorică utilizează schimbările reale ale pieței drept scenarii.

Tehnica bootstrapping, care poate fi gândită ca un tip de analiză Monte Carlo neparametrică, execută, de asemenea, mii de simulări, dar nu generează datele, ci pleacă de la date observate. Atât Monte Carlo, cât și bootstrapping pot explora mii de posibilități și pot deriva intervalele de încredere corespunzătoare. Diferența majoră dintre cele două este că Monte Carlo simulează datele, iar bootstrapping preia datele observate și doar execută reșantionări din acestea, în mod repetat.

Modelele hibride sunt proiectate pentru a îmbunătăți modelele VaR de bază existente și pentru a crea tehnici de estimare care preiau ce este mai bun din diferite abordări.

**În capitolul al IV-lea, intitulat „APLICAȚII PRIVIND MANAGEMENTUL RISCULUI DE TRANZACȚIONARE PE PIEȚELE FINANCIARE ȘI DE CAPITAL”, sunt prezentate două aplicații originale, prima având la bază aplicarea rețelelor neuronale în modelarea prețului și a doua analizează volatilitatea prin prisma analizei tehnice, ambele cu scopul de a minimiza riscul de tranzacționare.** În prima aplicație este analizat managementul riscului de tranzacționare bazat pe modelarea și predicția prețului, iar în cea de-a doua aplicație este analizat managementul riscului de tranzacționare bazat pe modelarea și predicția volatilității.

Pentru prima aplicație am considerat că predicția nivelurilor prețurilor este un demers dificil, provocator și, desigur, riscant. În conformitate cu ipoteza pieței eficiente, prețurile ar trebui să se adapteze instantaneu și în mod corect pentru a reflecta toate informațiile disponibile, majoritatea actorilor de pe piață considerând că pot prezice prețurile într-un mod care le-ar

---

putea reduce la minim riscurile de tranzacționare. Atât timp cât se admite predictibilitatea prețurilor, găsirea unor metode care îmbunătățesc puterea de predicție a modelelor devine crucială, regulile de decizie pe care aceste modele le încorporează se bazează fie pe analiza tehnică, fie pe analiza fundamentală a informațiilor din trecut.

Analiza tehnică utilizează strategii de proiectare în viitor a trendului, bazate pe afirmația că schimbările prețurilor au inerție. Aceasta implică utilizarea prețurilor istorice ale acțiunilor, volumele tranzacționate și alte date conexe pentru a prognoza mișcările viitoare ale prețurilor și a deduce reguli cu privire la deciziile de tranzacționare, prin care să se poată stabili când să se cumpere sau să se vândă un activ financiar ori cum să fie mai bine organizată protecția unei preluări ostile, fiind vorba de societăți strategice aflate în portofoliul statului român.

Un model estimat cu ajutorul unei rețele neuronale poate fi utilizat pentru a genera direct semnale de intrare/ ieșire sau ieșirile sale pot fi prelucrate de către un sistem de tranzacționare pentru a produce semnale de intrare/ ieșire. La anumite intervale de timp modelul poate fi estimat din nou, prin utilizarea noilor date colectate, permițând astfel sistemului de tranzacționare să-și actualizeze parametrii și deci să-și îmbunătățească performanțele.

Cele mai larg răspândite rețele neuronale de tip feed-forward care s-au dovedit a fi aproximatori universali de funcții reale sunt perceptronii multistrat (MLP = *MultiLayer Perceptrons*), cu unul sau mai multe straturi ascunse, ceea ce înseamnă că pot aproxima orice funcție calculabilă pe o mulțime compactă cu o precizie suficient de bună.

Modelele neliniare sunt potențial mai puternice decât cele liniare, în sensul că acestea pot modela mai multe caracteristici complexe care stau la baza seriilor de timp și, teoretic, nu trebuie să se asume staționaritatea seriei.

Rețelele neuronale au furnizat recent dovezi că sunt cel mai eficient instrument de analiză tehnică, în special datorită abilității lor de a reprezenta relații non-liniare și capacității lor de a învăța aceste relații din datele ce trebuie modelate. O rețea neuronală poate fi utilizată pentru a genera direct semnale de tranzacționare cumpără/ vinde sau ieșirile sale pot fi prelucrate de către un sistem de tranzacționare pentru a produce semnale cumpără/ vinde, iar aceste elemente pot fi ulterior agregate într-un sistem de alertă sau protecție la vânzare/ cumpărare ostilă. Odată ce sistemul de tranzacționare începe să își diminueze performanța, rețeaua neuronală poate fi din nou antrenată prin adăugarea noilor date colectate la cele deja existente.

Algoritmii genetici pot fi combinați cu rețele neuronale pentru a îmbunătăți performanța acestora prin găsirea parametrilor optimi sau pentru a fi utilizați în etapa de optimizare post-procesare, însă acest aspect nu face obiectul lucrării de față.

---

Aplicațiile arată modul de a evalua riscul de piață al unui portofoliu, folosind o tehnică de simulare istorică cu filtrare (FHS), ce combină un model al volatilității de tip GARCH cu o specificație neparametrică a distribuției de probabilitate a randamentelor activelor. Sunt extrași mai întâi reziduurile filtrați ai modelului și volatilitățile condiționate din seria de randamente ale portofoliului cu un model GARCH asimetric din care este formată seria reziduurilor standardizate independente și identic distribuite (iid). FHS păstrează natura neparametrică a simulării istorice prin utilizarea unei tehnici de bootstrapping (eșantionare după schema bilei revenite) din reziduurile standardizate. Aceste reziduuri standardizate sunt apoi utilizate pentru procesul de bootstrapping pentru a genera traiectorii în timp ale randamentelor viitoare ale activelor. În cele din urmă, simularea evaluează valoarea la risc (VaR) a portofoliului de acțiuni într-un orizont de o lună.

Datele brute constau din observații ale valorilor de închidere zilnice a celor 5 poziții ale portofoliului de societăți de stat sau majoritar de stat: CNTEE TRANSELECTRICA S.A. (TEL), SNTGN TRANSGAZ S.A. (TGN), SOCIETATEA NAȚIONALĂ NUCLEARELECTRICA S.A. (SNN), S.N.G.N. ROMGAZ S.A. (SNG) și ANTIBIOTICE S.A. (ATB), valori colectate în funcție de datele istorice avute la dispoziție, acestea fiind, în medie, pe ultimii 2 ani.

După ce s-au filtrat reziduurile modelului din seria de randamente ale portofoliului, se standardizează fiecare rezidual prin împărțire la deviația standard condiționată corespunzătoare. Aceste reziduuri standardizate reprezintă seria *iid* de medie zero și dispersie unitate. Proprietatea *iid* este importantă pentru bootstrapping și permite procedurii de eșantionare să evite în siguranță capcanele eșantionării dintr-o populație în care observații succesive sunt dependente serial (autocorelate).

După ce s-au simulat randamentele portofoliului, se raportează câștigul și pierderea maximă, precum și VaR la diferite niveluri de încredere, pe parcursul orizontului de risc de o lună. De asemenea, se trasează funcția empirică cumulativă de distribuție (CDF) și funcția de densitate de probabilitate (PDF) ale randamentelor cumulative ale portofoliului. Întrucât se lucrează cu randamente logaritmice zilnice, randamentele cumulate pe orizontul de risc sunt pur și simplu suma randamentelor pe fiecare perioadă intermediară.

În **capitolul al V-lea**, intitulat **„IMPLEMENTAREA UNUI SISTEM DE AGENȚI PENTRU MINIMIZAREA RISCULUI TRANZACȚIONAL LA ÎNTREPRINDERI CU CAPITAL DE STAT ȘI MAJORITAR DE STAT”**, am descris realizarea efectivă a unui sistem de agenți care colaborează, își transferă date și iau decizii în vederea îndeplinirii scopurilor propuse și anume minimizarea riscurilor prin analiza prețurilor și volatilității. Așa



---

cum am arătat în capitolele anterioare, avantajele sistemului astfel construit sunt date de modularitate, flexibilitatea cu care arhitectura sistemului poate fi modificată, posibilitatea de a stabili rapid noi conexiuni și de a adăuga facil noi nivele în sistem. Au fost urmărite și au fost realizate următoarele **caracteristici ale sistemului de agenți, proiectat și implementat:**

**1. Mobilitate.** O parte din agenții descriși sunt mobili, putând migra de la o mașină la alta, dependent de încărcarea mașinii pe care rulează fiecare. Pentru a reuși acest lucru, fiecare agent mobil a fost prevăzut cu o clonă proprie, gata compilată, pe care o poate transfera pe altă mașină și o poate lansa în execuție. Odată ajunsă la destinație, clona ia legătura cu originalul și îi comunică gradul de încărcare al mașinii pe care se află după care așteaptă decizia originalului. În cazul în care originalul decide că mediul în care se află clona este mai încărcat decât al său, instruește clona să intre într-o stare latentă și eventual transferă o altă clonă pe o altă mașină cu un grad mai mic de încărcare decât cea de pe care se transferă, după care reia procesul.

**2. Dependența de platformă.** Agenții au fost programați și implementați sub sistemul de operare Windows. Alegerea sistemului de operare a fost oarecum naturală datorită faptului că peste 95% din calculatoarele utilizate astăzi în România folosesc versiuni ale acestui sistem de operare. Testele au fost realizate sub sistemele de operare Windows XP, 7, 8 și 10. În viitor ne propunem să studiem extinderea portabilității sistemului prin realizarea unei versiuni multi-platformă, care să funcționeze și sub sistemul de operare Linux.

**3. Autonomie și delegarea sarcinilor.** Autonomia sistemului propus este relativă. Agenții de predicție și agenții inteligenți pot lucra independent unul de celălalt, dar nu pot funcționa dacă nu sunt alimentați cu datele de la nivelele superioare, iar activitatea lor este fără finalitate dacă agentul care le coordonează nu îi poate supraveghea și prelua datele procesate. În plus, filozofia care a stat la baza definirii arhitecturii sistemului presupune cooperarea între agenți și nu competiție. Agenții nu își pot delega unul altuia sarcinile, deoarece specializarea și subordonarea nu le permit acest lucru. Chiar și în cazul agenților situați la același nivel în sistem, delegarea nu este posibilă din cauza faptului că fiecare agent are încorporat și procesează structura de date a unui anumit emitent, iar aceasta este extrem de specifică.

**4. Capacitatea de comunicare.** Agenții comunică între ei printr-un mecanism bazat pe secvențe de meta-limbaj XML (eXtensible Markup Language). Avantajele recunoscute ale folosirii acestui mecanism sunt:

- a. Extensibilitatea* - reflectă posibilitatea introducerii facile de noi date;
- b. Independența* - datele pot fi vizualizate și prelucrate din afara aplicației prin intermediul unor programe standardizate;
- c. Validare* - datele pot fi validate extrem de simplu;

---

**d. Accesibilitate** - fiind în format text, datele pot fi vizualizate, înțelese și modificate cu ajutorul unui editor de text simplu.

Comunicarea prin XML a fost selectată natural și pentru că informațiile ce provin de la Bursa de Valori București (BVB) și ordinele de tranzacționare care se transmit către aceasta sunt același format.

**5. Coordonarea.** Agentul coordonator supervizează majoritatea agenților sistemului. La rândul său, acesta este supravegheat de utilizatorul uman care stabilește limitele competenței agentului de coordonare și poate invalida deciziile acestuia. Totuși, nu trebuie uitat că sistemul a fost gândit a funcționa în timp real și deci acțiunile acestuia pot fi cenzurate numai dacă utilizatorul urmărește atent toate acțiunile coordonatorului și reacționează extrem de rapid. În general, viteza medie de procesare și reacție a sistemului la o informație în timp real este sub 200 milisecunde, ceea ce înseamnă că de fapt utilizatorul uman nu poate cenzura în timp util deciziile luate automat.

**6. Reactivitate și responsabilitate.** Sistemul multiagent reacționează la schimbările din mediu. Acest fapt se traduce prin preluarea datelor de tranzacționare de la BVB și la luarea unor decizii bazate pe interpretarea pe mai multe niveluri a acestora. Cum tranzacțiile bursiere se efectuează în timp real, iar tranzacțiile nu pot fi anulate odată ce au fost încheiate, responsabilitatea sistemului este mare, iar un răspuns inadecvat poate determina în afara pierderilor financiare cât se poate de reale și decizii strategice eronate la nivelul unor companii de importanță strategică. Din această cauză, sistemul beneficiază de mai multe niveluri de protecție ce se activează automat la depășirea unor praguri prestabilite. În fapt, la depășirea pragurilor despre care vom discuta ulterior, sistemul se auto-dezactivează prin retragerea din piață a tuturor ordinelor de tranzacționare și intră într-o stare de așteptare a deciziilor operatorului.

Timpul de trecere de la activitate maximă (ordine de tranzacționare lansate pentru toate societățile de stat supervizate) la inactivitate totală (toate ordinele anulate, sistem în așteptare decizie operator) este **sub 10 milisecunde**.

**7. Capacitatea de predicție.** Pentru a putea îndeplini sarcinile ce-i revin, sistemul are în componență două tipuri de agenți predictivi: un tip care folosește metode sau algoritmi ce provin din analiza tehnică, celălalt realizând predicții bazate pe rețele neuronale. În ambele cazuri, datele necesare predicției sunt stocate în corpul agentului și suplimentate cu datele primite în timp real în cursul zilei de tranzacționare. Pentru agenții care își bazează predicția pe rețele neuronale, datele sunt actualizate la sfârșitul fiecărei zile de tranzacționare, moment în care se reia procesul de învățare pentru fiecare din societățile anterior enumerate.

Arhitectura sistemului multiagent proiectat și implementat este fundamentată pe

---

următoarele tipuri de agenți:

**Agentul de comunicare.** Este agentul care realizează conexiunea cu Bursa de Valori București. Agentul de comunicare cunoaște protocoalele de comunicație cu BVB și realizează o filtrare a informațiilor care ajung la el, rejectând fără să proceseze datele care nu prezintă interes. Așa cum am arătat anterior, datele sunt transferate bidirecțional în format XML. În medie, într-o zi obișnuită se transferă de la BVB către sistem aproximativ 50 MB de date, din care se filtrează și se ignoră aproximativ 48 MB. În direcție inversă, datele transferate sunt de ordinul a zeci sau sute de Kocteți.

Cea mai mare parte din datele furnizate de BVB intră în categoria informațiilor nesolicitate, în sensul că sistemul multiagent nu le cere explicit. Este vorba mai ales de datele privind ordinele de tranzacționare introduse anterior de toți participanții și de starea inițială a pieței pentru fiecare din societățile de stat. Bursa de Valori București denumește starea inițială a pieței „Market Picture”. În acest moment, pe piața reglementată de acțiuni a Bursei de Valori București sunt listați 86 de emitenți, targetul nostru fiind CNTEE TRANSELECTRICA S.A. (TEL), SNTGN TRANSGAZ S.A. (TGN), SOCIETATEA NAȚIONALĂ NUCLEARELECTRICA S.A. (SNN), S.N.G.N. ROMGAZ S.A. (SNG) și ANTIBIOTICE S.A. (ATB). Pentru fiecare ordin al fiecărui emitent sunt furnizate informații, ce sunt apoi transferate pentru fiecare tranzacție în parte, fiind în detaliu descrisă structura acestora, agentul de comunicare trebuind să mențină totdeauna în memorie o actualizare a acestora pentru fiecare emitent tranzacționat.

**Agentul ETL.** Agentul ETL (Extract Transform Load) are capacitatea de a extrage și stoca informațiile într-o bază de date la care are acces, fiind instruit de asemenea și să introducă aceste date într-o bază de date MySQL. A fost preferat acest tip de bază de date datorită popularității sale și, nu în ultimul rând, pentru că este gratuită. Pentru conectare, agentului i se transmit în faza de inițializare adresa gazdei (IP), portul pe care se realizează conectarea (PORT), numele de utilizator (USER) și parola de acces (PASSWORD). Agentul ETL stochează în baza de date informații generale despre evoluția pieței pentru emitenții supravegheați primite de la agentul de comunicare și informații despre activitatea sistemului de agenți primite de la agentul coordonator.

Pentru a putea opera în timp real, toate datele stocate de agentul ETL se află în memoria de lucru a agentului coordonator. Acesta apelează la datele stocate de agentul ETL numai atunci când comunicațiile au fost întrerupte și este necesară reconstituirea stării curente a sistemului. De remarcat că, în cazul întreruperii conexiunii cu baza de date, sistemul de agenți poate totuși funcționa pentru că toate datele se află în memorie.

---

**Agentul coordonator.** Este cel mai complex agent din sistem și singurul care este conectat permanent cu toți ceilalți. Datorită faptului că sistemul multiagent implementat nu impune existența agenților pe aceeași mașină (fizică sau virtuală), de două ori pe minut, agentul coordonator verifică conexiunea cu ceilalți agenți din sistem, semnalând utilizatorului orice întrerupere a conexiunii. În cazul în care agentul pentru interfața cu utilizatorul nu este accesibil, agentul coordonator emite semnale sonore pe mașina pe care este instalat și retrage toate ordinele din piață.

**Agentul rezilient.** Este agentul care ponderează riscul cumpărărilor la un preț prea mare sau a vânzărilor la un preț prea mic. În cadrul agentului sunt implementate patru niveluri de analiză care funcționează ca declanșatoare pentru operațiunea de retragere a ordinelor din piață. Modul de lucru este simplu și centrat pe viteză cât mai mare de reacție, agentul rezilient urmărește retragerea ordinelor din piață atunci când există pericolul înregistrării de tranzacții suspecte.

**Agentul predictiv pentru volatilitate.** Acest tip de agent este unul bazat pe analiza tehnică și analizează datele unui anumit emitent.

**Agentul de predicție a prețului.** Ca și agentul pentru predicția volatilității, agentul de predicție a prețului este, de asemenea, un agent inteligent, el antrenându-se întotdeauna cu datele unui anumit emitent. La sfârșitul fiecărei zile de tranzacționare, modelul predictiv al acestui agent este generat și este inclus în agentul care va folosi modelul pentru realizarea predicțiilor de preț în ziua următoare de tranzacționare. Antrenarea rețelei se face cu datele ultimelor 200 de zile de tranzacționare. Ambele modele predictive se generează în urma unui proces de instruire supervizată a unei rețele neuronale.

**Agentul de interfață utilizator.** Prin interfața oferită de acest agent, decidentul este informat despre acțiunile sistemului și poate interveni asupra deciziilor luate automat. Așa cum am arătat anterior, deciziile sistemului de agenți fiind luate și aplicate într-un interval foarte scurt de timp, utilizatorul nu poate decât să constate efectele acestora, dar poate opri și reconfigura sistemul dacă se constată disfuncționalități. De asemenea sistemul permite jurnalizarea tuturor operațiilor ce pot fi supuse ulterior unei analize tehnice sau de oportunitate, după caz.

## 6. CONCLUZII

Necesitatea cercetării a apărut ca urmare a listării la bursă a unor societăți naționale de importanță strategică. Astfel, a rezultat necesitatea creării unor instrumente de fundamentare și asistare a deciziei, de urmărire a procesului de acumulare de capital prin vânzarea de acțiuni,

---

privite ca parte a sistemelor de fundamentare și suport a deciziei manageriale la nivelul societăților deschise cu capital de stat. În lucrarea de față au fost avute în vedere CNTEE TRANSELECTRICA S.A. (TEL), SNTGN TRANSGAZ S.A. (TGN), SOCIETATEA NAȚIONALĂ NUCLEARELECTRICA S.A. (SNN), S.N.G.N. ROMGAZ S.A. (SNG) și ANTIBIOTICE S.A. (ATB).

Prin cercetarea de față se creează un subsistem de asistare a deciziei manageriale pe segmentul de tranzacționare a propriilor acțiuni, cu agregarea datelor la nivel sectorial și apoi național, bazat pe analiza tehnică clasică, completată cu mecanisme de identificare, colectare, structurare și actualizare a datelor, cu mecanisme de analiză a principalilor indicatori economico-financiar. Mecanismele identificate se pot constitui prin agregarea acestor date în instrumente de fundamentare și asistare a deciziei pentru factorii decidenți de la nivelul executivului sau Autoritatea pentru Administrarea Activelor Statului (AAAS).

S-au folosit metode bazate pe sisteme multiagenți, combinate cu rețele neuronale, utilizate în abordarea problemelor ce nu-și găsesc soluție și care nu pot fi rezolvate prin metode clasice exacte sau pentru care datele aflate la îndemână nu au fost suficiente pentru a construi un model bazat pe un algoritm cu ajutorul căruia problema să își găsească rezolvarea.

Din punct de vedere teoretic, un sistem format din agenți inteligenți trebuie să facă alegeri într-un spațiu de alternative relativ la alocarea resurselor disponibile într-un anumit scop. Ființele vii satisfac condiția de inteligență ca rezultat al competiției dintre ele pentru accesul la resursele disponibile. În cazul acestora, scopul lor este supraviețuirea, iar selecția naturală elimină soluțiile nepotrivite în realizarea acestui scop. Folosind contrara reciprocei, soluția nepotrivită este aceea care nu generează un comportament adecvat al ființei în raport cu mediul în care există.

Realizarea obiectivului general al lucrării de cercetare, acela de a minimiza riscul tranzacțional prin crearea unui suport decizional, în timp real sau aproape real, ce se adaptează zilnic, având la bază un sistem de agenți ce folosesc analiza tehnică și rețelele neuronale pentru realizarea unor predicții în timp real, în vederea adoptării celei mai bune decizii manageriale, a fost atins prin:

- construcția unei baze de date folosind sisteme specializate de agenți (ETL);
- crearea unui model generic de predicție pentru prețul și volatilitatea acțiunilor, încapsulate în agenți, cel pentru predicția prețului bazat pe rețele neuronale încapsulat într-un agent inteligent și cel pentru predicția volatilității, încapsulat într-un agent reactiv, aplicabil tuturor societăților cu capital de stat sau majoritar de stat;
- particularizarea modelului generic într-un model de predicție individual, pentru

---

fiecare societate, prin antrenarea și specializarea agentului inteligent generic pe un set de date de antrenament obținut din baza de date actualizată.

Modelul astfel generat, se recrează zilnic, antrenându-se cu datele zilei curente. Datele zilei curente actualizează interacția rețelei neuronale din ziua precedentă, se culeg între orele 10.00 - 18.00, agentul inteligent se antrenează împreună cu noua rețea neuronală între orele 20.00 - 23.30, acesta generând un nou model ce se aplică zilei următoare începând cu ora 10.00, ora de deschidere a tranzacțiilor.

Demonstrația primei ipoteze a cercetării: *I.1. Există cel puțin un sistem de agenți specializați, ce realizează identificarea, colectarea, structurarea și actualizarea datelor, organizate într-o bază de date consistentă, peste care se poate aplica un sistem de fundamentare și asistare a deciziei manageriale, pentru oricare societate cu capital integral sau majoritar de stat, a fost realizată prin crearea sistemului de agenți specializați descris în capitolul al V-lea (codul sursă se află în Anexa 1).*

Demonstrația celei de-a doua ipoteze a cercetării: *I.2. Oricare ar fi societatea cu capital de stat, există cel puțin un agent inteligent, construit pe baza unei rețele neuronale, care pe baza datelor colectate de sistemul de agenți de la I.1., creează modelul predictiv specific societății de stat și generează predicții, în timp real, privind evoluția volatilității și a prețului acțiunilor acesteia în vederea fundamentării deciziei manageriale în timp real, pentru minimizarea riscului tranzacțional, s-a realizat în cadrul capitolului al IV-lea, unde sunt prezentate două aplicații originale, având la bază aplicarea rețelelor neuronale și a analizei tehnice în modelarea riscului de tranzacționare, operaționalizarea celor două aplicații teoretice făcându-se în capitolul al V-lea.*

## **7. CONTRIBUȚII PERSONALE**

În cadrul demersului științific de față, denumit **„ÎMBUNĂTĂȚIREA DECIZIEI MANAGERIALE LA NIVELUL SOCIETĂȚILOR DESCHISE PRIN MODELAREA PREDICTIVĂ ÎN TIMP REAL”**, s-a realizat, ca și *contribuție teoretică, o prezentare punctuală a noțiunilor folosite în demersul final, prezentare corelată cu literatura de specialitate, cu raportare la realitățile și legitățile ce folosesc istoricul și permit evoluția ulterioară a societăților de stat sau cu capital de stat analizate. Tratarea unui subiect de interes, managementul post-privatizare al acestor societăți, prin oferirea unor instrumente de natura cuantificării riscului de tranzacționare și modelarea acestuia, pe o nișă îngustă a unor entități pentru care importanța strategică depășește cuantificarea profitabilității, a fost făcută nu prin tratarea conceptelor generale, ci printr-o abordare ținută pe un mecanism ce s-a dovedit viabil,*

---

integrat cu elementele specifice, ducând astfel rezultatele către nivelul WEB 4.0 al societății cunoașterii – agenții inteligenți<sup>1</sup>, în vederea implementării conceptului Industry 4.0<sup>2</sup> la nivelul societăților analizate.

Drept contribuții cu caracter original pot fi menționate cele două aplicații: „*Managementul riscului de tranzacționare bazat pe modelarea și predicția prețului*” și „*Managementul riscului de tranzacționare bazat pe modelarea și predicția volatilității*” ce au la bază aplicarea rețelelor neuronale în modelarea riscului de tranzacționare, respectiv analiza tehnică. În prima aplicație este analizat managementul riscului de tranzacționare bazat pe modelarea și predicția prețului, iar în cea de-a doua aplicație este analizat managementul riscului de tranzacționare bazat pe modelarea și predicția volatilității, ambele fiind pe larg detaliate în capitolul 4.

De asemenea, *proiectarea și implementarea sistemului de agenți*, descris pe larg în capitolul 5, având ca nucleu agenți inteligenți realizați pe structura aplicațiilor ce modelează predicția a două elemente de bază, prețul și volabilitatea acțiunilor unei societăți, integrați într-un sistem de agenți conectat online, reprezintă nu numai un element original, inovativ și de actualitate, ci se subsumează, așa cum am arătat anterior, evoluției către *economia și managementul cunoașterii* definite de conceptele WEB 4.0, BIGDATA, automatizarea proceselor și conducerea bazată pe agenți inteligenți specifice nivelului Industry 4.0 mult dorit de toate societățile strategice.

Rezultatele obținute în cadrul utilizării acestui sistem inteligent de agenți, certificate de datele folosite și de compararea rezultatelor predicțiilor cu valorile ulterioare obținute, au arătat validitatea demersului teoretic al celor două aplicații originale, rezultate prezentate prin simulările grafice și probabilitatea ridicată ulterior validată cu valori de peste 90%. Validarea ipotezelor cercetării s-a făcut concret, principiul existenței fiind demonstrat prin însăși exemplul construit, modelul fiind apoi antrenat, validat și testat cu rezultatele arătate.

## **8. DEZVOLTĂRI ULTERIOARE**

Putem considera, fără echivoc, că demersul de cercetare științifică se constituie într-o viziune și o cale de urmat pentru dezvoltarea unor instrumente concrete de suport al deciziei, cu rol dual, de alertă - *early-warning* pentru protecția societăților strategice, pe de o parte și de creștere a profitabilității societății pe de altă parte. În primul caz, pentru modelul realizat, decizia este luată automat - decizia de anulare tranzacție motivată de condiții specifice diferite

---

<sup>1</sup> <http://bigthink.com/big-think-tv/web-40-the-ultra-intelligent-electronic-agent-is-coming>

<sup>2</sup> [https://en.wikipedia.org/wiki/Industry\\_4.0](https://en.wikipedia.org/wiki/Industry_4.0)

---

de cele acceptate în procesul de tranzacționare este automată și măsurată în milisecunde. În cel de-al doilea, decizia vizează schimbarea funcției de minimizare a riscului în maximizarea profitului.

În momentul de față modelul propus funcționează cu câteva mașini virtuale de putere mică, dat fiind modelul redus de rețea neuronală implementată, precum și aplicațiile punctuale.

O direcție de dezvoltare naturală va fi scalarea puterii de calcul la sisteme distribuite, specifică rețelelor neuronale, alături de crearea unor modele specifice fiecărui sector de activitate. Scalarea astfel realizată ar permite creșterea profitabilității tuturor societăților listate la bursă, la care statul este acționar, alături de un control eficient și eficace al proceselor tranzacționale ale acestora.

O altă direcție de dezvoltare o reprezintă folosirea puterii de modelare oferită de rețelele neuronale pentru crearea de modele specifice fiecărui domeniu sectorial și validarea acestora (antrenare, validare, testare și compararea ulterioară a predicțiilor). Aceste modele generice la nivel sectorial ar putea fi particularizate pe domenii de interes, tot procesul având oportunitate de finanțare prin Programul Operațional Competitivitate 2014-2020.



---

## DISEMINAREA REZULTATELOR CERCETĂRII

Rezultatele cercetării în domeniul tezei de doctorat au fost publicate (sau sunt în curs de publicare) în reviste de specialitate recunoscute sau în volume ale unor manifestări științifice.

### **I. Articole publicate în reviste indexate BDI:**

1. **M. Cuc, A. Săndiță**, „*Considerații privind aplicabilitatea sistemelor multi-agent în noua economie specifică societății cunoașterii*”, GeoPolitica nr. 3/ 2016;
2. **A. Săndiță, M. Cuc**, „*Considerații privind importanța agenților în trecerea de la societatea informațională la societatea cunoașterii*”, Monitor Strategic nr. 1-2/ 2017;
3. **A. Săndiță, M. Cuc**, „*Platforme de dezvoltare și implementare a sistemelor de agenți în trecerea de la societatea informațională la societatea cunoașterii*”, GeoPolitica nr. 1/ 2017;

### **II. Participări cu prezentări la conferințe științifice de profil:**

4. **A. Săndiță, M. Cuc**, „*Platforme pentru sisteme Multi-Agent*”, a doua conferință „*Cercetători competitivi pe plan european în domeniul științelor umaniste și socio-economice. Rețea de cercetare multiregională (CCPE)*” POSDRU/159/1.5/S/140863, Panelul 4 Economia românească postaderare, 2015.

Noile competențe ale funcțiilor de conducere (ce includ și managementul riscului) specifice societății cunoașterii au fost publicate în cadrul Analizelor Ocupaționale și Standardelor Ocupaționale corespunzătoare ocupațiilor

### **III. Coautor pentru Analizele Ocupaționale, Standardele Ocupaționale și Calificările profesionale asociate, pentru ocupațiile:**

1. Inspector Școlar pentru Proiecte Educaționale  
<http://www.anc.edu.ro/uploads/SO/Inspector.scolar.proiecte.educationale.pdf>
2. Inspector Școlar pentru Managementul Resurselor Umane  
<http://www.anc.edu.ro/uploads/SO/InspectorScolarpentruManagementulResurselorUmane.pdf>
3. Director Club Sportiv Școlar  
<http://www.anc.edu.ro/uploads/SO/Director.Club.Sportiv.Scolar.pdf>
4. Expert în egalitate de șanse Cod COR 242230  
<http://www.anc.edu.ro/uploads/SO/Expert%20in%20egalitate%20de%20sanse.pdf>

### **IV. Responsabil organizare conferințe:**

1. Workshop I, II „*Elaborarea unui Ghid de bune practici OSCINT*” POSDRU/157/1.3/S/140010 „OSCINT XXI - Inovare pentru calitate în învățământul

- 
- preuniversitar din regiunile Sud Vest Oltenia, București-Ilfov, Sud-Est, Sud Muntenia”, 30 octombrie - 01 noiembrie 2015, 06 - 08 noiembrie 2015 Poiana Brașov;
2. Activitate interregională „*Strategii inovative OSCINT*” POSDRU/157/1.3/S/140010, 13 - 15 noiembrie 2015, Poiana Brașov;
  3. Activitate interregională „*Instrumentar OSCINT pentru o Școală Competitivă*” POSDRU/157/1.3/S/140010, 20 – 22 noiembrie 2015, Sinaia;
  4. Activitate interregională „*Intelligence educațional - realități și perspective în Societatea Cunoașterii*” POSDRU/157/1.3/S/140010, 27 - 29 noiembrie 2015, Sibiu;
  5. Activitate interregională „*Utilizarea tehnologiilor colaborative în dezvoltarea competențelor OSCINT aplicabile în sistemul de învățământ preuniversitar*” POSDRU/157/1.3/S/140010, 4 - 6 decembrie 2015, Sibiu;
  6. Conferința proiect strategic POSDRU/157/1.3/S/140010 „*OSCINT XXI - Inovare pentru calitate în învățământul preuniversitar din regiunile Sud Vest Oltenia, București-Ilfov, Sud-Est, Sud Muntenia*”, 11 - 13 decembrie 2015 Sibiu;
  7. Conferința proiect strategic POSDRU/157/1.3/S/140010 „*OSCINT XXI - Inovare pentru calitate în învățământul preuniversitar din regiunile Sud Vest Oltenia, București-Ilfov, Sud-Est, Sud Muntenia*”, 12 decembrie 2014 București;
  8. Conferința proiect strategic POSDRU/85/1.1/S/63376 „*Dezvoltarea competențelor manageriale ale personalului didactic cu funcții de conducere, îndrumare și control din sistemul preuniversitar, în societatea cunoașterii – OSCINT 2009*”, 27 iulie 2013 Poiana Brașov.