



Proiect cofinanțat din Fondul Social European prin Programul Operațional Sectorial Dezvoltarea Resurselor Umane 2007-2013  
**Investește în oameni!**

**Proiect InnoRESEARCH - POSDRU/159/1.5/S/132395**

*Burse doctorale și postdoctorale în sprijinul inovării și competitivității în cercetare*



UNIVERSITATEA **POLITEHNICA** DIN BUCUREȘTI

Facultatea **Automatică și Calculatoare**

Departamentul \_\_\_\_\_

Nr. Decizie Senat \_\_\_\_\_ din \_\_\_\_\_

*Metode Defensive pentru Asigurarea Securității Cibernetice*

*Intelligent Defensive Techniques for Cyber Security Assurance*

**REZUMAT AL TEZEI DE DOCTORAT**

**Autor: ing. Adriana Cristina Enache**

**Conducător de doctorat: prof. dr. ing. Valentin Sgârțiu**

**COMISIA DE DOCTORAT**

Președinte	Prof. univ. dr. ing. Theodor Borangiu	de la	Universitatea Politehnica București
Conducător de doctorat	Prof. univ. dr. ing. Valentin Sgârțiu	de la	Universitatea Politehnica București
Referent	Prof. univ. dr. ing. Victor Patriciu	de la	Academia Tehnică Militară
Referent	Prof. univ. dr. ing. Ion Bica	de la	Academia Tehnică Militară
Referent	Prof. univ. dr. ing. Dorin Cârstoiu	de la	Universitatea Politehnica București

București



Proiect cofinanțat din Fondul Social European prin Programul Operațional Sectorial Dezvoltarea Resurselor Umane 2007-2013  
**Investește în oameni!**

## Cuprins

<b>1</b>	<b>INTRODUCERE.....</b>	<b>1</b>
1.1	MOTIVAȚIA .....	1
1.2	OBIECTIVELE GENERALE.....	2
1.3	ORGANIZAREA ȘI STRUCTURA TEZEI.....	3
1.4	ACKNOWLEDGEMENT .....	3
<b>2</b>	<b>CONTEXTUL CIBERNETIC ACTUAL.....</b>	<b>3</b>
2.1	SECURITATEA CIBERNETICĂ .....	4
2.2	EXEMPLE DE ATACURI CIBERNETICE .....	5
2.2.1	<i>Distributed Denial of Service (DDoS)</i> .....	5
2.2.2	<i>Advanced Persistent Threats (APTs)</i> .....	5
2.2.3	<i>Ransomware</i> .....	6
2.3	NECESITATEA UNOR SOLUȚII INTELIGENTE .....	6
<b>3</b>	<b>ALGORITMI DE INTELIGENȚĂ COMPUTAȚIONALĂ.....</b>	<b>6</b>
3.1	SWARM INTELLIGENCE.....	7
3.1.1	<i>Bat Algorithm</i> .....	8
3.1.2	<i>Scurtă discuție despre SI</i> .....	9
3.2	ARTIFICIAL IMMUNE SYSTEMS .....	10
3.2.1	<i>Transpunerea NIS în AIS</i> .....	11
3.2.2	<i>Dendritic Cell Algorithm</i> .....	11
3.2.3	<i>Scurtă discuție despre AIS</i> .....	13
3.3	SWARM INTELLIGENCE ȘI ARTIFICIAL IMMUNE SYSTEMS. SCURTĂ DISCUȚIE .....	14
<b>4</b>	<b>PROPUNERILE DE ÎMBUNĂTĂȚIRE PENTRU ALGORITMI.....</b>	<b>15</b>
4.1	DENDRITIC CELL ALGORITHM .....	15
4.1.1	<i>Algoritmul DCA din Perspectiva Șablonului AIS</i> .....	15
4.1.2	<i>Enunțarea Problemei și Propunerea Soluției</i> .....	16
4.2	THE BAT ALGORITHM .....	17
4.2.1	<i>Enunțarea Problemei și Propunerea Soluției</i> .....	17
<b>5</b>	<b>SISTEMELE DE DETECȚIE A INTRUZIUNILOR.....</b>	<b>19</b>
5.1	NOȚIUNI DE BAZĂ .....	19
5.2	FUNCȚIONALITĂȚILE ȘI EVALUAREA PERFORMANȚELOR IDS .....	20
<b>6</b>	<b>SISTEME DE DETECȚIE A INTRUZIUNILOR PROPUSE BAZATE PE ALGORITMI DE INTELIGENȚĂ COMPUTAȚIONALĂ.....</b>	<b>22</b>
6.1	SETUL DE DATE .....	22
6.2	MODELE IDS BAZATE PE SI .....	22
6.2.1	<i>Componentele IDS</i> .....	22
6.2.2	<i>Optimizarea parametrilor SVM</i> .....	24
6.2.2.1	<i>Parametrii SVM</i> .....	24
6.2.2.2	<i>Modele Propuse</i> .....	24
6.2.3	<i>Metode de Selectare a Atributelor</i> .....	25



Proiect cofinanțat din Fondul Social European prin Programul Operațional Sectorial Dezvoltarea Resurselor Umane 2007-2013  
**Investește în oameni!**

6.2.3.1	Transformarea algorimilor SI în versiuni binare.....	25
6.2.3.2	Modele Propuse .....	26
6.2.4	<i>Modele Combinate</i> .....	28
6.3	MODELE IDS BAZATE PE AIS .....	30
6.3.1	<i>Componentele IDS</i> .....	30
<b>7</b>	<b>MODELE PROPUSE PENTRU DETECȚIA WEBSPAMMING .....</b>	<b>34</b>
7.1	MODELUL PROPUȘ .....	34
7.1.1	<i>Setul de Date</i> .....	34
<b>8</b>	<b>CONCLUZII. CONTRIBUȚII PERSONALE. DIRECȚII VIITOARE DE CERCETARE .....</b>	<b>36</b>
8.1	CONTRIBUȚIILE PERSONALE .....	37
8.2	PERSPECTIVE DE CERCETARE.....	38
8.3	LISTA DE LUCRĂRI PUBLICATE.....	38
<b>9</b>	<b>BIBLIOGRAFIE.....</b>	<b>40</b>



UNIUNEA EUROPEANĂ



GUVERNUL ROMÂNIEI



MINISTERUL  
EDUCAȚIEI ȘI  
CERCETĂRII ȘTIINȚIFICE



Fondul Social European  
POSDRU 2007-2013



Instrumente Structurale  
2007-2013



OPFSORU

MINISTERUL  
EDUCAȚIEI ȘI  
CERCETĂRII ȘTIINȚIFICE



Universitatea POLITEHNICĂ  
din București

Proiect cofinanțat din Fondul Social European prin Programul Operațional Sectorial Dezvoltarea Resurselor Umane 2007-2013  
**Investește în oameni!**

## 1 INTRODUCERE

Tehnologia a evoluat într-o manieră galopantă și a catalizat ritmul de creștere al numărului de utilizatori, volumului de date sau dimensiunii rețelelor. Prin urmare, atât entitățile private cât și cele guvernamentale trebuie să țină pasul și să fie capabile de a se adapta la noile tendințe din domeniul tehnologiei informației pentru a își asigura un loc cât mai sus în lista de potențiali colaboratori. Securitatea cibernetică se încadrează în regula anterioară, mai ales că scopul acesteia este de a proteja aceste sisteme noi de atacurile cibernetice aflate într-un continuu proces de metamorfoză și extindere către noile platforme. Pentru a asigura sistemelor informatice un nivel minim de securitate, trebuie în primul rând să cunoaștem contextul actual al amenințărilor cibernetice și să dispunem de metode și mecanisme avansate pentru detecția acestora.

Soluțiile pe care le propunem în cadrul acestei teze sunt bazate pe algoritmi de inteligență computațională (CI), care în opinia noastră pot oferi metode pentru crearea unor mecanisme automate și capabile de a oferi adaptabilitatea la noile transformări din ecosistemul cibernetic. În cadrul activității de cercetare, interesul nostru s-a îndreptat spre acei algoritmi inspirați din principiile și funcționalitățile sistemelor biologice, precum: Swarm Intelligence (SI) și Artificial Immune Systems (AIS). Natura a reprezentat întotdeauna o sursă de inspirație pentru mediul științific datorită echilibrului natural al componentele sale care creează un sistem eficient, adaptabil la schimbările perpetue existente în mediul biologic și durabil în timp.

În cadrul acestor teze sunt propuse două versiuni îmbunătățite pentru un algoritm SI recent (the Bat Algorithm) și o variantă modificată pentru un algoritm AIS de nouă generație inspirat din paradigma teoriei pericolului (Dendritic Cell Algorithm). Pentru a valida ipotezele teoretice am implementat noile versiuni, apoi le-am integrat în cadrul unor sisteme pentru detecția intruziunilor (IDS) și am testat modelele propuse pe baze de date publice care conțin înregistrări specifice anomaliilor și respectiv normale. Mai mult, am propus arhitecturi pentru detecția intruziunilor care combină algoritmi inspirați biologic cu algoritmi de clasificare convenționali, demonstrând astfel că această îmbinare poate îmbunătăți performanțele modelului. Totodată, am adresat problema de detecție web spamming prin propunerea, implementarea și testarea a două modele. Primul asociază SI cu clasificatorul de mașini cu suport vectorial, iar cel de al doilea apelează la cAnt-Miner pentru sarcina de clasificare.

Modelele pe care le propunem în cadrul acestei teze pot fi integrate cu ușurință în cadrul unor soluții pentru asigurarea securității cibernetice pentru componentele de extragere a atributelor cheie sau pentru procesul de detecție a anomaliilor. Prin urmare, rezultatele activității de cercetare au o gamă largă de aplicabilități și pot fi valorificate sub forma unor componente modulare pentru diverse sisteme precum: security and event management (SIEM), visual analytics, sisteme pentru detecția intruziunilor (IDS) sau alte produse pentru asigurarea securității sistemelor informatice și de comunicații.

### 1.1 MOTIVAȚIA

În ziua de azi, aproape orice individ are contact cu lumea cibernetică unde sunt stocate informații publice, dar și unele confidențiale sau sensibile ce trebuie protejate. Aceste date stocate electronic au devenit motorul activităților și proceselor esențiale desfășurate de entități, întrucât din aceste date se pot extrage informații valoroase despre clienți, furnizori sau chiar secrete care stau la baza produselor sau serviciilor oferite. Pierderea sau deteriorarea acestor date poate duce la decredibilizarea acelei companii, pierderi financiare uriașe sau poate determina chiar situații internaționale indezirabile (ex. spionajul cibernetic dintre

guvernele unor state). Cum orice informație valoroasă atrage atenția indivizilor cu intenții malițioase, nu este de mirare că numărul și varietatea atacurilor cibernetice continuă să crească în fiecare zi. Termenul de „cybersecurity” a devenit un cuvânt *metaforic* în concepția utilizatorilor de rând care nu îi înțeleg complet semnificația și nu știu prin ce metode să se protejeze de amenințările din mediul cibernetic, este o *corvoadă* pentru dezvoltatorii de software care trebuie să se alinieze la standardele de securitate care de multe ori reduc performanțele sistemelor informatice, și respectiv este o *necesitate* pentru managementul companiilor care au devenit conștienți de importanța securității informatice.

În ciuda interesului ridicat și progreselor în domeniul securității informatice, furtuna de atacuri cibernetice continuă să se intensifice în rafale continue din punct de vedere al numărului și diversității acestora. O dată cu evoluțiile tehnologiei informației, actorii cibernetici cu intenții malițioase și-au extins aria de atac către noile dispozitive sau platforme, acolo unde au găsit vulnerabilități și au apelat la tehnici avansate (ex. algoritmi de criptare) pentru a își îmbunătăți capabilitățile de atac. Așadar, instrumentele de hacking au evoluat și ele, astfel încât astăzi până și persoanele mai puțin instruite dar cu intenții malițioase pot intra în „arena” cybercrime prin cumpărarea sau închirierea unor instrumente de hacking la costuri reduse de pe „piața neagră” a Internetului (ex. DarkWeb). Prin urmare, este clar că peisajul atacurilor cibernetice este într-o continuă expansiune din punct de vedere al *volumului* (din ce în ce mai mulți indivizi cu intenții malițioase se pot „integra” ușor în ecosistemul cibernetic prin simpla închiriere a unor instrumente de hacking sau cumpărarea unor servicii de cybercrime) și *complexității* (noi tipuri de atacuri cibernetice ies la suprafață sau continuă să rămână ascunse în sistemele noastre informatice până la declanșarea sau descoperirea lor).

Luând în considerare toate cele prezentate anterior, am putea considera că asigurarea securității poate reprezenta un proces de tip cerere de cauțiune pentru utilizatorii care devin victimele sigure ale atacurilor și se află la mila acestora (ex. Ransomware). Așadar, pentru a preveni aceste situații, trebuie asigurat un nivel adecvat de securitate pentru sistemele informatice prin implementarea unor politici de securitate și integrarea unor soluții eficiente de securitate. Cu toate acestea, monitorizarea și auditarea tuturor evenimentelor din interiorul sistemelor informatice nu este o chestiune practică și poate duce la încărcarea ineficientă a sistemelor. Mai mult, interpretarea unui astfel de volum de date este imposibil de realizat de către utilizatorii umani și dificil de procesat de către sistemele informatice. Soluțiile pe care le propunem în cadrul acestei teze de doctorat se referă la utilizarea algoritmilor CI pentru filtrarea datelor și extragerea acelor componente lor cheie pentru etapa de detecție. Algoritmii de tip CI pot procesa volume mari de date într-o manieră eficientă prin utilizarea cunoașterii și a capacității de învățare continuă; având în vedere contextul dinamic al mediului cibernetic, cele două caracteristici ale CI reprezintă atribute benefice pe termen lung și pot ajuta la implementarea unor soluții de securitate viabile și cu un grad ridicat de adaptabilitate. Aceste ipoteze ne-au ghidat activitatea de cercetare și au conturat principalele obiective ale proiectului de cercetare.

## 1.2 OBIECTIVELE GENERALE

Principala direcție de cercetare a acestei lucrări se referă la propunerea și testarea unor tehnici inovative pentru asigurarea securității cibernetice, care să fie bazate pe algoritmi de inteligență computațională.

Principalele obiective generale ale tezei sunt enumerate mai jos:

- cercetarea algoritmilor de inteligență computațională și a aplicabilității acestora pentru asigurarea securității cibernetice;
- propunerea și testarea unor modele defensive de tip pro-active bazate pe algoritmi de inteligență computațională;

- îmbunătățirea unor algoritmilor de inteligență computațională și aplicarea acestora pentru asigurarea a securității cibernetice.

### 1.3 ORGANIZAREA ȘI STRUCTURA TEZEI

Am organizat această lucrare în opt capitole care urmăresc etapele principale ale activității de cercetare, pornind de la definiția și contextul actual al securității cibernetice și respectiv introducerea conceptului de inteligență computațională (CI). Principalele contribuții personale se regăsesc în capitolele următoare care prezintă variantele modificate pentru doi algoritmi inspirați biologic (the Bat Algorithm și Dendritic Cell Algorithm) și respectiv modelele care integrează algoritmi îmbunătățiți cu cei convenționali pentru a crea arhitecturi inovative pentru detecția intruziunilor sau pentru detecția web spamming.

Capitolul doi descrie conceptul de securitate cibernetice și principalele componente ale mediului cibernetic din perspectiva autorului. În continuare sunt prezentate o serie de amenințări cibernetice pentru a evidenția o parte din posibilele pericole care afectează nivelul de securitate al sistemelor informatice.

Capitolul trei prezintă algoritmi de inteligență computațională (CI), începând cu definiția și conceptele care stau la baza CI. Principalele obiective urmărite în cadrul acestui capitol se referă la introducerea algoritmilor utilizați în experimentele realizate. Acești algoritmi au fost împărțiți în două mari categorii: convenționali și respectiv inspirați biologic. În ceea ce privește algoritmi inspirați biologic, aici ne-am axat pe două categorii: Swarm Intelligence și Artificial Immune Systems. Am realizat o comparație a acestor două clase evidențiind similitudinile și respectiv caracterul lor complementar, din perspectiva autorului.

Capitolul patru include contribuțiile proprii referitoare la propunerea a două versiuni îmbunătățite pentru un algoritm SI recent (the Bat Algorithm) și respectiv o variantă modificată a unui algoritm AIS de generație nouă (Dendritic Cell Algorithm).

Capitolul cinci este un preambul al capitolului șase. Aici sunt prezentate istoria, definiția și o clasificare a modelelor de detecție a intruziunilor (IDS).

Capitolul șase include modelele IDS propuse care au la bază algoritmi SI sau AIS pentru componente de selectare a atributelor sau pentru etapa de detecție a anomaliilor.

Capitolul șapte se referă la detecția WebSpamming, pentru care am propus două metode bazate pe algoritmi SI.

La final, concluziile și contribuțiile proprii sunt incluse în capitolul opt. Tot aici sunt enumerate câteva perspective de cercetare.

### 1.4 ACKNOWLEDGEMENT

Rezultatele prezentate în acest articol au fost obținute cu sprijinul Ministerului Fondurilor Europene prin Programul Operational Sectorial Dezvoltarea Resurselor Umane 2007-2013, Contract nr. POSDRU/159/1.5/S/132395.

The work has been funded by the Sectoral Operational Programme Human Resources Development 2007-2013 of the Ministry of European Funds through the Financial Agreement POSDRU/159/1.5/S/132395.

## 2 CONTEXTUL CIBERNETIC ACTUAL

Astăzi tehnologia a devenit în mod progresiv o componentă omniprezentă și a îmbunătățit atât viața personală cât și activitățile de lucru ale oamenilor, generând astfel din ce în ce mai multe avantaje în viața de zi cu zi dar în același timp deschizând noi porți de intrare în sistemele informatice, sub forma unor vulnerabilități care pot fi exploatate de atacatori. În

fiecare zi dispozitivele devin mai inteligente și mai conectate la Internet. O dată cu aceasta, valoare datelor stocate și procesate crește foarte rapid, generând astfel necesitatea de a proteja aceste date critice care au devenit comustibilul proceselor esențiale desfășurate de companiile private și entitățile guvernamentale.

Datorită valorii datelor, acestea atrag interesul atacatorilor care vor încerca să obțină diverse avantaje de pe urma acestora. Profilul atacatorului este divers, iar motivația acestuia poate varia de la convingeri sociale sau afinități politice (hacktivism), beneficii economice (cyber-crime) până la spionaj sau cyber-warfare (susținute de entități guvernamentale). În acest peisaj cibernetic dinamic, amenințările ciberneticе au devenit din ce în ce mai complexe în ultimii ani, de la simple scheme de phishing până la campanii complexe numite Advanced Persistent Threats (APTs) care au vizat instituții financiare, companii industriale sau chiar entități guvernamentale. Prin urmare, pentru a putea asigura securitatea cibernetică trebuie să avem o privire de ansamblu asupra conceptului de securitate cibernetică și respectiv despre contextul actual al amenințărilor ciberneticе.

## 2.1 SECURITATEA CIBERNETICĂ

Există mai multe definiții acceptate în casta specialiștilor pentru termenul de *securitatea cibernetică*, majoritatea împărtășind aceeași piloni principali : confidențialitatea, integritatea și disponibilitatea. Conform ITU (Rec. ITU-T X.1205, Overview of *cybersecurity*, (04/2008)): "Cybersecurity is the collection of tools, policies, security concepts, security safeguards, guidelines, risk management approaches, actions, training, best practices, assurance and technologies that can be used to protect the cyber environment and organization and user's assets. Organization and user's assets include connected computing devices, personnel, infrastructure, applications, services, telecommunications systems, and the totality of transmitted and/or stored information in the cyber environment. Cybersecurity strives to ensure the attainment and maintenance of the security properties of the organization and user's assets against relevant security risks in the cyber environment. The general security objectives comprise the following:

- Availability
- Integrity, which may include authenticity and non-repudiation
- Confidentiality.”[13]

Cu alte cuvinte, securitatea cuprinde toate metodele și tehnicile, de la simplele politici de securitate până la sistemele avansate de securitate, toate acestea conlucrând împreună pentru asigurarea unui nivel de securitate adecvat al sistemului țintă. Un element interesant de remarcat în cadrul definiției date de ITU este utilizarea termenului „relevant risks”, care reliefează faptul că întotdeauna vor exista riscuri reziduale, iar protejarea completă a sistemelor informatice este aproape imposibilă. În schimb, ceea ce își propune securitatea informatică este să prevină amenințările cele mai probabile și toate acestea la un cost cât mai redus.

În opinia noastră securitatea informatică este compusă din două componente principale: bunurile critice (constând în elementele hardware sau software care stochează, procesează și transferă datele sensibile care trebuie protejate) și jucătorii (atacatorii și experții de securitate). Aceste două componente reflectă câmpul de luptă din mediul cibernetic și cursa continuă în care se află producătorii de malware cu experții de securitate, fiecare încercând să utilizeze tehnologia informației pentru propriile scopuri. Ecosistemul cibernetic este asimetric și fără frontiere, prin urmare schemele de atac pot fi diverse și forța lor de penetrare se poate exinde pe suprafețe teritoriale întinse pe mai multe continente. De la început, trebuie să stabilim faptul că panorama de amenințări ciberneticе este enormă și are o rată de creștere



exponențială. Prin urmare, scopul acestui capitol este de a oferi o mică parte din lumea complexă a mediului cibernetic și a amenințărilor existente.

## 2.2 EXEMPLE DE ATACURI CIBERNETICE

### 2.2.1 Distributed Denial of Service (DDoS)

*Distributed Denial of Service (DDoS)* este un tip de amenințare în care mai multe sisteme țintă sunt compromise în vederea obținerii unui nivel scăzut de securitate sub forma privării accesului utilizatorilor autorizați la anumite resurse. Pentru a realiza aceasta, atacatorul poate inunda sistemul cu un număr mare de mesaje până la punctul în care resursa vizată devine indisponibilă. DDoS este un atac vizibil la nivelul administratorului și de aceea este frecvent utilizat ca un instrument pentru hacktivism sau chiar pentru șantaj. Primele astfel de atacuri s-au desfășurat în aprilie 2007 și au avut drept ținte organizațiile din Estonia, inclusiv instituțiile bancare, guvernamentale și chiar mass-media. Mărul discordiei se pare să fi fost relocarea unei statui din bronz a lui Tallinn, un simbol pentru minoritatea rusă din Estonia.

Deși aparent simplu de realizat, atacurile de tip DDoS continuă să dăinuie în ciuda metodelor de securitate constatate, încă mai există hibe ale protocoalelor (ex. SlowLoris exploatează o vulnerabilitate a serverului Web Apache privind cererile de tip HTTP GET; aceste cereri pot include un număr limitat de linii permițând astfel retransmiterea lor la infinit) sau sistemelor (ex. neimplementarea unor politici minime de securitate). Mai mult, dacă până acum atacatorii aveau nevoie de o putere de calcul majoră prin crearea unei rețele de victime (botnets), astăzi aceștia pot apela la serviciile de cloud computing în același scop și toate la un cost redus care poate ajunge la suma de 150\$ pentru o săptămână.

### 2.2.2 Advanced Persistent Threats (APTs)

*Advanced Persistent Threat (APT)* este un tip de amenințare care utilizează tehnici de exploatare sofisticate pentru a pătrunde în sistemele țintă și a rămâne nedescoperite pentru o perioadă îndelungată de timp în care atacatorul va recolta informații valoroase. Spre deosebire de DDoS, aceste atacuri nu sunt vizibile imediat, iar obiectivele APTs nu sunt imediate ci din contră, urmăresc să rămână ascunse în timp ce extrag datele urmărite.

Multe dintre APTs de astăzi au fost dezvoltate în urmă cu câteva decenii și prin urmare entitățile care se bazează pe tehnicile tradiționale de securitate sunt mai mult ca sigur vulnerabile la aceste tipuri de atacuri. În istoria APT există mai multe astfel de exemple, printre primele se numără Moonlight Maze care a avut drept ținte entități guvernamentale ale SUA, apoi Titan Rain sau Operațiunea Aurora. Toate aceste atacuri s-au prelungit pe parcursul unei perioade îndelungate, existând în sistem fără ca utilizatorii să fie conștienți de prezența acestora și permițând extragerea unor informații secrete. Probabil unul dintre cele mai răsunătoare APTs este *Stuxnet*, care a generat o frenezie mediatică în anul 2010. Ce face acest atac interesant este faptul că este primul vierme informatic utilizat ca armă în războiul cibernetic tacit și care permitea obținerea controlului și sabotarea facilităților industriale prin operarea acestora în afara parametrilor autorizați. Acest tip de malware infecta PCLs (Programmable Logic Controllers) și oferea posibilitatea de a fi reprogramate de către atacatori, astfel încât să obțină degradarea componentelor industriale, în timp ce utilizatorul uman primea informații eronate sub forma unor valori normale transmise de malware. Se pare Stuxnet a vizat acele sisteme care rulau Siemens software Step 7 și conform rapoartelor Symatec [14] majoritatea victimelor se aflau în Iran, ceea ce a dus la incriminarea guvernelor SUA și a celui israelian, deși niciunul dintre acestea nu și-au recunoscut în mod public implicarea. Un alt aspect important, este faptul că au existat mai multe versiuni ale acestui malware, care se putea actualiza, iar ciclul său de viață era limitat întrucât avea programată o

dată de auto-distrugere (24 iunie 2012). Deși o parte dintre vulnerabilitățile exploatare (CVE-2010-2568) au fost soluționate, se pare că rezolvările au fost superficiale iar o parte dintre ele au fost redescoperite în august 2015 de către un cercetător de la HP și rezoluționate de către Microsoft. Prin urmare, sistemele Windows neactualizate încă sunt vulnerabile la aceste tipuri de amenințări.

### 2.2.3 Ransomware

**Ransomware** este un tip de amenințare care limitează accesul utilizatorilor autorizați la sistemele sau fișierele proprii, dacă nu este plătită o răscumpărare. Acest malware a fost creat în esență pentru a produce bani, iar tehnicile de propagare sunt diverse precum: atașamente trimise prin e-mail, linkuri compromise integrate în site-uri web sau chiar trimise prin IM (instant messaging). Acest tip de amenințare a evoluat în mod constant și a pornit de la o „joacă”, ajungându-se la instrumente de hacking pentru obținerea de avantaje materiale imediate.

Primul ransomware cunoscut este PC Cyborg care a fost dezvoltat de către J. Popp în anul 1989. Acest malware ascundea fișierele și cripta numele acestora, cerând victimei bani pentru reînnoirea licenței. Apoi, ransomware a evoluat sub forma unor avertismente de necesitatea de a actualiza sau instala un program anti-virus și ajungând în prezent să utilizeze metode avansate de criptare asimetrică pentru a priva accesul utilizatorului la date. Printre cele mai cunoscute Ransomware sunt CryptoLocker (2013) și CryptoWall (cu cele patru versiuni ale sale). Ambele utilizează criptare asimetrică și rețelele TOR pentru a comunica cu centru de comandă și control (C&C). Ceea ce face aceste amenințări periculoase este faptul că exploatează naivitatea utilizatorilor care deschid orice atașament sau dau un click pe un link aparent inofensiv și ajung să fie victimele atacatorilor care le vor cripta datele și apoi îi vor momi spre plățirea unei sume de bani în speranța obținerii datelor. Mai mult, algoritmi de criptare utilizați sunt avansați și greu de spart, iar recomandările specialiștilor se referă la păstrarea unor copii de siguranță a datelor importante.

## 2.3 NECESITATEA UNOR SOLUȚII INTELIGENTE

Evoluția atacurilor cibernetice depinde de evoluția tehnologiei și a oamenilor care o dezvoltă. Cu alte cuvinte, noua tehnologie este o sabie cu două tăișuri, de care atacatorii pot beneficia pentru a își implementa propriile metode de protecție, precum autentificarea botnet-urilor, criptarea datelor aparținând victimelor (ex. Ransomware) sau anonimizarea plăților (ex. BitCoin). Prin urmare, este clar că avem nevoie de noi soluții de securitate de tip pro-active care să permită protejarea bunurilor critice. O dată cu creșterea volumului de date generate de utilizatori, dezvoltarea uneltelor de hacking și metamorfozarea malware-ului, soluțiile de securitate trebuie să evolueze și ele, să fie capabile de a monitoriza și proteja sistemele informatice într-un mod inteligent. În cadrul acestei teze prin **soluții inteligente** înțelegem că sunt bazate pe algoritmi de inteligență computațională (CI).

## 3 ALGORITMI DE INTELIGENȚĂ COMPUTAȚIONALĂ

Părintele mașinilor inteligente este considerat Alan Turing, care în anul 1950 își publica lucrarea „Computing Machinery and Intelligence”. Prin urmare domeniul inteligenței artificiale este destul de nou, dacă îl comparăm cu altele precum matematica, fizica sau chiar domeniul calculatoarelor. Am menționat inteligența artificială (AI), întrucât inteligența computațională (CI) este o subramură a acesteia și de multe ori cei doi termeni sunt confunziți. Diferența este explicată de către Bezdek în 1994 [15] care puncta faptul că AI se

referă la procesarea simbolurilor și raționarea acestora, pe când CI se adresează raționării lingvistice, numerice sau granulare.

Inspirația algoritmilor CI este destul de holistică și cuprinde domenii precum: psihologia, selecția naturală sau colaborarea din cadrul grupurilor de animale, teoriile moderne privind logica sau chiar metode probabilistice care stau la baza luării unei decizii. Cu alte cuvinte, CI încearcă să transpună *comportamentul inteligent* în modele matematice pentru a construi algoritmi în vederea rezolvării unei game diverse de probleme. Unul dintre attributele cheie ale CI este învățarea, care se referă de fapt la extragerea și utilizarea cunoșterii pentru obținerea unor informații sau abilități noi. În funcție de *metoda de învățare* putem avea CI supervizați, nesupervizați, semi-supervizați sau RL (reinforcement learning). Există mai multe astfel de clasificări ale algoritmilor CI. În ceea ce privește proiectul nostru de cercetare, vom împărți algoritmi în două categorii: convenționali (ex. arborii de decizie, mașinile cu suport vectorial sau Naive Bayes) și cei inspirați din paradigme biologice (swarm intelligence și artificial immune systems). Această clasificare ne va ajuta să distingem algoritmi bine-cunoscuți sau convenționali de cei inspirați biologic, SI și AIS, care fac obiectul cercetării noastre. Pentru ultima categorie de algoritmi am realizat o comparație proprie și am propus câteva versiuni îmbunătățite. Prin urmare, în continuare ne vom limita la introducerea conceptelor care stau la baza algoritmilor SI și AIS, prezentarea versiunilor originale și cele modificate pentru doi algoritmi. Detaliile privind algoritmi convenționali și alți algoritmi SI și AIS utilizați în modelele propuse se regăsesc în teza autorului.

### 3.1 SWARM INTELLIGENCE

*Swarm Intelligence (SI) este o ramură a inteligenței computaționale care se ocupă cu sistemele naturale sau artificiale compuse din mai mulți indivizi sau agenți care se auto-organizează și nu necesită un punct de comandă central. Indivizii din sistem sunt relativ omogeni (sunt asemănători sau fac parte dintr-o anumită tipologie) și interacțiunea dintre aceștia se bazează pe reguli simple ce depind de informațiile locale schimbate cu alți indivizi în mod direct sau prin mediu (stigmergy). Deși nu există un punct de comandă central care să dicteze comportamentul indivizilor, interacțiunea dintre aceștia generează la nivel global un comportament inteligent al populației (swarm).[3]*

Conceptul de swarm intelligence este introdus în 1989 de către Gerardo Beni și Jim Wang în contextul sistemelor de roboți. Pornind de la agenți care se puteau autoorganiza, cercetătorii au extins conceptul de swarm intelligence pentru a defini algoritmi inspirați din acest comportament și din inteligența colectivă a unor colonii de insecte sau animale. Progresul major este atins după 1990, începând cu algoritmul propus de Marco Dorigo în teza sa de doctorat, care s-a inspirat din comportamentul coloniilor de furnici, algoritmul intitulat *Ant Colony Optimization*. Apoi, în 1995 un nou algoritm având la bază paradigma zborului cârdurilor de cocori (*Particle Swarm Optimization*) este propus de către J. Kennedy și R. Eberhart. În următoarele decenii au apărut o multitudine de algoritmi inspirați din comportamentul diverselor insecte sau animale precum albinele (Artificial Bee Colony, 2005), licuricii (Firefly Algorithm, 2008) sau liliicii (Bat Algorithm, 2010).

În general algoritmi de swarm intelligence au la bază două componente : *explorarea și exploatarea*, care sunt aplicate în mod diferit, de unde și diversitatea algoritmilor. Explorarea este componenta aleatoare a algoritmului care îi va permite acestuia să abordeze o plajă cât mai variată de posibile soluții. Cea de a doua componentă se referă la îmbunătățirea acestei soluții candidat când anumite condiții sunt întrunite. Majoritatea acestor algoritmi euristici implementează exploatarea prin algoritmi de tip greedy, precum ABC, sau prin metode de căutare locală, precum ACO. În orice caz, indivizii din grup își vor alege următorul candidat în funcție de experiența personală dar și de cea acumulată la nivelul grupului. O altă

componentă importantă este **funcția fitness** (sau funcția de performanță), care asociază un cost fiecărei soluții candidat. Strategia algoritmului urmărește îmbunătățirea valorii funcției și obținerea unei soluții așa-zis optime. Prin urmare, alegerea componentelor din cadrul funcției poate influența performanțele algoritmului.

În ultimele două decenii, algoritmi SI au devenit din ce în ce mai populari. Principalele motive fiind: *simplitatea* (majoritatea algoritmilor sunt ușor de înțeles și de implementat), *flexibilitatea* (deși simpli, algoritmi SI oferă flexibilitate, putând fi utilizați pentru o multitudine de aplicații cum ar fi probleme de optimizare, NP etc.) și *robustețea* (algoritmul va funcționa corect chiar dacă o parte dintre indivizi nu vor reuși să își realizeze sarcinile). [4]

### 3.1.1 Bat Algorithm

**Bat Algorithm (BA)** este un algoritm de Swarm Intelligence propus în 2010 de către Yang [16], care s-a inspirat din ecologia liliecilor. Când își caută hrana, aceștia emit vibrații de sunete cu frecvențe înalte care îi ajută să aproximeze diferența dintre un obstacol și o țintă urmărită. Pentru a transpune acest comportament într-un algoritm inteligent, autorul emite trei ipoteze:

- Toți liliecii folosesc ecologia pentru a aproxima diferența dintre un obstacol și o țintă.
- Liliecii zboară aleatoriu și traiectoria lor este definită de locația lor în spațiu ( $x_i$ ) și viteza de mișcare ( $v_i$ ). Aceste două variabile sunt calculate în funcție de frecvența ( $freq_i$ ), amplitudinea ( $A_i$ ) și vibrația emisiilor sonore ( $r_i$ ) ale individului. Mai mult, în funcție de proximitatea prăzii, individul își va ajusta amplitudinea și vibrațiile emisiilor.
- Ultima regulă presupune că amplitudinea variază de la o valoare maximă ( $A_0$ ) la o valoare minimă ( $A_{min}$ ).

Practic algoritmul se bazează pe un grup de *indivizi identici* care au înscrise în memoria internă următoarele date: *locația* ( $x_i$ ) (care este de fapt soluția candidat propusă de individ), *viteza* ( $v_i$ ) și *frecvența* ( $freq_i$ ) pe care și le va actualiza la fiecare iterație a algoritmului conform ecuațiilor următoare:

$$freq_i = freq_{min} + (freq_{max} - freq_{min})\beta \quad (1)$$

$$v_i^t = v_i^{t-1} + (x_i^{t-1} - x_{best})freq_i \quad (2)$$

$$x_i^t = x_i^{t-1} + v_i^t \quad (3)$$

Unde  $\beta \in [0, 1]$  este un număr aleator extras dintr-o distribuție uniformă. Cu cât individul se apropie de țintă, își va ajusta *amplitudinea* ( $A_i$ ) și *vibrațiile sunetelor* ( $r_i$ ) conform :

$$A_i^{t+1} = \alpha A_i^t \quad (4)$$

$$r_i^{t+1} = r_i^0 [1 - e^{-\gamma t}] \quad (5)$$

Unde  $\alpha$  ( $0 < \alpha < 1$ ) și  $\gamma$  ( $\gamma > 0$ ) sunt variabile constante, alese de utilizator la rularea algoritmului.

Pentru a îmbunătăți soluția candidat, autorul mai adaugă o etapă de căutare locală bazată pe random walks și astfel noua soluție devine:

$$x_{new} = x_{old} + \delta A_t^* \quad (6)$$

Unde  $\delta \in [-1, 1]$  este un număr aleator și  $A_t^*$  este media amplitudinii tuturor indivizilor din grup la iterația  $t$ . Pseudocodul lui BA este ilustrat mai jos.

---

#### **Algoritm 1 - Bat Algorithm**

---

1. **for**  $i \leq 1$  to SN **do**
2.  $f(x_i)$  := objective function
3.  $x_i$ ;  $v_i$  := initialize
4.  $A_i$ ;  $r_i$  := initialize
5.  $freq_i$  := initialize
6. **end for**

```

7. while t < MAX_IT do
8.   for i <= 1 to SN do
9.     Generate new solution cf. eq. (1) (2) (3)
10.    if rand > ri then
11.      Get best solution
12.      Local search for sol. cf. eq. (6)
13.    end if
14.    if rand < Ai AND f(xi) < f(xnew) then
15.      Accept new solution
16.      ri; Ai := update cf. eq. (4) (5)
17.    end if
18.  end for
19.  t := t + 1
20.  best := f(xbest)
21. end while

```

Ca orice algoritm SI, BA are două componente : explorarea și exploatarea. Toți indivizii din grup vor zbura aleatoriu și vor folosi random walks pentru a își diversifica locația. După ce și-a stabilit o zonă a soluției candidat, individul o va exploata prin ajustarea amplitudinii și a vibrațiilor sonore. Mai mult, această trecere de la explorare la exploatare se face în mod dinamic. Autorul susține că această proprietate va permite crearea unor aplicații eficiente, în sensul în care cel care implementează aplicația va putea decide când trebuie să se facă această trecere în funcție de cerințele și specificul aplicației.

### 3.1.2 Scurtă discuție despre SI

Algoritmii de SI sunt bazați pe agenți simplii care imită comportamentul altor indivizi din grup sau au trasate sarcini precise, însă niciunul nu are privirea de ansamblu asupra problemei. Deși nu există un lider desemnat al grupului, iar fiecare individ realizează sarcini simple, grupul are un comportament global inteligent datorită comunicării existente la nivelul populației. În opinia noastră principalele concepte care stau la baza algoritmilor SI includ: agenții (indivizii care fac parte din grup), explorarea (oferă diversitatea soluțiilor), exploatarea (realizată după explorarea spațiului de căutare pentru alegerea unei zone de interes), comunicarea (sub forma colaborării dintre indivizii care fac parte din grup) și funcția fitness (valoarea sa va cuantifica calitatea soluțiilor candidate).

În tabelul următor vom realiza o comparare a algoritmilor SI pe care i-am utilizat în modelele propuse, care are în vedere conceptele principale ale SI enumerate anterior.

Tabelul 1. Compararea algoritmilor SI

Denumire algoritm	Problema	Tipologii de indivizi	Explorarea	Exploatarea	Comunicarea	Fitness function
<i>PSO</i>	Dinamica mișcării grupului (cârdurile de cocori)	identici	Parametrii aleatori (r1, r2)	Parametrii de învățare (c1, c2)	Directă la nivel de grup	În funcție de calitatea locației
<i>ACO</i>	Găsirea celui mai scurt drum dintre mușuroi și hrană	identici	Funcția euristică și cantitatea de fero nom	Rata de evaporare a cantității de fero mon	Indirectă (stigmergy)	În funcție de calitatea drumului găsit

Denumire algoritm	Problema	Tipologii de Indivizi	Explorarea	Exploatarea	Comunicarea	Fitness function
<i>ABC</i>	Găsirea celei mai bune surse de hrană	3 categorii: lucrători, privitori și cercetași	Random walks (albinele cercetașe)	Algoritm de tip greedy (albinele lucrătoare)	Directă prin dansul albinelor lucrătoare	În funcție de calitatea sursei de hrană
<i>BA</i>	Găsirea țintei (prada vânată)	identici	Random walks, ajustarea frecvenței	Adaptarea intensității și ratei de emisie sonoră	Directă la nivel de grup	În funcție de locația țintei
<i>BAL</i>	Găsirea țintei (prada vânată)	identici	Lévy flights, ajustarea frecvenței	Adaptarea intensității și ratei de emisie sonoră	Directă la nivel de grup	În funcție de locația țintei
<i>BA(E)</i>	Găsirea țintei (prada vânată)	identici	Random walks, <b>distanța Euclidiană față de vecin</b> , ajustarea frecvenței	Adaptarea intensității și ratei de emisie sonoră	Directă la nivel de grup	În funcție de locația țintei

### 3.2 ARTIFICIAL IMMUNE SYSTEMS

*Artificial Immune System (AIS)* este o ramură a inteligenței computaționale care se referă la algoritmi inspirați biologic, ce transformă principiile, funcțiile și modelele din biologie în modele matematice care pot fi implementate în vederea rezolvării unei game variate de probleme [17]. Sistemul imunitar uman (NIS – Natural Immune System) protejează organismul de diversele amenințări din exterior, sarcinile acestuia fiind divizate între cele două componente principale ale sale: nativă și adaptivă, care împreună reușesc să construiască o arhitectură defensivă multi-nivel. Acest sistem complex este caracterizat de un grad ridicat de paralelizare și distributivitate adaptabilă obținute prin intermediul grupurilor de agenți imunitari care utilizează rețeaua chimică de trimitere a mesajelor și care iau decizii la nivel local sau chiar global.

După cum am precizat, sistemul imunitar este de tip multi-nivel, organizat astfel în: imunitatea nativă și imunitatea adaptivă. Sarcina principală a NIS este de a proteja corpul uman împotriva contaminării cu agenți precum viruși sau patogeni. O clasă de celule non-proprii sunt cunoscute sub denumirea de antigen. Astfel, când un patogen este identificat în corp, atacul inițial este realizat de componenta nativă a sistemului imunitar, iar componenta adaptivă este utilizată pentru acei patogeni care nu au fost distruși de către cea nativă [18].

- **Imunitatea nativă** – este acea componentă a NIS care constă în celulele și mecanismele utilizate în vederea prevenirii infecțiilor cauzate de alte organisme. Oferă un proces inițial de imunizare prin componenta nativă și nu garantează protecția totală [18].
- **Imunitatea adaptivă** – permite corpului să identifice și să contracareze orice microb printr-un receptor antigen, chiar dacă nu a mai întâlnit acest tip de invadator. Are un nivel de complexitate mai ridicată decât componenta nativă. La bază, folosește cele două tipuri de globule albe (limfocitele : T-cell și B-cell). Un proces aleator de generare a receptorilor antigenilor are loc, iar limfocitele sunt apoi responsabile cu identificarea și dituderea antigenilor [18].

### 3.2.1 Transpunerea NIS în AIS

Pentru a reprezenta aceste componente biologice în domeniul calculatoarelor, Castro și Timmis [17] au definit un framework multi-nivelar sub forma unui șablon, în vederea descrierii structurii paradigmelor AIS. În funcție de domeniul de aplicare al AIS, avem de definit trei componente:

- **Reprezentarea componentelor** – pentru a reprezenta componentele funcționale din sistem. Spre exemplu putem avea o mulțime  $S$ , cu două tipuri de componente: antigeni (Ag) și anticorpi (Ab). Acestea sunt definite ca vectori  $d$ -dimensionali, tipul acestora depinzând de tipul formei spațiului care poate include [17]:
  - **Valori reale** – atributele sunt reprezentate ca valori ale numerelor reale,
  - **Hamming** – atributele sunt elemente ale unui set finit dintr-un alfabet,
  - **Simboluri** – atributele sunt de tip nominal, reprezentate ca simboluri.
- **Măsurarea afinității** – pentru a cunatifica interacțiunile dintre componentele sistemului (în general dintre detector și antigen). Calculează distanța metrică dintre Ag și Ab, care poate fi distanța Euclidiană, Hamming etc. Pe baza valorii acestei funcții se vor lua deciziile algoritmului (eliminarea/generarea detectorilor etc).
- **Algoritmul imunitar** – pentru a determina dinamica sistemului și a componentelor acestuia.

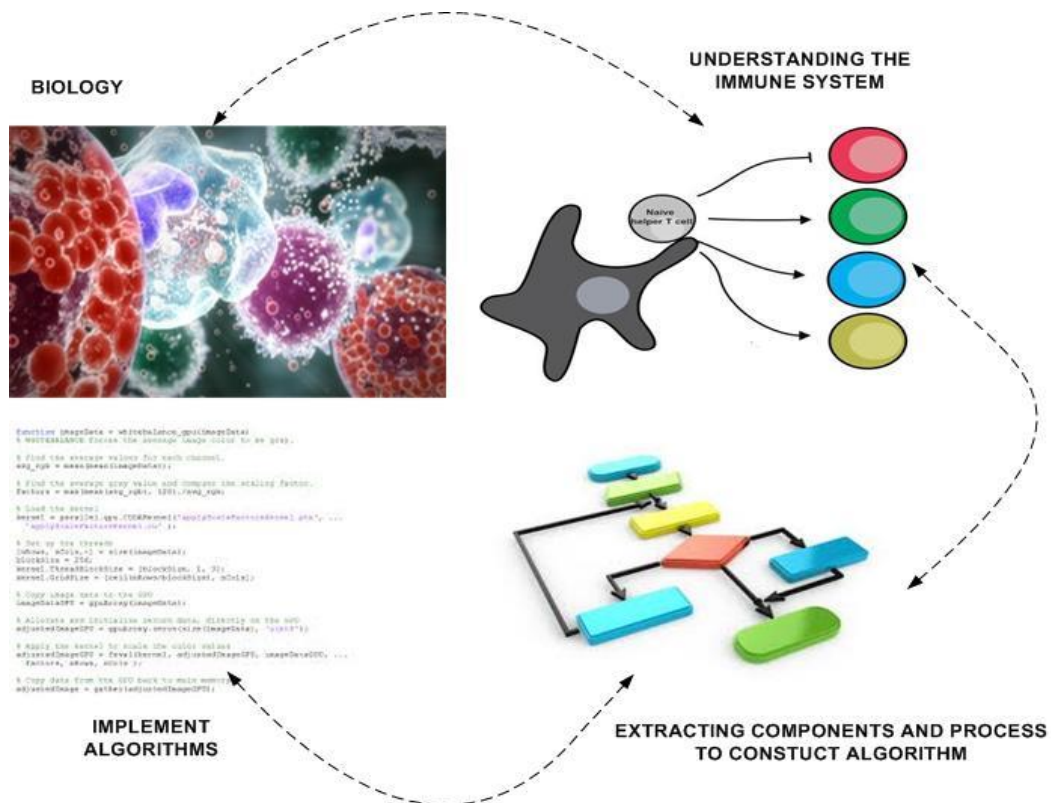


Figura 1. Transpunerea NIS în AIS

### 3.2.2 Dendritic Cell Algorithm

**Dendritic Cell Algorithm (DCA)** este un algoritm AIS de generație recentă care are la bază principiile din teoria pericolului propusă de Matzinger, referitoare la rolul și funcțiile celulelor dendritice (DC-cells). Autorii îmbină două concepte: *semnalele* (care evaluează

contextul) și *antigenii* (care sunt datele de intrare ce trebuie evaluate), pentru a calcula o variabilă MCAV (mature context antigen value) ce are o valoare cuprinsă în intervalul 0 și 1 [12]. În cadrul acestei teze ne vom referi la varianta deterministă a algoritmului DCA (dDCA).

Algoritmul are la bază o populație de celule DC, iar fiecare celulă se poate afla într-una din următoarele stări [12][10] :

- **Imaturitate** – este starea inițială a oricărei DC-cell, în care colectează antigen și procesează semnalele,
- **Semi-maturitate** – sunt celule imature care pot decide dacă un semnal este sigur,
- **Maturitate** – sunt celule mature care pot decide dacă semnalele locale reprezintă un pericol.

Toate celulele sunt inițial imature apoi, pe parcursul colectării de antigeni ele vor deveni semi-mature sau mature, în funcție de tipul semnalelor pe care le întâlnesc/colectează pe parcursul vieții (lifespan). Sunt definite trei tipuri de semnale, respectiv [23]:

- **PAMP (Pathogenetic Associated Molecular Patterns)** – are o influență considerabilă în vederea transformării unei celule DC din starea imatură într-o stare de maturitate; atributele care fac parte din această categorie de semnale indică, în general, pericolul.
- **Danger (Pericol)** – reflectă potențiale anomalii, cu cât valoarea acestora crește, proporțional va crește și status-ul de anormalitate al sistemului monitorizat.
- **Safe (Sigur)** – crește în valoare o dată cu observarea unui comportament normal al sistemului, acesta este un indicator de încredere al sistemului; cu alte cuvinte, exprimă un comportament normal al sistemului.

Tabelul 2. Matricea de ponderi pentru DCA

	<b>PAMP (<math>S_1</math>)</b>	<b>Danger (<math>S_2</math>)</b>	<b>Safe (<math>S_3</math>)</b>
<b>CSM (<math>O_1</math>)</b>	W1	W1 / 2	W1 * 1.5
<b>Semi-mature (<math>O_2</math>)</b>	0	0	W2
<b>Mature (<math>O_3</math>)</b>	W3	W3 / 2	-W3 * 1.5

DCA are trei etape principale, respectiv:

- a. **Pre-procesare** – este etapa în care analistul trebuie să stabilească metoda de reprezentare a componentelor de tip antigen (ex. ID-ul unui proces); tot în această etapă se aleg acele atribute relevante pentru detecție, care vor fi incluse în matricea de semnale și acestea vor fi grupate în cele trei categorii. Împărțirea atributelor pe categorii de semnale se poate face pe baza cunoștințelor unui expert în domeniu sau prin procese automatizate (ex. Information Gain, Principal Component Analysis etc.).
- b. **Detecția** – entitățile DC sunt create și încep să colecteze date (antigenii care trebuie analizați). Pentru fiecare antigen se va calcula un semnal de ieșire  $O_i$  :

$$O_i = \sum_{j=1}^3 W_{i,j} S_j$$

unde  $S_j$  reprezintă semnalul de intrare (PAMP, Danger sau Safe) și  $W_{i,j}$  reprezintă ponderea care este prestabilită pentru fiecare categorie de semnal, conform tabelului 2. Fiecare entitate DC are un timp de viață, iar o dată cu procesarea antigenilor, durata sa va scădea cu o valoare egală cu cea a semnalului CSM. O dată ce CSM va crește atât de mult încât va depăși pragul de migrare prestabilit pentru entitatea DC, celula va trece într-una din cele două stări de maturitate (semi-maturitate sau maturitate). Din



acest moment se începe evaluarea componentelor semi-mature și mature ale semnalului O. Componenta care are valoarea mai mare va determina polaritatea, K, pentru acel tip de antigen. O dată ajunsă la maturitate, entitatea DC își va trimite mai departe informațiile analizelor de antigeni și își va încheia ciclul de viață. Din acest moment grupul activ de entități DC este reînnoit cu o nouă entitate DC care îi va lua locul celei vechi care a murit.

- c. **Analiza** – este etapa finală, în care algoritmul va decide clasa antigenului. Pentru aceasta se va calcula valoarea MCAV pentru fiecare antigen în parte. Valoarea variabilei MCAV este dată de rezultatul fracției dintre numărul de entități care au catalogat antigenul ca anomalie și frecvența de colectare a celui tip de antigen de către grupul de celule DC.

Pe parcursul ultimului deceniu, au existat mai multe variante ale algoritmului DCA (pDCA-prototype, lbDCA-libtissue, rDCA etc.), însă cel mai frecvent utilizat este cel determinist (dDCA-deterministic DCA), obținând rezultate promițătoare și fiind previzibil din punct de vedere al rezultatelor obținute. În pseudocodul de mai jos este redat dDCA.

---

### **Algoritmul 2 – Dendritic Cell Algorithm [23]**

---

```

input : antigen and signal instances
output: antigen types and anomaly metric MCAV
    set DC population size;
    initialise DCs;
while data do
    if antigen then
        agCounter++;
        cellIndex = agCounter % populationSize;
        DC of cellIndex assigned antigen;
        update DC's antigen pro_le;
    end
    if signal then
        calculate csm and k;
        foreach DC do
            DC.lifespan -= csm;
            DC.sumK += k;
            if DC.lifespan <= 0 then
                record antigens and DC.sumK;
                reset DC;
            end
        end
    end
end
foreach antigen type do
    calculate MCAV;
end

```

---

### 3.2.3 Scurtă discuție despre AIS

Spre deosebire de algoritmi SI, AIS nu are un model arhetipal drept șablon, în schimb există patru mecanisme din teoria sistemelor imunitare din care autorii s-au inspirat: selectarea

negativă, principiul clonării selective, rețele imune idiotipice și teoria pericolului [19]; aceștia sunt detaliați în tabelul următor.

Tabelul 3. Algoritmi AIS

Componenta NIS	Mecanismul imunitar	Algoritmul AIS	Datele pentru antrenare	Aplicabilitatea în domeniul calculatoarelor
<b>Imunitatea adaptivă</b>	<i>Mecanismul de selectare negativă (limfocitele B-cell și T-cell)</i>	Negative Selection Algorithms (Forrest et. al. 1994 [20])	Celulele proprii	Detectia erorilor, detectia anomaliilor etc.
	<i>Principiul Clonării Selective (limfocitele B-cell)</i>	Clonal Selection Algorithms (CLONALG 2002 - Castro și Von Zuben [21])	Celulele non-proprii	Metode de optimizare sau căutare.
	<i>Teoria rețelelor idiotipice (limfocitele B-cell)</i>	Immune Network Algorithms (aiNet 2001 Castro et. al. [22])	Celulele non-proprii	Probleme de clasificare
<b>Imunitatea nativă</b>	<i>Teoria pericolului (DC-cell)</i>	DC algorithm Greensmith et. al. 2007 [23]	Celulele proprii și non-proprii	Detectia anomaliilor
	<i>Teoria pericolului (DC-cell și T-cell)</i>	TLR algorithm Twycross et. al. 2007 [24]	Celulele proprii	Detectia anomaliilor

### 3.3 SWARM INTELLIGENCE ȘI ARTIFICIAL IMMUNE SYSTEMS. SCURTĂ DISCUȚIE.

În opinia noastră SI și AIS prezintă similarități dar în același timp oferă perspective complementare. Ambele categorii de algoritmi sunt inspirați din natură (grupuri de animale sau sistemul imunitar format din grupuri de celule) și au la bază o populație de agenți care au de îndeplinit diverse sarcini pentru buna-funcționare a sistemului. Din punct de vedere biologic SI are ca obiectiv supraviețuirea grupului, pe când AIS are ca scop supraviețuirea gazdei. Pentru a își îndeplini scopul SI va avea în vedere soluțiile candidate cele mai bune, în funcție de valoare funcției fitness. În schimb, AIS va menține o populație de celule active în care vor fi incluse doar cele performante, restul fiind eliminate din grupul curent de lucru. Sistemul imunitar poate fi văzut ca un organism de grupuri (swarm) de celule care vor interacționa pentru a își proteja gazda.

În primul rând compararea celor două clase de algoritmi va avea în vedere definițiile acestora enunțate de Dorigo și Biratti (SI) și Castro și Timmis (AIS). Din acestea putem deduce că noțiunile care stau la baza SI sunt bine conturate, pe când definiția AIS este destul de generală și aruncă mingea în terenul teoriei imonologiei, lasând în același timp la latitudinea autorului algoritmului selectarea principiilor și a funcțiilor. În opinia noastră, principalul motiv pentru lipsa unei definiții complete se datorează complexității domeniului imunologic care încă mai are elemente și principii ascunse chiar și pentru specialiștii din domeniul biologiei.

În continuare vom enumera câteva elemente și principii care se regăsesc în SI și AIS, detalierea acestora fiind realizată în cadrul tezei: agenții, explorarea, exploatarea, comunicarea, funcția fitness, adaptabilitatea, învățarea, robustețea, paralelismul și auto-organizarea. Elementul cheie prezent în ambele clase de algoritmi este colaborarea, care în

opinia noastră este implementat diferit. SI apelează la soluția optimă la nivel individual sau global, pe când AIS apelează la o populație de agenți optimi care sunt supuși unui proces de selecție.

## 4 PROPUNERILE DE ÎMBUNĂȚĂȚIRE PENTRU ALGORITMI

După introducerea algoritmilor CI, în acest capitol sunt prezentate analiza, problemele sesizate și propunerile pentru îmbunătățire a doi algoritmi: the Bat Algorithm și Dendritic Cell Algorithm. Pentru detaliile privind analiza algoritmilor, vom face referire la teza autorului.

### 4.1 DENDRITIC CELL ALGORITHM

#### 4.1.1 Algoritmul DCA din Perspectiva Șablonului AIS

Fiind un algoritm de tip AIS, DCA se încadrează în șablonul stabilit de Castro și Timmis [17], după cum urmează:

- **Reprezentarea componentelor** – în cazul algoritmului DCA, vom stabili două componente: Antigenii (Ag) și Semnalele (S). Astfel, anticorpii din șablon sunt înlocuiți de semnale care au imprimat matricile de anomalii sau normalitate ale antigenilor. Cele două componente sunt reprezentate sub forma unor vectori de dimensiune  $d$ , unde cardinalitatea acestora este definită ca fiind :  $\langle S \rangle = \langle S_{PAMP} \rangle + \langle S_{Danger} \rangle + \langle S_{Safe} \rangle = \langle Ag \rangle = d$ . Mecanismul de reprezentare al spațiului în cazul DCA este distinct, întrucât avem de a face cu trei categorii de semnale ale căror valoare poate activa sau inhiba zona de pericol definită în preajma antigenilor. De fapt, ne interesează semnalul de ieșire, sau mai precis polaritatea (K) care va marca zona de detecție. Această polaritate trebuie să coincidă în cazul mai multor entități DC, iar populația de celule DC acționează asemenea unui forum decizional în care fiecare are o pondere egală în luarea deciziei finale referitoare la clasificarea antigenului. Pentru a înțelege mai ușor ne vom referi la reprezentarea geometrică a algoritmului DCA din figura 2.




Figura 2 Reprezentarea componentelor în cazul algoritmului DCA

Zona de determinare a antigenilor clasificați ca anomalii este delimitată de intersecția dintre entitățile DC care au o polaritate spre maturitate (semnalul lor de maturitate este mai mare decât cel de imaturitate).

- **Măsurarea afinității** – este intersecția dintre componente. Acest mecanism este înlocuit cu cel de vot majoritar realizat de entitățile DCA în stadiul de analiză. Mai mult clasificarea unui tip de antigen este rezultatul conlucrării întregului grup de celule DC. Dacă pragul critic prestabilit pentru valoarea MCAV este depășit, atunci acel antigen este detectat ca o anomalie.
- **Algoritmul imunitar** – se referă la necesitatea de a înțelege conceptele și principiile biologice ale sistemului imunitar înainte de a îi extrage conceptele și mecanismele pentru a le transpune în modele matematice. DCA preia din caracteristicile și funcțiile celulelor DC din cadrul sistemului imunitar, entități care participă în mod activ la detectarea anomaliilor având la bază procesarea semnalelor și a antigenilor.

#### 4.1.2 Enunțarea Problemei și Propunerea Soluției

DCA, propus în 2008 de către Greensmith [23], este unul din algoritmi de ultimă generație din clasa AIS. Algoritmul se bazează pe o populație de celule identice care colaborează în vederea obținerii unei analize pertinente referitoare la antigenii colectați. Mecanismul de colaborare este implementat sub forma unui vot majoritar al celulelor DC, care fac parte din grupul de decizie. Fiecare entitate DC are propria perspectivă asupra clasificării tipului de antigen (întrucât fiecare celulă DC are propriul ciclu de viață diferit) și are o putere egală în votul exprimat (la final fiecare analiză a unui tip de antigen are o pondere egală). Algoritmul calculează valoarea MCAV și o va atașa antigenului pentru a îl clasifica drept anomalie sau normal, în funcție de pragul de decizie prestabilit.

O posibilă problemă ar fi stabilirea acestui prag de decizie care ar putea influența performanțele de clasificare ale algoritmului DCA. Pentru a adresa această problemă voi face referire la reprezentarea geometrică din subcapitolul anterior (figura 2), pe care o vom transforma prin reprezentarea intersecției dintre celule (zona de anomalii delimitată). Pentru simplitate vom alege ilustrarea zonei de pericol pentru un tip de antigen, în cazul mai multor antigeni se va face multiplicarea acestora în spațiul de reprezentare al componentelor. Din figura 3 deducem că valoarea MCAV redă aria spațiului de decizie, care se împarte în două zone: de normalitate și respectiv de anomalii.




Figura 3 Reprezentarea componentelor algoritmului DCA și perspectiva de îmbunătățire

Penru a îmbunătăți algoritmul ne vom axa pe componenta de decizie, respectiv pragul ce stabilește frontiera dintre anomalii și zona de normal. Soluția pe care o propunem este de a crea o zonă de suspiciuni prin adăugarea unui prag suplimentar (vezi figura 3) pentru a delimita acele înregistrări pentru care atribuirea clasei este ușor incertă. Paradigma de vot majoritar este destul de comună și este utilizată de mulți algoritmi din domeniul calculatoarelor însă, ceea ce vrem să evidențiem în acest caz este faptul că unele dezbateri pot fi la limita dintre normalitate și anomalie. Prin urmare vom crea această zonă de confort care va face subiectul unei analize ulterioare mai detaliată în vederea luării deciziei finale privind tipul antigenului. Adăugarea acestui nou prag nu are influențe majore asupra algoritmului întrucât doar adaugă o operație suplimentară de comparare. Pentru analiza setului de date suspicioase putem alege opinia unui expert în domeniu sau un alt algoritm de clasificare.

## 4.2 THE BAT ALGORITHM

Bat Algorithm (BA) este un algoritm SI recent care imită comportamentul liliecilor ce utilizează ecolocația pentru a identifica prada sau obstacolele din drumul său. Structura algoritmului se pliază pe șablonul algoritmilor SI incluzând agenți identici, explorarea, exploatarea și funcția fitness pentru evaluarea soluțiilor. BA poate fi considerat o evoluție a lui PSO sub o formă mai generalizată și care oferă un grad mai ridicat de flexibilitate datorită saltului dinamic dintre explorare și exploatare. Algoritmul poate fi formalizat sub forma unei probleme de optimizare (a se vedea teză pentru mai multe detalii).

### 4.2.1 Enunțarea Problemei și Propunerea Soluției

Toți algoritmi SI sunt bazați pe *explorarea (diversificare) și exploatare (intensificare)*, iar echilibrul acestor două componente joacă un rol important în găsirea soluției. Prima se referă la diversificarea soluției prin realizarea unor operațiuni de căutare la nivel global și lărgirea ariei de căutare cât mai departe de soluția curentă astfel încât să permită acoperirea unui spațiu cât mai mare din aria posibilă. Prin urmare, această componentă oferă libertatea de explorare a cât mai multor soluții candidat. Avantajul evident este faptul că nu va permite blocarea căutării în jurul soluțiilor optime locale. Cu toate acestea, un grad ridicat de explorare poate determina căutarea oarbă a unor soluții și un nivel scăzut de convergență. Exploatarea se referă la realizarea unor căutări la nivel local. Această componentă exploatează o anumită regiune de soluții având în vedere informațiile locale. Acest proces este opus diversificării și va duce la convergența algoritmului.

Din testele pe care le-am realizat cu algoritmul BA, am sesizat că acesta are un început promițător, însă pierde desul de repede din diversitatea soluțiilor. Prin urmare, cu cât numărul de iterații crește, algoritmul pierde din gradul de explorare întrucât condiția  $\text{rand}(0, 1) > r$  este dificil de îndeplinit întrucât valoarea lui  $r$  crește exponențial. Mai mult, chiar dacă această condiție este satisfăcută noua soluție este generată în jurul candidatului cel mai bun găsit la nivel global și cu o abatere mică datorită amplitudinii scăzute. Prin urmare, algoritmul s-ar putea bloca în minimele locale. Pentru a rezolva această problemă am propus două îmbunătățiri prezentate în subcapitolele următoare.

### Zborurile Lévy

Îmbunătățirea algoritmului se referă la componenta algoritmului de *căutare locală* prin aplicarea *zborurile Lévy* [4][6]. Cu alte cuvinte, ecuația (7) va deveni:

$$x_{new} = x_{old} + t^{-\delta} A_t^* \quad (9)$$

Unde  $t^{-\delta}$  este distribuția Lévy și  $1 < \delta \leq 3$  este o constantă. Noua versiune a algoritmului poartă denumirea BAL.

**Zborurile Lévy** sunt procese Markov, iar cercetările recente au arătat că aceste distribuții pot descrie “metodele” de căutare a hranei pentru unele specii de animale (albatroșii sau alte animale prădătoare) [20]. De fapt, aceste distribuții sunt tot random walks, dar al căror pas este descris de o distribuție Lévy. Traectoria acestora descriu puncte apropiate, pentru o căutare în vecinătate, care apoi se transformă în întoarceri bruște de  $90^0$ .

Principalul motiv pentru înlocuirea distribuției este de a îmbunătăți componenta aleatorie a algoritmului, astfel încât acesta să nu rămână blocat în minimele locale. Astfel prin schimbarea distribuției, am avea posibilitatea de a “acoperi” un spațiu cât mai mare pentru primii pași ai iterațiilor în vedereaalegerii spațiului de exploatat. În acest mod, vom păstra logica algoritmului, modificând doar elementul de explorare locală.

### Distanța Euclidiană

În această a doua abordare, vom îmbunătăți componenta de *căutare locală* prin includerea unui termen adițional în ecuația de generare a noii soluții. Noua soluție va fi calculată conform următoarei formule:

$$x_{new} = x_{old} + u \sqrt{\sum_{i=1}^d (x_{old,i} - x_{j,i})^2} + \delta A_t^* \quad (10)$$

Unde  $0 < u \leq 1$  este un număr aleatoriu și  $x_j$  este un poziția vecinului  $j$  care are o soluție mai bună decât cea a individului curent pentru care se calculează noua soluție. Dacă un vecin cu o soluție mai bună nu este identificat într-un număr limitat de încercări, atunci se va păstra ecuația algoritmului original. Prin urmare liniile 10-13 din algoritmul 1 devin:

---

### Algoritmul 3 - BA(E)

---

```

1. if rand >  $r_i$  then
2.   trial = SN * 2; j= rand (1, SN)
3.   While trial <> 0 AND  $f(x_j) \leq f(x_i)$  do
4.     j= rand(1, SN); trial = trial - 1;
5.   end while
6.   if  $f(x_j) > f(x_i)$  then
7.     x_new = Improve_candidate_sol(x_old,  $x_j$ ) cf. (10)
8.   else
9.     x_new = Improve_candidate_sol(x_old) cf. (7)
10.  end if
11.  Accept new solution
12.  end if

```

---

În noua versiune a algoritmului, denumită BA(E), se va asigura convergența operațiunii de căutare într-o zonă unde soluțiile au valori ale funcției fitness mai bune. Din punct de vedere al complexității algoritmului, păstrăm numărul de evaluări ale funcției fitness însă creștem puțin timpul de execuție datorită operațiunii de căutare a unui vecin cu o soluție de o calitate superioară. Mai mult, forma originală a algoritmului este păstrată cu singura diferență că vom adăuga un termen suplimentar în ecuația de căutare locală a noii soluții.

## 5 SISTEMELE DE DETECȚIE A INTRUZIUNILOR

### 5.1 NOȚIUNI DE BAZĂ

**Sistemele de detecție a intruziunilor (IDS)** monitorizează evenimentele din sistem și decid dacă acestea sunt posibile intruziuni sau reprezintă operațiuni legitime. În general, IDS sunt clasificate în două categorii, în funcție de metoda de detecție utilizată, astfel: **IDS bazat pe semnături** și **IDS bazat pe anomalii**.

Prima categorie identifică intruziunile pe baza corespondenței datelor monitorizate cu descrieri predefinite ale unui comportament intruziv (precum semnături ale codurilor malițioase). Această metodă permite identificarea eficientă a intruziunilor, generând în același timp un număr scăzut de alarme false. Din acest motiv IDS bazate pe semnături sunt cele mai răspândite. Pe de altă parte, intruziunile pot fi polimorfe sau pot evolua continuu (criptarea virușilor informatici și recriptarea acestora după un timp; bombele logice pot fi identificate abia după ce se lansează atacul etc.). Detecția pe bază de semnături nu va putea identifica aceste tipuri de intruziuni necunoscute. O metodă de a rezolva această problemă este de a actualiza periodic baza de date cu semnături, manual (consumatoare de timp) sau automat (cu ajutorul unui algoritm de inteligență artificială de tip supervizat). Din păcate, elaborarea acestor seturi de date este destul de costisitoare, întrucât necesită analizarea intruziunilor respective și identificarea unor patternuri. O altă soluție pentru această problemă este oferită de Denning, care propune detecția anomaliilor bazate pe deviații de la profilul normal.

**Detecția anomaliilor** este ortogonală detecției bazate pe semnături. Această metodă pornește de la ideea că anomaliile din sisteme sunt rare și diferite de profilul normal. Așadar, va construi un profil normal al sistemului și va considera deviațiile de la acesta ca fiind intruziuni. Această metodă permite identificarea atacurilor noi și necesită doar date normale pentru a construi profilul. Cu toate acestea, un mare dezavantaj constă în identificarea limitei dintre profilul normal și cel anormal, datorită lipsei acestuia din setul de date pentru stagiul de învățare (putem simula o serie de atacuri, dar nu putem ști toate tipurile de atacuri).

În funcție de tipul de procesare utilizat de modelul “comportamental” al sistemului putem grupa tehnicile de detecție bazate pe anomalii în trei mari categorii [26]:

- **Statistice** – comportamentul sistemului este analizat folosind metode sau modele statistice. Pentru analiză se folosesc datele de audit colectate și în funcție de metrica stabilită (numărul unor evenimente, intervale de timp, supraîncărcarea unor resurse etc.) modelul statistic poate determina dacă datele observate sunt anomalii. Ca modele statistice se pot folosi : modelul operațional (compară datele observate cu un prag – threshold - prestabilit), procesele Markov (bazate pe probabilitatea tranziției), time series (ia în calcul ordinea și timpul dintre colectarea observațiilor) etc..Principalul dezavantaj este faptul că atacatorul poate simula anumiți parametri, astfel încât datele să “pară” normale (ex. Atacul SlowLoris de tip DDoS prin simularea unui trafic de date normal în rețea, dar cu cereri Http incomplete care pot păstra serverul ocupat, făcându-l indisponibil).
- **Cognitive (de cunoaștere)**–încearcă să contureze comportamentul normal al sistemului. Printre metodele cel mai des întâlnite se numără : mașina automată cu stări finite (Finite State Machine – care modelează sistemul sub forma unor stări, tranziții și acțiuni), modelul specialist (folosește cunoștințele specialiștilor umani pentru a rezolva probleme de incertitudine) etc.. Avantajele metodei sunt robustețea și flexibilitatea, însă pentru crearea unui astfel de model avem nevoie de expertiza unor persoane avizate, iar procesul de implementare este unul anevoios.
- **Bazate pe cunoaștere (AI)**–folosesc algoritmi de inteligență artificială pentru a detecta anomaliile (arborii de decizie, rețelele neuronale artificiale, mașinile cu suport vectorial

etc.). Modelele de IDS bazate pe AI sunt flexibile și au un grad ridicat de adaptabilitate. Dacă metodele clasice, reprezentate de clasificatorii tradiționali, precum SVM, rețelele neuronale sau arborii decizionali, sunt mai degrabă orientați spre clasificarea și nu spre detecția anomaliilor. Prin urmare, aceste modele sunt destul de „costisitoare”, dacă avem în vedere necesitatea de antrenare sau complexitatea modelelor matematice care stau la baza acestora, rezultând implementarea unor sisteme de monitorizare consumatoare de resurse. În general, performanțele oferite de algoritmi tradiționali sunt acceptabile, dacă avem în vedere FAR și ADR, însă performanțele acestora scad în condițiile unui mediu variabil și distribuit. Metodele inspirate biologic sunt mai simple și prezintă anumite proprietăți care le recomandă pentru detecția anomaliilor.

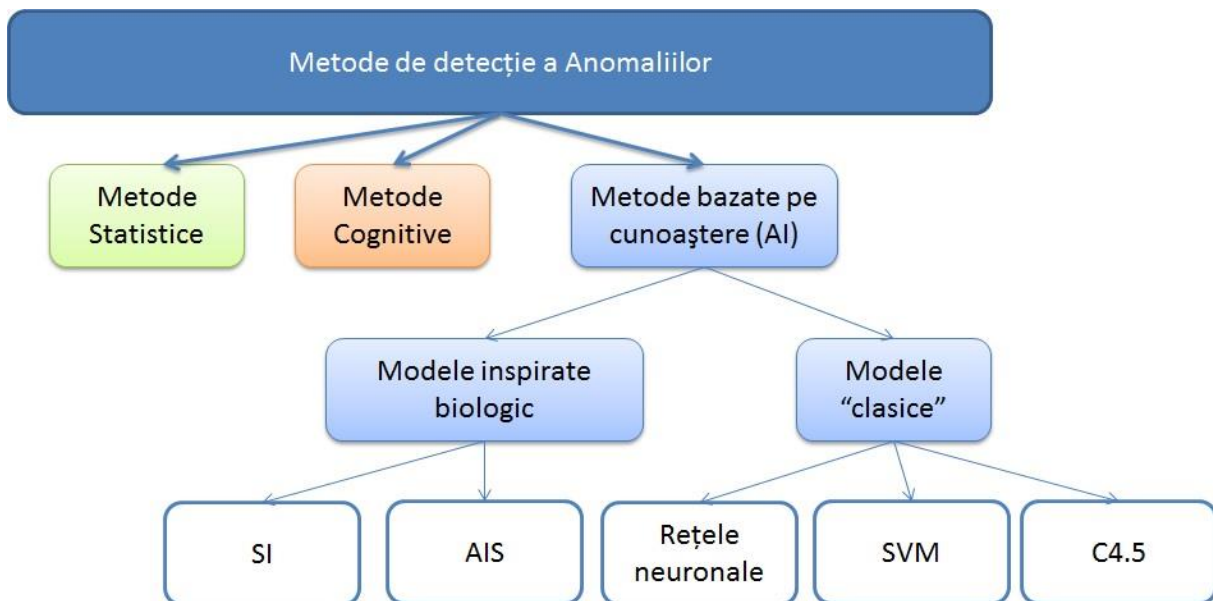


Figura 4. Clasificarea IDS bazate pe anomalii

## 5.2 FUNCȚIONALITĂȚILE ȘI EVALUAREA PERFORMANȚELOR IDS

Principalele patru funcționalități ale IDS sunt :

- **Colectarea datelor** – se referă la colectarea datelor din sursele diverse și omogenizarea acestora pentru procesul de interpretare.
- **Reducerea numărului de atribute** – unele atribute din setul de date pot fi redundante sau pot afecta negativ performanțele etapei de detecție. Așadar, pentru a micșora setul de atribute, putem utiliza diverse metode de reducere a atributelor, păstrând astfel doar setul relevant.
- **Detecția** – datele colectate și omogenizate trebuie analizate, rezultând informații cu privire la posibilele anomalii din sistem.
- **Răspunsul** – materializează rezultatul etapei de detecție prin generarea unor alarme sau chiar răspunsuri active (ex. blocarea sesiunii suspicioase sau eliminarea pachetelor).

În cadrul activității de cercetare am avut în vedere doar două funcționalități ale IDS: reducerea atributelor și respectiv etapa de detecție. Funcționalitățile IDS sunt ilustrate în figura 5.

Implementarea unor sisteme de detecție a intruziunilor eficiente este dificilă întrucât acestea trebuie să ofere un nivel scăzut de **alarme false (FAR)** și în același timp să



poată detecta atacurile din sisteme cu o **precizie** cât mai mare (ADR). Totodată, este de preferat ca IDS să ofere **răspunsuri în timp real**.

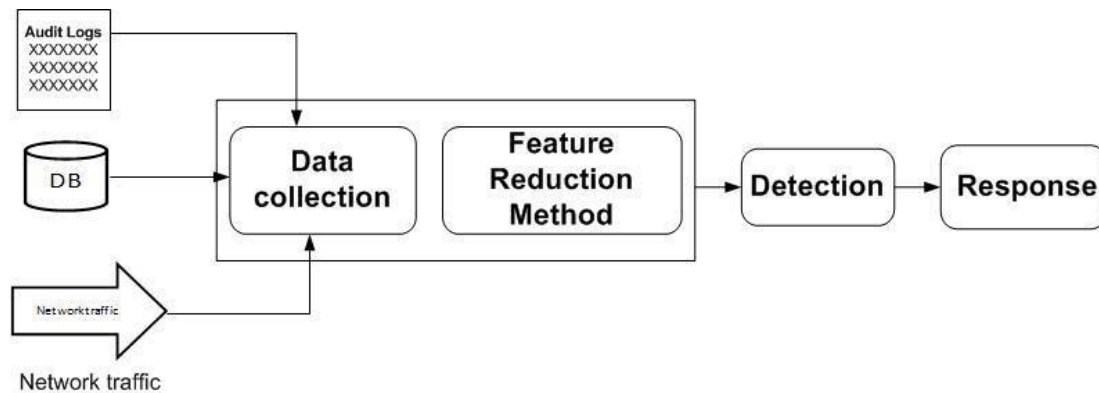


Figura 5. Funcționalitățile IDS

În contextul actual, în care sutele de aplicații și echipamente eterogene existente în infrastructură generează un volum considerabil de loguri, sistemele de monitorizare sunt suprasolicitate, iar uneori numărul mare de alarme false este dificil de interpretat de către operatorul uman. De cele mai multe ori, logurile includ date redundante sau irelevante pentru detecția intruziunilor, iar reducerea acestora a devenit aproape o necesitate.

Pentru a **evalua îmbunătățirea performanței IDS** avem nevoie de metrici și cum modelele propuse sunt bazate pe algoritmi de inteligență computațională, ne vom referi la : matricea de erori și curba ROC.

- a) **Matricea de erori (Confusion Matrix)** conține informații referitoare la clasa prezisă de clasificator și respectiv clasa reală. În general, evaluarea sistemelor este sintetizată sub forma unei matrici de erori care va permite determinarea cu ușurință a parametrilor de performanță.

Tabelul 4. Matricea de erori

		Clasa Prezisă	
		Clasa negativă (Normal)	Clasa pozitivă (Atac sau Intruziune)
Clasa Reală	Clasa Negativă (Normal)	TN	FP
	Clasa Pozitivă (Atac)	FN	TP

Pe baza acestei matrici putem calcula următorii parametri de performanță:

- Specificitatea (TNR) =  $\frac{TN}{TN+FP}$
  - Senzitivitatea sau Rata de Detecție (DR) (TPR) =  $\frac{TP}{TP+FN}$
  - Rata Alarmelor False (FAR) = 1-senzitivitatea =  $\frac{FP}{TN+FP}$
  - Acuratețea =  $\frac{TN+TP}{TN+TP+FN+FP}$
  - Precizia =  $\frac{TP}{TP+FP}$
- b) **Curbele ROC** – provin din tehnicile de detecție a semnalelor radar dezvoltate pe timpul celui de al doilea război mondial. Acestea sunt folosite pentru a indica rata de detecție în funcție de numărul de alarme false pentru un canal de comunicații

zgomotos. În domeniul detecției intruziunilor, metoda este utilizată pentru evaluarea diferitelor scheme de învățare. Un IDS optim trebuie să maximizeze DR și să minimizeze FAR. Curba ROC descrie grafic DR pe axa Y și FAR pe axa X pentru parametrii diferiți.

Dintre acestea, cel mai des sunt utilizate DR, care indică dacă IDS poate detecta intruziunile, FAR care măsoară numărul de alarme false generate de IDS ca urmare a clasificării logurilor normale ca intruziuni și respectiv acuratețea care arată dacă IDS este capabil să genereze alarme atunci când trebuie.

Avantajele și stadiul actual privind utilizarea algoritmilor SI și AIS în arhitecturile IDS se regăsesc în teză. În continuare ne vom axa asupra prezentării modelelor IDS propuse.

## 6 SISTEME DE DETECȚIE A INTRUZIUNILOR PROPUSE BAZATE PE ALGORITMI DE INTELIGENȚĂ COMPUTAȚIONALĂ

### 6.1 SETUL DE DATE

Pentru testarea modelelor IDS propuse am folosit setul de date NSL-KDD [27]. Acest set este o versiune îmbunătățită a lui KDD-Cup, în sensul că nu conține date redundante sau duplicate iar complexitatea acestora este mai scăzută. Fiecare înregistrare din setul de date conține 41 de atribute și este identificată ca activitate normală ori atac. Aceste atribute pot fi grupate în trei categorii principale: informații despre conexiune (10 atribute), informații despre timp (9 atribute), informații referitoare la conținut (13 atribute) și atribute de bază (9 atribute). Totodată, atacurile incluse în setul de date aparțin uneia dintre următoarele categorii:

- **DoS (Denial of Service)** – atacatorul încearcă să împiedice accesul la date al utilizatorilor autorizați.
- **R2L (Remote to Local)** – atacatorul obține accesul de la distanță la resursele locale ale sistemului.
- **U2R (User to Root)** - atacatorul obține drepturi de administrator pentru resursele sistemului.
- **Probing** – atacatorul încearcă să obțină accesul la resursele sistemului prin utilizarea unor puncte vulnerabile cunoscute (port-sweep, IP-weep etc.).

Mai multe detalii privind atributele setului de date se pot regăsi în anexa tezei de doctorat.

### 6.2 MODELE IDS BAZATE PE SI

#### 6.2.1 Componentele IDS

Diagrama modelului IDS este redată în figura 6, iar opțiunile privind algoritmi aleși pentru completarea blocurilor din diagramă sunt enumerați în tabelul 5.

Sumarul din tabelul 5 împarte modelele IDS propuse în trei categorii principale:

- optimizarea procesului de alegere al parametrilor pentru mașinile cu support vectorial (SVM),
- metode de selectare a atributelor, utilizând versiunile binare ale algoritmilor SI îmbunătățiți (BBAL - Binary Bat Algorithm cu zborurile Lévy, BBA(E) - Binary Bat Algorithm cu distanța Euclidiană),
- varianta care combină metodele de selectare a atributelor cu procesul de alegere a parametrilor pentru clasificatorul SVM.

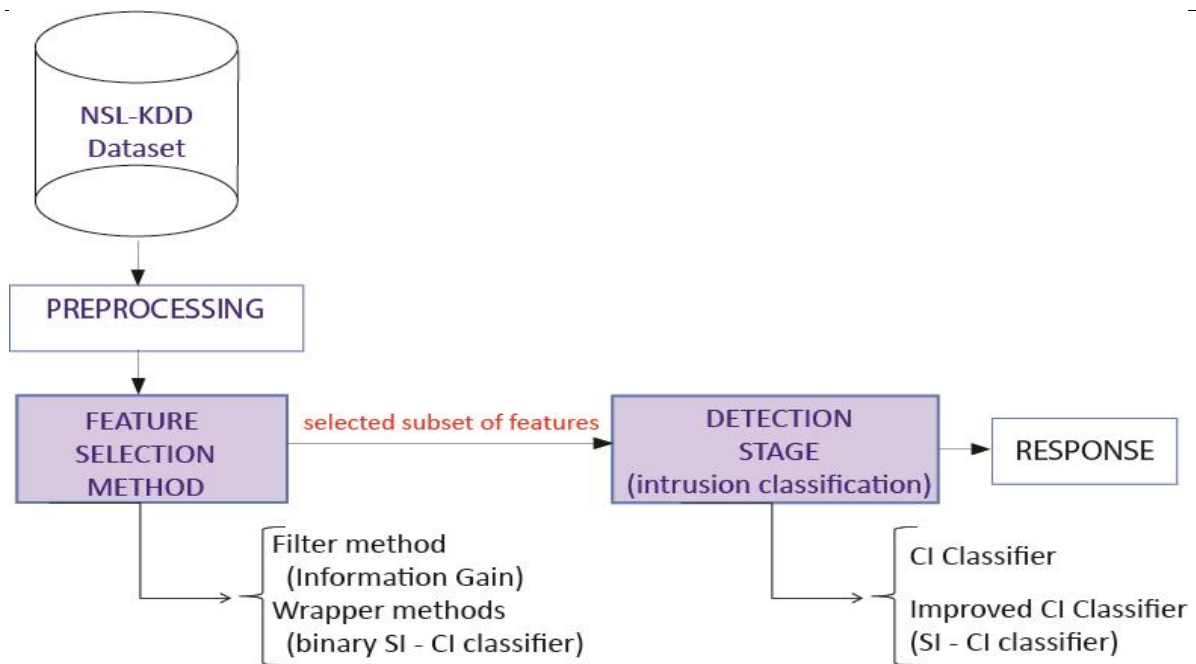


Figura 6. Diagrama modelelor IDS propuse

Tabelul 5. Sumarul modelelor IDS propuse care se bazează pe SI

Model IDS	Metodă pentru selectarea atributelor	Etapa de detecție
Setup 1 Îmbunătățirea procesului de selecție a parametrilor pentru SVM	Metode de tip filter Information Gain	SI*-SVM SI* $\in$ PSO (pt. comparare) SI* $\in$ PSO SI* $\in$ BA [7] SI* $\in$ ABC[2] SI* $\in$ BAL[11]
Setup 2 Metode pentru selectarea atributelor folosind versiunea binară a SI	Metode de tip wrapper SI*-CI SI* $\in$ BPSO (pt. comparare) SI* $\in$ BBA (pt. comparare) SI* $\in$ BBA(E) – CI $\in$ {SVM, C4. 5}[9] SI* $\in$ BBAL – CI $\in$ {SVM, NB}[6]	Clasificator CI CI $\in$ {SVM, C4. 5, NB} CI $\in$ {SVM, C4. 5, NB} CI $\in$ {SVM, C4. 5} CI $\in$ {SVM, NB}
Setup 3 Combinat	Metode de tip wrapper SI*-SVM SI* $\in$ BBA(E) SI* $\in$ BBA(E) SI* $\in$ BBA(E) SI* $\in$ BBAL SI* $\in$ BBAL	SI*-SVM PSO-SVM (pt. comparare) BA-SVM (pt. comparare) BA(E)-SVM [8] PSO-SVM (pt. comparare) BA-SVM [4]

Toate modelele IDS au fost implementate și testate pe o platformă cu procesor Intel Core 2 Duo, 1.80GHz, cu memorie RAM de 2GB și sistem de operare Ubuntu 10.04.4.. Algoritmii de Swarm Intelligence, în variantele lor binare sau standard, au fost implementați în

Java. Pentru Information Gain și algoritmi de clasificare convenționali (SVM, C4.5, NB) am utilizat biblioteca Weka versiunea 3.6.10 [32].

## 6.2.2 Optimizarea parametrilor SVM

### 6.2.2.1 Parametrii SVM

**SVM (Support Vector Machines, Mașinile cu suport vectorial)** sunt clasificatori binari liniari care își construiesc un hiperplan pentru a separa cele două clase, în cazul nostru anomaliile de trafic de rețea normal. Punctele care aparțin hiperplanului se numesc vectori suport iar distanța dintre aceștia poartă denumirea de margine. Datele nu sunt întotdeauna perfect liniar separabile și de aceea putem defini o margine soft, adică putem accepta unele erori în etapa de antrenare a modelului materializate sub forma unor înregistrări clasificate incorect. Mai mult, putem transforma setul de date într-un spațiu multidimensional de atribute în care datele să fie liniar separabile. Pentru aceasta, putem folosi **funcții kernel (funcții nucleu)**, cum ar fi funcția polinomială, funcția radial-basis (RBF) sau funcția sigmoidă, care sunt printre cele mai frecvent utilizate. Dintre acestea vom alege RBF întrucât are mai puțini parametri ce trebuie selectați și oferă transformări nonlineare bune.

Cu alte cuvinte algoritmul SI va căuta doi parametri [4][2] :

- $C$  – este parametrul de regularizare care controlează flexibilitatea marginii. O valoare mare pentru  $C$  va determina crearea unui model cu o acuratețe ridicată și cu o margine îngustă. Pe de altă parte, o valoare mică poate genera multe erori și va crea o margine largă. Valorile trebuie alese astfel încât să nu se creeze un model cu o acuratețe care să influențeze negativ proprietățile de generalizare, sau invers.
- $\sigma$  - este constanta funcției nucleu, care va influența proprietățile de overfitting și underfitting ale modelului. Acest parametru arată corelația dintre vectorii suport care construiesc hiperplanul.

### 6.2.2.2 Modele Propuse

În figura de mai jos se regăsește diagrama modelului IDS, conform șablonului din figura 6, dar în plus blocurile modelului sunt completate. Pentru îmbunătățirea procesului de alegere a parametrilor SVM am ales  $SI \in \{PSO, ABC, BA, BAL\}$ .

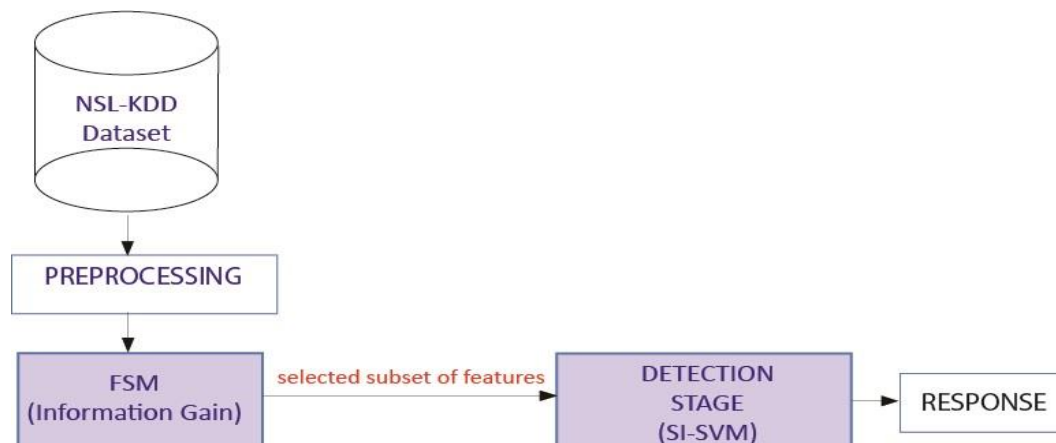


Figura 7. Diagrama modelelor IDS propuse pentru problema selectării parametrilor SVM

Pentru testarea modelului am selectat în mod aleator 9566 de înregistrări și le-am împărțit în două fișiere unul pentru antrenare și al doilea pentru testare. De asemenea, am transformat valorile simbolice în valori numerice, asociind valoarea 1 pentru atacuri și valoarea 0 pentru traficul normal.

Tabelul 6. Rezultatele testelor pentru modelele IDS propuse care se bazează pe SI

Sistemul	Nr. de caracteristici	ADR	FAR	Acuratețea
SVM	41	87.00%	0.265	89.30%
IG-SVM	26	85.00%	0.286	88.10%
IG-PSO-SVM	26	98.27%	0.044	98.68%
<b>IG-ABC-SVM [2]</b>	<b>26</b>	<b>98.53%</b>	<b>0.037</b>	<b>98.89%</b>
<b>IG-BA-SVM [7]</b>	<b>26</b>	<b>99.05%</b>	<b>0.030</b>	<b>99.15%</b>
<b>IG-BAL-SVM [11]</b>	<b>26</b>	<b>99.15%</b>	<b>0.019</b>	<b>99.38%</b>

Rezultatele testelor sunt ilustrate în tabelul 6. Acestea relevă faptul că algoritmi de SI pot fi utilizați pentru a îmbunătăți performanța clasificatorului SVM. Deși metoda de selectare a atributelor duce la performanțe mai scăzute, totuși va reduce nivelul de complexitate al clasificatorului. Acest lucru este important întrucât IDS trebuie să proceseze seturi de date multidimensionale și cu un nivel ridicat de zgomot. Se poate observa că PSO obține rezultatele cele mai slabe, însă convergența rapidă și simplitatea algoritmului pot reprezenta avantaje în cazul unor aplicații care necesită o execuție rapidă și acceptă mici inadvertențe de performanță.

După cum era de așteptat ABC are nivelul cel mai ridicat de complexitate, întrucât este construit dintr-un grup de trei tipologii de indivizi, iar uneori aceștia trebuie să se aștepte între ei. Deși obține rezultate mai bune decât PSO, algoritmul ABC este consumator de resurse din punct de vedere al timpului de execuție și al memoriei utilizate.

Cele mai bune rezultate sunt obținute de BA și BAL. Deși diferențele de performanță nu sunt atât de mari, ele pot deveni totuși importante în cazul unor sisteme reale (aici testele au fost realizate pe un set redus de date). Din punct de vedere al complexității, algoritmi BA și BAL sunt mai simplii decât ABC și sunt comparabili cu PSO din punct de vedere al timpului de execuție și al memoriei utilizate. Mai mult, performanțele obținute de algoritmul BAL sunt ușor superioare algoritmului original (număr mai mic de alarme false și o rată de detecție mai mare). De aceea putem concluziona că BA și BAL sunt candidații preferați, cu mențiunea că rezultatele sunt valide numai pentru acest set de date ales aleator din NSL-KDD.

## 6.2.3 Metode de Selectare a Atributelor

### 6.2.3.1 Transformarea algoritmilor SI în versiuni binare

Versiunea binară, denumită Binary Bat Algorithm (BBA), presupune că individul (liliacul) din grup va căuta într-un spațiu multidimensional binar. Prin urmare, locația individului, sau soluția, devine un șir de zero și unu. Pentru aceasta autorii folosesc funcția sigmoidă [28]:

$$S(v_{i,j}) = \frac{1}{1 + e^{-v_{i,j}}} \quad (11)$$

Așadar coordonatele fiecărui individ din grup devin:

$$x_{i,j} = \begin{cases} -1, & \text{dacă } S(v_{i,j}) > \delta \\ 0, & \text{altfel} \end{cases} \quad (12)$$

Unde  $\delta$  este un număr aleator între zero și unu. Astfel, soluția devine un șir de zero și unu. Putem abstractiza fiecare coordonată, astfel încât aceasta să reflecte prezența atributului în set, dacă coordonata are valoarea unu, sau absența atributului din set, dacă coordonata are valoarea zero. Cea mai bună locație găsită la nivelul grupului este *soluția problemei de optimizat*, în cazul de față este setul optim de atribute. Pentru a determina calitatea soluției propuse, algoritmul are la bază o *funcție de performanță*, iar îmbunătățirea valorii acesteia reflectă o soluție mai bună. Prin urmare, este important să alegem componentele corespunzătoare și proporțiile corecte pentru a defini această funcție de a cărei valoare depinde calitatea soluției determinate.

### 6.2.3.2 Modele Propuse

În figura 8 se regăsește diagrama modelului IDS, conform șablonului din figura 6, dar în plus blocurile modelului sunt completate. Pentru metodele de selectare a atributelor am ales *binary SI*  $\in \{BPSO, BBA, BBAL, BBA(E)\}$ .

În acest caz avem două setări pentru funcțiile de performanță :

$$\text{Opțiunea 1} \quad \text{fitness} = 90 \% \text{ Accuracy} + 10 \% \frac{1}{nbFeat} \quad (13)$$

$$\text{Opțiunea 2} \quad \text{fitness} = 60\% \text{ ADR} + 30 \% \frac{1}{FAR} + 10 \% \frac{1}{nbFeat} \quad (14)$$

Rezultatele testelor și algoritmi CI utilizați pentru testarea modelelor sunt redată în tabelele următoare.

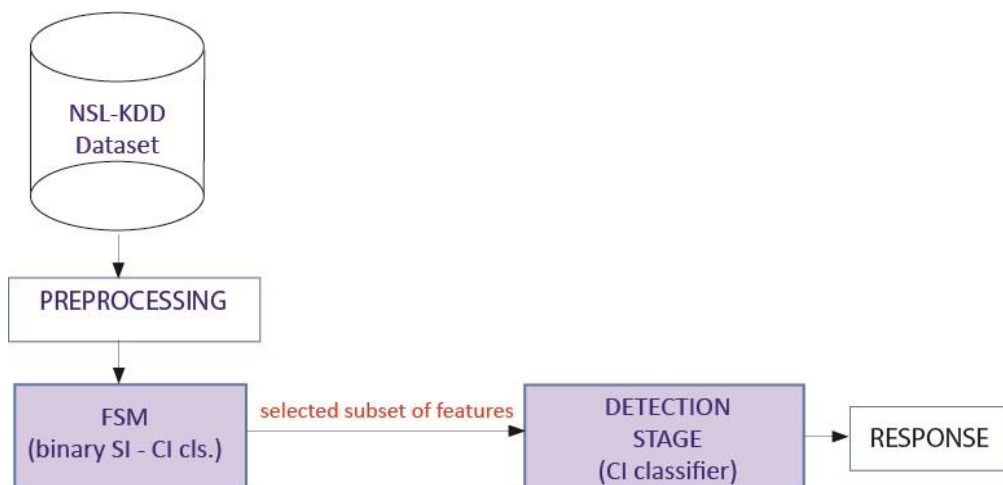


Figura 8. Diagrama modelelor IDS propuse – metode de selectare a atributelor

Din tabelul 7 putem deduce că BBAL este un candidat mai bun decât BBA sau BPSO pentru alegerea atributelor, întrucât necesită mai puține iterații pentru a ajunge la rezultate similare și

chiar uneori superioare; acest lucru fiind mai vizibil în cazul clasificatorului Naive Bayes. Mai mult, introducerea numărului de attribute ca element al funcției de performanță determină alegerea unui număr mai mic de attribute (comparabil cu cele alese în lucrarea anterioară[4]).

Tabelul 7. Rezultatele testelor pentru modelele IDS – opțiunea 1

	Setul de date pentru antrenare				Setul de date pentru testare		
Alg. SI	Nr. Atr.	ADR	FAR	Nr. Iterații	ADR	FAR	Timp (ms.)
<b>BBAL-NB</b>	15	95.91	2.95	53	91.62	5.73	764
<b>BBA-NB</b>	18	94.62	5.30	70	89.73	7.24	793
<b>BPSO-NB</b>	22	93.73	6.37	80	89.44	7.86	829
<b>NB Simplu</b>	41	91.46	8.35		90.53	6.66	1019
	Setul de date pentru antrenare				Setul de date pentru testare		
Alg. SI	Nr. Atr.	ADR	FAR	Nr. Iterații	ADR	FAR	Timp(ms.)
<b>BBAL-SVM</b>	16	99.07	0.86	4	95.78	2.89	68768
<b>BBA-SVM</b>	22	99.00	0.96	6	95.03	3.28	78251
<b>BPSO-SVM</b>	23	98.89	1.07	10	94.03	4.01	80726
<b>SVM Simplu</b>	41	98.93	1.05		89.64	6.88	82603

Rezultatele din tabelul 8 arată că BBA(E) este un candidat mai bun decât BBA sau BPSO pentru alegerea atributelor, întrucât necesită mai puține iterații pentru a ajunge la rezultate similare; Mai mult introducerea numărului de alarme false ca element al funcției de performanță determină valori mai reduse ale FAR (comparabil cu modelul anterior din tabelul 7).

Tabelul 8. Rezultatele testelor pentru modelele IDS – opțiunea 2

	Setul de date pentru antrenare					Setul de date pentru testare	
Alg. SI	Nr. Indivizi	ADR	FAR	Nr. Atr.	Nr. Iterații	ADR	FAR
<b>BBA(E)-C4.5</b>	2	99.76	0.23	15	60	96.02	2.75
<b>BBA- C4.5</b>	2	99.76	0.23	18	80	96.01	3.20
<b>BPSO- C4.5</b>	2	99.36	0.56	20	87	96.66	2.62
<b>C4.5 Simplu</b>		99.26	0.73	41		95.67	3.02
	Setul de date pentru antrenare					Setul de date pentru testare	
Alg. SI	Nr. Indivizi	ADR	FAR	Nr. Atr.	Nr. Iterații	ADR	FAR
<b>BBA(E)-SVM</b>	2	99.76	0.23	15	60	96.02	2.75
<b>BBA-SVM</b>	2	99.76	0.23	18	80	96.01	3.20

Alg. SI	Setul de date pentru antrenare					Setul de date pentru testare	
	Nr. Indivizi	ADR	FAR	Nr. Atr.	Nr. Iterații	ADR	FAR
BPSO-SVM	2	99.36	0.56	20	87	96.66	2.62
BBA(E)-SVM	5	99.49	0.42	16	13	97.23	1.3
BBA-SVM	5	99.48	0.44	16	18	91.23	5.5
BPSO-SVM	5	99.54	0.40	17	25	97.11	1.5
SVM simplu		89.81	7.28	41		89.64	6.88

#### 6.2.4 Modele Combinat

În figura 9 se regăsește diagrama modelului IDS, conform șablonului din figura 6, dar în plus blocurile modelului sunt completate. În acest caz există două setări, însă în cadrul acestui rezumat vom face referire doar la una dintre acestea, cea de-a doua fiind detaliată în cadrul tezei.

În acest caz avem două setări pentru funcțiile de performanță, în funcție de modulul în care sunt utilizate :

Metoda de selectare a atributelor (FSM)

$$fitness = 90 \% Accuracy + 10 \% \frac{1}{nbFeat} \quad (13)$$

Selectarea parametrilor pentru SVM

$$fitness = 60 \% ADR + 30 \% \frac{1}{FAR} + 10 \% \frac{1}{nbFeat} \quad (14)$$

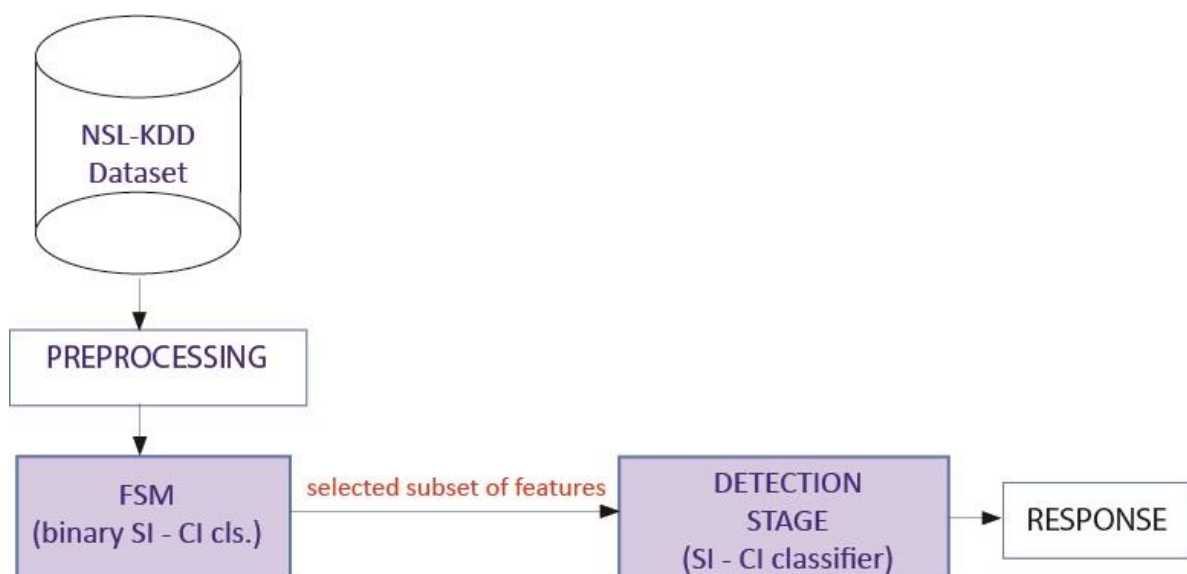


Figura 9. Diagrama modelelor IDS propuse – modelul combinat



Tabelul 9. Rezultatele testelor pentru modelele IDS – combinate (FSM și selectarea parametrilor)

Alg. SI	Setul de date pentru antrenare					Setul de date pentru testare	
	Nr. Indivizi	ADR	FAR	Nr. Atr.	Nr. Iterații	ADR	FAR
BBA(E)-SVM	2	99.29	0.61	19	50	97.17	1.6
BBA- SVM	2	99.38	0.52	19	80	90.25	5.3
BPSO- SVM	2	99.36	0.56	21	100	96.88	1.8
BBA(E)-SVM	5	99.49	0.42	16	13	97.57	1.3
BBA- SVM	5	99.48	0.44	16	18	91.23	5.5
BPSO- SVM	5	99.54	0.40	17	25	97.11	1.5
SVM simplu		98.93	1.05	41		89.64	6.88
Alg. SI	C	$\sigma$	ADR	FAR	Timp	Nr. Iterații	Nr. Indivizi
BA(E)-SVM	1	0.001	97.44	1.51	72.89	6	5
BA- SVM	1.26	0.001	96.75	2.0	70.39	11	5
PSO- SVM	1479.82	0.001	96.61	2.57	43.70	13	5
SVM simplu	1	0.5	93.8	4.97	77.45		

Rezultatele din tabelul 9 arată că BBA(E)-SVM obține cele mai bune performanțe și necesită un număr mai mic de iterații decât BPSO sau BBA. Totodată, se observă că dacă scădem numărul de indivizi din grup, numărul de iterații pentru a obține performanțe similare va crește; fapt care era de așteptat având în vedere că mai puțini indivizi înseamnă mai puțini candidați cu soluții.

În cazul selectării atributelor am utilizat doar setul ales de BBA(E)-SVM. Rezultatele testelor arată faptul că pentru performanțe similare BA și PSO necesită un număr mai mare de iterații, uneori numărul acestora fiind chiar dublu.

În concluzie, putem spune că ipotezele noastre privind BA(E) și BAL au fost confirmate, ambele versiuni depășind ușor performanțele algoritmului original, fapt vizibil în numărul mai mic de iterații necesare pentru obținerea unor performanțe similare. Am realizat și o comparare a celor doi algoritmi propuși (BA(E) și BAL), însă putem spune că performanțele lor sunt similare cu diferența că BAL poate depăși BA(E) în unele cazuri, întrucât BA(E) trebuie să caute vecinul cu o funcție de cost superioară soluției curente.

## 6.3 MODELE IDS BAZATE PE AIS

### 6.3.1 Componentele IDS

Diagrama modelului IDS este redată în figura 10, iar opțiunile privind algoritmi aleși pentru completarea blocurilor din diagramă sunt enumerate în tabelul 10.

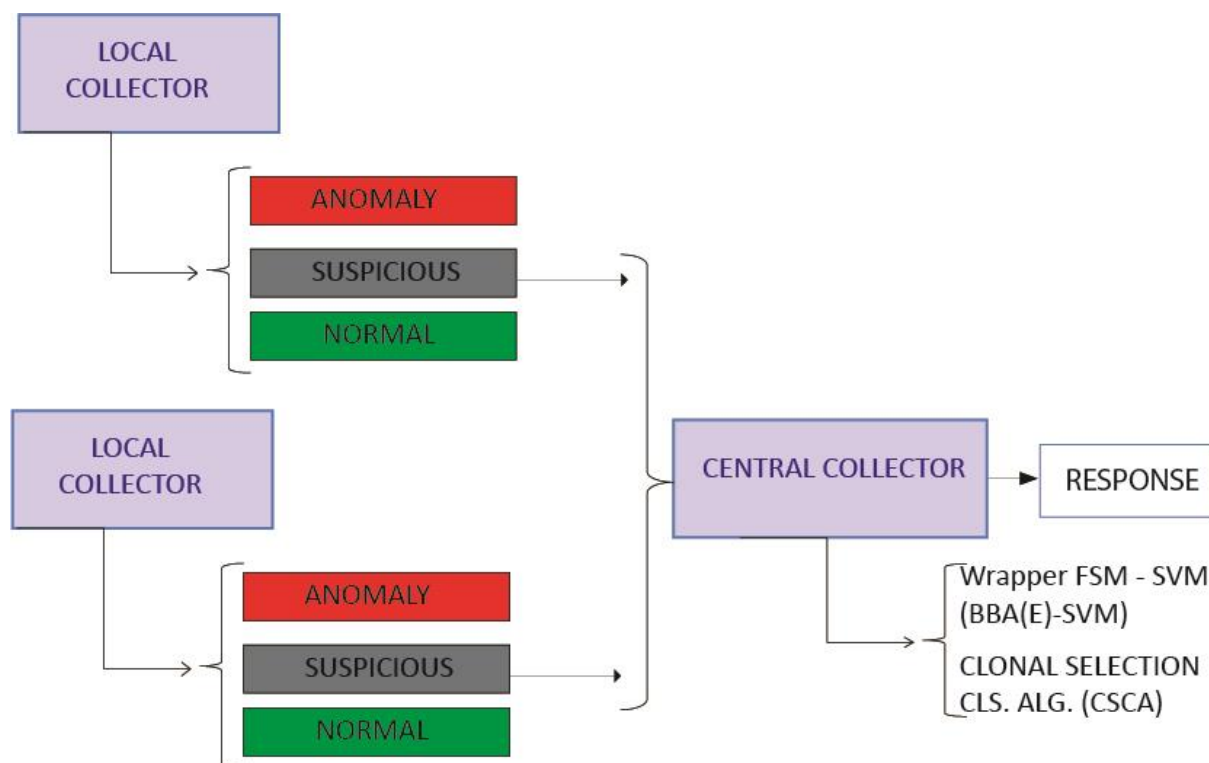


Figura 10. Diagrama modelelor IDS propuse

Sumarul din tabelul 10 împarte modelele IDS propuse în funcție de versiunea DCA utilizată și algoritmul de clasificare utilizat pentru colectorul central. În cadrul acestui raport sunt prezentate rezultatele publicate în lucrarea autorului [12].

Tabelul 10. Sumarul modelelor IDS propuse care se bazează pe SI

<i>Model IDS</i>	<i>Colector Local</i>	<i>Colector Central</i>
<i>Setup 1 [10]</i>	<i>DCA* cu multiplicare de antigen</i>	<i>BBA(E)-SVM</i>
<i>Setup 2 [12]</i>	<i>DCA* cu segmentare de antigen</i>	<i>CSCA</i>

Modelul propus [12] este un IDS bazat pe anomalii cu răspuns activ, construit pe baza a două componente, care îmbină rapiditatea DCA cu precizia clasificatorului CSCA. Arhitectura sistemului este construită pe baza următoarelor componente:

- *Componenta Locală* – care va colecta logurile locale de la host și va realiza o detecție rapidă utilizând DCA. Înregistrările vor fi clasificate în funcție de valoarea lui MCAV

astfel: anomalii ( $MCAV > 0.85$ ), suspicioase ( $MCAV \in [0.65, 0.85]$ ) sau normale ( $MCAV < 0.65$ ).

- *Componenta Centrală* – care va colecta toate înregistrările suspicioase de la toate componentele locale din sistemul monitorizat. Pentru detecția finală, vom utiliza clasificatorul CSCA. Mai mult, pentru a compara performanțele obținute de CSCA vom avea în vedere rezultatele obținute de alți doi algoritmi de clasificare tradiționali: SVM (mașinile cu suport vectorial) și C4.5, în cazul setului de date suspect.

Sistemul IDS propus va permite o detecție rapidă, aproape în timp real, pentru componenta locală, care va bloca conexiunile clasificate ca anomalii și suspicioase, urmând ca analiza avansată să fie realizată la nivelul central, care va lua decizia privind veridicitatea datelor considerate suspicioase. Componenta locală are la bază algoritmul DCA determinist în versiunea prezentată în capitolul 4, cu multiplicare de antigen și respectiv cea cu segmentare de antigeni. Dacă în primul caz detecția se va realiza după analiza unui set mare de date, în cazul segmentării, rezultatul detecției va fi întors după analiza unui număr determinat de înregistrări. Reamintim că îmbunătățirea algoritmului constă în introducerea unui prag suplimentar. Am considerat utilă introducerea unei limite suplimentare, întrucât procentajul rezultat din valoarea MCAV poate reflecta un nivel de “indecizie” sau decizie la limită, prin urmare pentru acel segment de înregistrări vom apela la algoritmi clasici pentru a obține răspunsul.

Testele au fost realizate pe o platformă cu sistemul de operare Windows 8.1, procesor Intel i7 și 8GB de memorie RAM.

#### a. Configurarea Componentei Locale

Prima etapă constă în alegerea acelor atribute din setul de date care vor constitui semnalele. Pentru aceasta alegem un proces automat bazat pe *information gain (IG)* și astfel semnalele vor fi clasificate în funcție de scorul obținut după cum urmează:

*PAMP: error\_rate, srv\_error\_rate, same\_srv\_rate, dst\_host\_error, dst\_host\_error\_rate;*

*Danger: count, srv\_count;*

*Safe: logged\_in, srv\_different\_host\_rate, dst\_host\_count.*

Tabelul 11 Parametrii pentru componenta locală

Versiunea dDCA	Numărul de celule DC	Multiplicarea de antigen	Intervalul ciclului de viață	Segmentarea antigenului
AM1	100	10	$\in [100, 300]$	
AM2	20	5	$\in [20, 60]$	
AS1	100	10	$\in [100, 300]$	$\in \{100, 500, 950\}$
AS2	20	5	$\in [20, 60]$	$\in \{100, 500, 950\}$
AS2*	20	5	$\in [20, 60]$	$\in \{20, 50\}$

Pentru testarea modelului vom alege algoritmul DCA determinist cu multiplicare de antigen și respectiv cel determinist cu segmentare de antigen, fiecare având mai multe configurări enumerate în tabelul 11. Am implementat în Java versiunea dDCA cu multiplicare de antigen (AM) și pe cea cu segmentarea de antigen (AS). În cazul segmentării vom testa mai multe opțiuni de dimensiuni de segmente pentru a identifica influența acestora asupra performanțelor obținute. Aceste variante sunt identificate ca fiind:  $AS_{i_1}$  (100 de antigeni per segment),  $AS_{i_5}$  (500 de antigeni per segment) și  $AS_{i_9}$  (950 de antigeni per segment), unde  $i$

corespunde scenariului de testare al modelului și are valorile 1 sau 2. În cel de al doilea scenariu am mai inclus două dimensiuni de segmente, în cazul unui număr mai mic de celule DC și le-am notat ca fiind:  $AS_{22}$  (20 de antigeni per segment) și  $AS_{20}$  (50 de antigeni per segment).

### **b. Configurarea Componentei Centrale**

Pentru clasificatorii CSCA (`clonalg.CSCA`), SVM (`functions.SMO`) și C4.5 (`trees.J48`) am utilizat implementarea lor implicită în Java din cadrul bibliotecii de algoritmi Weka versiunea 3.6.10[32].

Rezultatele din tabelul 12 arată faptul că DCA reușește să obțină rezultate bune în ceea ce privește ADR, FAR și timpul de execuție (în cazul dDCA cu segmentare am avut în vedere timpul de procesare al unui singur segment, întrucât acest interval de timp este necesar pentru a obține un răspuns de la componenta locală). Rezultatele testelor din tabelul 12 au în vedere doar datele normale și cele clasificate ca anomalii, dar nu și pe cele considerate suspicioase întrucât acestea urmează a fi analizate de către componenta centrală. Multiplicarea de antigeni este integrată în vederea îmbunătățirii performanțelor algoritmului DCA, avantajul oferit fiind acela că un antigen va fi proliferat și va fi analizat de mai multe celule DC. Prin urmare, clasificarea antigenului nu va fi rezultatul singular al unei celule ci va fi obținut sub forma unui vot majoritar al mai multor celule care au cicluri de viață diferite. Mai mult, segmentarea poate produce mai multe seturi de rezultate, nu ca în cazul multiplicării de antigeni. Prin urmare, am repetat testele de 20 de ori și am luat în calcul valorile ADR și FAR obținute după ce toate segmentele au fost procesate.

În cazul primului scenariu, am configurat DCA cu valori mai mari pentru ciclul de viață și respectiv pentru factorul de multiplicare al antigenilor. În consecință, un antigen ar putea fi testat de mai multe ori decât în cazul celui de al doilea scenariu. AM1 obține rezultate slabe întrucât timpul de execuție (10 minute) este destul de îndelungat, iar numărul de înregistrări suspicioase reprezintă aproximativ 85% din setul de date original. Segmentarea de date reduce setul de suspiciuni la 45% din setul inițial, în cazul  $AS_{11}$  și îmbunătățește ADR cu 13% în cazul lui  $AS_{15}$ , dacă le comparăm cu opțiunea AM1. Cu cât crește numărul de antigeni incluși în segmente, ADR are o evoluție descendentă, dacă numărul de celule DC este mai mare decât numărul de antigeni din cadrul unui segment. Această evoluție este mai apoi regăsită în rezultatele obținute de AM1, care are numărul de segmente egale cu numărul de înregistrări. Dacă numărul de celule DC este egal sau mai mic decât dimensiunea segmentului atunci, procesul de multiplicare este cumva păcălit, întrucât ar putea fi aceeași celulă care va analiza un anumit tip de antigen. Această ipoteză explică rezultatele slabe obținute de  $AS_{11}$ , în comparație cu  $AS_{15}$  care are un număr mai mare de antigeni. Pe de altă parte FAR are o evoluție ușor descendentă o dată cu creșterea dimensiunii segmentului, întrucât cu cât numărul de antigeni trimiși spre analiză este mai mic DCA devine mai susceptibil la FP (false positive).

În ceea ce privește cel de al doilea scenariu, reducerea numărului de celule, al factorului de multiplicare și respectiv al pragului pentru ciclul de viață al celulei DC, poate determina rezultate mai performante și cu un număr de date suspicioase mai redus. AM2 obține performanțe mai bune și un număr mai mic de înregistrări suspicioase. Cu toate acestea, timpul de execuție este destul de îndelungat (16 secunde). Prin adăugarea segmentării de antigeni, modelul obține valori mai ridicate pentru ADR (cu o îmbunătățire de aproximativ 12% dacă avem în vedere rezultatele obținute de AM2) și un timp de execuție mai redus (12 ms în cel mai bun caz). Modificarea numărului de antigeni care fac parte din segment, aduce

îmbunătățiri ale ADR, comparabil cu AM2. Dacă numărul de celule este mai mic decât numărul de antigeni din cadrul segmentului, atunci ADR va crește până când numărul de antigeni va depăși numărul de celule DC care fac parte din grup. În acest ultim caz, un număr mai mare de antigeni va determina scăderea valorii ADR. Ca și în scenariul anterior, un număr mai mic de antigeni va afecta numărul de alarme false.

Tabelul 12. Rezultatele testelor obținute de componenta locală

Versiunea dDCA	ADR (%)	FAR (%)	Timpul de execuție (ms)	Nr. de înregistrări suspicioase
AM1	61 (+0.2/-0.3)	4.1 (+/-0.12)	642 X 10 <sup>3</sup>	8071 (+/-10)
AS <sub>11</sub>	68 (+0.2/-0.34)	3 (+0.4/-0.2)	[200, 270]	4250 (+30/-9)
AS <sub>15</sub>	79 (+1.5/-0.5)	3.3 (+/-0.21)	[2600, 2705]	6900 (+20/-5)
AS <sub>19</sub>	72 (+1.2/-0.2)	4 (+0.11/-0.10)	[6120, 7050]	6500 (+/-20)
AM2	71 (+0.9/-0.4)	5 (+/-0.25)	16 X 10 <sup>3</sup>	2250 (+/-30)
AS <sub>22</sub> *	78 (+1.2/-0.34)	8 (+0.9/-0.2)	[12, 16]	2250 (+40/-3)
AS <sub>20</sub> *	80 (+3.1/-0.41)	6 (+0.6/-0.4)	[12, 16]	2220 (+30/-5)
AS <sub>21</sub>	78 (+1.2/-0.34)	5 (+0.6/-0.4)	[12, 16]	2200 (+34/-2)
AS <sub>25</sub>	76 (+1.5/-0.5)	5 (+/-0.31)	[15, 227]	2070 (+50/-5)
AS <sub>29</sub>	75 (+1.2/-0.1)	5.1 (+0.11/-0.1)	[225, 409]	2010 (+40/-3)

În ambele scenarii segmentarea va influența pozitiv rata de detecție a atacurilor, în timp ce numărul de alarme false va avea un trend ușor crescător dar cu o valoare neglijabilă. Pe când, multiplicarea în segmente va crește rata de detecție a atacurilor.

Tabelul 13. Rezultatele testelor obținute de componenta centrală

Algoritmul	Setul de date suspicioase	ADR	FAR
<b>Setul de date generat de AM1</b>			
CSCA	8071	94.01	5.31
SVM	8071	98.22	1.52
C4.5	8071	99.11	0.08
<b>Setul de date generat de AS<sub>19</sub></b>			
CSCA	6949	94.37	4.99
SVM	6949	91.60	3.67
C4.5	6949	9.19	0.07
<b>Setul de date generat de AS<sub>11</sub></b>			
CSCA	4251	93.92	4.96
SVM	4251	90.40	6.90
C4.5	4251	99.04	0.077
<b>Setul de date generat de AM2</b>			
CSCA	2250	98.50	6.50
SVM	2250	81.32	62.03
C4.5	2250	99.64	0.155

În cele din urmă, ultima etapă a experimentului am avut în vedere componenta centrală care a analizat datele “suspicioase” colectate de la componenta locală. Vom avea în vedere doar o parte din seturile de date suspicioase obținute în etapa inițială de testare a componetei

locale. Pentru a evalua performanțele clasificatorilor am utilizat cross validare (10 folds cross validation). CSCA obține performanțe bune, depășindu-le pe cele obținute de SVM și fiind apropiate de cele ale binecunoscutului C4.5. Din rezultatele slabe obținute de SVM, am putea deduce faptul că acesta are nevoie de seturi mai mari de date pentru procesul de antrenare, pe când CSCA și C4.5 reușesc să obțină performanțe ridicate chiar și în cazul unor seturi de date de mici dimensiuni.

## 7 MODELE PROPUSE PENTRU DETECȚIA WEBSPPAMMING

Astăzi internetul a devenit indispensabil pentru majoritatea oamenilor. De obicei căutările pe internet încep prin acesarea unui motor de căutare (ex. Google, Bing etc.). Principalele procese derulate de acesta sunt: web crawling, indexarea și căutarea. În funcție de un algoritm interior propriu, motorul de căutare va ierarhiza paginile de internet returnate utilizatorului. În mod evident, ordinea de apariție a paginilor este importantă pentru companii sau chiar pentru hackeri care pot utiliza acest mecanism pentru a porni un atac cibernetic.

Termenul de **Web Spamming** (*spamindex, search engine spam etc.*) a fost introdus în 1996 [29] și se referă la încercările deliberate de a vicia algoritmi de ierarhizare din motoarele de căutare pe internet, având ca scop clasarea pe primele poziții a anumitor pagini web.

În general tehnicile de web spamming se pot clasifica în următoarele categorii [30]:

- *Content spam* – inserarea unor cuvinte frecvent căutate de utilizatori, dare care nu au legătură cu conținutul paginii.
- *Link spam* – crearea unor linkuri în paginile web pentru a crește scorul bazat pe link-uri.
- *Cloacking* – spammer-ul va întoarce un content diferit web crawler-ului față de ceea ce vede utilizatorul.

Pentru detecția web spamming am propus două modele care au fost publicate în două lucrări ale autorului care utilizează PSO-SVM [1] și respectiv cAnt-Miner[3] pentru detecția content spam. Dintre acestea, în cadrul acestui rezumat vom prezenta doar modelul PSO-SVM.

### 7.1 MODELUL PROPUȘ

Modelul propus combină o versiune paralelizată a algoritmului PSO și clasificatorul SVM. Algoritmul PSO va fi utilizat pentru selectarea celor doi parametrii SVM ( $C$  și  $\sigma$ ). Întrucât setul de date pentru testare este destul de redus (3766 de înregistrări) și dorim să păstrăm logica algoritmului PSO, am implementat o versiune paralelizată de tip sincronizată. Mai mult, platforma de testare nu dispune de un număr mare de procesoare, prin urmare implementarea variantei asincrone ar putea determina creșterea nivelului de load balance între core-urile procesorului. Calcularea funcției fitness este operațiunea cea mai consumatoare de resurse. Așadar aceasta va fi componenta paralelizată (vezi figura 11).

#### 7.1.1 Setul de Date

Pentru testarea modelului am utilizat setul de date WEBSPPAM-UK2011[31] ce conține înregistrări din domeniul .uk. Setul de date include atribute de tip conten based și conține: 1998 de înregistrări de tip spam și 1768 de înregistrări de tip non-spam. Fiecare înregistrare are 11 atribute. Întrucât setul de date este echilibrat, vom utiliza nivelul de acuratețe pentru funcția fitness a algoritmului PSO. Atributele sunt enumerate în tabelul 14.

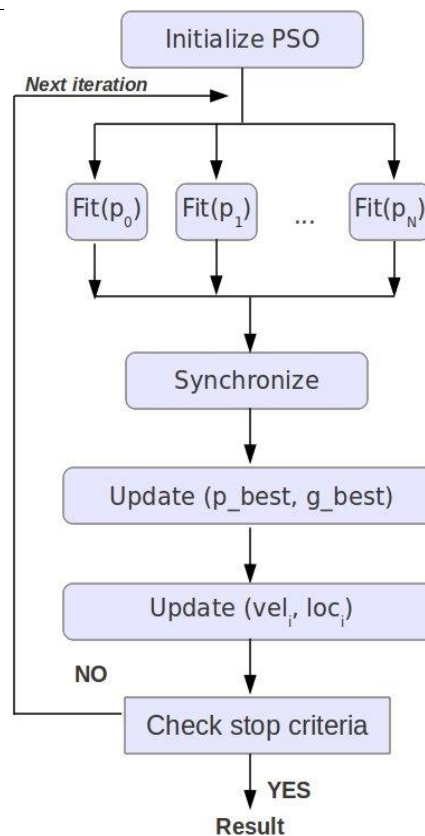


Figura 11. Versiunea sincronă pentru paralelizarea algoritmului PSO

Tabelul 14. Atributele din setul de date WEBSpAM-UK2011

Atributele din setul de date WEBSpAM-UK2011[31]	
amount_of_anchor_text; meta_char; meta_word; unique_word; total_word;	max_length; min_length; average_length; title_words; comp_ratio; img.

Testele au fost realizate pe o platformă cu 6GB de RAM, sistem de operare Windows 8 și procesor Intel Core i7-4700HQ (4 core). Versiunea secvențială și cea paralelizată a algoritmului PSO au fost implementate în Java. Pentru clasificatorul SVM am utilizat librăria Weka 3.6.10 [32]. Algoritmul PSO are 10 indivizi în grup, prin urmare avem 10 fire de execuție. Parametrii  $C$  și  $\sigma$  variază astfel :  $C \in [1, 10^8]$ ,  $\sigma \in [0.001, 36]$ ; aceste două intervale dictează arăările de căutare pentru soluțiile bidimensionale ale algoritmului PSO. Pentru testare am realizat două abordări : în prima am utilizat cross validare (10 folds cross validation), iar în a doua am creat două fișiere separate pentru învățare și testare. Rezultatele testelor sunt redată în tabelele următoare. După cum era de așteptat versiunea paralelizată a algoritmului PSO se execută de 3,5 ori mai repede decât versiunea secvențială, ceea ce era de așteptat având în vedere arhitectura procesorului pe care a fost testat algoritmul.

Tabelul 15. Timpul de execuție obținut de algoritmul PSO pentru selectarea parametrilor SVM

<i>Sistem</i>	<i>Paralel</i>	<i>Secvențial</i>
<i>PSO-SVM-10 (10 fold cross-validation)</i>	<i>44.6 min</i>	<i>156.8 min</i>
<i>PSO-SVM-1 (fișiere separate pentru antrenare și testare)</i>	<i>3.3 min</i>	<i>11.2 min</i>

Totodată, am comparat rezultatele obținute cu performanțele altor algoritmi de clasificare precum Naive Bayes sau arborii de decizie (C4.5, algoritmul J48 din Weka). Pentru web spamming este importantă detecția acestuia, prin urmare am avut în vedere acuratețea și recall (TPR) pentru metricile de performanță. Rezultatele din tabelul 15 arată că modelul propus de noi este mai performant decât ceilalți algoritmi de clasificare. Mai mult, modelul nostru obține rezultate mai bune decât cel propus de Silva et. al. [33].

Tabelul 16. Rezultatele testelor pentru detecția web spamming

<i>Sistemul</i>	<i>Acuratețea</i>	<i>TPR</i>
<b>PSO-SVM-10</b>	<b>93.5 %</b>	<b>90.19%</b>
<b>PSO-SVM-1</b>	<b>72.86%</b>	<b>66.18 %</b>
SVM	56.21 %	54.79%
C4.5	86.98 %	87.47 %
Naive Bayes	56.85 %	55.26 %
SVM [33] – WebSpamUK2006	71.1 %	60.06 %
SVM [33] – WebSpamUK2007	70.6 %	49.8 %

## 8 CONCLUZII. CONTRIBUȚII PERSONALE. DIRECȚII VIITOARE DE CERCETARE

Peisajul atacurilor cibernetice este într-o continuă expansiune din punct de vedere al volumului, dacă avem în vedere actorii cibernetici sau datele gestionate în mediul cibernetic, dar și din punct de vedere al complexității amenințărilor cibernetice. Atacurile cibernetice au fost generate din nevoia utilizatorilor cu intenții malițioase de a obține un avantaj sub forma unui renume social, beneficiu economic sau chiar pentru a realiza spionaj informatic. Prin urmare, este clar că atât timp cât informații valoroase vor fi vehiculate în mediul informatic, acestea vor atrage interesul atacatorilor cibernetici. Contracurarea atacurilor cibernetice este similară procesului de stingere a unui incendiu, întrucât experții de securitatea trebuie să ofere o soluție cât mai rapid și trebuie să protejeze sistemele care încă nu au devenit victimele atacatorilor. Așadar, este necesară dezvoltarea unor instrumente noi de securitate capabile de a se adapta la procesele dinamice din spațiul cibernetic. În opinia noastră, aceste soluții noi trebuie să permită procesarea unor volume mari de date fără a consuma multe resurse și respectiv fără a supraîncărca sistemele protejate.

Am început activitatea de cercetare prin studierea algoritmilor de inteligență computațională, axându-mă pe algoritmi inspirați biologic. Natura reprezintă o sursă de inspirație pentru multe soluții științifice și tehnologice; principalele motive pentru alegerea acestora în vederea dezvoltării unor modele matematice pentru diverși algoritmi includ simplitatea și eficiența dovedită în timp, care a asigurat existența și supraviețuirea acestor sisteme în cadrul unui mediu care este obiectul unor schimbări continue. Din paleta largă de



algoritmi inspirați biologic am ales să studiez a două clase: swarm intelligence și artificial immune systems.

În același timp am început să cercetăm peisajul curent al amenințărilor cibernetice. Concluziile fiind că, în ciuda eforturilor constante ale experților de securitate, atacurile cibernetice continuă să prolifereze în contextul unor produse malware metamorfozate și a unor unele de hacking care au devenit mult mai accesibile. Așadar, o dată cu evoluția tehnologiei instrumentele de hacking au evoluat și ele. Monitorizarea și auditarea continuă a evenimentelor din sistem generează volume mari de date, care trebuie apoi analizate și din care trebuie extrase acele elemente de interes pentru stabilirea stării de normalitate/anormalitate a sistemulelor protejate. Având în vedere proprietățile algoritmilor SI și AIS, am considerat că aceștia ar putea oferi soluții viabile pentru asigurarea securității cibernetice.

Din clasa de algoritmi SI am ales algoritmul Bat Algorithm, pentru care am propus două versiuni îmbunătățite, respectiv dintre algoritmii AIS am selectat un algoritm de generație nouă, Dendritic Cell Algorithm, pentru care am modificat componenta de clasificare. Toate aceste ipoteze teoretice au fost validate prin implementarea unor modele de detecție a intruziunilor care utilizează acești algoritmi pentru componentele de detecție sau pentru selectarea atributelor.

## 8.1 CONTRIBUȚIILE PERSONALE

Soluțiile pe care le-am propus în cadrul acestei teze sunt bazate pe algoritmi de inteligență computațională și ar putea ajuta la implementarea unor soluții de securitate capabile de a învăța și a oferi adaptabilitate la schimbările permanente din ecosistemul cibernetic.

Contribuțiile personale sunt enumerate în cele ce urmează:

- Am propus **două modele** de detecție a intruziunilor care îmbină Information Gain pentru metoda de selectare a atributelor cu clasificatorul SVM îmbunătățit cu un algoritm SI pentru selectarea parametrilor. Dintre algoritmii SI am ales : Artificial Bee Colony (ABC)[2] și the Bat Algorithm (BA)[7], pe care i-am comparat cu binecunoscutul PSO.
- Am propus **două versiuni modificate** ale algoritmului BA care îmbunătățesc procesul de căutare locală. Prima soluție pe care am numit-o BAL înlocuiește random walks cu zborurile Levy. Cea de a doua variantă include un termen suplimentar reprezentat de distanța Euclidiană dintre soluția curentă a individului și o soluție cu o funcție de performanță superioară soluției curente. Propunerile teoretice au fost validate empiric în modele de detecție a intruziunilor care utilizează algoritmi sub forma lor binară pentru implementarea unor metode de selectare a atributelor sau în forma lor standard pentru problema îmbunătățirii procesului de selectare a parametrilor clasificatorului SVM. Mai mult, aceste modele utilizează funcții de performanță diferite și totodată combină diverși algoritmi de clasificare pentru a confirma ierarhia algoritmilor SI. Toate aceste modele au fost publicate în *șase lucrări ale autorului* [4][5][6][8][9][11].
- Am realizat o analiză și o comparație proprie a algoritmilor SI, evidențiind proprietățile cheie ale acestor algoritmi și metodele diferite prin care acestea se regăsesc în diverși algoritmi (vezi tabelul 1).
- Am oferit o perspectivă personală asupra similitudinilor și naturii complementare existente între algoritmii de Swarm Intelligence și algoritmii Artificial Immune Systems (vezi capitolul 3).
- În cadrul acestei teze am extins analiza teoretică a algoritmului Dendritic Cell Algorithm (DCA) și am oferit propria perspectivă asupra încadrării acestui algoritm în clasa Artificial Immune System, conform șablonului propus de Castro și Timmis [17].

- Am propus o variantă modificată a algoritmului DCA . Îmbunătățirea algoritmului se referă la modificarea funcției de clasificare prin includerea unui prag suplimentar, care creează astfel o regiune de suspiciuni. Aceste înregistrări suspicioase fac obiectul unei analize detaliate care poate fi realizată de către experți de securitate sau prin intermediul altor algoritmi de clasificare. Propunerile teoretice au fost validate empiric prin includerea algoritmului DCA modificat în două variante (DCA-AM, cu multiplicare de antigen și DCA-AS, cu segmentare de antigen) sub forma unei componente locale în cadrul unor modele pentru detecția intruziunilor. Pentru analiza detaliată am utilizat un algoritm AIS (CSCA) și respectiv o versiune a clasificatorului SVM îmbunătățită (BBA(E)-SVM). Ambele modele fiind publicate în cadrul a **două lucrări ale autorului** [10][12].
- Am abordat problema detecției WebSpamming, pentru care am propus două modele de detecție bazate pe algoritmi SI. Primul combină o variantă paralelizată PSO cu clasificatorul SVM, iar a doua soluție utilizează cAnt-Miner pentru sarcina de clasificare. Ambele modele fac obiectul a **două lucrări ale autorului** [1][3].

## 8.2 PERSPECTIVE DE CERCETARE

Viitoarele perspective de cercetare ar putea include următoarele aspecte:

- Aplicarea modelelor propuse în alte domenii sau pentru alte probleme de securitate informatică. În opinia noastră modelele propuse pot fi ușor integrate în alte soluții de securitate pentru componente de detecție sau extragere a atributelor cheie.
- Integrarea librăriei de algoritmi în diverse instrumente de securitate (ex. AlienVault). Totodată, integrarea unei componente de colectare și omogenizare a datelor colectate ar permite mai multe simulări în cazul unor scenarii variate.
- În activitatea noastră de cercetare am abordat doar o parte din paleta largă de algoritmi SI și AIS. Prin urmare, testarea altor algoritmi pentru comparații este de interes.

Mediul cibernetic este într-un continuu proces de transformare și de aceea de cele mai multe ori ceea ce era valabil astăzi mâine poate fi permiat. În opinia noastră, pentru a putea crea uneltele de securitate compatibile cu proprietățile ecosistemului cibernetic, acestea trebuie să utilizeze cunoașterea și să permită adaptarea la schimbările permanente printr-un proces de învățare. Din acest punct de vedere CI ar putea oferi o speranță în acest sens. Mai mult, se pare că nu suntem singulari, dovadă fiind proiectele și concursurile care încurajează aplicarea acestor algoritmi pentru soluții de securitate informatică (ex. DARPA Cyber GrandChallenge to create an automatic tool based on Artificial Intelligence for detecting security aws: <https://www.cybergrandchallenge.com/>; <http://www.csail.mit.edu/System predicts 85 percent of cyber attacks using input from human experts;>).

## 8.3 LISTA DE LUCRĂRI PUBLICATE

- 1) A.-C. Enache and V. Sgarciu. *Spam host classification using pso-svm. In 2014 IEEE International Conference on Automation, Quality and Testing, Robotics, pages 1-5, 2014.[ISI Thomson Proceedings, IEEE Xplore]*
- 2) A.-C. Enache and V. V. Patriciu. *Intrusions detection based on support vector machine optimized with swarm intelligence. In 9th IEEE International Symposium on Applied Computational Intelligence and Informatics, SACI 2014, Timisoara, Romania, May 15-17, 2014, pages 153-158, 2014. [ISI Thomson Proceedings, IEEE Xplore, dblp][citat în cadrul unui articol indexat ISI]*
- 3) A.-C. Enache and V. V. Patriciu. *Spam host classification using swarm intelligence. In 10th International Conference on Communications (COMM), 2014, pages 1-4, 2014.[ISI Thomson Proceedings, IEEE Xplore]*

- 4) A.-C. Enache and V. Sgarciu. Enhanced intrusion detection system based on bat algorithm support vector machine. In *SECRYPT 2014 - Proceedings of the 11th International Conference on Security and Cryptography*, Vienna, Austria, 28-30 August, 2014, pages 184-189, 2014. **[ISI Thomson Proceedings, IEEE Xplore, dblp]**
- 5) A.-C. Enache and V. V. Patriciu. Comparative study on intrusion detection systems using support vector machines improved with swarm intelligence. *Scientific bulletin of Politehnica University of Timisoara, Transactions on Automatic Control and Computer Science*, 59(2): 141-147, December 2014 **[BDI]**
- 6) A.-C. Enache, Valentin Sgarciu, and A. Petrescu-Nita. Intelligent feature selection method rooted in binary bat algorithm for intrusion detection. In *10th IEEE Jubilee International Symposium on Applied Computational Intelligence and Informatics, SACI 2015, Timisoara, Romania, May 21-23, 2015*, pages 517-521, 2015. **[ISI Thomson Proceedings, IEEE Xplore, dblp]**
- 7) A.-C. Enache and V. Sgarciu. Anomaly intrusions detection based on support vector machines with bat algorithm. In *18th International Conference on System Theory, Control and Computing*, October 17-19, 2014, Sinaia, Romania, pages 856-861, 2014. **[IEEE Xplore]**
- 8) A.-C. Enache and V. Sgarciu. An improved bat algorithm driven by support vector machines for intrusion detection. In *International Joint Conference - CISIS'15 and ICEUTE'15, 8th International Conference on Computational Intelligence in Security for Information Systems - 6th International Conference on European Transnational Education*, Burgos, Spain, 15-17 June, 2015, pages 41-51, 2015. **[ISI Thomson Proceedings, dblp, publicație Springer]**
- 9) A.-C. Enache and V. Sgarciu. A feature selection approach implemented with the binary bat algorithm applied for intrusion detection. In *38th International Conference on Telecommunications and Signal Processing, TSP 2015, Prague, Czech Republic, July 9-11, 2015*, pages 11-15, 2015. **[ISI Thomson Proceedings, IEEE Xplore, dblp]**
- 10) A.-C. Enache, M. Ionita, and V. Sgarciu. An immune intelligent approach for security assurance. In *2015 International Conference on Cyber Situational Awareness, Data Analytics and Assessment (CyberSA)*, London, United Kingdom, June 8-9, 2015, pages 1-5, 2015. **[ISI Thomson Proceedings, IEEE Xplore, dblp]**
- 11) A.-C. Enache and V. Sgarciu. Anomaly intrusions detection based on support vector machines with an improved bat algorithm. In *2015 20th International Conference on Control Systems and Computer Science*, Bucuresti, Romania, pages 317-321, 2015. **[ISI Thomson Proceedings, IEEE Xplore]**
- 12) A.-C. Enache and V. Sgarciu. Designing real-time anomaly intrusion detection through artificial immune systems, In *2016 15th European Conference on Cyber Warfare and Security*, Munich, Germany, pages 331-341, 2016. **[trimis spre indexare ISI Thomson Proceedings]**

## 9 BIBLIOGRAFIE

- [1] A.-C. Enache and V. Sgarciu. *Spam host classification using pso-svm*. In *2014 IEEE International Conference on Automation, Quality and Testing, Robotics*, pages 1-5, 2014.
- [2] A.-C. Enache and V. V. Patriciu. *Intrusions detection based on support vector machine optimized with swarm intelligence*. In *9th IEEE International Symposium on Applied Computational Intelligence and Informatics, SACI 2014, Timisoara, Romania, May 15-17, 2014*, pages 153-158, 2014.
- [3] A.-C. Enache and V. V. Patriciu. *Spam host classification using swarm intelligence*. In *10th International Conference on Communications (COMM), 2014*, pages 1-4, 2014.
- [4] A.-C. Enache and V. Sgarciu. *Enhanced intrusion detection system based on bat algorithm – support vector machine*. In *SECRYPT 2014 - Proceedings of the 11th International Conference on Security and Cryptography, Vienna, Austria, 28-30 August, 2014*, pages 184-189, 2014.
- [5] A.-C. Enache and V. V. Patriciu. *Comparative study on intrusion detection systems using support vector machines improved with swarm intelligence*. *Scientific bulletin of Politehnica University of Timisoara, Transactions on Automatic Control and Computer Science*, 59(2):141-147, December 2014.
- [6] A.-C. Enache, Valentin Sgarciu, and A. Petrescu-Nita. *Intelligent feature selection method rooted in binary bat algorithm for intrusion detection*. In *10th IEEE Jubilee International Symposium on Applied Computational Intelligence and Informatics, SACI 2015, Timisoara, Romania, May 21-23, 2015*, pages 517-521, 2015.
- [7] A.-C. Enache and V. Sgarciu. *Anomaly intrusions detection based on support vector machines with bat algorithm*. In *18th International Conference on System Theory, Control and Computing, October 17-19, 2014, Sinaia, Romania*, pages 856-861, 2014.
- [8] A.-C. Enache and V. Sgarciu. *An improved bat algorithm driven by support vector machines for intrusion detection*. In *International Joint Conference - CISIS'15 and ICEUTE'15, 8th International Conference on Computational Intelligence in Security for Information Systems - 6th International Conference on European Transnational Education, Burgos, Spain, 15-17 June, 2015*, pages 41-51, 2015.
- [9] A.-C. Enache and V. Sgarciu. *A feature selection approach implemented with the binary bat algorithm applied for intrusion detection*. In *38th International Conference on Telecommunications and Signal Processing, TSP 2015, Prague, Czech Republic, July 9-11, 2015*, pages 11-15, 2015.
- [10] A.-C. Enache, M. Ionita, and V. Sgarciu. *An immune intelligent approach for security assurance*. In *2015 International Conference on Cyber Situational Awareness, Data Analytics and Assessment (CyberSA), London, United Kingdom, June 8-9, 2015*, pages 1-5, 2015.
- [11] A.-C. Enache and V. Sgarciu. *Anomaly intrusions detection based on support vector machines with an improved bat algorithm*. In *2015 20th International Conference on Control Systems and Computer Science, Bucuresti, Romania*, pages 317-321, 2015.
- [12] A.-C. Enache and V. Sgarciu. *Designing real-time anomaly intrusion detection through artificial immune systems*, In *2016 15th European Conference on Cyber Warfare and Security, Munich, Germany*, pages 331-341, 2016.
- [13] ITU. *Definition of cybersecurity*. <http://www.itu.int/en/ITU-T/studygroups/com17/Pages/cybersecurity.aspx>, 2016. [Online; accessed 23-May-2016].
- [14] E. Chien N. Falliere, L. Murchu. *W32.stuxnet dossier*. [http://www.symantec.com/content/en/us/enterprise/media/security\\_response/whitepapers/w32\\_stuxnet\\_dossier.pdf](http://www.symantec.com/content/en/us/enterprise/media/security_response/whitepapers/w32_stuxnet_dossier.pdf), 2011. [Online; accessed 1-August-2016].
- [15] James C. Bezdek. *Computational Intelligence: Imitating Life*, chapter *What is computational intelligence ?*, pages 1-11. IEEE Press, New York, 1994.
- [16] X. S. Yang, “A New Metaheuristic Bat-Inspired Algorithm”, *Proc. of the Nature Inspired Cooperative Strategies for Optimization (NISCO 2010), Studies in Computational Intelligence*, Springer Berlin, 284, Springer, 2010, pp. 65-74.
- [17] L. N. de Castro and J. Timmis, „Artificial Immune Systems: A New Computational Intelligent Approach”, Springer-Verlag, 2002.

- [18] P. K. Mishra, M. Bhusry, „Artificial Immune System: State of the Art Approach”, *International Journal of Computer Applications* (0975 – 8887) Volume 120 – No.20, June 2015.
- [19] Fen Gu. *Theoretical and Empirical extensions of the Dendritic Cell Algorithm*. PhD thesis, Department of Computer Science, University College London, 2011.
- [20] S. Forrest, A. Perelson, L. Allen, and R. Cherukuri, “Self-nonsel self discrimination in a computer”, *In Proceedings of the IEEE Symposium on Research Security and Privacy*, pages 202-212, 1994.
- [21] L. N. de Castro and F. J. Von Zuben, “Learning and optimisation using the clonal selection principle”, *IEEE Transactions on Evolutionary Computation*, 6(3):239-251, 2002.
- [22] Leandro N. de Castro and Fernando J. Von Zuben. *aiNet: An artificial immune network for data analysis*. In Hussein A. Abbass, Ruhul A. Sarker, and Charles S. Newton, editors, *Data Mining: A Heuristic Approach*, chapter 12, pages 231-259. Idea Group Publishing, 2001.
- [23] J. Greensmith. *The Dendritic Cell Algorithm*. PhD thesis, Department of Computer Science, University of Nottingham, 2007.
- [24] J. Twycross. *Integrated innate and adaptive artificial immune systems applied to process anomaly detection*. PhD thesis, Department of Computer Science, University of Nottingham, 2007.
- [25] Xin-She Yang, “Random walks and lévy flights”, *In Nature-Inspired Metaheuristic Algorithms Second Edition*, pages 11–20. Luniver Press, 2010.
- [26] P. Garcia- Teodoroa, J. Diaz-Verdejoa, G. Macia-Fernandez, E. Vazquez, “Anomaly based network intrusion detection; technique, systems and challenges”, *Computers and Security* 28, 18–28, 2009.
- [27] M. Tavallaee, E. Bagheri, W. Lu, and A. A. Ghorbani. *A detailed analysis of the KDD CUP 99 data set*. *In Proceedings of the IEEE Symposium on Computational Intelligence in Security and Defense Applications*, pages 1-6. IEEE, 2009.
- [28] K. Costa D. Rodrigues J. Papa R. Nakamura, L. Pereira and X. S. Yang, “BBA: a binary bat algorithm for feature selection”, *In Proceedings of the 25th Conference on Graphics, Patterns and Images (SIBGRAPI '12)s*, pages 291–297, 2012.
- [29] E. Convey. *Porn sneaks way back on web*, 1996.
- [30] Nikita Spirin and Jiawei Han. *Survey on web spam detection: principles and algorithms*. *SIGKDD Explorations*, 13(2):50-64, 2011.
- [31] H. Wahsheh, I. Abu Doush, M. Al-Kabi, I. Alsmadi, and E. Al-Shawakfa. *Using machine learning algorithms to detect content-based arabic web spam*. *International Journal of Information Assurance and Security (JIAS)*, 7(1):14-24, 2012.
- [32] Mark Hall, Eibe Frank, Geoffrey Holmes, Bernhard Pfahringer, Peter Reutemann, and Ian H. Witten. *The weka data mining software: an update*. *SIGKDD Explor. Newsl.*, 11:10-18, 2009
- [33] R. M. Silva, T. A. Almeida, and A. Yamakami. *Machine learning methods for spamdexing detection*. *International Journal of Information Security Science*, 2(3):1-22, 2013