

Evaluarea Vulnerabilității la Atac a Rețelelor de Calculatoare prin GSPN Credibil Agregate

Emilian GUȚULEAC, Sergiu ZAPOROJAN, Ion GÎRLEANU, Alexei SCLIFOS, Inga IAVORSCHI
Technical University of Moldova
Emilian.Gutuleac@calc.utm.md

Abstract — Cu dezvoltarea cercetărilor securității rețelelor de calculatoare (RC), modelarea atacurilor în rețea și tehnicile de analiză ale vulnerabilității acestora au atras din ce în ce mai multă atenție. În lucrarea dată este propusă o metodă de modelare a atacurilor și analiză a vulnerabilității RC prin rețele Petri stochastice generalizate (GSPN) cu rate fuzzy (GSPNF) credibil agregate. Pentru fiecare tip de atac, este construit un model GSPNF pentru a descrie în mod grafic relația dintre componentele acestora. Este prezentată o metodă de construire a modelului GSPNF ce redă mai nuanțat atacurile combinate concurente și colaborative ale atacatorului și o metodă de analiză a costului de exploatare a vulnerabilității RC. Metoda propusă, fiind relativ simplă, diferă de cea tradițională. În acest context, este prezentat un exemplu ce validează metoda propusă de analiză a vulnerabilității unei RC.

Index Terms — Agregare, calculatoare, credibilitate, fuzzy, rețele Petri, securitate, vulnerabilitate.

I. INTRODUCERE

Odată cu dezvoltarea rapidă a rețelelor de calculatoare (RC) problema securității informațiilor acestora devine deosebit de proeminentă. Virușii și atacurile hackerilor provoacă pierderi incommensurabile utilizatorilor și întreprinderilor, deci trebuie să fie luate măsuri eficiente pentru a asigura funcționarea în siguranță a RC [12,13,15]. Metodele și tehnicile tradiționale de apărare pasivă a RC, cum ar fi detectarea intruziunilor și firewall-urile, deja nu mai satisfac cerințele actuale de securitate ale utilizatorilor. Mulți cerce-tători au studiat activ problema analizei vulnerabilității securității RC, precum și au dezvoltat metode și tehnologii de modelare, evaluare și analiză a atacurile ce sunt la baza evaluării securității RC. Recent, în ceea ce privește modelarea atacurilor RC, au fost obținute unele rezultate. Metodele cunoscute includ modele cu arbori de atac [12], grafuri de atac [1 4], diagrame de stări ale vulnerabilității [2], modele de propagare a amenințărilor [3], modele cu jocuri teoretice [6, 13, 15], grafuri de exploatare a vulne-rabilității [2] și modele de lanțuri Markov ascunse [11]. Ele reflectă schimbarea de stare a atacatorului și a sistemului de securitate al RC din diferite puncte de vedere, dar acestor tipuri de modele le lipsesc capacitatea de a descrie procesul de atac colaborativ și concurrent în atacurile combinate ale RC. În contrast, rețelele Petri stochastice (eng. SPN) [3, 7] și SPN generalizate (GSPN) [4] sunt un formalism grafic de modelare matematică care au mai multe avantaje, cum ar fi normalizarea semantică și capacitatea lor puternică de exprimare. Acest fapt, permite de a descrie în mod graphic mai compact procesul de atac al RC prin SPN sau GSPN. În plus, recent cele mai multe evaluări ale securității bazate pe un model matematic utilizează metoda de analiză a probabilității de success a secvenței de atac [11, 12]. Dezavantajul este acela că se calculează probabilitatea maximă de succes a atacului ceea ce generează rezultate extreme de analiză. Dacă există o situație de a determina o probabilitate nejustificată, ar face ca rezultatele să fie cu mari devieri. Deci, cercetătorii încearcă de a analiza securitatea RC și a evalua costul optimist de apărare.

Metodele tradiționale de modelare și analiză a indicatorilor QoS la atac [6, 13, 15] folosesc date referitoare la parametrii componentelor (ratele de atac și apărare, de reconfigurare, etc.) care se presupune că sunt cunoscute cu o anumită precizie și apoi validate prin experiențe reale. Însă, deseori, revenirea la experiențe, cu regret, este insuficientă pentru a valida cu precizia specificată a parametrilor de vulnerabilitate, atac și apărare. De asemenea, la modelarea și analiza indicatorilor QoS ai RC una dintre cele mai importante subiecte care trebuie luată în considerare este *incertitudinea*, legată de motivul pentru care parametrii modelului sunt, de obicei, sub forma unor parametri fuzzy. Deși abordarea cea mai frecvent folosită pentru reprezentarea incertitudinii la modelarea acestor tip de procese este efectuată prin modele markoviene, care se bazează pe procese stochastice, acest tip de modele nu totdeauna sunt bine potrivite pentru a descrie toate dimensiunile de incertitudine. Mai ales, imprecizia datelor, care este, de exemplu, rezultatul preciziei limitate de măsurare care nu are o natură statistică și deci, ea nu poate fi descrisă numai prin utilizarea modelelor probabilistice [6, 15]. De asemenea, spre deosebire de defectiuni, atacurile intrușilor nu întotdeauna pot fi bine caracterizate prin modele de natură pur aleatorie, ceea ce reduce cunoștințele sistemului de securitate al RC despre riscul reușitei unui atac. De cele mai multe ori atacatorii acționează intenționat luând în considerare posibilele consecințe: satisfacție, profit sau statutul său față de efortul și riscul acțiunilor sale înainte de a acționa. Cu toate acestea, pentru a modela corect atacurile intenționate asupra unei RC, orice model probabilistic trebuie să includă și incertitudinile epistemice ale comportamentului atacatorilor. Acest aspect este unul dintre principalele provocări atunci când sunt utilizate tehnicile de modelare stocastică la cuantificarea vulnerabilității securității RC. Argumentăm că comportamentul atacatorului trebuie să fie reprezentat ca o distribuție de probabilitate asupra posibilelor acțiuni de atac în fiecare stare a modelului și, de asemenea, pe o abordare bazată pe utilizarea numerelor fuzzy [1, 6, 9], pentru a reprezenta incertitudinea probabilităților de aflare în stările respective de atac ale RC.

În conformitate cu problemele menționate mai sus, în această lucrare este prezentată o abordare de modelare și analiză credibilă a indicatorilor cantitativi QoS ai vulnerabilității securității RC prin îmbinarea modelelor GSPN [4] cu rate fuzzy de declanșare ale tranzițiilor temporizate (GSPNF) și a teoriei credibilității [9]. Acest tip de modele sunt deosebit de potrivite pentru a descrie atacuri combinate concurente și colaborative, a efectua evaluarea cantitativă a vulnerabilității și a performanțelor sistemului de securitate RC, evitând problema de analiză a probabilităților de succes ale secvențelor de atac.

Avantajul acestei metode constă în capacitatea sa de a explica atât incertitudinea obiectivă, cât și cea subiectivă prin integrarea abordărilor stochastice și a celor fuzzy. Atacurile și măsurile de apărare sunt modelate ca evenimente aleatorii, în timp ce incertitudinea în ratele de apariții ale acestor evenimente este modelată folosind teoria mulțimilor fuzzy și a teoriei credibilității [9]. În acest mod, distribuția interapariției atacurilor, duratele acestora sunt evaluate luând în considerare simultan incertitudinea obiectivă și cea subiectivă.

Avantajul îmbinării unor astfel de paradigme constă în faptul că modelele GSPNF descriu mai real și mai nuanțat comportamentul așteptat al atacurilor RC. Metoda propusă, fiind relativ simplă, diferă de cea tradițională și ea este validată printr-un exemplu de analiză cantitativă a costului la atac a vulnerabilității unei RC.

II. ELEMENTE ALE TEORIEI CREDIBILITĂȚII

Lanțurile markoviene și cele semimarkoviene în timp continuu (LMTC) sunt un instrument important ce descriu fenomene dinamice sub incertitudine aleatorie. Totuși, în lumea reală deseori întâlnim probleme dificile care nu pot fi tratate prin utilizarea doar a teoriei proceselor stocastice.

Pentru a face față unor astfel de probleme complexe, Liu în [9] a propus teoria credibilității (TC), care este o ramură a matematicii pentru studierea comportamentului fenomenelor fuzzy. Teoria mulțimilor fuzzy și conceptele cu numere fuzzy [1, 6] au apărut din necesitatea de a exprima cantitativ mai nuanțat mărimi imprecise, în care domeniul de valori pe care îl ia funcția de apartenență nu mai este limitată la două valori, ci se extinde la întreg intervalul [0, 1].

Pentru a facilita expunerea metodei propuse în această lucrare, prezentăm unele elemente de bază ale TC.

O mulțime fuzzy \tilde{A} este definită astfel:

$$\tilde{A} = \{(x, \mu_A(x)) / x \in X, \mu_A(x) \in [0, 1]\},$$

unde funcția de apartenență $\mu_A(x)$, asociată mulțimii fuzzy, arată gradul în care fiecare element din mulțimea X aparține mulțimii fuzzy \tilde{A} . Cu cât valoarea $\mu_A(x)$ este mai apropiată de 1, cu atât este mai puternică apartenența la mulțimea dată.

Două tipuri de numere fuzzy sunt cel mai des întâlnite în aplicații: numerele triunghiulare și cele trapezoidale. Utilizarea acestor tip de numere fuzzy este mai indicată, un motiv fiind și acela al volumului de calcul.

Un număr fuzzy al A este un număr fuzzy triunghiular (NFT), notat $\tilde{A}(a_1, a_2, a_3)$, numai în cazul în care există trei numere reale $a_1 \leq a_2 \leq a_3$ astfel încât funcția de apartenență $\mu_A(x)$ a căruia este redată de următoarea relație:

$$\mu_A = \begin{cases} (x - a_1)/(a_2 - a_1), & a_1 \leq x \leq a_2 \\ 1, & x = a_2 \\ (a_3 - x)/(a_3 - a_2), & a_2 \leq x \leq a_3 \\ 0, & \text{altfel} \end{cases}$$

De asemenea, în literatura de domeniu NFT \tilde{A} sunt reprezentate și prin așa numite α -tăieturi (eng. α -cut): $\tilde{A}_\alpha = \{x : \mu_A(x) \geq \alpha \in [0, 1]\}$ cu următoarele intervale de încredere posibile la nivel α [11]:

$$\tilde{A}_\alpha = [a_1 + \alpha(a_2 - a_1), a_3 - \alpha(a_3 - a_2)].$$

În Fig.1 este prezentată funcția de apartenență a unui NFT \tilde{A} .




Fig. 1. Funcția de apartenență a unui NFT \tilde{A} .

Un număr fuzzy al A este un număr fuzzy trapezoidal (NFTz), notat $\tilde{A}(a_1, a_2, a_3, a_4)$, numai în cazul în care există patru numere reale $a_1 \leq a_2 \leq a_3 \leq a_4$ astfel încât funcția de apartenență $\mu_A(x)$ a căruia este:

$$\mu_A = \begin{cases} (x - a_1)/(a_2 - a_1), & a_1 \leq x \leq a_2 \\ 1, & a_2 \leq x \leq a_3 \\ (a_4 - x)/(a_4 - a_3), & a_3 \leq x \leq a_4 \\ 0, & \text{altfel} \end{cases}$$

Este evident că un NFTz este un NFT pentru cazul special cu $a_2 = a_3$.

În Fig.2 este prezentată funcția $\mu_A(x)$ a unui NFTz \tilde{A} .




Fig. 2. Funcția de apartenență a unui NFTz \tilde{A} .

Credibilitatea măsoară gradul de încredere, acordat unei mulțimi anumite de date, apariției unor evenimente, a unor variabile fuzzy, etc. Scopul teoriei credibilității este de a combina eficient informațiile din diverse surse: date precedente și actuale, date privind riscul individual și riscul colectiv, rate ale apariției atacurilor și a măsurilor de apărare, etc. [9]. În continuare, introducem noțiunile de bază ale teoriei credibilității, cum ar fi: măsura de credibilitate; spațiul de credibilitate; variabilă fuzzy aleatorie; funcția de apartenență; distribuția credibilității și valoarea ei medie.

Fie Θ o mulțime nevidă, iar $Bag(\Theta)$ este puterea de descriere a acesteia, adică mulțimea tuturor submulțimilor lui Θ . Fiecare element al lui $Bag(\Theta)$ este numit un eveniment. Pentru fiecare element $A \in Bag(\Theta)$ este definită o măsură de credibilitate $Cr\{A\}$ care exprimă șansa apariției unui eveniment fuzzy A [9]. La definirea axiomatică a credibilității, este necesar să atribuim fiecărui eveniment fuzzy $A \in Bag(\Theta)$ un număr $Cr\{A\}$ care indică credibilitatea de apariție a acestuia. În [9] este demonstrat că mulțimea de funcții $Cr\{\Theta\}$ este o măsură de credibilitate dacă și numai dacă aceasta satisface condițiile de:

1) *normalitate*: $Cr\{\Theta\} = 1$; 2) *monotonie*: $Cr\{A\} \leq Cr\{B\}$ oricând $A \subset B$; 3) *autodualitate*: $Cr\{A\} + Cr\{A^c\} = 1$ pentru orice $A \in Bag(\Theta)$; 4) *maximalitate*: $Cr\{\sum_i \cup_i A_i\} \wedge 0.5 = \sup_i Cr\{A_i\}$ pentru orice A_i cu $Cr\{A_i\} \leq 0.5$.

Tripletul (Θ, Bag, Cr) este numit spațiu de credibilitate, iar o variabilă fuzzy este definită ca o funcție (măsurabilă) din acest spațiu pe mulțimea numerelor reale IR [9].

Fie variabila fuzzy ξ este o funcție măsurabilă din spațiul (Θ, Bag, Cr) pe IR . Conform [9], funcția de apartenență $\mu(x)$ a lui ξ este derivată din măsura de credibilitate în modulul următor:

$$\mu(x) = (2Cr\{\xi = x\}) \wedge 1, \quad x \in IR, \quad (1)$$

iar pentru orice mulțime $B \in IR$ de numere reale avem:

$$Cr\{\xi \in B\} = (\sup_{x \in B} \mu(x) + 1 - \sup_{x \in B^c} \mu(x)) / 2. \quad (2)$$

Valoarea medie $\bar{\xi} = E[\xi]$ a lui ξ este determinată de relația (3) [??]:

$$E[\xi] = \int_0^{+\infty} Cr\{\xi \geq x\} dx - \int_{-\infty}^0 Cr\{\xi \leq x\} dx \quad (3)$$

În continuare, vom folosi funcții de apartenență $\mu(x)$ ale câtorva tipuri de variabile fuzzy și anume: *echiposibile*, *triunghiulare* și *trapezoidale* pentru a descrie parametrii modelului GSPNF ce descrie comportamentul atacatorului care folosește informațiile fuzzy despre vulnerabilitățile RC date.

O variabilă fuzzy *echiposibilă* este redată de părechea (a, b) de valori certe cu $a < b$, funcția de apartenență $\mu(x)$ a căreia este:

$$\mu(x) = \begin{cases} 1, & \text{dacă } a \leq x \leq b \\ 0, & \text{altfel} \end{cases}. \quad (4)$$

Calculul valorilor medii $\bar{\xi} = E[\xi]$ ale unei variabile fuzzy *echiposibile*, *triunghiulare* și *trapezoidale*. Fie ξ este o variabilă fuzzy echiposibilă pe $[a, b]$ cu $a \geq 0$. În conformitate cu relațiile (2) și (4) avem:

$$Cr\{\xi \geq x\} = \begin{cases} 1, & x \leq a \\ 0.5, & a < x < b \\ 0, & x \geq b \end{cases}.$$

Folosind relația (4) obținem:

$$\bar{\xi} = \int_0^a 1 \cdot dx + \int_a^b 0.5 \cdot dx + \int_b^{+\infty} 0 \cdot dx = (a + b) / 2. \quad (5)$$

În mod asemănător pentru o variabilă fuzzy *triunghiulară* η pe $[a, b, c]$ cu $0 \leq a < b < c$, obținem relația:

$$\bar{\eta} = E[\eta] = (a + 2b + c) / 4. \quad (6)$$

Pentru o variabilă fuzzy trapezoidală ζ pe $[a, b, c, d]$ cu $0 \leq a < b < c < d$, obținem relația:

$$\bar{\zeta} = E[\zeta] = (a + b + c + d) / 4. \quad (7)$$

La modelarea și analiza vulnerabilității RC cunoștințele despre valorile ratelor de atac, riscurile de vulnerabilitate, etc. sunt, în general, imperfecte [1] și ea poate avea două origini. Prima sursă de incertitudine provine din caracterul aleatoriu de informații, care are o variabilitate naturală stocastică. A doua sursă de incertitudine epistemică este legată de caracterul imprecis și incomplet al informațiilor din cauza lipsei de cunoștințe despre valorile reale ale parametrilor RC ce își schimbă în mod dinamic stările sale. Deci, pentru a modela într-un mod mai realist incertitudinea comportamentului atacatorului și reacția de apărare a sistemului de securitate, este necesar de a lua în considerare, de asemenea, atât aspectele probabilistice, cât și cele fuzzy [1, 6]. Acest fapt poate fi realizat prin definirea unei noi extensii a GSPN în care unele atribute cantitative pot avea mărimi fuzzy. Ea se bazează pe fuzzificarea ratelor de declanșare ale tranzițiilor, în baza cărora sunt determinate probabilitățile fuzzy de stare [6].

III. GSPN CU RATE FUZZY ALE TRANZIȚIILOR

În continuare, prezentăm unele definiții și notații, în conformitate cu [4, 7], care sunt necesare pentru a introduce GSPN cu rate fuzzy ale tranzițiilor, GSPNF.

Definiția 1. O rețea GSPNF, este o structură de obiecte Γ , redată de următorul 13-tuplu: $\Gamma = \langle P, T, Pre, Post, Test, Inh, K_p, Pri, G, \omega, \tilde{\lambda}, \mu_\lambda, M_0 \rangle$, unde: P este mulțimea nevidă de *locații*, $|P| = k$. Locațiile pot să conțină un număr întreg pozitiv de jetoane. În reprezentarea grafică locațiile sunt redată prin cerceulețe; T este mulțimea nevidă de *tranziții*, declanșarea cărora modifică marcajul curent. $|T| = n$ și $P \cap T = \emptyset$. În reprezentarea grafică tranzițiile sunt redată prin bare subțiri sau dreptunghiuri negre; *Pre*, *Test* și *Inh*: $P \times T \times IN_+^{|P|} \rightarrow IN_+$ sunt funcții de incidență *înainte*, *test* și *inhibiție*, iar *Post*: $P \times T \times IN_+^{|P|} \rightarrow IN_+$ este funcții de incidență *înapoi*. IN_+ este mulțimea numerilor întregi nenegative. Prin arce normale se consumă jetoane din *pre-locații* sau se produc jetoane în *post-locații* respective (relație *consumator-productor*). Aceste arce sunt reprezentate prin săgeți. Prin arcele inhibitorie și/sau test nu se consumă jetoane. Un arc inhibitor este reprezentat printr-o linie cu un cerceuleț mic la sfârșit, iar un arc test este reprezentat printr-o săgeată cu o linie întreruptă. Ponderea unui arc ce este egală cu 1 nu se menționează explicit; Funcția de capacitate a locațiilor este $K_p: P \times IN_+^{|P|} \rightarrow (IN_+ \cup +\infty)$ și ea redă capacitatea maximă de jetoane în $\forall p_i \in P, 0 < K_p(p_i) < +\infty$. Implicit, $K_p(p_i)$ este nelimitată; *Pri*: $T \times IN_+^{|P|} \rightarrow IN_+$ este funcția de priorități dinamice ale declanșării tranzițiilor validate de către marcajul curent. Implicit, prioritățile ce nu sunt menționate ale unor tranziții sunt considerate nule; *G*: $T \times IN_+^{|P|} \rightarrow \{true, false\}$ este funcția de gardă (eng. *Guard-function*). Ea determină pentru orice t o funcție

Booleană $g(t, M)$ în marcajul curent M . Dacă tranziția t este validată de marcajul curent M și $g(t, M)$ are valoarea 'true', atunci tranziția t rămâne validată și eventual ea poate fi declanșată, iar dacă ea are valoarea 'false' - această tranziție nu este validată. Implicit $g(t, M) = 'true'$; T este partiționată în $T = T_\tau \cup T_0$, $T_\tau \cap T_0 = \emptyset$ cu $\text{Pri}(T_0) > \text{Pri}(T_\tau)$, unde T_τ este mulțimea tranzițiilor temporizate cu o durată aleatorie fuzzy de declanșare ce are o distribuție exponențial-negativă, iar T_0 este mulțimea tranzițiilor imediate cu o durată de declanșare nulă; $\omega: T_0 \times IN_+^{|P|} \rightarrow IR_+$ este funcția de pondere cu $0 \leq \omega(t, M) < \infty$ ce determină probabilitatea de declanșare a tranziției imediate în marcajul curent M care descrie un selector probabilistic. $\tilde{\Lambda}: T^\tau \times IN_+^{|P|} \rightarrow IR_+$ este funcția ce determină rata fuzzy $0 < \tilde{\lambda}(t, M) < +\infty$ de declanșare a tranziției temporizate validate $t \in T_\tau(M)$ în marcajul curent M , adică parametrul legii exponențial-negative. $\mu_\lambda: \tilde{\Lambda} \rightarrow [0, 1]$ este funcția gradului de apartenență al lui $\tilde{\lambda}(t, M)$ la mulțimea fuzzy $\tilde{\Lambda}$ care determină valorile numerice fuzzy ale ratelor de declanșare ale tranzițiilor temporizate. IR_+ este mulțimea numerilor reale nenegative; $M: P \rightarrow \text{Bag}(P)$ este un vector coloană ce reprezintă o funcție de marcarea a locațiilor $p \in P$ în care $M(p) \in IN_+$ este numărul de jetoane în locația p . M_0 este marcajul inițial. ■

Mulțimea tranzițiilor validate de marcajul curent M al rețelei Γ este notată $T(M) = T_0(M) \cup T_\tau(M)$.

Regulile de funcționare ale modelelor Γ de rețele GSPNF și metoda de analiză a proprietăților lor comportamentale sunt aceleași ca și ale modelelor de GSPN, descrise în [??]. Deosebirea se referă numai prin identificarea ratelor medii de declanșare a tranzițiilor validate ale GSPNF. Astfel, mai întâi identificăm ratele de declanșare ale tranzițiilor care sunt reprezentate ca NFT și/sau NFTz. Apoi în baza relațiilor (5), (6) și (7) din secțiunea 2 determinăm mărimile medii credibile ale ratelor $\bar{\lambda}_j$ de declanșare ale fiecărei tranziții t_j a GSPNF din Γ . Folosind mărimile respective ale acestor rate medii, modelul Γ de rețea GSPNF este analizat în mod similar unui model GSPN. Însă, în această lucrare vom considera numai modele GSPNF în care toate atributele structural (ponderile arcelor, funcția de gardă și prioritățile tranzițiilor) au mărimi implicite, iar capacitatea tuturor locațiilor este egală cu 1.

IV. ANALIZA VULNERABILITĂȚII RC

Pentru a reda proprietăți compoziționale analitice modelelor de rețele GSPN în [7] este introdusă noțiunea de *dexel* (*descriptive expression element*) și un set de operatori compoziționali, cu atribute respective, care permit de a construi expresii descriptive (DE) ce apoi sunt mapate direct în GSPN. În acest context, pentru a facilita expunerea lucrării date, prezentăm succint doar unii operatori compoziționali. Mai detaliat cititorul poate consulta lucrările [6, 7]. Implicit, la aplicarea acestor operatori, locațiile și tranzițiile ce au același nume se vor contopi în

mod respectiv. Într-o DE, orice simbol-locație sau simbol-tranziție poate fi folosit în orice ordine de mai multe ori. Astfel, se va subînțelege că în rețele Γ respective, redade de o DE, aceleași locații (tranziții), cu același simbol vor fi contopite într-un singur simbol-locație (simbol-tranziție).

Pentru a descrie organizarea ierarhică modulară a sistemului dat și funcționarea lui prin compunerea submodelelor Γ_i ale atacurilor A_i , vom folosi, în mod similar cu [7], paradigma de rețele Γ membranale (ΓM) [7]. Un submodel de rețea Γ_i este structurat într-o membrană $[_i]_i$, redat de o expresie descriptivă Z_i , adică $\Gamma M_i = [_i Z_i]_i$ sau $\Gamma M_i = [_i \Gamma_i]_i$. În Z_i sau Γ_i vom folosi două *indexuri* pentru a codifica simbolurile-locații $p_{i,k}$ și cele ale tranzițiilor $t_{i,j}$, unde primul index i arată numărul de ordine al ΓM_i , adică al membranei $[_i \Gamma_i]_i$, iar al doilea index j arată numărul de ordine al simbolului-nod respectiv în acest model. La construirea modulară (membranală) a modelului ΓM ce descrie comportamentul unui atacator al RC, acest model este partiționat în atacuri atomice și/sau atacuri combinate (*compozite*) folosind operații compoziționale respective.

Înainte de a prezenta unele submodele ΓM_i de GSPNF ale comportamentului unui atacator vom folosi notațiile: $\bullet p = \{t | \text{Post}(t, p) > 0\}$ (resp. $\bullet p = \{t | \text{Pre}(t, p) > 0\}$) este mulțimea de tranziții incidente *înainte* (resp. *înapoi*) la locația p ; $\bullet t = \{p | \text{Pre}(t, p) > 0\}$ (resp. $\bullet t = \{p | \text{Post}(t, p) > 0\}$) este mulțimea de locații incidente *înainte* (resp. *înapoi*) la tranziția t .

Un atac atomic A_i este redat de un submodel $\Gamma M_i = [_i \Gamma_i]_i$ în care Γ_i conține: $T_i = \{t_{i,1}\}$, $P_i = \{p_{i,1}, p_{i,2}\}$, $p_{i,1} \in \bullet t_{i,1}$, $p_{i,2} \in t_{i,1}^\bullet$, $\bullet p_{i,1} = \emptyset$, $p_{i,2}^\bullet = \emptyset$, iar activitatea de atac atomic este redată de tranziția temporizată $t_{i,1}$. Locația $p_{i,1}$ denotă echipamentele pe care atacatorul le alocă, precum și statutul acestuia atunci când atacul este lansat, iar $p_{i,2}$ denotă echipamentele pe care atacatorul deja le-a alocat, precum și statutul său după terminarea atacului.

Vom estima costul așteptat al atacatorului ce exploatează cu succes vulnerabilitatea sistemului de securitate al RC la atingerea obiectivului său prin durata medie de atac (DMA) $\bar{\tau}_{Atac}$. Cu cât este mai mare mărimea așteptată $\bar{\tau}_{Atac}$, cu atât este mai mare și efortul depus, deci și costul atacatorului pentru a finaliza obiectivul său. Putem evalua costul succesului prin estimarea $\bar{\tau}_{Atac} = 1/\bar{\lambda}_{Atac}$, unde $\bar{\lambda}_{Atac}$ este rata medie credibilă a activității de *Atac*.

În cazul în care atacatorul poate continua să realizeze atacul A_j cu noi resurse de atac după ce deja el a realizat atacul A_i , atunci considerăm că există o relație dintre A_i și A_j . Atacul combinat cu un comportament A_i și A_j poate fi direcționat către același calculator gazdă sau pe diferite calculatoare gazde. Vom considera că cea mai bună cale de atac este cea care are cea mai mică *DMA*.

Operații combinate ale comportamentului atacatorului. Comportamentele unui atacator ce realizează atacuri multi-

ple pot fi combinate într-un atac compozit cu relații dintre comportamente de atac atomic prin operații compoziționale binare [5, 7]: operații secvențiale “|”, operații concurente “∨” sau operații de selecție “⊕”. Combinațiile dintre comportamentele de atac pot fi definite formal astfel:

$$A_k ::= (A_i | A_j) / (A_i \vee A_j) / (A_i \oplus A_j),$$

unde A_i , A_j și A_k denotă comportamentele respective ale atacatorului. Atacuri combinate din două atacuri atomice A_1 și A_2 , cu atribute respective, sunt prezentate în Fig. 3.

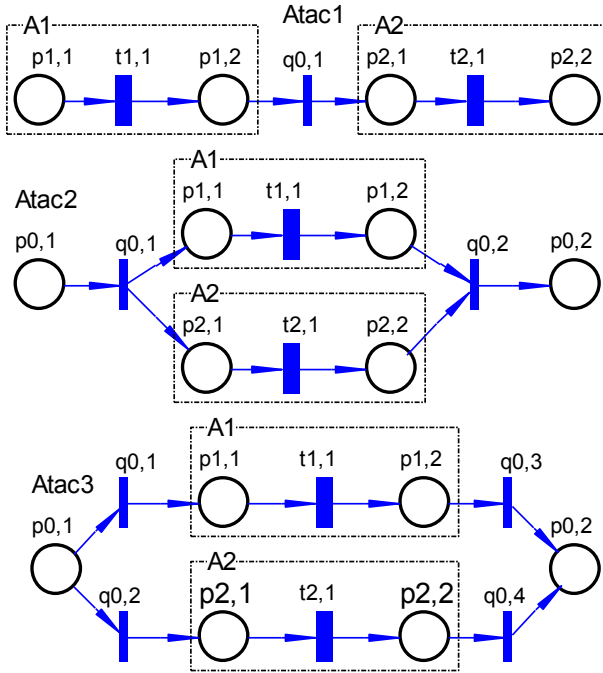


Fig. 3. Combinații ale comportamentului atacatorului: Atac1-secvențial; Atac2-concurent; Atac3-selecție.

Atacul *Atac1* din figura 3a este compus din comportamentele atacator A_1 și A_2 prin operație secvențială. Rolul tranziției imediate $q_{0,1}$ este de a conecta cele două comportamente ale atacatorului. Ratele medii de declanșare ale tranzițiilor temporizate $t_{1,1}$ și $t_{2,1}$ sunt, respectiv $\bar{\lambda}_{1,1}$ și $\bar{\lambda}_{2,1}$. În acest caz DMA este: $\bar{\tau}_{Atac1} = 1/\bar{\lambda}_{1,1} + 1/\bar{\lambda}_{2,1}$.

Dacă atacul este compus prin operații secvențiale din mai multe comportamente atacator A_1, A_2, \dots, A_n , redade de tranzițiilor temporizate $t_{1,1}, t_{2,1}, \dots, t_{n,1}$ cu ratele medii respective $\bar{\lambda}_{1,1}, \bar{\lambda}_{2,1}, \dots, \bar{\lambda}_{n,1}$, atunci DMA este [3]:

$$\bar{\tau}_{Atac1} = \sum_{i=1}^n (1/\bar{\lambda}_{i,1}). \quad (8)$$

Atacul *Atac2* din Fig. 3 este compus din comportamentele atacator A_1 și A_2 prin operație concurentă. Locațiile $p_{0,1}$ și $p_{0,2}$ sunt respectiv locație de intrare și locație de ieșire ale atacului combinat. Rolul tranziției imediate $q_{0,1}$ este de a genera condițiile inițiale ale comportamentelor A_1 și A_2 ale atacatorului în funcție de datele de intrare, iar rolul tranziției imediate $q_{0,2}$ este de a genera rezultatul total de ieșire. Ratele medii de declanșare ale tranzițiilor

temporizate $t_{1,1}$ și $t_{2,1}$ sunt, respectiv, $\bar{\lambda}_{1,1}$ și $\bar{\lambda}_{2,1}$. DMA este [16]: $\bar{\tau}_{Atac2} = 1/\bar{\lambda}_{1,1} + 1/\bar{\lambda}_{2,1} - 1/(\bar{\lambda}_{1,1} + \bar{\lambda}_{2,1})$.

Dacă atacul este compus din comportamentele atacator A_1, A_2, \dots, A_n prin operații concurente, în care ratele medii de declanșare ale tranzițiilor temporizate $t_{1,1}, t_{2,1}, \dots, t_{n,1}$ sunt respectiv $\bar{\lambda}_{1,1}, \bar{\lambda}_{2,1}, \dots, \bar{\lambda}_{n,1}$, atunci DMA este [3]:

$$\begin{aligned} \bar{\tau}_{Atac2} = & \sum_{i=1}^n (1/\bar{\lambda}_{i,1}) - \sum_{i=1}^{n-1} \sum_{j=i+1}^n (1/(\bar{\lambda}_{i,1} + \bar{\lambda}_{j,1})) + \\ & \sum_{i=1}^{n-2} \sum_{j=i+1}^{n-1} \sum_{k=j+1}^n (1/(\bar{\lambda}_{i,1} + \bar{\lambda}_{j,1} + \bar{\lambda}_{k,1})) + \\ & \dots + (-1)^{n-1} / (\sum_{i=1}^n \bar{\lambda}_{i,1}). \end{aligned} \quad (9)$$

Atacul *Atac3* din Fig. 3 este compus din comportamentele atacator A_1 și A_2 prin operație de selecție. $p_{0,1}$ și $p_{0,2}$ sunt respectiv locație de intrare și cea de ieșire ale atacului combinat. Rolul tranzițiilor imediate $q_{0,1}, q_{0,2}, q_{0,3}, q_{0,4}$ este de a transmite jetonul de la locația de intrare $p_{0,1}$ către locația de ieșire $p_{0,2}$, iar probabilitățile de declanșare ale $q_{0,1}$ și $q_{0,2}$ sunt respectiv α și $1-\alpha$. Ratele medii de declanșare ale tranzițiilor temporizate $t_{1,1}$ și $t_{2,1}$ sunt, respectiv $\bar{\lambda}_{1,1}$ și $\bar{\lambda}_{2,1}$, iar DMA este:

$$\bar{\tau}_{Atac3} = \alpha/\bar{\lambda}_{1,1} + (1-\alpha)/\bar{\lambda}_{2,1}.$$

În cazul în care atacul este compus din comportamentele atacator A_1, A_2, \dots, A_n prin operații de selecție cu rate medii de declanșare respective, atunci DMA este [3]:

$$\bar{\tau}_{Atac3} = \sum_{i=1}^n (\alpha_i / \bar{\lambda}_{i,1}). \quad (10)$$

Construirea modelului GSPNF. Pentru a construi modelul GSPNF al comportamentului atacatorului ce exploatează vulnerabilitatea unei RC date este necesar de a efectua următoarele activități [5, 7]:

- Colectarea informațiilor în ce privește vulnerabilitatea echipamentelor RC, inclusiv și cea privind informațiile calculatoarelor gazdă, celor de servire și, de asemenea, colectarea relațiilor conexe ale echipamentelor;
- Construirea modelului fiecărui comportament de atac atomic și determinarea condițiilor în care apar tranziții;
- Definirea stării inițiale a rețelei și a atacurilor combinate prin operații compoziționale în conformitate cu relațiile comportamentale dintre atacurile atomice;
- Simplificarea modelului pentru a reduce complexitatea acestuia. Atacurile atomice sau atacurile combinate sunt reprezentate prin tranziții compozite cu rate echivalente conform expresiilor prezentate mai sus [7];
- În baza ratelor echivalente astfel determinate este identificată cale de atac care are cea mai mică DMA;
- Verificarea și validarea modelului prin metoda construirii LMTC al GSPN, subiacent GSPNF cu ratele medii credibile respectiv identificate [4, 6]. În cazul în care modelul nu este corect, ce vor efectua modificările necesare în GSPNF astfel construit.

Reducerea modelului. Dacă există prea multe stări în modelul GSPNF astfel construit, putem simplifica acest model prin metoda prezentată mai sus, folosind relațiile (8), (9) și (10) [3]. Astfel, pentru modelul GSPNF $\Gamma M1$ din Fig. 5 comportamentele atacurilor combinate pot fi reprezentate mai simplu așa cum este arătat în Fig. 6. Rata

medie de declanșare a tranzițiilor temporizate compozite, astfel agregată, este $1/\bar{\tau}_{DMA_j}$.

III. ESTIMAREA CELEI MAI BUNE CĂI DE ATAC

Vom considera cazul în care atacatorul lansează atacuri, de exemplu un atac DDOS, către nodul RC vizat ca stare finală [5, 6]. În timpul procesului de atac pot exista mai multe căi și scopul principal al atacatorului constă în a obține cea mai bună cale de atac. Fie γ^* este mărimea pragului de cost al atacului, mărimea maximă a căreia este determinată de cel mai mare cost stabilit. Tipul de atac, condiționat de vulnerabilitatea nodurilor RC, determină rezultatele comportamentale ale atacatorilor. În modelul GSPNF astfel construit $p_{0,1}$ este locația de unde este lansat atacul, iar $p_{0,n0}$ este locația țintă a atacului.

Ipoțeză 1: Atacatorii sunt conștienți de vulnerabilitățile care există în sistemul de securitate al RC (SRC) și au capacitatea de a exploata aceste vulnerabilități și cele ale aplicațiilor curente pentru a aduce pagube acestei RC.

Ipoțeză 2: Orice tranziție $t_{i,1}$ ce se află în calea de atac este declanșată doar o singură dată. De asemenea, este presupusă o monotonie a comportamentelor de atac.

Algoritmul determinării celei mai bune căi de atac.

Pasul 1. Determinăm $p_{0,2}$, $p_{0,n0}$ și setăm inițial valoarea DMA egală cu zero. Atribuim $\bar{\lambda}_{1,1}, \bar{\lambda}_{2,1}, \dots, \bar{\lambda}_{n,1}$ tranzițiilor temporizate respective $t_{1,1}, t_{2,1}, \dots, t_{n,1}$;

Pasul 2. Pornind de la locația inițială, traversăm în modelul GSPNF toate căile posibile de atac prin algoritmul de căutare în adâncime și de determinare a T-invariantelor ale GSPN, subiacentă acestui model;

Pasul 3. Calculăm mărimea DMA a fiecărei combinații de atac folosind formulele de calcul respective ale operațiilor secvențiale, concurente și de selecție menționate mai sus.

Pasul 4. Acumulăm mărimile DMA $\bar{\tau}_{Atac_A_i}$ a fiecărui atac combinat pe calea de atac $Atac_j$ considerată. Dacă mărimea DMA $\bar{\tau}_{DMA_j}$ acumulată a căii de atac considerată este mai mare decât cea maximă de prag γ^* , atunci se va renunța la această cale. În cele din urmă, sunt obținute mărimile DMA ale fiecărei căi de atac posibil.

Pasul 5. Comparăm mărimile DMA ale fiecărei căi de atac $\bar{\tau}_{DMA_j}$. Calea care are mărimea DMA minimă este cea mai bună cale de atac.

Pasul 6. Sfârșit.

Pentru a reduce complexitatea algoritmului, stabilim unele condiții de limitare la luarea deciziilor. De exemplu, în al doilea pas, este considerată monotonicitatea căii de atac. În al patrulea pas, decidem dacă mărimea DMA a căii exploreate este mai mare decât cea de a pragului γ^* . Aceste restricții vor reduce cu mult complexitatea algoritmului și va spori caracterul practic al acestuia. În cazul în care modelul construit conține m vârfuri și n muchii, complexitatea calculului duratei necesare pentru a traversa toate locațiile și tranzițiile este de ordinul $O(m+n)$. Deci, acest

tip de model satisface cerințele de evaluare rapidă la atac a vulnerabilității securității RC.

Regulile de funcționare ale unei rețele GSPN, subiacente GSPNF, și cele de construire a lanțului Markov timp continuu (LMTC) inclus sunt descrise mai detaliat în [4].

V. STUDIU DE CAZ

Pentru a demonstra capabilitatea acestei abordări vom considera o rețea RC1, structura căreia este prezentată în Fig. 4 [6]. RC1 este constituită din IP1 gazdă ce oferă servicii telnet, IP2 gazdă ce oferă servicii FTP, IP3 gazdă ce furnizează servicii cu baza de date și IP4 gazdă ce oferă servicii HTTP. Fie că scopul atacatorului RC1 este de a controla trei IP gazdă pentru a lansa un atac de refuz al serviciului asupra IP4 gazdă. Informațiile, privind vulnerabilitatea RC1, sunt prezentate în continuare.




Fig. 4. Topologia RC1[6].

Modelul GM1 de GSPNF, construit prin activitățile descrise mai sus și mai detaliat în [7], este prezentat în Fig. 5.

Valabilitatea și eficacitatea modelului pot fi dovedite prin metoda construirii arborelui de accesibilitate și a LMTC care este analizat folosind produsul program instrumental de analiză a modelelor GSPN: VNP și PIPE 2.5 [10]. Comportamentul atacului atomic A_m este compus din locația de intrare $p_{m,1}$ și cea de ieșire $p_{m,2}$ a tranziției temporizate $t_{m,1}$, $m = 1, \dots, 12$.

În modelul GM1 din Fig. 5, $p_{0,1}$ indică faptul că atacatorul dorește să atace, iar $p_{0,2}$ faptul că atacul este lansat; $p_{0,3}$ indică faptul că scopul atacului este atins; $p_{i,1}$ și $p_{i,2}$, $i = 1, 2, 3$ reprezintă respectiv starea atacatorului înainte și după atacul respectiv a lui IP1, IP2, IP3; $p_{4,1}$ și $p_{4,2}$ denotă starea atacatorului înainte și după atacul IP2, când atacatorul este deja în IP1; $p_{5,1}$ și $p_{5,2}$ denotă starea atacatorului înainte și după atacul IP3, când atacatorul este deja în IP1; $p_{6,1}$ și $p_{6,2}$ denotă starea atacatorului înainte și după atacarea lui IP1, când atacatorul este deja în IP2; $p_{7,1}$ și $p_{7,2}$ denotă starea atacatorului înainte și după atacul IP3, când atacatorul este deja în IP2; $p_{8,1}$ și $p_{8,2}$ denota starea atacatorului înainte și după atacul IP1, când atacatorul este deja în IP3; $p_{9,1}$ și $p_{9,2}$ denotă starea atacatorului înainte și după atacul IP2, când

atacatorul este deja în IP3; $p_{j,1}$ și $p_{j,2}$, $j=10,11,12$ reprezintă respectiv starea atacatorului înainte și după realizarea atacului DDoS.

Din Fig. 5 determinăm că există trei căi de atac:

$$Atac_1 = [{}_1 A1 | (A4 \checkmark A5) | A10]_1,$$

$$Atac_2 = [{}_2 A2 | (A6 \checkmark A7) | A11]_2,$$

$$Atac_3 = [{}_3 A3 | (A8 \checkmark A9) | A12]_3.$$

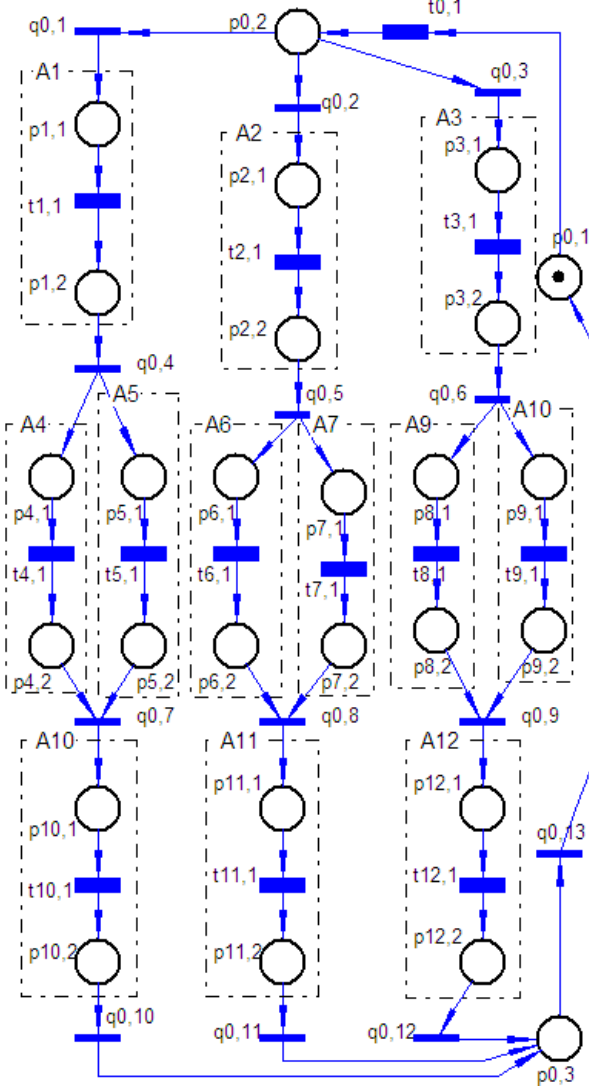


Figura 5. Modelul $\Gamma M1$ de rețea GSPNF al RC1.

Rolul tranzițiilor imediate $q_{0,k}$, $k=1,2,\dots,12$ este de a conecta comportamentele combinate de atac respective, iar tranziția imediată $q_{0,13}$ denotă revenirea la starea inițială; $q_{0,1}, q_{0,2}$ și $q_{0,3}$ au aceeași probabilitate de declanșare. Ratele fuzzy de declanșare ale tranzițiilor temporizate $t_{0,1}$ și $t_{1,1}, t_{2,1}, \dots, t_{12,1}$ sunt respectiv $\tilde{\lambda}_{0,1}, \tilde{\lambda}_{1,1}, \tilde{\lambda}_{2,1}, \dots, \tilde{\lambda}_{12,1}$ în care, $t_{1,1}, t_{6,1}, t_{8,1}$ denotă atac de revărsare trafic (overflow) Linux7.0-telnet și de instalare a software-ului troian; $t_{2,1}, t_{4,1}, t_{9,1}$ denotă atac revărsare trafic ServU5.0 și instalarea software-ului troian; $t_{3,1}, t_{5,1}, t_{7,1}$ denotă atac

Sql-no-password și instalarea software-ului troian; $t_{10,1}, t_{11,1}, t_{12,1}$ reprezintă atac DDoS.

Analiza numerică. Folosind cunoștințele experților din domeniu [3], pentru ratele $\tilde{\lambda}_j$ ale atacurilor, ce sunt variabile fuzzy, stabilim următoarele mărimi numerice:

$$\tilde{\lambda}_{0,1} = (0.005, 0.008, 0.03) \text{ (u.t.) sunt NFT;}$$

$$\tilde{\lambda}_{1,1} = \tilde{\lambda}_{6,1} = \tilde{\lambda}_{8,1} = (0.1, 0.2, 0.4) \text{ (u.t.) sunt NFT;}$$

$$\tilde{\lambda}_{2,1} = \tilde{\lambda}_{4,1} = \tilde{\lambda}_{9,1} = (0.05, 0.15, 0.2, 0.4) \text{ (u.t.) sunt NFTz;}$$

$$\tilde{\lambda}_{3,1} = \tilde{\lambda}_{5,1} = \tilde{\lambda}_{7,1} = (0.3, 0.5, 0.6) \text{ (u.t.) sunt NFT;}$$

$$\tilde{\lambda}_{10,1} = \tilde{\lambda}_{11,1} = \tilde{\lambda}_{12,1} = (0.06, 0.1, 0.25, 0.35) \text{ (u.t.) sunt NFTz.}$$

În baza relațiilor (6) și (7) din secțiune 2 obținem următoarele mărimi ale ratelor medii credibile de atac:

$$\bar{\lambda}_{0,1} = 0,051 \text{ (u.t.); } \bar{\lambda}_{1,1} = \bar{\lambda}_{6,1} = \bar{\lambda}_{8,1} = 0.225 \text{ (u.t.);}$$

$$\bar{\lambda}_{2,1} = \bar{\lambda}_{4,1} = \bar{\lambda}_{9,1} = 0.200 \text{ (u.t.); } \bar{\lambda}_{3,1} = \bar{\lambda}_{5,1} = \bar{\lambda}_{7,1} = 0.475$$

$$\text{(u.t.); } \bar{\lambda}_{10,1} = \bar{\lambda}_{11,1} = \bar{\lambda}_{12,1} = 0.19 \text{ (u.t.)}$$

Pentru aceste mărimi ale $\bar{\lambda}_{j,1}$ în baza relațiilor (8), (9) și (10) calculăm $DMA \bar{\tau}_{DMA_j}$ pe calea respective de atac $Atac_j, j=1, 2, 3$. În rezultat obținem:

$$\bar{\tau}_{DMA_1} = 1/\bar{\lambda}_{1,1} + (1/\bar{\lambda}_{4,1} + 1/\bar{\lambda}_{5,1} - 1/(\bar{\lambda}_{4,1} + \bar{\lambda}_{5,1})) + 1/\bar{\lambda}_{10,1} = 15.331 \text{ (u.t.);}$$

$$\bar{\tau}_{DMA_2} = 1/\bar{\lambda}_{2,1} + (1/\bar{\lambda}_{6,1} + 1/\bar{\lambda}_{7,1} - 1/(\bar{\lambda}_{6,1} + \bar{\lambda}_{7,1})) + 1/\bar{\lambda}_{11,1} = 15.382 \text{ (u.t.);}$$

$$\bar{\tau}_{DMA_3} = 1/\bar{\lambda}_{3,1} + (1/\bar{\lambda}_{8,1} + 1/\bar{\lambda}_{9,1} - 1/(\bar{\lambda}_{8,1} + \bar{\lambda}_{9,1})) + 1/\bar{\lambda}_{12,1} = 14.459 \text{ (u.t.)}$$

Stabilim $\gamma^* = 18,00$ (u.t.). În rezultat, constatăm că atacul pe calea $Atac_3$ are cea mai mică durată medie, deci ea este cea mai bună pentru a ataca. Astfel, ar trebui să acordăm prioritate consolidării măsurii securității RC1 în acest sens.

Modelul GSPN $\Gamma M2$ al GSPNF $\Gamma M1$ care este redus prin agregarea credibilă a ratelor medii este prezentat în figura 6. În acest model tranzițiile temporizate agregate $t_{13,1}$, $t_{14,1}$ și $t_{15,1}$ reprezintă căile respective de atac $Atac_j, j=1, 2, 3$.

Ratele de declanșare ale tranzițiilor din $\Gamma M2$ sunt:

$$\bar{\lambda}_{13,1} = 1/\bar{\tau}_{DMA_1} = 0.0653, \bar{\lambda}_{14,1} = 1/\bar{\tau}_{DMA_2} = 0.0650 \text{ și}$$

$$\bar{\lambda}_{15,1} = 1/\bar{\tau}_{DMA_3} = 0.0692.$$

Pentru validarea acestor rezultate a fost efectuată simularea modelului $\Gamma M1$ prin metoda tradițională, folosind platformele software instrumentale VHPN și PIPE 2.5 [10]. Rezultatele acestei simulări sunt după cum urmează:

$$\bar{\tau}'_{DMA_1} = 15.296, \bar{\tau}'_{DMA_2} = 15.397 \text{ și } \bar{\tau}'_{DMA_3} = 14.418.$$

Diferența dintre cele două abordări este foarte mică. Metoda tradițională de analiză a modelelor GSPNF, bazată LMTC inclus [4], are o complexitate de calcul în timp care, în caz general, este exponențială, pe când metoda de analiză prin reducerea modelului GSPNF prezentată în această lucrare are o complexitate liniară. Deci, metoda de

calcul prezentată în această lucrare este simplă și mai practică.




Fig. 6. Modelul GSPN $\Gamma M2$ al GSPNF $\Gamma M1$ redus.

O generalizare a acestei abordări pe viitor poate fi efectuată în baza GSPN colorate (GSPNC) [8] cu rate fuzzy intuiționiste (GSPNFC) [1, 6] care oferă posibilitatea de a modela vulnerabilitățile RC și comportamentele atacatorilor într-un mod mult mai compact și mai nuanțat decât prin modele GSPNF, deoarece ele folosesc mecanisme de nivel înalt, similare cu cele ale limbajelor de programare: cu fiecare jeton este asociat o valoare a unui anumit tip de date (set de culori). Astfel, pentru un marcaj inițial dat numărul de comportamente ce pot fi exprimate de un model GSPNFC este cu mult mai mare decât cel prin GSPNF considerate în această lucrare.

Cu toate acestea GSPNF nu pot fi folosite pentru a descrie funcționarea sistemelor ce trebuie reconfigurate în mod dinamic sau mobilitatea lor. Pe viitor vom considera și aceste aspect.

VI. CONCLUZII

Pentru a deveni mai nuanțate, cuprinzătoare și comprehensive, în lucrarea dată este propusă o metodă de modelare a atacurilor și analiză a vulnerabilității RC la atacuri prin rețele Petri stochastice generalizate (GSPN) cu rate fuzzy (GSPNF) credibil agregate. Pentru fiecare tip de atac, este construit un model GSPNF care descrie intuitive în mod grafic relația dintre componentele acestora. Este prezentată o metodă de construire a modelului GSPNF, ce descrie mai nuanțat atacurile combinate concurente și colaborative ale atacatorului și o metodă de analiză a costului de exploatare a vulnerabilității RC. În același context, este prezentat un exemplu ce validează metoda propusă de analiză a vulnerabilității unei RC. Metoda propusă de evaluare a vulnerabilității RC este simplă și este ușor de efectuat prin manipulări automate. Ea poate ajuta administratorii de securitate și elimina în mod eficient dezavantajele de securitate și pericolele ascunse în RC.

Pe viitor, vom considera modele GSPNF colorate în care vom lua în considerație aspectul stochastic fuzzy intuiționist de funcționare al RC cu aplicații orientat pe servicii reconfigurabile și vom prezenta mai detaliat aplicabilitatea acestui demers.

Lucrarea dată a fost efectuată în cadrul Proiectului Național de Cercetări Științifice Aplicative 15.817.02.28A din Republica Moldova.

REFERINȚE

- [1] K. T. Atanassov, "Intuitionistic fuzzy sets," *Fuzzy Sets and Systems*, vol. 20, pp. 87-96, 1986.
 - [2] P. Ammann, D. Wijesekera, S. Kaushik, "Scalable graph-based network vulnerability analysis," *Proceedings of the 9th ACM Conf. on Computer and Communications Security*, pp. 217-224, 2002.
 - [3] L. Chuang, Q. Yang, Z. Bo, T. Li-qin, "An Approach to Performance Equivalent Simplification and Analysis of Stochastic Petri Nets," *Acta Electronica SINICA*, vol. 30, pp. 1620-1623, 2002.
 - [4] G. Chiola, M. A. Marsan, G. Balbo, et al., "Generalized stochastic Petri nets: A definition at the net level and its implications," *IEEE Transactions on Software Engineering*, vol. 19, pp. 89-107, 1993.
 - [5] X. Gao, Y. Zhu, J. Fei, T. Han, "Method Based on GSCP for Network Vulnerability Analysis," *Journal of Software*, vol. 8, no. 8, pp. 2032-2038, 2013.
 - [6] Gîrleanu, E. Guțuleac, Modelarea și evaluarea riscului la atac al rețelelor Ad-hoc mobile prin rețele Petri cu jocuri stocastice fuzzy. *Materialele Conf. Intern. "Modelare Matematică, Optimizare și Tehnologii Informaționale"*, vol. 1, Chișinău, 22-25 martie, pp. 154-163, 2016.
 - [7] E. Guțuleac, "Descriptive compositional HSPN modeling of computer systems," *Annals of the University of Craiova, Series: Automation, Computers, Electronics and Mechatronics*, Vol. 3(30), No.2, Ed.: Universitaria, Craiova, România, pp. 82-87, 2006.
 - [8] K. Jensen, *Coloured Petri nets: Basic concepts analysis methods and practical use. Volume 1, Basic concepts*. Berlin: Springer-Verlag, 1997.
 - [9] X. Li, B. Liu, "Foundation of credibilistic logic," *Fuzzy Optimization and Decision Making*, vol.8, no.1, pp. 91-102, 2009.
 - [10] Petri Nets Tools Database Quick Overview. <https://www.informatik.uni-hamburg.de/TGI/PetriNets/tools/quick.html>.
 - [11] A. Sh. Sendi, M. Dagenais, et al., "Real Time Intrusion Prediction based on Optimized Alerts with Hidden Markov Mode," *J. of Networks*, vol. 7, pp. 311-321, 2012.
 - [12] M. Tao, H. Shan, "An improved method of the attack tree model for mobile Ad-Hoc networks," *Research. Computer Applications and Software*, Vol. 26, Issue 4, pp. 271 - 273, 2009.
 - [13] Y. Wang, C. Lin, et al., "Analysis of Attack Actions for E-Commerce Based on Stochastic Game Nets Model," *J. of Computers*, vol. 4, pp. 461-468, 2009.
 - [14] W. Yong-jie, et al., "Study of network security evaluation based on attack graph model," *Journal on Communications*, vol. 28, pp. 29-34, 2007.
- W. Zhuo, C. Lin, X. Chen, "Quantitative analysis method of network attack and defense based on stochastic game model," *J. of Computers*, Vol. 9, p. 1748 - 1762, 2010.