



UNIVERSITATEA „POLITEHNICA“ din BUCUREȘTI

Facultatea de Automatică și Calculatoare

Catedra de Calculatoare

Fenomene Emergente în Sistemele Bazate pe Agenți

Rezumat

Autor: Ing. Șerban Iordache

Conducător de doctorat: Prof. dr. ing. Florica Moldoveanu

BUCUREȘTI 2011

1. INTRODUCERE.....	2
1.1. Motivație.....	2
1.2. Contribuții originale	3
1.3. Publicații științifice	5
1.4. Structura tezei.....	5
2. FUNDAMENTE TEORETICE.....	7
2.1. Sisteme bazate pe agenți.....	7
2.2. Emergența	8
2.3. Automate celulare.....	8
2.4. Optimizarea cu colonii de furnici	9
3. O VIZIUNE DIFERITĂ ASUPRA EMERGENȚEI.....	10
4. METFREM – UN META-FRAMEWORK PENTRU STUDIUL EMERGENȚEI	14
4.1. Conceptele și structura MetFrEm	14
4.2. O descriere formală a MetFrEm.....	16
4.3. Structura algoritmică.....	17
5. CĂUTAREA GHIDATĂ DE CONSULTANT	19
5.1. Metaeuristica CGS	19
5.2. Metaeuristica CGS aplicată la Problema Comis Voiajorului	21
5.3. Metaeuristica CGS aplicată la problema asignării pătratice	22
5.4. Metaeuristica CGS aplicată la problema generalizată a comis voiajorului.....	23
ANEXA A. AGSYSLIB – UN PACHET SOFTWARE PENTRU IMPLEMENTAREA SOLUȚIILOR BAZATE PE AGENȚI	24
BIBLIOGRAFIE.....	27

1. INTRODUCERE

1.1. Motivație

Emergența reprezintă unul dintre cele mai interesante fenomene care se manifestă în sistemele complexe. Esența sa constă în apariția unor proprietăți care nu se regăsesc în elementele ce compun sistemul considerat. Avem de a face cu un fenomen emergent atunci când interacțiunea dintre componente este guvernată de reguli relativ simple, dar care la nivel microscopic generează un comportament complex. În multe cazuri acest comportament este greu sau chiar imposibil de dedus printr-o simplă analiză a proprietăților elementelor ce compun sistemul. Conceptul de emergență este adesea exprimat concis prin fraza: „întregul este mai mare decât suma părților sale”. Emergența se manifestă în sisteme descentralizate, în care comportamentul observat nu este rezultatul unui control la nivel global, ci apare ca efect al interacțiunii dintre entități independente, pe care le putem numi generic agenți.

Un exemplu clasic din natură este cel al unei colonii de așa numite „insecte sociale” (furnici, termite, albine etc.). O astfel de colonie poate fi privită ca un macroorganism cu comportament complex, capabil să se adapteze situațiilor neprevăzute, deși fiecare insectă în parte este lipsită de inteligență și reacționează numai pe baza unor reguli simple la stimulii din mediul înconjurător. De exemplu, anumite specii de termite își clădesc un mușuroi a cărui înălțime poate atinge câțiva metri. În interiorul acestuia, datorită unui sistem complicat de canale ce asigură o răcire pasivă, temperatura se menține constantă, indiferent de fluctuațiile din mediul exterior. Arhitecții și inginerii s-au inspirat din acest model pentru a construi clădiri care nu necesită instalații de aer condiționat pentru reglarea temperaturii [1]. În cazul termitelor însă, mușuroiul nu este construit pe baza planurilor unor arhitecți și nici sub coordonarea unor ingineri. Fiecare termită acționează după un algoritm simplu, dar la nivelul întregii colonii rezultatul este uimitor.

Fenomenele emergente pot fi observate în cele mai diverse sisteme. Exemplele includ crearea ambuteiajelor, variația prețurilor pe piața liberă, apariția striatiilor în dunele de nisip, formarea unui fulg de zăpadă sau a unui uragan. Cele mai surprinzătoare exemple pot fi găsite însă în sistemele biologice: o celulă vie ia naștere din interacțiunea moleculelor sale; sistemul imunitar, capabil să protejeze organismul împotriva bolilor, este rezultatul acțiunii combinate a câtorva tipuri de limfocite; celulele din creier se auto-organizează într-o rețea neuronală complexă, care duce la apariția inteligenței și chiar a conștiinței.

Întreaga materie din univers este compusă din particule elementare. De aceea, chiar și cele mai complexe fenomene reprezintă în ultimă instanță rezultatul interacțiunii câtorva tipuri de particule elementare. Cum este posibil acest lucru? Cum pot aceste particule elementare să se auto-organizeze în structuri din ce în ce mai complexe? Cum poate viața să apară din materie lipsită de viață? Cum ajung ființele vii să aibă scopuri proprii, când particulele din care sunt ele constituite sunt lipsite de orice scop? Cum pot să apară inteligența și conștiința din particule lipsite de inteligență?

Deși aceste întrebări sunt îndeajuns de importante pentru a justifica studiul emergenței, cercetarea prezentată în lucrarea de față are o altă motivație principală: problema proiectării unui anumit comportament emergent. Ca urmare a creșterii continue a numărului de aplicații descentralizate, bazate pe agenți, aceasta reprezintă o problemă importantă, pentru care nu există în momentul de față o metodologie unanim acceptată. Metodele tradiționale de inginerie software nu pun în valoare comportamentul emergent manifestat de aplicațiile bazate pe agenți. Cele mai multe metodologii orientate pe agenți consideră că fenomenele

emergente sunt indezirabile și încearcă să prevină comportamentul „neșteptat” impunând diverse constrângeri agenților. Ar fi bineînțeles preferabil să proiectăm aplicații care exploatează comportamentul emergent în loc să îl evite, dar aceasta este o sarcină dificilă, ținând cont de aparenta impredictibilitate a fenomenelor emergente.

În ultimii ani, unii cercetători s-au inspirat din natură pentru a proiecta algoritmi care produc un anumit comportament emergent dorit. Multe sisteme naturale sunt capabile să se adapteze la schimbările rapide din mediu și pot efectua în mod eficient anumite operații pentru care algoritmi convenționali cunoscuți sunt impractici. De aceea, este tentantă ideea de a imita astfel de sisteme naturale pentru a obține un comportament similar. Un exemplu în acest sens îl oferă optimizarea cu colonii de furnici [11], care este o metodă euristică inspirată de modul în care furnicile își caută hrana. În drumul lor către o sursă de hrană și înapoi spre cuib, furnicile depun mici cantități de substanțe chimice numite feromoni. Celelalte furnici au capacitatea de a percepe acești feromoni și urmează cu predilecție drumurile pe care concentrația de feromoni este mai ridicată. Această simplă strategie de căutare a hranei conduce în cele din urmă la descoperirea drumului cel mai scurt până la sursa de hrană. Cu alte cuvinte, drumul cel mai scurt apare ca urmare a interacțiunii dintre furnici și mediul înconjurător. Optimizarea cu colonii de furnici este inspirată de acest fenomen emergent și a fost folosită inițial pentru a rezolva problema comis voiajorului. Ulterior, ea a fost aplicată la un număr mare de alte probleme de optimizare combinatorială și a fost de asemenea adaptată pentru probleme de optimizare continuă.

Deși natura constituie o bogată sursă de inspirație, nu întotdeauna poate fi găsit un sistem natural care manifestă un anumit comportament emergent. În plus, nu este de ajuns să fie identificat un sistem corespunzător, ci este necesar să se înțeleagă modul în care acesta funcționează, pentru a îl putea imita. De aceea, o întrebare importantă care apare este cum putem proiecta un sistem bazat pe agenți în cazul în care nu găsim o sursă de inspirație în natură. În lucrarea de față am atacat această problemă atât prin abordări teoretice, cât și practice.

Punctul de interes principal în această teză este proiectarea unui comportament complex și adaptiv, asemănător cu cel manifestat de organismele vii, deoarece este foarte dificil să se obțină un astfel de comportament folosind tehnici tradiționale de inginerie software. Una din ipotezele centrale de la care am pornit este că pentru a proiecta un astfel de comportament, este preferabil să considerăm sisteme eterogene cu agenți simpli, în loc de a ne axa pe sisteme omogene cu agenți complecși.

1.2. Contribuții originale

Teza de față aduce trei contribuții originale importante:

- **Un formalism matematic al emergenței în sistemele bazate pe agenți.** Fenomenele emergente sunt adesea descrise ca neșteptate, surprinzătoare sau greu predictibile. De aceea, multe definiții ale emergenței implică un anumit grad de subiectivitate. Alte definiții oferă o descriere riguroasă a proprietăților ce caracterizează fenomenele emergente, dar nu reușesc să surprindă toate aspectele legate de emergență, sau necesită calcule extrem de complexe pentru a putea decide dacă un anumit comportament este emergent sau nu. Pentru a oferi o definiție care este atât obiectivă, cât și adecvată pentru scopuri practice, am adoptat un punct de vedere diferit asupra emergenței. Formalismul propus este bazat pe ideea că o definiție a fenomenelor emergente trebuie să ia în considerare numai modul în care acestea apar și nu trebuie să discute proprietățile acestor fenomene.

- **MetFrEm – un meta-framework pentru studiul emergenței.** Pentru a putea studia emergența într-o manieră riguroasă, am introdus un meta-framework numit MetFrEm, care permite modelarea unor framework-uri algoritmice variate, bazate pe populații de agenți care interacționează. MetFrEm favorizează modelarea sistemelor descentralizate, puternic eterogene, cu agenți ghidați de reguli simple.
- **Metaeuristica de căutare bazată pe consultanți (Consultant-Guided Search - CGS).** Metaeuristica propusă face parte din clasa “swarm intelligence” și pune în valoare comportamentul emergent manifestat de o populație de persoane virtuale care interacționează. Am aplicat această metaeuristică la o serie de probleme de optimizare combinatorială, iar rezultatele experimentale arată că CGS atinge o performanță de cel mai ridicat nivel în cazul fiecăreia dintre aceste clase de probleme:
 - *problema comis voiajorului (TSP - Traveling Salesman Problem)* – Experimentele efectuate cu și fără căutare locală arată că CGS depășește în performanță cei mai buni algoritmi de optimizare cu colonii de furnici pentru TSP: Ant Colony System [10] și MAX-MIN Ant System [32].
 - *problema asignării pătratice (QAP - Quadratic Assignment Problem)* – Algoritmul CGS pentru QAP se dovedește mai performant decât MAX-MIN Ant System [31], care este în prezent cel mai bun algoritm de optimizare cu colonii de furnici pentru această clasă de probleme.
 - *problema generalizată a comis voiajorului (GTSP - Generalized Traveling Salesman Problem)* – Rezultatele experimentale arată că din punct de vedere statistic nu există diferențe semnificative între algoritmul nostru și algoritmul memetic al lui Gutin și Karapetyan [12], care reprezintă cea mai performantă euristică pentru GTSP publicată până în momentul de față.

Pe lângă aceste contribuții, cercetarea prezentată în această teză a condus la crearea a trei produse software open source, importante din punct de vedere practic pentru comunitatea științifică:

- **AgSysLib** (<http://agsyslib.sourceforge.net/>). AgSysLib este un pachet software pentru rezolvarea problemelor folosind metode bazate pe agenți. El asistă utilizatorii în toate aspectele legate de proiectarea, implementarea, depanarea și ajustarea configurației algoritmilor bazați pe agenți. AgSysLib este atât un framework, cât și o bibliotecă și dispune de o arhitectură bazată pe componente, care permite construirea algoritmilor într-o manieră modulară și ușurează experimentarea și analiza diverselor variante ale unui algoritm.
- **SwarmTSP** (<http://swarmtsp.sourceforge.net/>). SwarmTSP este o bibliotecă Java de algoritmi din clasa swarm intelligence pentru problema comis voiajorului (traveling salesman problem - TSP) și pentru problema generalizată a comis voiajorului (generalized traveling salesman problem – GTSP). SwarmTSP implementează toți algoritmi de tipul CGS (căutare ghidată de consultant) propuși în această teză pentru TSP și GTSP, precum și o serie de algoritmi de optimizare cu colonii de furnici: Ant System, Ant Colony System, MAX-MIN Ant System, Elitist Ant System, Rank-Based Ant System și Best-Worst Ant System.
- **SwarmQAP** (<http://swarmqap.sourceforge.net/>). SwarmQAP este o bibliotecă Java de algoritmi din clasa swarm intelligence pentru problema asignării pătratice (quadratic assignment problem - QAP). SwarmQAP implementează toți algoritmi de tipul CGS (căutare ghidată de consultant) propuși în această teză pentru QAP, precum și algoritmul MAX-MIN Ant System.

1.3. Publicații științifice

Iordache, S. *Consultant-Guided Search - A New Metaheuristic for Combinatorial Optimization Problems*. In: GECCO 2010: Proceedings of the 12th Genetic and Evolutionary Computation Conference, Portland, Oregon, USA, ACM Press, 2010, pp. 225-232 [19] (**nominalizată pentru “best paper award”**).

Iordache, S. *Consultant-Guided Search Algorithms with Local Search for the Traveling Salesman Problem*. In: 11th International Conference Parallel Problem Solving from Nature - PPSN XI. LNCS 6239, Krakow, Poland, Springer, 2010, pp. 81-90 [17].

Iordache, S. *Consultant-Guided Search Algorithms for the Quadratic Assignment*. In: Hybrid Metaheuristics - 7th International Workshop, HM 2010. LNCS 6373, Vienna, Austria. Springer, 2010, pp. 148-159 [15].

Iordache, S., Moldoveanu, F. *AgSysLib - A Software Tool for Agent-Based Problem Solving*. In: Scientific Bulletin of "Politehnica" University of Bucharest, C Series (Electrical Engineering), vol. 73, issue 2, ISSN 1454-234x, 2011 [20].

Iordache, S. *A Framework for the Study of the Emergence of Rules in Multiagent Systems*, In: Katalinic, B. (Ed.), Proceedings of the 20th International DAAAM Symposium, Vienna, Austria, ISSN 1726-9679, 2009, pp. 1285-1286 [14].

Iordache, S., Pop, P.C. *An Efficient Algorithm for the Generalized Traveling Salesman Problem*. In: A. Quesada-Arencibia et al. (Eds.), Proceedings of the 13-th International Conference on Computer Aided Systems Theory (EUROCAST 2011), Las Palmas de Gran Canaria, Spain, ISBN: 978-84-693-9560-8, 2011, pp. 264-267 [21].

Iordache, S. *Consultant-Guided Search algorithms for the quadratic assignment problem*. In: GECCO 2010 companion: Proceedings of the 12th annual conference companion on Genetic and evolutionary computation. ACM Press, 2010, pp. 2089-2090 [16].

Iordache, S. *Consultant-Guided Search combined with local search for the traveling salesman problem*. In: GECCO 2010 companion: Proceedings of the 12th annual conference companion on Genetic and evolutionary computation. ACM Press, 2010, pp. 2087-2088 [18].

Pop, P.C., **Iordache, S.** *A Hybrid Heuristic Approach for Solving the Generalized Traveling Salesman Problem*. In: GECCO 2011: Proceedings of the Genetic and Evolutionary Computation Conference, Dublin, Ireland, ACM Press, 2011 (acceptată) [28].

1.4. Structura tezei

Capitolul 2 prezintă principalele concepte și tehnici relevante pentru conținutul acestei teze. După o scurtă introducere a sistemelor bazate pe agenți, sunt prezentate diferite aspecte ale noțiunii de emergență și sunt discutate diverse fenomene emergente care se manifestă în automatele celulare. Apoi, este descrisă optimizarea cu colonii de furnici, ca un exemplu de tehnică de rezolvare a problemelor care pune în valoare fenomenele emergente.

În capitolul 3 este dezvoltat un formalism matematic pentru studiul emergenței, care pune emergența într-un context orientat pe agenți, în concordanță cu cadrul impus de problema proiectării unui comportament emergent.

În capitolul 4 este propus un meta-framework pentru studiul emergenței, numit MetFrEm, care poate fi utilizat pentru a descrie diverse framework-uri algoritmice bazate pe populații de

agenți care interacționează. Scopurile avute în vedere pentru proiectarea acestui meta-framework reflectă obiectivele și ipotezele principale ale acestei teze de doctorat. După o descriere intuitivă a conceptelor și a structurii lui MetFrEm, este oferită și o descriere formală a acestui meta-framework. Apoi, cu ajutorul unor studii de caz, este ilustrat modul în care pot fi modelate diverse sisteme în MetFrEm.

Capitolul 5 introduce căutarea ghidată de consultant (Consultant-Guided Search – CGS), o nouă metaeuristică pentru probleme de optimizare combinatorială, inspirată de posibilitatea de a privi interacțiunile din MetFrEm din perspectiva unor clienți care primesc recomandări de la consultanți. Această metaeuristică este aplicată la câteva clase de probleme (problema comis voiajorului, problema asignării pătratice și problema generalizată a comis voiajorului), iar rezultatele experimentale sunt comparate cu cele obținute de cei mai performanți algoritmi pentru aceste probleme.

În Anexa A este descris AgSysLib, un produs software pe care l-am dezvoltat pentru a oferi ajutor în rezolvarea problemelor folosind metode bazate pe agenți. După identificarea problemelor întâmpinate pe parcursul proiectării, implementării, depanării și ajustării configurației unui nou algoritm bazat pe agenți, este prezentat modul în care ele pot fi depășite folosind acest produs software. AgSysLib este atât un framework, cât și o bibliotecă, și a jucat un rol important în dezvoltarea algoritmilor prezentați în capitolul 5.

2. FUNDAMENTE TEORETICE

2.1. Sisteme bazate pe agenți

În esență, un sistem bazat pe agenți reprezintă un sistem compus din agenți care interacționează. De aceea, pentru a putea defini un sistem bazat pe agenți, este necesar să precizăm semnificația noțiunii de *agent*. La ora actuală, nu există însă o definiție unanim acceptată a acestui termen. Sistemele bazate pe agenți joacă un rol important în diverse domenii și, de obicei, sensul acordat noțiunii de *agent* diferă de la un domeniu la altul și chiar în cadrul aceluiași domeniu.

În majoritatea cazurilor, cercetarea legată de sistemele bazate pe agenți poate fi încadrată în domeniul *inteligenței artificiale*. Acesta este un domeniu de cercetare foarte vast și de aceea este dificil de definit conceptul de *agent* într-un context atât de general. Cu toate acestea, Russel și Norvig [30] oferă următoarea definiție: “Un *agent* este orice lucru despre care se poate considera că își percepe mediul prin intermediul unor senzori și acționează asupra lui print intermediul unor efectori”.

În contextul *modelării și simulării bazate pe agenți* (agent-based modeling and simulation – ABMS), Macal și North [24] identifică următoarele caracteristici definitorii ale unui agent:

- un agent este autonom.
- un agent este modular.
- un agent este social, în sensul că interacționează cu alți agenți.

Majoritatea sistemelor considerate în ABMS sunt sisteme adaptive complexe (complex adaptive systems – CAS) [25]. Acestea sunt sisteme care „își modifică și își reorganizează părțile componente pentru a se adapta la problemele impuse de mediul înconjurător” [13]. În contextul CAS, “*agenții* sunt unități semi-autonome care evoluează în timp în încercarea de a-și maximiza fitness-ul” [8].

Un număr mare de definiții ale conceptului de agent au fost oferite în domeniul *sistemelor multi-agent* (multi-agent systems – MAS). Ele diferă, uneori în mod substanțial, prin caracteristicile pe care le asociază unui agent. În general, aceste definiții impun capacități mai ridicate decât în cazul ABMS și, adesea, principala abstracție folosită este cea de *agent inteligent*. Wooldridge [34] propune următoarea definiție:

Un *agent* este un sistem computațional care este situat într-un mediu înconjurător și care este capabil de acțiuni autonome în acest mediu, pentru a-și putea atinge obiectivele.

În absența unei definiții general acceptate, este necesar să specificăm ce înțelegem prin *agent* în contextul prezentei teze. Întrucât suntem interesați în principal de comportamentul complex care apare din interacțiunea agenților guvernați de reguli simple, avem nevoie de o definiție care să impună un număr mic de restricții agenților. În lucrarea de față, privim ca agenți chiar și entități foarte simple precum automatele celulare. Singura cerință pe care o avem este ca un agent să acționeze în mod autonom, adică să decidă el însuși ce acțiuni să execute, fără a primi comenzi de la entități externe. În capitolul 3 dezvoltăm un formalism pentru studiul emergenței, care ne permite să definim riguros principalele concepte legate de sistemele bazate pe agenți.

2.2. Emergența

Emergența constă în apariția la nivelul sistemului a unor caracteristici care nu se regăsesc la nivelul elementelor care compun sistemul considerat. Exemplele includ apariția vieții din materie lipsită de viață sau apariția conștiinței ca urmare a interacțiunii unui număr mare de neuroni. Un alt exemplu îl constituie o colonie de furnici, unde urme de feromoni corespunzând drumurilor cele mai scurte între cuib și sursele de hrană apar ca urmare a comportamentului colectiv al furnicilor.

Persoane diferite atribuie sensuri diferite acestui termen, dar în general ele pot fi grupate în două categorii: emergența puternică și emergența slabă. Chalmers [4] consideră că un sistem manifestă *emergență puternică* dacă „fenomene de nivel înalt sunt produse de domeniul de nivel coborât, dar adevărurile referitoare la aceste fenomene nu sunt *deductibile* nici măcar în principiu din adevărurile referitoare la domeniul de nivel coborât”. Exemplul tipic de fenomen în jurul căruia se fac speculații legate de emergența puternică este conștiința. Existența emergenței puternice este însă un subiect de discuție în filozofie, iar majoritatea oamenilor de știință resping ideea acestui tip de emergență. Chalmers [4] consideră că un sistem manifestă *emergență slabă* dacă „fenomene de nivel înalt sunt produse de domeniul de nivel coborât, dar adevărurile referitoare la aceste fenomene sunt *neșteptate*, date fiind principiile care guvernează domeniul de nivel coborât”.

În lucrarea de față suntem interesați să proiectăm sisteme bazate pe agenți care produc un anumit comportament emergent dorit. În acest context, suntem preocupați în principal de emergența slabă, dar atașăm acestui termen o semnificație mai largă, deoarece pentru scopurile noastre nu este relevant dacă percepem comportamentul manifestat ca neașteptat sau nu. Interesul nostru se îndreaptă numai asupra sarcinii dificile de a găsi un set de reguli simple pentru agenți, care să permită obținerea unui comportament dorit. Propria noastră definiție a emergenței este oferită în capitolul 3, în care dezvoltăm un formalism matematic pentru studiul emergenței în sistemele bazate pe agenți.

2.3. Automate celulare

Fenomene emergente pot fi observate chiar și în sisteme computaționale extrem de simple, precum automatele celulare. Acestea sunt sisteme deterministe, discrete din punct de vedere spațial și temporal, caracterizate numai de interacțiuni locale. Ele sunt constituite dintr-o rețea regulată de celule, fiecare dintre acestea aflată într-o stare dintr-o mulțime finită de posibile stări. Fiecare celulă are aceeași regulă după care își actualizează starea, bazată numai pe starea unui anumit număr de celule învecinate. Modificarea stării are loc simultan în toate celulele, la fiecare cuantă de timp.

Există un număr infinit de automate celulare, ce pot fi obținute combinând valorile diversilor factori ce caracterizează un automat celular. Câțiva dintre acești factori sunt:

- **numărul de dimensiuni:** cel mai des studiate sunt automatele celulare uni- și bidimensionale, care permit și o vizualizare comodă.
- **numărul de stări:** cele mai simple automate celulare au numai două stări (notate de obicei 0 și 1), care sunt adesea reprezentate grafic prin două culori diferite (de obicei alb și negru).
- **vecinătatea:** numărul de vecini ai unei celule și modul în care aceștia sunt identificați. Trebuie de asemenea precizat dacă vecinătatea unei celule o include și pe ea însăși.
- **regula de actualizare:** determină noua stare a celulei în funcție de starea celulelor din vecinătatea ei. Este adesea reprezentată în formă tabulară.

- **tipul de univers celular:** în cazul în care universul este finit, trebuie precizat cum se aplică regulile în cazul celulelor aflate la margine. De multe ori se consideră un aranjament circular sau toroidal al celulelor, evitând astfel problema marginilor chiar și în cazul unui univers finit. O altă soluție este să se considere că toate celulele din afara universului au o anumită stare dată.

Automatele celulare elementare reprezintă cel mai simplu tip de automate celulare. Ele au numai două stări (notate 0 și 1), iar universul celular este infinit, adică linia pe care sunt dispuse celulele se întinde în ambele direcții la infinit. Vecinătatea unei celule este constituită din celula însăși și cele două celule alăturate. Deși extrem de simple, automatele celulare elementare pot manifesta un comportament complex și s-a demonstrat [5] că unul dintre cele 256 de automate elementare posibile este echivalent din punct de vedere computațional cu o mașină Turing universală.

Un exemplu de proiectare a comportamentului emergent folosind automate celulare este oferit de Mitchell *et al.* [26], care folosesc algoritmi genetici pentru a evolua o populație de automate celulare în scopul rezolvării unei anumite probleme date.

2.4. Optimizarea cu colonii de furnici

Fenomene emergente pot fi observate în multe sisteme naturale, iar oamenii de știință se inspiră adesea din natură pentru a proiecta algoritmi care pun în valoare comportamentul emergent manifestat în aceste sisteme. Un astfel de exemplu este oferit de optimizarea cu colonii de furnici (ant colony optimization – ACO), care are ca sursă de inspirație comportamentul furnicilor în căutarea hranei.

În drumul lor către o sursă de hrană și înapoi spre cuib, furnicile depun pe sol substanțe chimice numite feromoni. Celelalte furnici pot percepe prezența acestor feromoni și au tendința de a urma calea pe care concentrația acestora este mai mare. Deși extrem de simplă, această strategie le permite furnicilor să transporte în mod eficient hrana către cuib. Interacțiunile dintre furnici sunt mediate de feromoni. Acest mod de comunicare indirectă, în care acțiunea unui individ asupra mediului influențează acțiunile altor indivizi sau chiar ale lui însuși, a primit numele de *stigmergie* [33]. Algoritmii ACO sunt bazați pe observația că o urmă de feromoni corespunzând celui mai scurt drum între cuib și sursa de hrană apare ca urmare a interacțiunii furnicilor.

Problema comis voiajorului a fost prima problemă rezolvată folosind această tehnică. Algoritmii ACO folosesc o populație de furnici virtuale, care imită într-o anumită măsură comportamentul furnicilor reale. Fiecare furnică virtuală construiește la fiecare iterație o soluție a problemei. Pentru a evita vizitarea repetată a unui oraș, fiecare furnică menține o listă a nodurilor deja vizitate în iterația curentă. De obicei, la începutul unei noi iterații fiecare furnică este plasată într-un oraș ales în mod aleator. La fiecare pas din construcția soluției, o furnică virtuală trebuie să decidă care va fi următorul oraș vizitat. Alegerea următorului nod de vizitat se face în mod probabilistic, în funcție de concentrația de feromoni pe calea către nodul considerat și în funcție de anumite informații euristice. Cei mai mulți algoritmi folosesc drept informație euristică inversul distanței până la nodul considerat. La sfârșitul fiecărei iterații, concentrația de feromoni pe fiecare cale între două orașe este actualizată. Regula de actualizare este bazată pe doi factori care afectează concentrația feromionilor în cazul furnicilor reale: evaporarea feromonilor și acumularea de feromoni pe căile traversate.

Primul algoritm ACO, denumit Ant System, a fost introdus de Marco Dorigo [9]. O serie de extensii ale lui au fost ulterior propuse, dintre care în momentul de față cele mai performante sunt: Ant Colony System [10] și MAX-MIN Ant System [32].

3. O VIZIUNE DIFERITĂ ASUPRA EMERGENȚEI

Cercetarea prezentată în această teză este motivată de problema proiectării unui comportament emergent. Aceasta este o problemă dificilă, deoarece mecanismele pe care se bazează emergența nu sunt pe deplin înțelese, iar fenomenele emergente sunt caracterizate de aparenta lor impredictibilitate. În acest capitol dezvoltăm un formalism matematic pentru studiul emergenței, cu scopul de a studia principiile ce stau la baza comportamentului emergent. Formalismul nostru plasează emergența într-un context orientat pe agenți, care este consistent cu cadrul impus de problema proiectării unui comportament emergent.

Există o mulțime de definiții ale emergenței, care cuprind formulări intuitive sau formale și care diferă prin aspectele emergenței pe care reușesc să le captureze. Multe dintre definițiile formale pornesc de la o definiție preliminară intuitivă, pe care încearcă apoi să o formuleze într-un mod riguros. Acest proces vizează de obicei acele aspecte care disting comportamentul sau proprietățile emergente de cele ne-emergente. În anumite cazuri, această distincție poate fi ușor formalizată, dar nu există o procedură generală care permite să se decidă dacă un fenomen este emergent sau nu. Un exemplu este definiția lui Darley [7], care consideră că “un fenomen emergent adevărat este unul pentru care mijlocul optim de predicție este simularea”. În alte cazuri, caracteristicile definitorii ale unui fenomen emergent sunt mai greu de exprimat formal, iar definițiile formalizează de fapt o procedură pentru detectarea emergenței. Aceasta este de exemplu abordarea propusă de Bonabeau and Dessalles [2]. În multe definiții, emergența este detectată prin intermediul unui observator. Uneori, acest lucru duce la o descriere subiectivă care plasează emergența “în ochii observatorului”. Exemplele includ testul Turing pentru emergență [3] sau folosirea unui observator care se bazează pe elementul surpriză [29]. Există însă și încercări de a oferi o definiție obiectivă a emergenței. Un exemplu în acest sens este abordarea lui Crutchfield [6], care introduce *emergența intrinsecă*, noțiune caracterizată de o creștere a capacității computaționale intrinsece. Dincolo de importanța lor teoretică, definițiile obiective sunt atrăgătoare deoarece oferă în principiu o modalitate automată de a detecta fenomenele emergente. Cu toate acestea, ele implică de obicei calcule extrem de complexe, ceea ce le face neadecvate pentru scopuri practice.

În lucrarea de față adoptăm un punct de vedere diferit asupra emergenței, care ne permite să oferim o definiție care este atât obiectivă, cât și adecvată pentru scopuri practice. Ideea pe care o susținem este că o definiție a fenomenelor emergente trebuie să ia în considerare numai modul în care apar aceste fenomene și nu trebuie să ia în discuție proprietățile acestora. În viziunea noastră proprietățile fenomenelor emergente trebuie să fie subiectul unui întreg domeniu de cercetare și nu parte a definiției emergenței. Din această perspectivă, o definiție trebuie exprimată numai în termenii proceselor care dau naștere fenomenelor emergente. Ca punct de plecare în dezvoltarea formalismului nostru propunem următoarea definiție:

Definiția 3.1 *Numim comportament emergent comportamentul manifestat de un sistem descentralizat bazat pe agenți.*

Evident, definiția de mai sus este obiectivă, pentru că nu depinde de modul în care un observator percepe comportamentul. Ea este de asemenea adecvată pentru scopuri practice, deoarece elimină necesitatea detectării emergenței. O obiecție care ar putea fi însă adusă este că această definiție este prea largă, întrucât consideră chiar și comportamente “neinteresante” ca fiind emergente. Pentru a ne apăra punctul de vedere, apelăm la un exemplu din teoria complexității, pornind de la problema comis voiajorului (traveling salesman problem - TSP), care, după cum se știe, este NP-completă. O instanță a TSP a cărei matrice a costurilor conține

numai zerouri poate fi rezolvată fără dificultate și nu prezintă niciun interes pentru cineva care studiază această clasă de probleme, dar cu toate acestea reprezintă o instanță a acestei clase de probleme NP-complete. Un cercetător ar putea fi interesat de instanțe ne-elementare ale TSP, pentru care există algoritmi exacti care pot găsi soluții într-un interval de timp rezonabil. Un alt cercetător ar putea considera interesante acele instanțe ale TSP care nu pot fi rezolvate folosind algoritmi exacti, dar pentru care anumiți algoritmi euristici obțin rezultate foarte bune. Iar un alt cercetător ar putea considera că o instanță a TSP este interesantă dacă niciun algoritm exact sau euristic nu este capabil să găsească o soluție satisfăcătoare într-un interval de timp rezonabil. În opinia noastră, a defini emergența pe baza caracteristicilor comportamentului manifestat este ca și când cineva ar include în definiția clasei de probleme TSP condiția ca instanțele să fie “interesante”. Din acest motiv, considerăm că decizia de a exclude proprietățile comportamentului din definiția comportamentului emergent reprezintă un pas necesar către elaborarea unei teorii a emergenței.

Unul dintre cele mai interesante aspecte ale emergenței este că până și reguli foarte simple sunt capabile să dea naștere unui comportament complex. Se pune însă întrebarea cum ar putea fi exprimată în mod formal noțiunea de regulă simplă. Utilizarea unor noțiuni de complexitate algoritmică precum complexitatea Kolmogorov [22] nu este practic posibilă, deoarece complexitatea Kolmogorov nu este calculabilă. De aceea, propunem o abordare pragmatică, bazată pe arbori sintactici, pentru a putea evalua complexitatea regulilor agenților. Presupunând că a fost stabilită o metodă de reprezentare a regulilor agenților ca arbori sintactici, măsurăm complexitatea regulilor unui agent ca numărul de frunze din arborele sintactic corespunzător. Evident că aceasta nu este o măsură ideală, întrucât depinde de limbajul folosit pentru a exprima regulile și pentru că aceeași regulă poate fi exprimată în mai multe moduri. Cu toate acestea, ea reprezintă o măsură utilă pentru scopuri practice.

Suntem acum în măsură să oferim o definiție formală a modelelor bazate pe agenți. În paragrafele ce urmează, indicii superiori denotă agenții, iar indicii inferiori cuantele de timp.

Definiție 3.2 *Un model bazat pe agenți este un sistem dinamic discret descris de un tuplu (S, L, A_0) , unde:*

- S este spațiul stărilor.
- L este limbajul utilizat pentru a descrie regulile agenților, împreună cu o metodă bine definită de reprezentare folosind arbori sintactici.
- A_0 este mulțimea inițială finită de agenți. Un agent este un tuplu $(s_0, \sigma, f, \varphi)$, unde:
 - $s_0 \in S$ este starea inițială.
 - $\sigma : 2^S \rightarrow 2^{\mathcal{A}}$ este funcția de selecție, care returnează mulțimea de agenți cu care agentul considerat interacționează. (\mathcal{A} denotă mulțimea tuturor posibililor agenți, adică mulțimea tuturor tuplurilor posibile de forma (s, σ, f, φ) . Notația $2^{\mathcal{M}}$ denotă mulțimea tuturor submulțimilor lui \mathcal{M} .)
 - $f : 2^S \rightarrow S$ este regula de interacțiune, care calculează noua stare a unui agent pe baza stărilor agenților cu care acesta interacționează. f este descrisă în limbajul L .
 - $\varphi : S \rightarrow 2^{\mathcal{A}}$ este regula de transformare care decide dacă un agent trebuie să moară și/sau dacă alți agenți trebuie să fie creați. Valoarea returnată de φ este chiar agentul însuși, dacă agentul continuă să existe și nu sunt creați agenți noi; este mulțimea vidă, dacă agentul moare și nu sunt creați agenți noi; este o mulțime finită de agenți (care poate conține și agentul însuși), dacă sunt creați noi agenți. Funcția φ este descrisă în limbajul L .

- Interacțiunea între agenți este reflexivă, în sensul că dacă un agent a interacționează cu un agent b la un anumit moment de timp t , atunci și b interacționează cu a la momentul t :

$$\forall t \in \mathbb{N}, \forall a, b \in A_t, b \in \sigma^a(s_t^a) \Leftrightarrow a \in \sigma^b(s_t^b)$$

- Starea unui agent evoluează în timp conform următoarei reguli:

$$s'_{t+1} = f(\{s_t\} \cup \{s_t^a \mid a \in \sigma(s_t)\})$$

În ecuația de mai sus, s'_{t+1} denotă starea preliminară a unui agent la momentul $t + 1$, adică starea înainte de aplicarea regulii de transformare. Configurația definitivă a modelului bazat pe agenți la momentul $t + 1$ este:

$$A_{t+1} = \bigcup_{a \in A_t} \varphi^a(s'_{t+1})$$

În continuare, oferim o definiție a unui model descentralizat bazat pe agenți, care reprezintă o formalizare a definiției 3.1:

Definition 3.3 *Un model bazat pe agenți este descentralizat dacă:*

$$\sigma^a(s_t^a) \cup \{a\} \subset A_t, \forall t \in \mathbb{N}, \forall a \in A_t.$$

În studiul emergenței este interesant de analizat și comparat comportamentul manifestat de o gamă variată de modele, de la cele centralizate până la cele puternic descentralizate. De aceea, este util să avem o măsură a gradului de descentralizare a unui model bazat pe agenți. Să observăm mai întâi că putem exprima condiția impusă de definiția 3.3 și sub forma:

$$|\sigma^a(s_t^a)| + 1 < |A_t|, \forall t \in \mathbb{N}, \forall a \in A_t.$$

Bazat pe această observație, oferim următoarea definiție:

Definition 3.4 *Nivelul de centralizare al unui model bazat pe agenți este o cantitate γ definită după cum urmează:*

$$\gamma = \max_{t \in \mathbb{N}} \max_{a \in A_t} \frac{|\sigma^a(s_t^a)| + 1}{|A_t|}$$

Folosind măsura de mai sus, putem defini un model bazat pe agenți puternic descentralizat ca fiind un model cu un nivel de centralizare extrem de scăzut:

Definition 3.5 *Un model bazat pe agenți este puternic descentralizat dacă $\gamma \ll 1$.*

Fenomenele emergente pot apărea și în sisteme care sunt numai parțial descentralizate. Pentru acest concept oferim următoarea definiție:

Definition 3.6 *Un model bazat pe agenți este parțial descentralizat dacă:*

$$\exists T \subseteq \mathbb{N}, a. \hat{i}. |T| = \infty \text{ și } \sigma^a(s_t^a) \cup \{a\} \subset A_t, \forall t \in T, \forall a \in A_t$$

Așa cum am mai menționat, în această lucrare suntem interesați în principal de fenomenele emergente manifestate în sisteme cu agenți care urmează numai reguli simple. În consecință, avem nevoie de o măsură a complexității regulilor agenților.

Definition 3.7 *Dându-se o funcție g descrisă în limbajul L care specifică o metodă bine definită de reprezentare folosind arbori sintactici, complexitatea regulii g relativă la limbajul L , notată $\rho_L(g)$, este dată de numărul de frunze al arborelui sintactic al lui g în reprezentarea asociată cu limbajul L .*

Folosind această măsură, introducem următoarea definiție a complexității regulilor unui model bazat pe agenți:

Definition 3.8 *Complexitatea regulilor unui model bazat pe agenți este o cantitate r dată de formula:*

$$r = \max_{t \in \mathbb{N}} \max_{a \in A_t} (\rho_L(f^a) + \rho_L(\varphi^a))$$

Există o clasă largă de modele bazate pe agenți pentru care mulțimea de agenți nu se modifică în decursul timpului: agenții nu mor și nu se creează noi agenți. În astfel de modele, regula de transformare a fiecărui agent este funcția de identitate, care are o complexitate a regulii egală cu 1. Deoarece mulțimea de agenți nu se modifică în timp, complexitatea regulilor unui astfel de model este determinată de mulțimea inițială a agenților:

$$r = \max_{a \in A_0} (\rho_L(f^a) + 1)$$

Definition 3.9 *Dinamica unui model descentralizat bazat pe agenți, exprimată în termenii proprietăților de nivel înalt, poartă numele de comportament emergent pur.*

Definition 3.10 *Dinamica unui model parțial descentralizat bazat pe agenți, exprimată în termenii proprietăților de nivel înalt, poartă numele de comportament parțial emergent.*

Formalismul introdus în acest capitol reprezintă un prim pas către o *Teorie a Comportamentului Emergent* (Emergent Behavior Theory – EBT). El este în concordanță cu punctul nostru de vedere conform căruia fenomenele emergente trebuie definite numai în termenii modelelor de calcul capabile să le producă, în timp ce caracteristicile acestor fenomene trebuie să reprezinte obiectul de studiu al unui întreg domeniu din cadrul EBT. Din această perspectivă, EBT trebuie să identifice și să analizeze diferite clase de comportament emergent, cum ar fi:

- comportament emergent caracterizat de o creștere a complexității;
- comportament emergent caracterizat de apariția unor tipare;
- comportament emergent haotic;
- comportament emergent caracterizat de atractori;
- comportament emergent pentru care cel mai rapid mod de predicție este simularea.

Unul dintre motivele principale pentru care am dezvoltat acest formalism matematic a fost posibilitatea de a demonstra într-un mod riguros aserțiuni referitoare la proprietățile emergenței. Metoda pe care o propunem în această teză este una empirică: astfel de aserțiuni trebuie mai întâi identificate efectuând experimente computaționale, iar apoi ele pot fi exprimate, analizate și demonstrate folosind formalismul nostru matematic, pentru a obține noi rezultate teoretice. Această metodă presupune existența unui framework experimental pentru studiul emergenței, care trebuie să fie compatibil cu formalismul nostru matematic. În următorul capitol prezentăm un meta-framework pe care l-am proiectat pentru a întruni aceste cerințe.

4. METFREM – UN META-FRAMEWORK PENTRU STUDIUL EMERGENȚEI

Pentru a studia în mod riguros fenomenele emergente, avem nevoie de un cadru de lucru care să ofere o modalitate comună de a modela sistemele în care se manifestă acest fenomen. În acest scop, am conceput un **Meta-Framework** pentru studiul **Emergenței**, numit *MetFrEm*, care poate fi folosit pentru a descrie diverse modele algoritmice care implică o populație de agenți. MetFrEm este un meta-framework, deoarece este în general folosit pentru a modela algoritmi abstracți, de nivel înalt, cum ar fi metaeuristicile, care sunt la rândul lor framework-uri ce permit descrierea unor algoritmi specifici.

Modelând diferite specificații algoritmice de nivel înalt în același meta-framework, avem posibilitatea de a face o comparație riguroasă a metodelor considerate. MetFrEm oferă un set de concepte și de reguli care trebuie folosite pentru a modela sistemele dorite și impune o structură algoritmică generală pentru aceste sisteme. Obiectivele principale ale MetFrEm sunt:

- să permită modelarea oricărui framework algoritmic bazat pe agenți.
- să favorizeze modelarea sistemelor puternic descentralizate.
- să favorizeze modelarea sistemelor cu agenți ghidați numai de reguli simple.
- să faciliteze modelarea framework-urilor algoritmice cu agenți eterogeni.
- să ofere o metodă unitară de modelare a comunicației directe și a celei bazate pe stigmergie.

4.1. Conceptele și structura MetFrEm

Univers

Denumim *univers* un model bazat pe agenți reprezentat în MetFrEm. Acesta este un model de discret în timp, care nu are un mediu înconjurător. Elementele de mediu pot fi reprezentate ca agenți obișnuiți, numiți *mecanisme* în terminologia MetFrEm. Un metamodel în MetFrEm conține un singur univers, care la rândul lui conține toate mecanismele metamodelului.

Mecanism

Folosim termenul *mecanism* pentru a desemna un agent în MetFrEm. O caracteristică importantă a mecanismelor din MetFrEm este că ele știu cum să interacționeze cu alte mecanisme, fără a avea nevoie să știe ce tipuri de mecanisme există în univers.

Proprietate

Starea internă a unui mecanism este caracterizată de valorile *proprietăților sale interne*. Mulțimea proprietăților care caracterizează un mecanism este o submulțime a unei *mulțimi finite globale de proprietăți* definite în universul considerat. Fiecare proprietate are o valoare numerică variabilă în timp. În general, un mecanism nu își expune complet starea în fața celorlalte mecanisme. În plus, în contexte diferite, un mecanism expune diferite proprietăți, folosind vederea (view) corespunzătoare contextului respectiv.

Vedere (View)

A *vedere (view)* reprezintă un grup de proprietăți pe care un mecanism le expune altor mecanisme. Acest grup de proprietăți poate fi o submulțime a proprietăților interne sau poate include proprietăți ale căror valori combină valorile anumitor proprietăți interne. Proprietățile expuse de o vedere trebuie să reprezinte o submulțime a mulțimii globale de

proprietăți din univers. Fiecare mecanism oferă trei vederi: *vederea observabilă*, *vederea activă* și *vederea reactivă*. Fiecareia dintre cele trei vederi în corespunde o *funcție de vedere*, care este folosită pentru a calcula valorile proprietăților expuse. Acestea sunt respectiv: *funcția de vedere observabilă* v_O , *funcția de vedere activă* v_A și *funcția de vedere reactivă* v_R . Numim *stare observabilă* a unui mecanism mulțimea de valori returnate de funcția de vedere observabilă v_O .

Vecinătate

La fiecare moment de timp, un mecanism poate iniția o interacțiune cu o submulțime de mecanisme. Această submulțime este selectată dintr-o familie de potențiale submulțimi, care reprezintă *vecinătatea* mecanismului la momentul respectiv de timp. Fiecare mecanism are asociată o *funcție de vecinătate* η , care returnează vecinătatea unui mecanism la un moment de timp dat, pe baza *stărilor observabile* ale celorlalte mecanisme din univers.

Funcție de evaluare

Pentru a alege o submulțime de mecanisme cu care să inițieze o interacțiune la un moment de timp dat, un mecanism trebuie să evalueze fiecare submulțime din vecinătatea sa. Această operație este efectuată cu ajutorul unei *funcții de evaluare* ψ , care returnează o valoare numerică indicând cât de adecvată este submulțimea respectivă. Gradul de adecvare al unei submulțimi este calculat pe baza valorilor proprietăților expuse de *vederea observabilă* a fiecărui mecanism din submulțime.

Funcție de selecție

Pe baza valorilor gradelor de adecvare returnate de funcția de evaluare, un mecanism selectează cu ajutorul *funcției de selecție* σ setul de mecanisme cu care va iniția o interacțiune.

Funcție de interacțiune

În MetFrEm, unul din mecanismele implicate într-o interacțiune joacă un rol activ și este numit *inițiatorul* acțiunii. Celelalte mecanisme, care sunt determinate de funcția de selecție σ , reprezintă *ținta* interacțiunii și joacă un rol pasiv. În timpul interacțiunii, inițiatorul își expune starea în fața celorlalte mecanisme prin intermediul *vederii active*, iar un mecanism țintă își expune starea în fața inițiatorului și a celorlalte mecanisme țintă prin intermediul *vederii reactive*. În general, starea unui mecanism se modifică în urma interacțiunii. Această modificare este reflectată de modificarea valorilor proprietăților interne ale mecanismului. Noua stare internă este calculată cu ajutorul unei *funcții de interacțiune*. Fiecare mecanism are asociate două funcții de interacțiune: o *funcție de interacțiune activă* f_A și o *funcție de interacțiune reactivă* f_R . În funcție de rolul jucat de mecanism în interacțiune, se folosește una sau cealaltă dintre aceste două funcții: mecanismul inițiator își calculează noua stare cu ajutorul *funcției de interacțiune active*, iar mecanismele țintă cu ajutorul *funcției de interacțiune reactive*.

Funcție de transformare

Ca urmare a interacțiunii, un mecanism poate continua să existe, poate să dispară sau poate să creeze noi mecanisme. Aceste operații sunt efectuate de o *funcție de transformare* φ , care înlocuiește mecanismul dat cu o mulțime de alte mecanisme. Dacă mecanismul continuă să existe și nu se creează alte mecanisme, această mulțime are ca unic element mecanismul însuși. Dacă mecanismul dispare și nu se creează noi mecanisme, funcția de transformare returnează mulțimea vidă. Dacă se creează noi mecanisme, funcția de transformare returnează o mulțime finită de mecanisme, care conține și mecanismul însuși, în cazul în care acesta continuă să existe.

4.2. O descriere formală a MetFrEm

În această secțiune, oferim o descriere formală a conceptelor prezentate în paragrafele de mai sus. Începem prin a introduce *mulțimea globală de proprietăți* din univers:

$$\mathcal{P} = \{p_1, p_2, p_3, \dots, p_z\}$$

unde $z \in \mathbb{N}$ este numărul de proprietăți globale.

Fiecare element p_i din mulțimea \mathcal{P} identifică o proprietate măsurabilă. De exemplu, un univers care modelează particule microscopice poate include proprietăți precum: masa, poziția și viteza. În MetFrEm, valoarea unei proprietăți este o cantitate adimensională exprimată printr-un număr real.

Notăm cu \mathcal{M} mulțimea infinită a tuturor mecanismelor posibile. Un *univers* în MetFrEm este un tuplu (\mathcal{P}, M_0) , unde \mathcal{P} este mulțimea globală de proprietăți, iar $M_0 \subset \mathcal{M}$ este mulțimea inițială finită de mecanisme.

Un *mechanism* este definit ca un tuplu $(P_I, P_O, P_A, P_R, s_0, v_o, v_A, v_R, \eta, \psi, \sigma, \varphi, f_A, f_R)$, unde:

- $P_I \subseteq \mathcal{P}$ este mulțimea proprietăților interne;
- $P_O \subseteq \mathcal{P}$ este mulțimea proprietăților observabile.;
- $P_A \subseteq \mathcal{P}$ este mulțimea proprietăților active;
- $P_R \subseteq \mathcal{P}$ este mulțimea proprietăților reactive;
- $s_0 \in \mathbb{R}^{|P_I|}$ este starea internă inițială, adică mulțimea valorilor inițiale ale proprietăților interne;
- $v_o : \mathbb{R}^{|P_I|} \rightarrow \mathbb{R}^{|P_O|}$ este funcția de vedere observabilă, care calculează mulțimea valorilor ce constituie starea observabilă a mecanismului;
- $v_A : \mathbb{R}^{|P_I|} \rightarrow \mathbb{R}^{|P_A|}$ este funcția de vedere activă, care calculează mulțimea valorilor expuse în timpul unei interacțiuni inițiate de acest mecanism;
- $v_R : \mathbb{R}^{|P_I|} \rightarrow \mathbb{R}^{|P_R|}$ este funcția de vedere reactivă, care calculează mulțimea valorilor expuse în timpul unei interacțiuni în care acest mecanism joacă rolul de țintă;
- $\eta : 2^{\mathbb{R}} \rightarrow 2^{2^{\mathcal{M}}}$ este funcția de vecinătate, care returnează o familie de submulțimi de mecanisme cu care mecanismul dat poate iniția o interacțiune. Valoarea de retur este calculată pe baza stărilor observabile ale tuturor mecanismelor din univers.
- $\psi : 2^{\mathbb{R}} \rightarrow \mathbb{R}$ este funcția de vedere evaluare, care calculează gradul de adecvare al unei submulțimi de mecanisme din familia de submulțimi potențiale, pe baza stărilor observabile ale acestora.
- $\sigma : 2^{\mathbb{R}} \rightarrow 2^{\mathcal{M}}$ este funcția de evaluare, care alege o submulțime de mecanisme cu care acest mecanism va iniția o interacțiune, pe baza gradului de adecvare al fiecărei potențiale submulțimi.
- $\varphi : \mathcal{M} \rightarrow 2^{\mathcal{M}}$ este funcția de transformare, care returnează o mulțime de mecanisme ce reflectă transformarea suferită de acest mecanism la sfârșitul unei interacțiuni: el poate continua să existe, poate să dispară și/sau poate crea noi mecanisme.
- $f_A : 2^{\mathbb{R}} \rightarrow 2^{\mathbb{R}}$ este funcția de interacțiune folosită de mecanismul inițiator pentru a-și calcula noua stare internă, pe baza stării sale curente și pe baza valorilor proprietăților reactive ale mecanismelor țintă.
- $f_R : 2^{\mathbb{R}} \rightarrow 2^{\mathbb{R}}$ este funcția de interacțiune folosită de un mecanism țintă pentru a-și calcula noua stare internă, pe baza stării sale curente, a valorilor proprietăților active ale mecanismului inițiator și a valorilor proprietăților reactive ale celorlalte mecanisme țintă.

În următoarele paragrafe, vom arăta cum dinamica universului rezultă din aplicarea funcțiilor asociate mecanismelor. Vecinătatea unui mecanism μ , adică mulțimea potențialelor submulțimi de mecanisme cu care acesta poate iniția o interacțiune la momentul t , es te calculată astfel:

$$\mathcal{N}_t^\mu = \eta^\mu \left(\bigcup_{m \in M_t} v_o(s_t^m) \right) \quad (4.1)$$

unde M_t este mulțimea tuturor mecanismelor care există la momentul t , iar s_t^m reprezintă starea internă a mecanismului m la momentul t .

Mulțimea valorilor gradelor de adecvare corespunzătoare fiecărei potențiale submulțimi din vecinătate este dată de:

$$B_t^\mu = \bigcup_{N \in \mathcal{N}_t} \psi^\mu \left(\bigcup_{m \in N} v_o^\mu(s_t^m) \right) \quad (4.2)$$

Submulțimea de mecanisme cu care un mecanism μ inițiază efectiv interacțiunea este:

$$V_t^\mu = \sigma^\mu(B_t^\mu) \quad (4.3)$$

În MetFrEm, un mecanism poate interacționa cu alte mecanisme în mod activ sau reactiv. Mulțimea tuturor mecanismelor cu care un mecanism interacționează trebuie deci să includă mecanismele implicate în ambele tipuri de interacțiune. Pentru un mecanism dat μ , această multime este:

$$W_t^\mu = V_t^\mu \cup \{m \in M_t \mid \mu \in V_t^m\} \quad (4.4)$$

În MetFrEm, este posibil ca la un anumit moment t , un mecanism să fie implicat în mai multe interacțiuni: el poate juca rolul de inițiator într-una dintre acestea și rolul de țintă în celelalte. Noua stare în urma unei interacțiuni în care mecanismul joacă rolul de inițiator este calculată folosind funcția de interacțiune activă f_A . Noua stare în urma unei interacțiuni în care mecanismul joacă rolul de țintă este calculată folosind funcția de interacțiune reactivă f_R . Starea finală a mecanismului este obținută prin aplicarea succesivă a acestor funcții pentru fiecare interacțiune a mecanismului considerat. Dacă notăm cu μ mecanismul inițiator, starea sa preliminară în urma interacțiunii, adică starea înaintea aplicării regulii de transformare, este dată de:

$$s'_{t+1}^\mu = f_A^\mu(\{s_t^\mu\} \cup \{v_R^m(s_t^m) \mid m \in V_t^\mu\}) \quad (4.5)$$

Starea preliminară a unui mecanism țintă λ în urma interacțiunii este:

$$s'_{t+1}^\lambda = f_R^\lambda(\{s_t^\lambda\} \cup \{v_A^\mu(s_t^\mu)\} \cup \{v_R^m(s_t^m) \mid m \in V_t^\mu, m \neq \lambda\}) \quad (4.6)$$

Configurația definitivă a universului la momentul $t + 1$ este:

$$M_{t+1} = \bigcup_{m \in M_t} \varphi^m(s'_{t+1}^m) \quad (4.7)$$

4.3. Structura algoritmică

Evoluția unui univers în MetFrEm este prezentată în pseudocod în figura de mai jos:

```

1 procedure MetFrEm ()
2   M ← initializeUniverse ()
3   while (termination condition not met) do
4     executePreliminaryActions (M)    // optional
5     foreach initiator ∈ M do
6       neighborhood ← getNeighborhood (initiator)
7       suitabilities ← evaluateNeighborhood(neighborhood)
8       targets ← selectTargets (neighborhood, suitabilities)
9       initiator.state ← activeInteraction (initiator, targets)
10      replacement ← transform(initiator)
11      M ← (M \ {initiator}) ∪ replacement
12      foreach target ∈ targets do
13        target.state ← reactiveInteraction (target, initiator, targets)
14        replacement ← transform(target)
15        M ← (M \ {target}) ∪ replacement
16      end foreach
17    end foreach
18    executeFinalActions (M)    // optional
19  end while
20 end procedure

```

Figure 4-1. Descrierea în pseudocod a evoluției unui univers în MetFrEm.

În faza de inițializare (linia 2), se creează mulțimea inițială de mecanisme și se configurează starea fiecărui mecanism. Algoritmul intră apoi în bucla principală (liniile 3-19). Pentru a permite modelarea sistemelor care nu se încadrează perfect în structura formală specificată de MetFrEm, algoritmul oferă 2 proceduri opționale: *executePreliminaryActions* (linia 4) și *executeFinalActions* (linia 18). De obicei ele implementează operații globale care nu pot fi modelate ca acțiuni descentralizate. De exemplu, în anumiți algoritmi de optimizare cu colonii de furnici, numai cea mai performantă furnică are dreptul să depună feromoni. Această operație necesită informații globale despre soluțiile construite de toate furnicile existente și poate fi deci implementată de una dintre procedurile opționale.

În timp ce acțiunile efectuate de procedurile opționale nu sunt specificate explicit, funcționarea celorlalte proceduri din pseudocodul de mai sus este complet determinată de funcțiile și vederile aferente introduse în descrierea formală a MetFrEm. Procedura *getNeighborhood* (linia 6) folosește funcția de vecinătate η pentru a determina mulțimea potențialelor submulțimi de mecanisme cu care inițiatorul poate interacționa, în concordanță cu formula 4.1. Procedura *evaluateNeighborhood* (linia 7) folosește funcția de evaluare ψ pentru a calcula valoarea gradului de adecvare pentru fiecare mulțime de mecanisme din vecinătate, în concordanță cu formula 4.2. Procedura *selectTargets* (linia 8) folosește funcția de selecție σ pentru a alege mulțimea de mecanisme țintă, în concordanță cu formula 4.3. Procedura *activeInteraction* (linia 9) folosește funcția de interacțiune activă f_A pentru a calcula starea inițiatorului în urma interacțiunii, în concordanță cu formula 4.5. Procedura *reactiveInteraction* (linia 13) folosește funcția de interacțiune reactivă f_R pentru a calcula starea unui mecanism țintă în urma interacțiunii, în concordanță cu formula 4.6. Procedura *transform* (liniile 10 și 14) folosește funcția de transformare φ pentru a determina mulțimea de mecanisme care înlocuiește un mecanism dat, în concordanță cu formula 4.7.

5. CĂUTAREA GHIDATĂ DE CONSULTANT

Meta-framework-ul introdus în capitolul anterior a fost proiectat pentru a permite modelarea sistemelor puternic eterogene, cu agenți care știu cum să interacționeze cu orice tip de agent, fără a avea nevoie să știe ce tipuri de agenți există în sistem. Din acest motiv, o interacțiune în MetFrEm este realizată în doi pași. Mai întâi, inițiatorul alege o submulțime de mecanisme țintă dintr-o familie de potențiale submulțimi, iar apoi interacționează cu țintele alese. Să considerăm pentru simplitate cazul în care mulțimea de mecanisme țintă conține un singur element, adică inițiatorul interacționează cu un singur mecanism. Ca urmare a interacțiunii, inițiatorul își modifică starea. Noua stare este calculată pe baza valorilor expuse de vederea reactivă a mecanismului țintă. Întrucât vederea reactivă oferă și valori care nu sunt în general disponibile în vederea observabilă, aceste valori suplimentare pot fi interpretate ca informații private oferite de mecanismul țintă. Inițiatorul primește aceste informații numai datorită faptului că a ales să interacționeze cu acest mecanism țintă. Putem privi mecanismul țintă ca pe un consultant care are cunoștințe de specialitate, pe care le pune la dispoziția mecanismelor care sunt dispuse să interacționeze cu el. În mod similar, inițiatorul poate fi privit ca un client care alege unul dintre consultanții disponibili, pentru a primi de la acesta informații prețioase. Văzută din această perspectivă, interacțiunea mecanismelor în MetFrEm ne-a condus la ideea unei metode euristice, pe care am denumit-o Căutarea Ghidată de Consultant (Consultant-Guided Search – CGS), și care constituie subiectul acestui capitol.

5.1. Metaeuristica CGS

Căutarea Ghidată de Consultant (CGS) este o metaeuristică bazată pentru probleme de optimizare combinatorială. Ea este bazată pe populații și se inspiră din modul în care oamenii iau decizii pe baza recomandărilor primite de la consultanți. Un individ dintr-o populație a CGS este o persoană virtuală, care poate juca simultan rolul de client și de consultant. În postura de client, o persoană virtuală construiește la fiecare iterație o soluție a problemei. În postura de consultant, o persoană virtuală oferă recomandări clienților, în concordanță cu **strategia** sa. În general, la fiecare pas din construcția soluției există mai multe variante din care un client poate alege. Varianta recomandată de consultant are o probabilitate mai mare de a fi aleasă, dar clientul poate opta și pentru una dintre celelalte variante, pe care o va alege pe baza unei anumite euristici.

La începutul fiecărei iterații, un client își alege un consultant pe baza **preferinței sale personale** și pe baza **reputației** consultantului. Reputația unui consultant crește cu numărul de succese raportate de clienții săi. Spunem că un client a raportat un **succes**, dacă a construit o soluție mai bună decât toate soluțiile găsite până în acel moment de vreun client ghidat de același consultant. De fiecare dată când un client de-al său raportează un succes, consultantul își ajustează strategia pentru a reflecta secvența de decizii luate de client. Întrucât reputația unui consultant scade cu trecerea timpului, este important ca în mod constant clienții săi să obțină succese. În cazul în care reputația unui consultant scade sub o anumită valoare limită, acesta intră într-o **perioadă sabatică**, pe parcursul căreia nu își va mai oferi serviciile de consultant, ci va căuta o nouă strategie pe care să o aplice în viitor.

Pseudocodul care formalizează metaeuristica CGS este prezentat în Fig. 5.1. În faza de inițializare (liniile 2-5), se creează persoanele virtuale, care sunt apoi plasate în modul sabatic. În funcție de modul său, o persoană virtuală construiește la fiecare iterație fie o soluție a

problemei (linia 13), fie o strategie (linia 9). O procedură de optimizare locală (linia 17) poate fi apoi aplicată pentru a îmbunătăți această soluție sau strategie.

După faza de construcție, o persoană aflată în perioada sabatică verifică dacă a găsit o strategie mai bună decât cele anterioare (liniile 20-22), iar o persoană în stare normală verifică dacă a obținut un succes, în care caz consultantul acesteia își va ajusta în mod corespunzător strategia (liniile 24-29).

```

1 procedure CGSMetaheuristic()
2   create the set  $\mathcal{P}$  of virtual persons
3   foreach  $p \in \mathcal{P}$  do
4     setSabbaticalMode(p)
5   end foreach
6   while (termination condition not met) do
7     foreach  $p \in \mathcal{P}$  do
8       if actionMode[p] = sabbatical then
9         currStrategy[p] ← constructStrategy(p)
10      else
11        currCons[p] ← chooseConsultant(p)
12        if currCons[p] ≠ null then
13          currSol[p] ← constructSolution(p, currCons[p])
14        end if
15      end if
16    end foreach
17    applyLocalOptimization()           // optional
18    foreach  $p \in \mathcal{P}$  do
19      if actionMode[p] = sabbatical then
20        if currStrategy[p] better than bestStrategy[p] then
21          bestStrategy[p] ← currStrategy[p]
22        end if
23      else
24        c ← currCons[p]
25        if c ≠ null and currSol[p] is better than all solutions
26          found by a client of c since last sabbatical then
27          successCount[c] ← successCount[c] + 1
28          strategy[c] ← adjustStrategy(c, currSol[p])
29        end if
30      end if
31    end foreach
32    updateReputations()
33    updateActionModes()
34  end while
35 end procedure

```

Fig. 5.1. Metaeuristica CGS.

Reputațiile sunt ajustate pe baza *rezultatelor* obținute de clienți (line 32): reputația unui consultant este incrementată ori de câte ori unul dintre clienții săi obține un succes și, pe deasupra, primește un bonus în cazul în care unul dintre clienți găsește o soluție mai bună decât toate cele descoperite până în prezent. Pentru fiecare consultant, algoritmul memorează cel mai bun rezultat obținut de unul dintre clienții săi și menține un clasament al consultantilor, bazat pe aceste rezultate. Pentru un anumit număr de consultanți aflați în fruntea acestui clasament, CGS fixează o limită sub care reputația acestora nu poate să scadă.

În final, se actualizează modul de acțiune al fiecărei persoane (linia 33): consultanții a căror reputație a scăzut sub limita minimă intră în perioada sabatică, iar consultanții a căror perioadă sabatică a luat sfârșit intră în starea normală.

5.2. Metaeuristica CGS aplicată la Problema Comis Voiajorului

În această secțiune propunem un algoritm CGS pentru problema comis voiajorului (traveling salesman problem – TSP), pe care îl denumim CGS-TSP. Pentru a aplica CGS la o anumită clasă de probleme, trebuie definite diversele concepte folosite de această metauristică (strategie, rezultat, preferință personală etc.) în contextul respectivei clase de probleme. Apoi, trebuie decis cum vor fi implementate acțiunile pentru care metaeuristica nu oferă o specificăție (*constructStrategy*, *constructSolution*, *chooseConsultant* etc.).

Construirea unei soluții pentru TSP înseamnă realizarea unui circuit închis care conține fiecare nod al grafului o singură dată. Pentru a evita vizitarea repetată a unui nod, fiecare persoană virtuală din CGS-TSP menține o listă a nodurilor deja vizitate în interația curentă. **Strategia** unui consultant este reprezentată de un tur pe care acesta îl recomandă clienților săi. **Rezultatul** unui tur este calculat ca inversul lungimii sale. Deoarece atât construcția soluției cât și a strategiei implică realizarea unui tur, același tip de decizie trebuie luat de o persoană virtuală în ambele cazuri: ea trebuie să aleagă următorul oraș pe care îl vizitează. Totuși, regulile folosite în luarea acestei decizii diferă în cele două cazuri.

Pentru a restrânge numărul de variante disponibile la fiecare pas al construcției, CGS-TSP folosește *liste candidat* care conțin pentru fiecare oraș i cele mai apropiate *cand* orașe, unde *cand* este un parametru. În acest fel, vecinătatea efectivă a unei persoane k aflate în orașul i reprezintă mulțimea orașelor din lista candidat a lui i pe care persoana k nu le-a vizitat încă.

În timpul *perioadei sabatice*, consultanții construiesc strategii folosind o euristică bazată numai pe distanțele dintre orașul curent și potențialele orașe succesori: cu o probabilitate a_0 (unde a_0 este un parametru constant), o persoană virtuală se deplasează la cel mai apropiat oraș din vecinătatea sa efectivă, iar cu o probabilitate $(1 - a_0)$ ea alege pseudo-aleator unul dintre orașele învecinate, ținând cont de distanța până la orașul i .

La fiecare pas din construcția soluției, un client primește de la consultantul său o recomandare privind următorul oraș de vizitat. Această recomandare este bazată pe turul ce constituie strategia consultantului. Fie i orașul vizitat de clientul k la un anumit pas al construcției din iterația curentă. Pentru a decide ce oraș să recomande pentru următorul pas, consultantul localizează poziția pe care orașul i apare în turul promovat de el și identifică orașul care îl precede și cel care îi urmează lui i în acest tur. Dacă niciunul dintre aceste două orașe nu a fost încă vizitat de client, consultantul îl recomandă pe cel mai apropiat de orașul i . Dacă numai unul dintre cele două orașe este nevizitat, acesta va fi recomandat. Dacă ambele orașe au fost deja vizitate, consultantul nu poate face o recomandare pentru următorul pas.

Clientul nu urmează întotdeauna recomandarea consultantului. O regulă pseudo-aleatoare bazată pe doi parametri constanți q_0 și b_0 este folosită pentru a alege orașul vizitat la următorul pas: dacă s-a primit o recomandare de la consultant, aceasta va fi urmată cu probabilitatea q_0 ; cu o probabilitate $b_0(1 - q_0)$ clientul se deplasează către cel mai apropiat oraș din vecinătatea sa efectivă; cu o probabilitate $(1 - b_0)(1 - q_0)$ clientul alege pseudo-aleator unul dintre orașele învecinate, influențat de distanța până la orașul i .

Un client ține cont de doi factori în alegerea unui consultant: **reputația** consultantului și **preferința personală** a clientului. În CGS-TSP preferința personală este dată de rezultatul turului promovat de consultant, adică de inversul lungimii acestuia.

De fiecare dată când un client repurtează un succes (adică găsește un tur mai scurt decât cel promovat de consultantul său), consultantul își actualizează strategia, înlocuindu-și turul promovat cu cel construit de client.

Experimente cu și fără căutare locală arată că CGS-TSP este capabil să depășească în performanță cei mai buni algoritmi de optimizare cu colonii de furnici.

5.3. Metaeuristica CGS aplicată la problema asignării pătratică

În această secțiune analizăm modul în care CGS poate fi aplicată la problema asignării pătratică (Quadratic Assignment Problem - QAP) și propunem algoritmul CGS-QAP, care combină CGS cu o procedură de căutare locală. Dându-se o mulțime de fabrici și o mulțime de locații, o matrice a fluxurilor între fiecare pereche de fabrici, precum și o matrice a distanțelor între fiecare pereche de locații, problema asignării pătratică constă în găsirea unei repartizări a fabricilor la locațiile existente, astfel încât suma produselor dintre fluxuri și distanțele corespunzătoare să fie minimă.

În CGS-QAP, *strategia* este implementată ca o soluție promovată de consultant. Ea este reprezentată printr-o repartiție a fabricilor la locații, care este construită în timpul *perioadei sabatice*. În algoritmul propus, perioada sabatică durează o singură iterație. Pentru a construi o nouă strategie, un consultant generează în mod aleator o repartiție pe care apoi o îmbunătățește folosind o procedură de căutare locală. *Preferința personală* pentru un anumit consultant este determinată de costul repartiției promovate de acesta. Împreună cu *reputația*, este folosită pentru a calcula probabilitatea de a alege un anumit consultant.

La fiecare pas al construcției, un client plasează o fabrică nealocată în una dintre locațiile libere. În CGS-QAP, ordinea în care fabricile sunt repartizate este aleatoare. La fiecare pas, un client primește de la consultantul său o recomandare privind locația pe care să o aleagă. Locația recomandată este cea care corespunde fabricii considerate în repartiția promovată de consultant. Pentru a decide dacă va urma recomandarea, clientul folosește o regulă pseudo-aleatoare: cu o probabilitate q_0 , clientul plasează fabrica dată în locația recomandată de consultant, iar cu o probabilitate $(1 - q_0)$ plasează fabrica în mod aleator în una din locațiile libere. Valoarea parametrului q_0 este critică pentru performanța algoritmului. O valoare mare a lui q_0 duce la o căutare agresivă, concentrată în jurul repartiției promovate de consultant. O valoare mică a lui q_0 favorizează explorarea spațiului de căutare, permițând algoritmului să scape din regiunile optime locale.

Oro de câte ori un client repurtează un succes (adică găsește o repartiție mai bună decât cea promovată de consultantul său), consultantul își actualizează strategia, înlocuind repartiția promovată cu cea construită de client.

La sfârșitul fiecărei iterații, se aplică o procedură de căutare locală, pentru a îmbunătăți repartițiile construite de clienți. În mod asemănător cu alți algoritmi pentru QAP, CGS-QAP poate folosi ca procedură de căutare locală metoda *2-opt* sau scurte execuții ale algoritmilor *tabu search* sau *simulated annealing*.

Rezultatele experimentale arată că algoritmul nostru este mai performant decât MAX-MIN Ant System (MMAS) pentru instanțe nestructurate ale QAP. Una din temele de cercetare viitoare pe ne-o propunem este să investigăm dacă CGS-QAP este capabil să concureze cu MMAS și pentru instanțe structurate ale QAP.

5.4. Metaeuristica CGS aplicată la problema generalizată a comis voiajorului

Problema generalizată a comis voiajorului (generalized traveling salesman problem – GTSP) este o problemă NP-completă care extinde problema clasică a comis voiajorului, prin introducerea unei partiționări în clustere a nodurilor grafului. Problema constă în găsirea celui mai scurt circuit închis care vizitează un singur nod din fiecare cluster. Algoritmul pe care îl propunem combină metoda CGS cu o abordare local-globală pentru rezolvarea GTSP. Cele mai multe instanțe GTSP de interes practic sunt probleme simetrice cu distanțe euclidiene, unde clusterelor sunt compuse din noduri apropiate în spațiu unele de celelalte. Algoritmul nostru este proiectat pentru a beneficia de structura acestor instanțe.

Abordarea local-globală a fost introdusă de Pop [27] în cazul problemei generalizate a arborelui de acoperire minim (generalized minimum spanning tree problem). În cazul GTSP, abordarea local-globală face distincție între *conexiunile globale* (conexiuni între clustere) și conexiunile locale (conexiuni între noduri din clustere diferite). Fiind dată o secvență în care sunt vizitate clusterelor (adică un circuit Hamiltonian global), există o serie de circuite Hamiltoniene generalizate corespunzătoare acesteia. Cel mai bun circuit Hamiltonian generalizat (din punctul de vedere al costului) poate fi determinat fie folosind o rețea pe niveluri, fie folosind metode de programare liniară cu numere întregi. În paragrafele ce urmează desemnăm prin *graf global* graful obținut prin înlocuirea tuturor nodurilor unui cluster printr-un supernod care să reprezinte clusterul.

În algoritmul pe care îl propunem, un client construiește la fiecare iterație un tur global, adică un ciclu Hamiltonian în graful global. Strategia unui consultant este reprezentată de asemenea printr-un tur, pe care consultantul îl recomandă clienților. Algoritmul aplică o procedură de căutare locală pentru a îmbunătăți tururile globale ce reprezintă fie soluția globală a unui client, fie strategia unui consultant aflat în perioada sabatică. Apoi, folosind o procedură de optimizare a clusterelor, algoritmul găsește cel mai bun tur generalizat corespunzând turului global returnat de procedura de căutare locală.

Pentru a compara strategiile construite în perioada sabatică, un consultant ține cont de costul turului generalizat corespunzător fiecărei strategii. În mod similar, succesul unui client este evaluat pe baza costului soluției generalizate construite de acesta.

Euristica folosită în perioada sabatică pentru a construi a nouă strategie este bazată pe distanțele virtuale dintre supernodurile din graful global. Calculăm distanța virtuală dintre două supernoduri ca distanța dintre centrele de masă ale celor două clustere corespunzătoare. Alegerea acestei euristici este justificată de clasa de probleme pentru care este proiectat algoritmul nostru: instanțe simetrice cu distanțe euclidiene, cu clustere compuse din noduri apropiate spațial unele de celelalte. Datorită introducerii distanțelor virtuale dintre clustere, avem posibilitatea să utilizăm liste candidat pentru a restrânge numărul de variante disponibile la fiecare pas al construcției.

Rezultatele experimentale arată ca algoritmul propus în această secțiune poate concura cu cei mai performanți algoritmi pentru GTSP.

ANEXA A. AGSYSLIB – UN PACHET SOFTWARE PENTRU IMPLEMENTAREA SOLUȚIILOR BAZATE PE AGENȚI

Multe fenomene complexe ce apar în sisteme fizice și biologice pot fi descrise în mod natural folosind modele bazate pe agenți. Aceste modele pot captura comportamentul complex care rezultă din interacțiunea unor agenți ghidați de reguli simple. Este tentantă ideea de a folosi abordări bazate pe agenți nu numai pentru a descrie fenomene existente, ci și pentru a rezolva probleme complexe care nu pot fi atacate prin metode convenționale. De aceea, în ultimii ani s-a înregistrat o creștere continuă a interesului pentru proiectarea algoritmilor care pun în valoare comportamentul emergent manifestat în sistemele cu agenți care interacționează.

Diversele biblioteci software disponibile la ora actuală pentru modelarea și simularea bazată pe agenți (agent-based modeling and simulation - ABMS [24]) se pot dovedi utile și în conceperea unui nou algoritm bazat pe agenți. Cu toate acestea, software-ul ABMS nu poate oferi asistență în toate aspectele legate de proiectarea, implementarea și ajustarea algoritmilor bazați pe agenți. În acest capitol, identificăm dificultățile întâmpinate pe parcursul acestor etape și arătăm cum pot fi ele depășite folosind AgSysLib, un pachet software pe care l-am dezvoltat pentru a ușura activitățile legate de implementarea soluțiilor bazate pe agenți.

Principala problemă în proiectarea algoritmilor bazați pe agenți este găsirea unui set de reguli care să producă un comportament emergent dorit. Deoarece nu există o metodologie unanim acceptată, proiectarea acestor algoritmi este adesea un proces bazat pe încercări, care ar putea beneficia de pe urma ajutorului oferit de un pachet software.

În timp ce ABMS permite în principal o înțelegere calitativă a fenomenelor, în cazul implementării soluțiilor bazate pe agenți accentul cade pe obținerea unor rezultate cât mai performante. Transformarea unei simulări cu caracter demonstrativ într-o implementare la cel mai înalt nivel al tehnicii este un proces anevoios, pentru care ABMS nu oferă în general sprijin. AgSysLib umple acest gol și vine în ajutorul celor care doresc să implementeze soluții bazate pe agenți pentru probleme complexe.

AgSysLib este în același timp un framework și o bibliotecă Java. El oferă o API care trebuie implementată de fiecare algoritm bazat pe agenți și pune la dispoziție o serie de clase care ușurează efectuarea diverselor activități legate de rezolvarea problemelor folosind metode bazate pe agenți. Pentru multe dintre interfețele specificate de API, AgSysLib oferă implementări implicite sau clase abstracte care pot fi ușor instanțiate, extinse și personalizate.

AgSysLib are o arhitectură bazată pe componente, care permite construirea modulară a algoritmilor și facilitează experimentarea și analiza diverselor variante ale unui algoritm. O nouă variantă a unui algoritm poate fi obținută prin simpla înlocuire a unei anumite componente din implementarea de bază cu o altă componentă. AgSysLib permite și procesarea în loturi, pentru a putea aplica în mod repetat un algoritm la aceeași problemă, la probleme diferite, sau folosind valori diferite ale parametrilor.

Așa cum am mai menționat, unele dintre funcțiile puse la dispoziție de pachetele software ABMS sunt utile și în soluționarea problemelor prin metode bazate pe agenți. AgSysLib nu își propune să ofere o nouă implementare a acestor funcții, ci are în vedere acele aspecte legate de proiectarea, implementarea și ajustarea algoritmilor bazați pe agenți, care nu sunt acoperite de pachetele ABMS. Pentru a oferi însă în continuare posibilitatea de a beneficia de facilitățile disponibile în produsele ABMS, AgSysLib poate acționa ca un container pentru aceste

biblioteci. În acest fel, AgSysLib poate transforma un pachet ABMS într-o unealtă software capabilă să asiste în soluționarea problemelor prin metode bazate pe agenți. Există în prezent un număr mare de pachete ABMS, cu capabilități și scopuri diferite. AgSysLib poate integra multe dintre aceste pachete, dar în configurația standard el înglobează biblioteca MASON. MASON [23] este un mediu de simulare cu evenimente discrete implementat în Java, care permite execuția rapidă și de un număr mare de ori a modelelor cu un număr mare de agenți.

Configurarea

Soluționarea problemelor prin metode bazate pe agenți necesită realizarea unor diverse tipuri de experimente. Unul dintre acestea implică evaluarea diverselor variante ale unui algoritm. Adesea, trecerea la o nouă variantă a unui algoritm se face comentând porțiuni din codul original și înlocuindu-le cu noi porțiuni de cod, sau folosind flag-uri în diverse părți ale programului pentru a activa porțiunile de cod corespunzătoare variantei de algoritm dorite. O astfel de practică face codul sursă greu de citit și de întreținut. O arhitectură bazată pe componente permite o separare clară a porțiunilor de cod specifice fiecărei variante a unui algoritm, dar necesită în continuare modificări în codul original pentru a preciza componentele ce trebuie utilizate. AgSysLib permite specificarea componentelor unui sistem bazat pe agenți într-un fișier de configurare. În acest mod, nu mai sunt necesare modificări ale codului sau flag-uri suplimentare pentru a comuta între diversele variante ale unui algoritm.

Un alt tip de experimente presupune compararea rezultatelor obținute de un algoritm pentru diverse valori ale parametrilor săi sau chiar pentru diverse formule utilizate în cadrul lui. Dacă valorile parametrilor sau formulele algoritmului fac parte din codul programului, se ajunge din nou la un cod greu de întreținut. De aceea, AgSysLib oferă un număr mare de funcții utilitare pentru citirea diverselor tipuri de valori, precum și a formulelor matematice din fișiere de configurare. În plus, AgSysLib permite declararea de liste de valori ale parametrilor și execuția loturilor corespunzătoare fiecărei combinații de valori ale acestora. Este de asemenea posibil să se specifice că valoarea unui parametru din fișierul de configurare trebuie calculată pe baza unei formule care folosește valorile altor parametri.

Componente de urmărire a evoluției (listeners)

Pe parcursul experimentelor cu un algoritm bazat pe agenți, este adesea necesar să se inspecteze evoluția diverselor mărimi prelucrate de aplicație sau a unor valori agregate ale acestora, cu scopul de a înțelege comportamentul emergent la sistemului. Informații similare sunt necesare pe parcursul activităților de depanare și de ajustare a configurației. Instrucțiunile necesare pentru a afișa aceste informații “murdăresc” codul sursă. În plus, ele afectează performanța algoritmului, deși în general ele nu mai sunt necesare în versiunea finală a aplicației. Pentru a putea ține aceste instrucțiuni separate de codul sursă principal, interfața de programare (API) a AgSysLib introduce componente de urmărire a evoluției (listeners) și permite în același timp activarea și dezactivarea rapidă a acestor porțiuni de cod. O componentă de urmărire a evoluției oferă metode activate de următoarele evenimente:

- începerea procesării unui lot
- terminarea procesării unui lot
- începerea procesării unui sistem dintr-un lot
- terminarea procesării unui sistem dintr-un lot
- începerea unui pas din evoluția unui sistem
- terminarea unui pas din evoluția unui sistem
- terminarea operațiilor efectuate de un agent la un pas din evoluția sistemului.

Componentele de urmărire a evoluției active pe parcursul unei execuții pot fi specificate într-un fișier de configurare. În acest fel, nu sunt necesare modificări în codul aplicației pentru a adăuga sau a șterge o astfel de componentă.

Experimentarea și ajustarea configurației (tuning)

Așa cum am mai menționat, AgSysLib permite specificarea unor liste de valori în fișierele de configurare, pentru a putea executa un algoritm folosind toate combinațiile posibile ale valorilor parametrilor acestuia. În acest mod se poate realiza o formă elementară de ajustare a configurației (tuning). AgSysLib oferă însă și o metodă de tuning mai elaborată, bazată pe algoritmi genetici și permite de asemenea o integrare comodă cu pachetele software de configurare automată a parametrilor.

AgSysLib oferă o serie de clase ce permit evaluarea formulelor matematice care apar într-un fișier de configurare. Pentru evaluarea formulelor nu se folosește un interpretor, întrucât acesta ar avea un impact negativ asupra performanței. În schimb, AgSysLib generează on-the-fly o clasă Java pentru fiecare formulă și creează o instanță a acestei clase. Clasa generată dinamic conține o metodă care acceptă ca argumente variabilele prezente în formula dată și returnează valoarea corespunzătoare evaluării acesteia. Generarea on-the-fly a clasei are loc o singură dată, la pornirea programului. În acest fel, evaluarea unei formule are loc la fel de rapid ca în cazul în care formula ar fi înscrisă direct în codul algoritmului.

Depanarea

Aplicațiile bazate pe agenți sunt în general foarte adaptive, de aceea se pretează la rezolvarea unor probleme reale complexe, în medii dinamice. Pe de altă parte însă, depistarea neregulilor în astfel de aplicații este mai dificilă, pentru că în multe cazuri chiar și o implementare cu erori este capabilă să rezolve problema, chiar dacă nu atât de eficient pe cât ar fi posibil. În plus, pentru o euristică nou concepută nu se știe în avans cât de eficientă ar putea fi o implementare a acesteia, de aceea bug-urile care afectează numai performanța algoritmului pot rămâne foarte ușor neobservate. Deoarece mulți algoritmi bazați pe agenți sunt stohastici, reproducerea unui comportament neobișnuit se poate dovedi de asemenea dificilă.

Investigarea problemelor legate de aplicațiile bazate pe agenți presupune adesea o analiză detaliată a dinamicii stării interne a programului. AgSysLib oferă o componentă GUI care permite conectarea prin RMI (Remote Method Invocation) la o aplicație în curs de execuție și interogarea, urmărirea sau modificarea stării interne a acesteia. Componenta GUI este denumită teleconsolă de control. Deoarece ea poate stabili o conexiune nu doar la pornire, ci în orice moment al execuției unui program, teleconsola de control poate fi folosită și pentru a investiga un comportament neașteptat apărut pe parcursul execuției unui program care nu se afla de fapt în faza de depanare.

Accesul la starea internă a unui program este oferit prin intermediul unor script-uri în limbajul de programare Groovy. Astfel, se pot face interogări complexe ale stării interne a unui program sau se pot face modificări multiple ale acesteia, cum ar fi alterarea într-un anumit mod a stării fiecărui agent, folosind numai câteva linii de cod. Script-urile pot fi și înregistrate, pentru a fi executate la fiecare pas. În plus, rezultatele interogării stării interne pot fi folosite pentru a configura puncte de întrerupere condiționale foarte complexe.

BIBLIOGRAFIE

- [1] Philip Ball, "For sustainable architecture, think bug," *New Scientist*, no. 2748, pp. 35-37, February 2010.
- [2] Eric Bonabeau and Jean-Louis Dessalles, "Detection and emergence," *Intellectica*, vol. 2, no. 25, pp. 85--94, 1997.
- [3] Fabio Boschetti and Randall Gray, "A Turing Test for Emergence," in *Advances in Applied Self-organizing Systems*, Lakhmi Jain, Xindong Wu, and Mikhail Prokopenko, Eds.: Springer London, 2008, pp. 349-364.
- [4] David J Chalmers, "Strong and weak emergence," in *The Re-Emergence of Emergence.:* Oxford University Press, 2006, pp. 244-254.
- [5] M. Cook, "Universality in elementary cellular automata," in *Complex Systems, Vol. 15, Issue 1.*, 2004, pp. 1-40.
- [6] James P Crutchfield, "The calculi of emergence: computation, dynamics and induction," *Physica D*, vol. 75, no. 1-3, pp. 11--54, August 1994.
- [7] Vince Darley, "Emergent phenomena and complexity," *Artificial Life*, vol. 4, pp. 411--416, 1994.
- [8] Kevin Dooley, "Complex adaptive systems: A nominal definition," *The Chaos Network*, no. 8, pp. 2-3, 1996.
- [9] M Dorigo, A Colorni, and V Maniezzo, "Positive feedback as a search strategy," Dipartimento di Elettronica, Politecnico di Milano, Milan, Italy, Technical Report 91-016, 1991.
- [10] Marco Dorigo and Luca Maria Gambardella, "Ant Colony System: A cooperative learning approach to the traveling salesman problem," *IEEE Transactions on Evolutionary Computation*, vol. 1, no. 1, pp. 53-66, 1997.
- [11] M. Dorigo and T. Stützle, *Ant Colony Optimization.:* The MIT Press, 2004.
- [12] Gregory Gutin and Daniel Karapetyan, "A memetic algorithm for the generalized traveling salesman problem," *Natural Computing*, vol. 9, no. 1, pp. 47--60, March 2010.
- [13] John H Holland, "Complex adaptive systems," in *A new era in computation.* Cambridge, MA, USA: MIT Press, 1993, pp. 17--30.
- [14] Serban Iordache, "A Framework for the Study of the Emergence of Rules in Multiagent Systems," in *Proceedings of the 20th International DAAAM Symposium*, Vienna, Austria, 2009, pp. 1285-1286.
- [15] Serban Iordache, "Consultant-Guided Search Algorithms for the Quadratic Assignment Problem," in *Hybrid Metaheuristics - 7th International Workshop, HM 2010. LNCS*, vol.

- 6373, Vienna, Austria, 2010, pp. 148-159.
- [16] Serban Iordache, "Consultant-guided search algorithms for the quadratic assignment problem," in *Proceedings of the 12th annual conference companion on Genetic and evolutionary computation*, ortland, Oregon, USA, 2010, pp. 2089-2090.
- [17] Serban Iordache, "Consultant-Guided Search Algorithms with Local Search for the Traveling Salesman Problem," in *11th International Conference Parallel Problem Solving from Nature - PPSN XI. LNCS*, vol. 6239, Krakow, Poland, 2010, pp. 81-90.
- [18] Serban Iordache, "Consultant-guided search combined with local search for the traveling salesman problem," in *Proceedings of the 12th annual conference companion on Genetic and evolutionary computation*, Portland, Oregon, USA, 2010, pp. 2087-2088.
- [19] Serban Iordache, "Consultant-guided search: a new metaheuristic for combinatorial optimization problems," in *Proceedings of the 12th annual conference on Genetic and evolutionary computation, GECCO 2010. ACM Press*, Portland, Oregon, USA, 2010, pp. 225--232.
- [20] Serban Iordache and Florica Moldoveanu, "AgSysLib - A Software Tool for Agent-Based Problem Solving," *Scientific Bulletin of "Politehnica" University of Bucharest, C Series (Electrical Engineering)*, vol. 73, no. 2, 2011.
- [21] Serban Iordache and Petrica C. Pop, "An Efficient Algorithm for the Generalized Traveling Salesman Problem," in *Proceedings of the 13-th International Conference on Computer Aided Systems Theory (EUROCAST 2011)*, Las Palmas de Gran Canaria, Spain, 2011, pp. 264-266.
- [22] Ming Li and Paul Vitányi, *An introduction to Kolmogorov complexity and its applications*, 2nd ed.: Springer-Verlag New York, Inc., 1997.
- [23] Sean Luke, Claudio Cioffi-Revilla, Liviu Panait, Keith Sullivan, and Gabriel C Balan, "MASON: A Multiagent Simulation Environment," *Simulation*, vol. 81, no. 7, pp. 517-527, 2005.
- [24] C M Macal and M J North, "Agent-based Modeling and Simulation," in *Winter Simulation Conference*, Austin, TX, USA, 2009, pp. 86 -98.
- [25] John H Miller and Scott E Page, *Complex Adaptive Systems: An Introduction to Computational Models of Social Life.*: Princeton University Press, 2007.
- [26] M. Mitchell, J. P. Crutchfield, and R. Das, "Evolving Cellular Automata with Genetic Algorithms: A Review of Recent Work," in *Proceedings of the First International Conference on Evolutionary Computation and Its Applications (EvCA'96)*, Moscow, Russia, 1996.
- [27] Petrica C. Pop, "The Generalized Minimum Spanning Tree Problem," The Netherlands, PhD thesis 2002.
- [28] Petrica C. Pop and Serban Iordache, "A Hybrid Heuristic Approach for Solving the Generalized Traveling Salesman Problem," in *GECCO 2011: Proceedings of the Genetic and Evolutionary Computation Conference*, Dublin, Ireland, 2011.

- [29] Edmund M Ronald, Moshe Sipper, and Mathieu S Capcarrère, "Design, Observation, Surprise! A Test of Emergence," *Artificial Life*, vol. 5, pp. 225-239, 1999.
- [30] S.J. Russell and P. Norvig, *Artificial Intelligence: A Modern Approach*. Englewood Cliffs, NJ: Prentice Hall, 1995.
- [31] Thomas Stützle and Marco Dorigo, "ACO algorithms for the quadratic assignment problem," *New ideas in optimization*, pp. 33-50, 1999.
- [32] Thomas Stützle and Holger H Hoos, "MAX-MIN Ant system," *Future Gener. Comput. Syst.*, vol. 16, pp. 889--914, 2000.
- [33] G Theraulaz and E Bonabeau, "A brief history of stigmergy," *ARTIFICIAL LIFE*, vol. 5, no. 2, pp. 97-116, 1999.
- [34] Michael Wooldridge, *An Introduction to MultiAgent Systems.*: John Wiley & Sons, 2002.