

Influenta inteligentei artificiale asupra sistemelor suport pentru decizii de grup. Retele neuronale si algoritmi genetici

Asist. Loredana MOCEAN

Facultatea de Stiinte Economice, Catedra de Informatica Economica
Universitatea Babes-Bolyai, Cluj-Napoca

Artificial Neural Networks are collections of mathematical models that emulate some of the observed properties of biological nervous systems and draw on the analogies of adaptive biological learning. The key element of the ANN paradigm is the novel structure of the information processing system. It is composed of a large number of highly interconnected processing elements that are analogous to neurons and are tied together with weighted connections that are analogous to synapses.

Genetic algorithms are a part of evolutionary computing, which is a rapidly growing area of artificial. Essentially, Genetic Algorithms (GA) are a method of "breeding" computer programs and solutions to optimization or search problems by means of simulated evolution. Processes loosely based on natural selection, crossover, and mutation are repeatedly applied to a population of binary strings which represent potential solutions. Over time, the number of above-average individuals increases, and better fit individuals are created, until a good solution to the problem at hand is found.

This paper tries to present the some aspects of the influente of Artificial Intelligence in Groups Decision Support Systems: the Artificial Neural Networks and Generic Algorithms.

Keywords: Artificial Neural Networks, Genetic Algorithms, Groups Decision Support Systems.

Experienta își spune cuvântul. În numeroase cazuri, probleme manageriale complexe se confruntă cu două aspecte: fie sunt prea complexe pentru o formalizare matematică riguroasă iar algoritmul de rezolvare este prea complicat și de o complexitate prea mare, fie sunt prea costisitoare pentru a fi implementate prin tehnici de optimizare sau simulare.

„Pentru a depăși aceste dificultăți, se utilizează mai multe alternative de soluții bazate pe inteligență artificială, termen care desemnează o ramură a informaticii orientată către transpunerea pe calculator a unor proprietăți de raționament similare celor ale intelectului uman”¹.

Retele neuronale („Artificial neural networks”) apar ca o „soluție inteligentă la care se poate recurge în ultima instanță, atunci când celelalte metode de asistare informatică sunt inaplicabile din cauza slabei

structurării decizionale”². Ele se fundamentează în esență pe două concepte de bază:

- ✂ operarea la nivelul unor unități de procesare independentă
- ✂ existența unei legi de învățare.

Algoritmii bazati pe rețele neuronale sunt algoritmi paraleli și calculul este de asemenea paralel.

Tehnicile bazate pe rețele neuronale pot fi clasificate în tehnici *supervizate* și *nesupervizate*. În primul caz, un set de exemple de antrenare se prezintă secvențial, calculând ieșirile pe baza intrărilor curente. Rezultatele sunt ulterior comparate cu cele dorite, importanțele nodurilor fiind ajustate în scopul minimizării diferențierilor dintre ieșirile curente și cele dorite. În al doilea caz, se prezintă un vector de intrare dintr-un set de intrări posibile. Regula de învățare a rețelei ajustează importanțele nodurilor astfel încât exemplele de intrare sunt

¹ Nicolescu, O., *Sistemul informational managerial al organizației*, Ed. Economica, București, 2001, pg. 246

² Nicolescu, O. *Sistemul informational managerial al organizației*, Ed. Economica, București, 2001, pg. 249

grupate si clasificate pe baza proprietatilor statistice. În cazul SSD rețelele neuronale au fost utilizate la construirea si rezolvarea modelelor.

Pentru SSDG, dintre metodele de învățare nesupervizate, hartile autoorganizabile Kohonen constituie o metoda ideala pentru gruparea documentelor textuale. Orwig si Chen au adaptat acesti algoritmi pentru clasificarea rezultatelor unei sesiuni de generare a ideilor în cadrul SSDG (Orwig, R., Chen, H., Nunamaker, J.F, *A Graphical, Self-Organizing Approach to Classifying Electronic Meeting Output*, *Journal of the American Society for Information Science*, 48(2), 1997, pg. 157-170). Participatii examineaza ulterior lista sugerata împreuna cu comentariile aferente fiecarui concept în parte. Acestia pot de asemenea sa revizuiasca lista produsa în scopul realizarii consensului final. Hartile autoorganizabile au doua caracteristici distinctiv:

1) subiectele asemanatoare sunt grupate împreuna (ipoteza de proximitate);

2) regiunile mai largi reprezinta elemente mai importante în cadrul colectiei de date (ipoteza dimensiunii). Aceste caracteristici au implicatii deosebite în ergonomia analizei textului din punctul de vedere al interactiunii om-calculator.

Kohonen si-a fundamentat rețeaua pe asociativitatea neuronilor cerebrali. Rețeaua consta din doua straturi de noduri: un strat de intrare si un strat de mapare sub forma unei grile bidimensionale. Stratul de iesire actioneaza ca un strat de distributie. Numarul de noduri din stratul de intrare este egal cu numarul de elemente asociate intrarii. Fiecare nod al stratului de mapare contine de asemenea acelasi numar de elemente. Astfel, stratul de intrare împreuna cu fiecare nod al stratului de mapare poate fi reprezentat ca un vector care contine numarul elementelor de intrare. Rețeaua este complet conectata în sensul ca fiecarui nod din stratul de corendenta îi corespunde un nod de intrare (figura 1).




Fig. 1. Topologia hartilor autoorganizabile Kohonen

Aplicatiile tipice includ pe cele de vizualizare a starilor procesului sau a rezultatelor financiare prin reprezentarea dependentei dintre date. Un model al observatiilor multidimensionale, eventual un vector al trasaturilor, este asociat fiecărei unitati în parte. Harta încearca sa reprezinte toate observatiile disponibile cu o acuratete optima utilizând un set restrâns de modele. În acelasi timp modelele se ordoneaza pe grila astfel încât modele similare sunt apropi-

ate unul de altul iar cele mai putin similare mai îndepartate.

O serie de studii recente au adaptat aceste caracteristici pentru analiza si clasificarea textului. Astfel s-a realizat aplicatia WEBSOM pentru clasificarea textului si gruparea mesajelor trimise prin grupurile de stiri. Astfel de demersuri au o importanta deosebita mai ales pentru cazul SSDG distribuite, în cadrul carora imposibilitatea comunicarii verbale conduce inherent la o

ineficiența a structurării și la o focalizare mai lentă a procesului decizional. În condițiile în care scopul urmărit de sistemele suport de decizie este asigurarea unei funcționări normale a sistemului – obiect, rețelele neuronale se dovedesc rapide, robuste în efectuarea de raționamente aproximative și mai puțin sensibile la perturbări, dar sunt lipsite de facilitățile explicative proprii sistemelor expert.

Algoritmii genetici sunt „algoritmi generali de căutare care aplică principalele mecanisme ale vieții, *selectia* și *evolutia* pentru a favoriza conservarea și reproducerea, dintr-o populație numeroasă, a celor mai performanți, mai bine adaptați indivizi”³. Algoritmii genetici funcționează prin producerea de generații succesive de indivizi. Indivizii cei puternici supraviețuiesc iar indivizii neadaptați dispar imediat. Unitățile elementare care controlează evoluția sunt genele. Prin reproducere, genele părinților se combină și conduc la o nouă generație mai bine adaptată. Căutarea este realizată dintr-o populație de agenți neavând un punct unic de început. Astfel de agenți, denumiți siruri, puncte sau cromozomi, explorează un spațiu de căutare utilizând trei operatori de bază.

1. Sirul este evaluat în concordanță cu o *funcție de modelare* a obiectivului. Aceasta evaluează, influențează probabilitatea ca o anumită parte din sir să facă parte din următorul sir generat la următoarea serie de timp.

2. Sirurile selectate sunt recombinate, sau încrucisate, în speranța de a descoperi sirurile mai bune prin combinarea materialului genetic.

3. Sirurile selectate sunt modificate în mod aleator pentru a înlocui orice pierdere de varietate după procesul de selecție și încrucisare. În consecință algoritmii genetici sunt tehnici de căutare stohastice.

Selecția intervine într-o manieră similară cu cea naturală. Cromozomii ce sunt estimați cu ajutorul unei funcții predefinite de

optimalitate ca fiind buni, sunt din punct de vedere stohastic mai probabil de a fi reprezentați în cadrul populațiilor viitoare. Sirurile sunt construite prin înlocuirea din generația curentă, ținând cont de măsura de optimalitate, urmând ulterior să fie plasate în următoarea generație. Aceasta metodă este cunoscută sub numele de contorizare stohastică cu înlocuire sau mai comun „selecția ruletei”. Alte scheme de selecție includ selecția competiției, selecția ordonării, etc.

După ce procedura de selecție este completată, încrucisarea este aplicată cu o probabilitate fixă predeterminată, denumită rată de încrucisare. Membrii vor fi ulterior selectați cu o anumită probabilitate dată de rată de încrucisare.

Încrucisarea și mutația joacă un rol important în procesul de căutare. Acești operatori direcționează căutarea către zona cea mai promițătoare a spațiului de căutare prin evitarea unui optim local. Încrucisarea acționează ca operator de focalizare prin combinarea elementelor sirurilor determinate a fi mai promițătoare după operația de selecție. Ideea constă în combinarea a două siruri care au soluții relativ bune pentru a crea noi siruri care să conțină elemente de la ambii părinți. Pe de altă parte, mutația acționează pentru a introduce un nou sir căutării și de asemenea de a recupera sirurile eliminate anterior. Funcția de mutație, în sens matematic, abate căutarea de la un optim local.

O serie de probleme abordate în cadrul grupurilor sprijinite de un SSDG pot fi văzute ca o problemă de căutare în cadrul unui spațiu al posibilelor soluții. Acest spațiu de căutare este mult mai complex, altfel nu ar fi necesar un grup pentru rezolvare. În consecință, acestea implică găsirea soluției la o problemă destul de complexă, pentru care nu se poate garanta utilizarea exclusivă a unui sistem computerizat. De asemenea, problema sau situația necesită competențe diverse pentru a adresa în mod eficient problema.

Pentru aceste tipuri de probleme se va detalia mai jos un model de generare a ideii-

³ Zaharie, D, Albescu, F, s.a. *Sisteme informatice pentru asistarea deciziei*, Ed. Dual Tech, București, 2001, pg. 270

lor, negociere si învățare ca un simplu model genetic propus de Rees si Koehler⁴. Autorii sugereaza faptul ca utilizarea SSDG se comporta ca un simplu algoritm genetic în maniera în care solutiile posibile sunt generate, îmbunătățite si modificate în cautarea solutiei decizionale sau consensului. Pe de alta parte, procesul decizional de grup este el însusi un proces evolutiv. Fiind data o problema participantii propun anumite idei sau posibile solutii. Ideile promitatoare sunt interschimbate între participantii. Aceste propuneri sunt rafinate ulterior până în momentul în care grupul ajunge la un acord în ceea ce priveste solutia finala. În mod ocazional, sunt propuse idei sau solutii care diferita substantial. Propunerea unei idei sau procesul de generare poate fi descris ca o selectie. Generarea ideilor presupune încrucișarea. În fine, generarea aleatoare a ideilor sau a solutiilor (variata de la linia discutiilor curente) implica o mutatie. În mod evident analogia este simplista si nu încorporeaza toate nuanțele diferitelor elemente ale SSDG, însa ilustreaza procesele de baza din cadrul SSDG. Astfel rezolvarea problemei de către un grup asistat de un SSDG, poate fi modelata cu un algoritm genetic utilizând selectia, încrucișarea si mutatia.

Daca grupurile ce utilizeaza SSDG pot fi modelate ca un algoritm genetic, acest model devine benefic aprofundarii procesului decizional de grup. Variabilele si diferitele constrângeri de mediu ce influenteaza procesul ar putea fi legate de parametrii algoritmului genetic iar aspecte, precum comportamentul previzibil al sistemului, pot fi determinate si optimizate. Un motiv în plus pentru utilizarea algoritmilor genetici pentru modelarea procesului SSDG consta în baza de calcul ce include atât proprietati stohastice cât si deterministice. Se pot dezvolta astfel modele utile în simularea procesului decizional de grup. Acestea pot fi utilizate ulterior pentru a examina combinatiile diferitelor variabilele ale SSDG.

Proiectarea unui SSDG bazat pe algoritmi genetici presupune o buna înțelegere a mecanismului specific de functionare si a importanței valorilor parametrilor de selectie, încrucișare si mutatie, pentru a evita anumite riscuri de deviere spre solutii optime locale.

În consecinta, pe lângă dezvoltarea în continuare a deciziilor multicriteriale se poate observa implicarea tot mai profunda a metodelor provenite din cadrul inteligentei artificiale pe toate palierele de suport ale SSDG. Ca maniera de analiza, proiectare si integrare, metodele inteligentei artificiale par sa fie solutia cea mai adecvata a directiei de extindere a conceptelor SSDG catre o plaja cât mai larga de aplicatii, utilizatori si situatii decizionale.

⁴ Rees, J. si G. Koehler *Brainstorming, Negotiating and Learning in Group Decision Support Systems: An Evolutionary Approach*. În *Proceedings of the 32nd Hawaii International Conference on Systems Sciences*, Kauai, Hawaii, IEEE Computer Society Press, 1999