

The Possibility to Use Genetic Algorithms and Fuzzy Systems in the Development of Tutorial Systems

Conf.dr. Ileana Adina UȚĂ, prof.dr. Rodica MIHALCA,
asist. Anca ANDREESCU, lect.dr. Iulian ÎNTORSUREANU
Academia de Studii Economice București
Ing.dr. Ștefan KOVACS, INCDPM

In this paper we are presenting state of the art information methods and techniques that can be applied in the development of efficient tutorial systems and also the possibility to use genetic algorithms and fuzzy systems in the construction of such systems. All this topics have been studied during the development of the research project INFOSOC entitled "Tutorial System based on Eduknowledge for Work Security and Health in SMEs According to the European Union Directives" accomplished by a teaching staff from the Academy of Economic Studies, Bucharest, in collaboration with the National Institute for Research and Development in Work Security, the National Institute for Small and Middle Enterprises and SC Q'NET International srl.

Keywords: Tutorial system, genetic algorithms, fuzzy systems.

Algoritmi genetici pentru dezvoltarea sistemelor tutoriale

În continuare se prezintă succint un exemplu de algoritm genetic, folosit în cadrul unui sistem telematic tutorial, în care persoana instruită primește în mod direct, în timp real, feedback-ul la acțiunile pe care este solicitată să le desfășoare la locul în care este examinată, prin interpretarea imaginilor cu ajutorul unui algoritm genetic.

În cadrul algoritmului genetic se pleacă de la citirea serială a unei imaginii. Acest tip de citire "baleiază" imaginea, cu un strat de grosime definită și de pe urma fiecărei baleieri se obține un vector. Acest vector este transmis algoritmului genetic care încearcă să descopere, în baza sa de cazuri, vectori similari. Dacă o poate face, generează părinții inițiali iar dacă nu, părinții inițiali sunt generați aleator. Fiabilitatea fiecărui părinte este verificată prin raportare la imagine, fiind reținuți părinții cei mai fiabili. Aceștia generează la rândul lor copii asupra cărora sunt aplicați operatorii de tip mutație, în strânsă corelație cu datele din imagine; verificările odată făcute, soluțiile fiabile sunt trimise rețelei neuronale, pentru a declanșa procesul de învățare și trecere a datelor în baza de cazuri. Procesul este repetitiv până la parcurgerea completă a

imaginii. Schema sa generală poate fi observată în figura 1.

Descrierea în pseudocod a algoritmului genetic canonic este următoarea:

Alege populația inițială (mame și tați)

Evaluează fiabilitatea fiecărui individ

Repetă

Selectează indivizii care se vor reproduce

Dezvoltă aleator copii

Aplică operatori mutageni

Evaluează fiabilitatea fiecărui individ

Până ce imaginea a fost parcursă

O altă aplicație concretă a algoritmilor genetici o reprezintă interpretarea (din punct de vedere al securității) unor acțiuni aleatoare ale unui operator uman.

Din literatura de specialitate este cunoscut termenul de „algoritm de liber arbitru Hodgkin-Watters”, algoritm dezvoltat pentru interpretarea comportamentelor aleatorii ale subiecților umani.

Algoritmii dezvoltați cu metoda Hodgkin-Watters pot interpreta atât imagini statice, imagini și secvențe video cât și script-uri care să descrie activitatea unei persoane. Introducerea unui astfel de instrument poate oferi specialiștilor posibilitatea unor prognoze pe termen scurt și foarte scurt asupra acțiunilor unor subiecți, existând premisele unei inter-

venții înainte de producerea unui accident. Prezentăm în continuare aspectele esențiale din transcrierea adaptată a unui astfel de script și interpretarea Hodgkin-Watters



Fig.1. Procesarea cu ajutorul algoritmilor genetici

Script

Start script

Fr.1:Subiectul se apleacă spre stânga;

Fr.2:Subiectul clipește nervos;

Fr.2.1.Nu-și poate fixa privirea asupra indicatorului de temperatură-t.:00.33.31

Fr.2.2.Nu-și poate concentra privirea-t:00.33.32

Fr.2.3.Clipește spre indicator-t:00.33.33

Fr.3:Subiectul se clatină;

Fr.4:Subiectul pare dezorientat;

Fr.5:Subiectul duce mâna la cap.....

Conclusion

Aționați imediat pentru scoaterea subiectului din sala de control și preluarea controlului asupra procesului:

based on: ttpa.sda.con1.con22.....

Sisteme Fuzzy

Sistemele fuzzy pot fi utilizate în cadrul sistemelor tutoriale, pentru a oferi acestora abilitatea de a simula și modela activități în timp

real. Astfel, persoanele instruite pot fi puse în fața unor acțiuni și decizii reale, fără ca acest lucru să presupună dezvoltarea unor simulații foarte costisitoare sau lucrul în spațiu real cu posibilitatea de a provoca accidente.

În continuare va fi prezentat un subsistem de modelare fuzzy în timp real, dezvoltat de specialiștii de la SafetyNet – Germania și bazat pe teza de doctorat susținută în 2001 de către Jurgen Prohnowski (din cadrul SafetyNet-Germania) la Institutul informatic din Bonn [5].

Acest subsistem utilizează inferența fuzzy de tip Sugeno, introdusă pentru prima oară în 1985 sub denumirea de inferență fuzzy Takagi-Sugeno-Kang (Sugeno M., „Fuzzy measures and fuzzy intervals; a survey”, în „Fuzzy automata and decision processes”, pg.89-102, North-Holland, New York, 1977 precum și Sugeno M., „Industrial applications of fuzzy control”, Elsevier Science Pub.Co.,1985).

O regulă tipică fuzzy într-un model de ordin zero Sugeno are forma **if x is A and y is B then z=k** unde A și B sunt seturi fuzzy ale antecedentului regulii iar k este o constantă a consecinței regulii.

Pentru un model Sugeno de ordin primar regulile sunt de forma **if x is A and y is B then z=p*x+q*y+r** unde A și B sunt la fel ca și înainte seturile fuzzy ale antecedentului iar p, q și r sunt constante.

Sistemele care folosesc inferența de tip Sugeno permit folosirea tehnicilor adaptive pentru construirea modelelor fuzzy. Aceste tehnici adaptive permit ca sistemul fuzzy să "învețe" informații despre un set de date pentru a calcula funcțiile de apartenență care sunt cele mai bine adaptate pentru rezolvarea problemei, în această privință ele asemănându-se cel mai bine rețelelor neuronale.

Lucrarea propusă va folosi un astfel de sistem cunoscut sub denumirea de ANFIS (Adaptive Neuro-Fuzzy Inference System). Plecând de la un set dat de intrări-ieșiri (de exemplu poziția obiectelor dintr-o cameră/ poziția țintelor robotului) ANFIS dezvoltă un sistem de inferență fuzzy a cărui funcții de apartenență sunt ajustate corespunzător folo-

sind un algoritm de „propagare înapoi” (backpropagation). Acest aspect permite sistemului fuzzy să învețe din datele modelate, în condițiile în care parametrii asociați funcțiilor de apartenență se modifică în cursul procesului de învățare (condiții dinamice). Ajustarea acestor parametri este facilitată de un vector gradient care oferă o măsură a cât de bine modelează sistemul fuzzy setul de date de intrare/ieșire.

ANFIS folosește un set de date de testare-pentru instruire și de asemenea un set de date de verificare pentru a controla gradul în care modelul „super-folosește” datele. Această „super-folosire” determină ca, de la un anumit punct de lucru cu datele de testare curba de eroare a procesului de învățare să crească brusc. Setul de date de testare conține perechile input-output.

În continuare prezentăm, ca exemplu, un sistem fuzzy care urmărește comportamentul unui muncitor care trebuie să execute o intervenție de urgență. Pentru aceasta el trebuie să ajungă la un anumit obiect într-un mediu potențial ostil; sistemul ia în considerare ca seturi fuzzy de intrare următoarele tipuri de seturi, componente ale acestui mediu:

- obiecte fixe;
- obiecte în mișcare;
- uși (fixe sau în mișcare), caracterizate prin vectori proprii,

Ca set fuzzy de ieșire, succesul sau eșecul realizării sarcinii, exprimat prin probabilitatea succesului pe o plajă între 0 (eșec) și 1 (succes).

Schema grafică a acestui exemplu poate fi observată în figura 2:




Fig.2. Schema generală

Se poate observa că există mai multe obiecte fixe, un obiect mobil, o ușă care trebuie deschisă pentru a atinge ținta. Datele de intrare/ieșire au fost sistematizate într-un set de antrenament. Încărcarea acestui set de antrenament în sistemul fuzzy conduce la obținerea următoarei distribuții a datelor (figura 3).




Fig.3. Distribuția datelor în sistemul fuzzy




Fig.4. Distribuția datelor după încărcarea setului de validare

Setul de validare permite validarea modelului intrări-ieșiri. După încărcarea acestui set, distribuția va arăta ca în figura 4.

După ce s-a făcut și încărcarea setului de validare se aleg parametrii de intrare-ieșire, respectiv numărul de funcții de apartenență corespunzător numărului de seturi fuzzy și distribuția funcției de apartenență fuzzy specifică pentru fiecare set, în acest caz a fost preferată o distribuție gaussiană (figura 5).

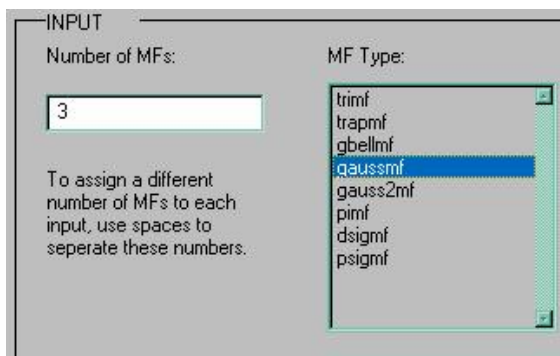


Fig.5. Alegerea parametrilor de intrare

Tipul ieșirii a fost ales tipul liniar. Figura 6 prezintă schema de inferență cu nodurile necesare pentru a ajunge de la intrare la ieșire folosind conectori de tip and, or și not.




Fig.6. Schema de inferență

Rezultatul obținut în urma instruirii sistemului fuzzy cu setul de antrenament este prezentat în figura 7.




Fig.7

Parametrii au fost astfel aleși astfel încât să nu se producă fenomenul de overfitting, respectiv curbele de eroare să fie constant descrescătoare. Pentru a obține acest lucru, nu-

mărul epocilor de antrenament a fost considerat 50 de epoci.

Rezultatul propriu-zis al instruirii sistemului de inferență adaptiv neuro-fuzzy este prezentat în figura 8:




Fig.8. Rezultatul instruirii sistemului de inferență adaptiv neuro-fuzzy

Se poate observa faptul că datele de validare se suprapun aproape perfect pe curba output-ului.

Concluzii

Utilizarea algoritmilor genetici și a sistemelor fuzzy în dezvoltarea sistemelor tutoriale oferă posibilitatea ca subiectul instruit să se apropie cât mai mult de realitate în procesul de instruire. Această apropiere se realizează prin „atragera” subiectului instruit în procese interactive care au loc în sisteme de referință pseudo-reale. Astfel, subiectul poate căpăta anumite deprinderi fără ca acest lucru să presupună folosirea unor simulatoare foarte costisitoare sau desfășurarea activității în realitate, cu posibilitatea de a produce accidente sau avarii.

Bibliografie

- [1]. Brubaker, D. (1996, April 11). Fuzzy cognitive maps. EDN, 41, 209-212.
- [2]. Contract 156/2004 INFOSOC – Faza I/2004
- [3]. Creangă Camelia (2000). Designing in safety, The Comoti experience, SafetyNet, www.safetynet.de
- [4]. Creangă Camelia (2000). Safety Integrators, Proceedings of the SafeCon Congress, Athens, June 2000
- [5]. J.Prohnowski „The mirror image-fuzzy techniques in safety assurance”, Ph.D.Thesis, Institut fur Informatik, Bonn, 15 sept 2001
- [6]. Kara-Zaitri, C. and Fleming, P. V. (1997). Applications of fuzzy inference methods to failure modes effects and criticality analysis (FMECA). International Conference on Safety and Reliability, 2403-2414.
- [7]. Kosko, B. (1986). Fuzzy cognitive maps. International Journal of Man-Machine Studies, 24, 65-75.
- [8]. Peláez, C. E. and Bowles, J. B. (1996). Using fuzzy cognitive maps as a system model for failure modes and effects analysis. Information Sciences, 88, 177-199.
- [9]. Russomanno, D. J., Bonnell, R. D., and Bowles, J. B. (1994). Viewing computer-

aided failure modes and effects analysis from an artificial intelligence perspective. Integrated Computer-Aided Engineering, 1(3), 209-228.

- [10]. Sugeno M., Industrial applications of fuzzy control, Elsevier Science Pub.Co.,1985
- [11]. Sugeno M., "Fuzzy measures and fuzzy intervals; a survey", în „Fuzzy automata and decision processes”, pg.89-102, North-Holland, New York, 1977