

ASPECTE PRIVIND MODELAREA ȘI REGLAREA UNOR PROCESE ENERGETICE UTILIZÂND INTELIGENȚA ARTIFICIALĂ

Horățiu Ștefan GRIF, Adrian GLIGOR

Universitatea "Petru Maior" din Tg. Mureș

Rezumat

Abilitatea de a învăța relații funcționale neliniare folosind numai datele de intrare/ieșire ale sistemului de controlat este o performanță atrăgătoare. Acesată lucrare este un exemplu al utilizării controlului inteligent într-o problemă de urmărire a unei traiectorii. Rezultatele oferă posibilitatea abordării în viitor a problemelor de optimizare a iluminatului, de management și economie de energie dintr-un alt punct de vedere, și anume cel al inteligenței artificiale.

Generalități

Inteligența artificială (IA) se definește ca un termen general pentru a descrie calculatorul sau programele care rezolvă problemele prin metode calitative, intuitive, similare ființelor umane, în locul metodelor strict cantitative bazate pe date și calcule exacte, specifice sistemelor digitale convenționale de calcul - [1]. Domeniul IA cuprinde trei componente:

- a) sisteme expert;
 - b) rețele neuronale artificiale;
 - c) sisteme fuzzy.
- a) Sistemele expert

Un sistem expert (SE) reprezintă un program alcătuit din două componente: o bază largă de date, respectiv un set de reguli de căutare în această bază, cu scopul găsirii soluției optime pentru o problemă dată. Baza de date și setul de reguli sunt dezvoltate prin chestionarea experților în problema dată. Spre deosebire de majoritatea programelor de calcul, care cer informații complete pentru luarea deciziilor, programele SE sunt proiectate să găsească soluția optimă pe baza datelor disponibile, la fel cum ar face un expert uman. De asemenea SE pot fi

proiectate, ca în cazul diagnozei, să poată sugera testele suplimentare necesare pentru clarificarea diagnosticului (de exemplu, în cazul unui SE pentru diagnoză medicală).

Sistemele expert au un mare avantaj în comparație cu experții umani: cunoștințele acumulate de mai mulți experți se pot interschimba sau transmite la scară planetară prin actualele sisteme moderne de comunicații în rețele.

b) Rețelele neuronale artificiale

Se cunoaște că în creierul uman există miliarde de celule nervoase sau neuroni. Ieșirea fiecăruia este conectată la intrarea câtorva mii de alți neuroni prin sinapse. Dacă suma semnalelor de la intrarea unui neuron depășesc un anumit prag, atunci neuronul se excită și trimite un semnal altor neuroni.

O rețea neuronală artificială (RNA) reprezintă un ansamblu de procesoare (neuroni) puternic interconectate, organizate în structuri masiv paralele și care pot rezolva probleme complexe prin cooperarea între elementele simple de calcul. Deci au fost împrumutate caracteristici ale fiziologiei creierului.

RNA se pot implementa în mod hard sau soft.

Implementările hard se realizează pe două căi:

- Prin procesor dedicat fiecărui neuron. Soluția este foarte performantă ca rapiditate, dar costisitoare prin efortul tehnologic reclamat de realizarea unor chip-uri adecvate.
- Printr-un singur procesor global asociat cu un tabel de conexiuni (lookup table). Unei RNA îi este asociat un tabel pentru a specifica numărul și tipul conexiunilor, împreună cu ponderile respective. Procesorul are menirea de a accesa în mod dinamic tabelul pentru a răspunde unei

aplicații. Soluția este de fapt mixtă, hard/soft, dar este mai ieftină, fiind realizabilă de pildă sub forma unor plăci electronice (plug-in cards) compatibile cu calculatoarele PC.

Implementările soft, mai frecvente, reprezintă defapt niște programe de simulare a RNA. Aceste programe permit atât executarea fazei de antrenare a rețelei cât și a fazei de operare în aplicația dată. Soluția soft este foarte convenabilă ca și cost, dar performanțele de viteză sunt limitate, fiind dependente de tipul calculatorului pe care sunt executate programele respective. Din acest motiv, multe din soluțiile oferite de RNA nu sunt satisfăcătoare în aplicații de timp real - [1].

Câteva avantaje ale RNA:

- Nu trebuie programate, ci învățate (antrenate) să producă răspunsul dorit. Din acest motiv costurile programării unei aplicații sunt eliminate.
- Își pot îmbunătăți răspunsul prin învățare. De exemplu, o RNA se poate readapta în situația în care i se prezintă la intrare o structură diferită de cea cu care s-a antrenat.
- Datele de intrare pot să nu fie precise, pentru că o RNA lucrează cu sume de intrări. De exemplu, o rețea de recunoaștere a unei ființe umane poate satisface (recunoaște omul respectiv) și dacă persoana și-a schimbat coafura între timp. Sistemele de calcul digitale convenționale efectuează această operație de recunoaștere extrem de dificil.
- Informația dobândită nu este păstrată în locații specifice de memorie ca și în cazul calculatoarelor digitale. Ea este stocată "asociativ", sub forma unei rețele de interconexiuni condiționate. Rezultatul este că, prin distrugerea câtorva neuroni, informația stocată nu se degradează într-atât încât să modifice comportarea RNA.

c) Sistemele fuzzy

Logica incertă (fuzzy logic), spre deosebire de logica exactă-binară operează cu elemente vagi. Obiectivul preferat al logicii fuzzy îl reprezintă regulatoarele (controlerele) din structura sistemelor automate. Un controler fuzzy este programat cu reguli, la fel ca un sistem expert, dar regulile lui sunt mult mai flexibile.

Câteva avantaje ale sistemelor fuzzy:

- Pot lucra cu termeni imprecizi ca: frig/cald/fierbinte, aproape/depart, rapid/lent, care sunt dificil și arbitrar măsurabili, chiar și pentru ființele umane. În termeni hard aceasta înseamnă că sistemele fuzzy nu reclamă convertoare analog/digitale precise pentru achiziționarea semnalelor.
- Sunt capabile de a controla foarte lin sistemele mecanice, cât mai confortabil cu putință.

Schema de control și modelare

Modulul de învățare (modelare proces) este utilizat pentru a modela procesul on-line, el primind la intrare semnalul de control u aplicat procesului. Regulatorul și blocul de modelare a procesului sunt incluse în rețeaua neuro-fuzzy - [4].




Fig.1. Schema de reglare

Configurația utilizată a schemei de modelare și control este prezentată în Fig.1, unde r reprezintă semnalul de referință iar u reprezintă semnalul de comandă.

Partea de modelare și control este realizată cu o rețea neuro-fuzzy, mai exact o combinație între o rețea neuronală artificială de tip memorie asociativă (MA) și un sistem fuzzy. Rețeaua neuro-fuzzy utilizată poate fi reprezentată ca un sistem cu trei nivele (straturi) - [4] după cum urmează:

- nivelul intrărilor normalizate;
- nivelul funcțiilor bază (basis function);
- nivelul vectorului de ponderi și ieșirea sistemului.

În prezenta lucrare a fost utilizat un controler realizat cu o rețea neuro-fuzzy de tip B-spline, implementat în formă adaptivă. Spațiul normalizat bidimensional este câmpul de intrare

al rețelei neuro-fuzzy. Spațiul intrărilor este format din:

- eroarea de referință (diferența dintre ieșirea curentă și ieșirea de referință);
- viteza de variație a erorii (diferența dintre eroarea curentă și cea anterioară).

Stratul ascuns este reprezentat de un set de funcții bază care în cazul de față sunt funcții B-spline. Seturile parametrilor adaptivi - vectorul de ponderi - sunt antrenate pe rând pentru a obține comportarea dorită. MA B-spline își modifică vectorul de ponderi folosind în general algoritmi instantanei de tipul celor mai mici pătrate (CMMP), cu scopul de a realiza o aplicație particulară, modificând ponderea cu care o funcție de bază particulară contribuie la ieșirea rețelei - [2,3]. Reprezentarea distribuției interne a rețelei simplifică procesul de învățare printr-un mic procent al ponderilor care contribuie la ieșire și numai prin acei parametri care sunt modificați de regula CMMP. De aceea, această rețea are potențialul de a fi folosită pentru învățarea on-line deoarece algoritmul adaptiv operează în timp real și legile de adaptare sunt liniare. Pentru aplicații mai complexe de învățare, structura modelului (definirea funcției de bază, intrări etc.) trebuie învățată din date de antrenare ca și cunoștințe apriori. Este posibil să obținem algoritmi de inițializare pentru rețelele cu funcții B-spline care exploatează faptul că pe măsură ce flexibilitatea rețelei crește, noul model îl poate reproduce pe cel vechi exact. Noi variabile pot fi introduse pentru a permite informație suplimentară, mărinde sensibilitatea rețelei cu referire la o variabilă de intrare. Toate aceste tehnici fac rețeaua mai inteligentă, dar comportamentul ei devine mai imprevizibil și calculele sunt semnificative - [2,3].

Rezultate experimentale

Pentru experimentare s-au luat trei tipuri de traiectorii: una formată dintr-o succesiune de trepte generate aleator (Fig.2), o traiectorie dintr-o succesiune de trepte și rampe generate aleator (Fig.3, Fig.4) și respectiv una sinusoidală (Fig.5). Ponderile rețelei neuronale au fost inițializate cu zero. Durata unei simulări este de 5 s, respectiv

perioada de eșantionare de 10 ms. Simulările s-au realizat în limbajul Borland C++.

Ca aplicație, schema de reglare poate fi utilizată la menținerea constantă a iluminării din încăperi (birouri, spații comerciale, hale etc.) la nivel corespunzător unei bune desfășurări a activităților profesionale indiferent de variația intensității luminii naturale (tranzițiile: noapte-zi, zi-noapte, senin-înnorat).




Fig.2 Y1-iesirea prescrisă, Y2-iesirea reală




Fig.3 Y1-iesirea prescrisă, Y2-iesirea reală




Fig.4 Y1-iesirea prescrisă, Y2-iesirea reală




Fig.5 Y1-iesirea prescrisă, Y2-ieșirea reală

Concluzii

După cum se observă din figurile de mai sus, indiferent de tipul traiectoriei impuse, în prima fază eroarea de reglare este foarte mare deoarece inițial rețeaua neuro-fuzzy nu are nici o informație despre proces, iar pe măsură ce RNA învață eroarea de reglare scade.

Bibliografie

[1] Viorel Trifa, Elena Ioana Gaură, Rețele Neuronale Artificiale. Arhitecturi Fundamentale. Editura Mediamira 1996.

[2] Junhong, N. Derek, A.L., Fuzzy-Neural Control, Prentice Hall, 1995

[3] Brown, M. Harris C., Neurofuzzy Adaptive Modelling and Control, Prentice Hall, 1994.

[4] Laszlo F. Marton, Horațiu Grif, Tihamer S. Brassai. CMAC Type Artificial Neural Network Used in Trajectory Following. RAAD 1998 Bratislava.

Abstract

The ability of learning nonlinear functional relations using input/output data only of controlled system is an attractive performance. This paper present a study of using intelligent control in a trajectory tracking problem. The results provide the possibility of approaching in future of lighting optimization, energy management and economy problem from artificial intelligence point of view.

Horațiu Ștefan GRIF, preparator

Adrian GLIGOR, preparator

Universitatea "Petru Maior" din Tg. Mureș, Str. Nicolae Iorga Nr.1, 4300 - Tg. Mureș

e-mail: hgrif@uttgm.ro

e-mail: agligor@uttgm.ro