New Architectures of Neuronal Networks

Lect.dr. Cristina COCULESCU
Universitatea Româno-Americană Bucureşti

Because of need to overrun some lacks of classical models of neuronal networks (the multi – system perceptron, Hopfield's network etc.) it appeared a series of new architectures of neuronal networks that have a big degree of specialization on solving some real problems. Some of these modern theories have also a biological motivation like the non – cognitron or the network based on adaptive resonance that reach to join a series of mechanisms of human feelings. Others, like fuzzy neuronal networks or „walvet" networks, are joints between neuronal model and some mathematical theories.
Keywords: *random neuronal network, fuzzy neuronal network, evolutional computing, genetic algorithms.*

Rețele neuronale probabilistice

Modelarea rețelelor neuronale cu ajutorul teoriei probabilităților sau a teoriilor de incertitudine aduce o serie de avantaje față de abordările deterministe, cum ar fi:

- reprezentarea mai veridică a modului de funcționare a rețelelor neuronale biologice, în care semnalele se transmit mai ales ca impulsuri;
- eficiență de calcul superioară celei din cadrul rețelelor feedforward, cu 4-5 ordine de mărime;
- instruire uşoară şi cvasiinstantanee, rezultând posibilitatea folosirii acestor rețele neuronale în timp real;
- forma suprafețelor de decizie poate fi oricât de complexă prin modificarea unui singur parametru (de netezire), ele putând aproxima optim suprafețele Bayes;
- pentru statistici variabile în timp, noile forme pot fi suprapuse peste cele vechi;
- comportare bună la forme de intrare cu zgomot sau/şi incomplete.

Astfel pentru o problemă biclasă, se consideră o rețea neuronală probabilistă în care stratul numit *„unități ale formei"* conține elemente având structura din figura 1 **[2]**.

Pentru o distribuție normală a densității de probabilitate, estimatorul pentru clasa A este:

$$f_A(x)=\frac{1}{(2\pi)^{p-2}\sigma^p}\frac{1}{m}\sum_{i=1}^{m}\exp\left|-\frac{(x-x_{Ai})^t(x-x_{Ai})}{2\sigma^2}\right| \quad (1)$$

funcție ce apare la ieşirea unității formei, unde $X \to W$. Unitățile sumatoare adună datele de la unitățile formei ce corespund mulțimii de instruire şi au o pondere variabilă, C_k (figura 2).

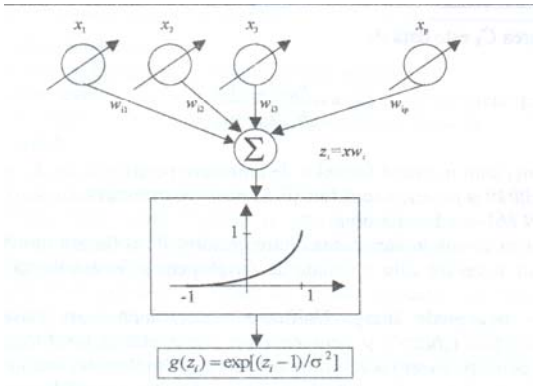

Fig. 1. Unitatea formei

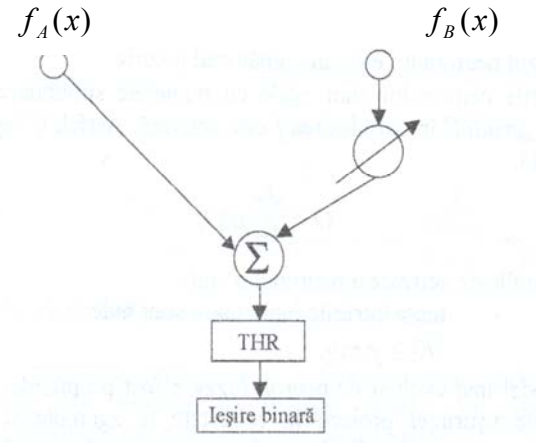

Fig. 2. Neuron sumator

Ponderea C_k este dată de: $C_k=-\frac{h_{BK}I_{Bk}}{h_{AK}I_{Ak}}\frac{n_{Ak}}{n_{Bk}}$ (2), unde n_{Ak} şi n_{Bk} sunt numărul formelor

de antrenare pentru clasele A_k, respectiv B_k, *h* sunt probabilităţi *a priori*, *I* sunt funcţii de pierdere în cazul unei decizii eronate, iar *THR* (figura 2) este funcţia prag.
Instruirea constă în identitatea dintre vectorul W_i şi fiecare formă de antrenare *X*. Astfel este necesară câte o unitate de formă pentru fiecare formă din mulţimea de instruire.

Reţele neuronale fuzzy

Unificarea celor două mari clase de sisteme cognitive: nuanţate (*„fuzzy"*) şi neuronale s-a impus atât la nivel topologic (pentru neuroni şi ponderi fuzzy) cât şi la cel al algoritmilor de instruire. Utilizarea mecanismelor de inferenţă nuanţată măreşte capacitatea reţelelor neuronale de a recunoaşte/clasifica forme complexe, distorsionate sau incomplete **[6], [*3]**.
Există mai multe modele de neuroni nuanţaţi (*„fuzzy"*), unul fiind introdus de S. Lee, prin generalizarea clasicului neuron McCulloch-Pitts prin următoarele aserţiuni:

- $e_j(k)$, $i_j(k) \in [0,1]$, unde $e_j(k)$ este *„gradul"* în care intrarea excitatoare acţionează la momentul *k* iar $i_j(k)$ este intrarea inhibitoare, astfel, intrarea este acum mulţimea nuanţată. $E = \sum_{i=1}^{m} e_i(k) E_i$ (3), cu E_i o serie de etichete.
- Pragul neuronului este un număr real pozitiv.
- Ieşirile neuronului sunt egale cu numerele subunitare şi pozitive m_j, ce denotă *„gradul"* în care ieşirea *j* este activată. Astfel, şi ieşirea este o mulţime nuanţată,

$$O = \sum_{i=1}^{p} \mu_i O_i \quad (4)$$

- Regulile de activare a neuronului sunt: toate intrările inhibitoare sunt nule; $|E| \geq prag$.

Un model mai evoluat de neuron fuzzy a fost propus de T. Yamakawa, care are avantajele uşurinţei proiectării, robusteţe la zgomote şi forme incomplete, precum şi viteză mare de clasificare în varianta hardware. De asemenea, decizia poate fi luată cu un singur strat al reţelei neuronale. Modificările constau în:

- ✓ Ponderile se înlocuiesc cu funcţii de apartenenţă.
- ✓ Intrările excitatoare şi cele inhibitoare sunt reprezentate prin funcţiile MAX, respectiv prin complementii logici urmaţi de MIN.
- ✓ Nu există prag.

O altă structură de reţea neuronală a fost propusă de către T. Watanabe care foloseşte neuronul logic (figura 3), şi prezintă avantajul vitezei şi al unei capacităţi discriminatorii remarcabile (pragul este independent de mărimea, în biţi, a componentelor vectorului de intrare). În această reţea există două tipuri de vectori pondere, ajustarea vectorului rezultant realizându-se după diferenţa dintre ieşirea dorită şi răspunsul sistemului la diferite intrări în cursul instruirii. Ieşirea z_i este generată prin propagarea *înainte* a informaţiei. Pentru fiecare vector de intrare, ieşirea neuronului logic *I* primeşte răspunsul dorit d_i, conform unei asignări anterioare.
Neuronul logic prezentat reprezintă o extensie a structurilor neuronale ADALINE şi MADALINE propuse de Widrow (1988), în care adaptarea ponderilor se face cu algoritmul MEP (minimizarea erorii pătratice).

Principii de calcul evolutiv

Problema fundamentală în proiectarea reţelelor neuronale este găsirea unei topologii capabile să rezolve o anumită problemă. Datorită numărului mare de restricţii legate de stabilirea ponderilor, metodele tradiţionale eşuează în rezolvarea problemelor de mare complexitate.
Astfel au apărut o serie de metode moderne de căutare care rezolvă probleme complexe de optimizare pornindu-se de la algoritmii genetici. Aceştia se bazează pe paradigma biologică a evoluţiei vieţii mai exact pe „mecanica selecţiei naturale şi a geneticii, rezultând algoritmi în care este implicat şi flerul inovator al căutării umane" (D.E. Goldberg, 1989) **[2]**.
Astăzi evoluţia este privită ca un proces de optimizare bazat pe populaţie. Teoriile matematice subsumate acestei direcţii pot fi grupate sub denumirea de *calcul evolutiv*.
În cadrul *calculului evolutiv* există trei direc-

ții de cercetare care se întrepătrund: algoritmii genetici, strategiile de evoluție şi programarea evolutivă. Dintre acestea, algoritmii genetici au căpătat o importanță deosebită în proiectarea şi instruirea rețelelor neuronale.

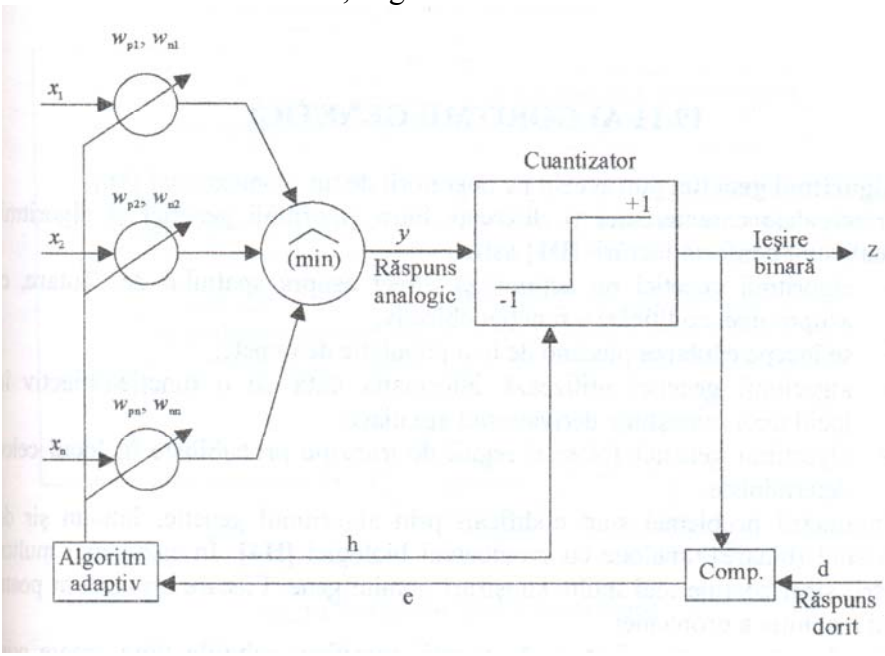

Fig. 3. Configurația unui neuron logic tip AND

În ultimii ani s-au făcut cercetări intense privind utilizarea calculului evolutiv şi a algoritmilor genetici pentru determinarea topologiei optime şi a distribuției ponderilor. Aceste studii au dus la următoarele concluzii:

- Aplicarea algoritmilor genetici în proiectarea topologiilor de rețea neuronală. Se variază numărul straturilor ascunse şi cel al nodurilor. Instruirea foloseşte combinarea calculului genetic cu propagarea înapoi;
- Utilizarea algoritmilor genetici pentru aflarea distribuției optime a ponderilor rețelei, fiind dată topologia ei. Funcția de evaluare conduce la creşterea preciziei pasului de adaptare a ponderilor. Dezavantajul constă în mărirea complexității soluțiilor;
- Folosirea tehnicilor evolutive pentru a recompensa diferite funcții de învățare, care determină strategia de instruire să devină adaptivă.

Topologiile şi ponderile pot fi codificate direct prin şiruri binare; astfel spațiul soluțiilor creşte iar eficiența algoritmului scade. Practic, se alege fie proiectarea topologiei, fie adaptarea ponderilor rețelei, în funcție de natura problemei de rezolvat.

Un alt motiv al utilizării calculului genetic pentru instruirea rețelelor neuronale este acela că adesea informația de gradient (pentru actualizarea ponderilor) nu este disponibilă sau este greu de obținut.

Ponderile unei rețele notată cu η pot fi modificate folosind regula de actualizare:

$$w = w + N(0, \alpha\varepsilon(\eta)),\ (\forall)w \in \eta \quad (5)$$

unde $\varepsilon(\eta)$ este eroarea (medie pătratică) rețelei conform problemei de rezolvat, α este o constantă iar $N(\mu\sigma^2)$ este o variabilă aleatoare cu distribuție normală.

Folosirea principiilor evolutive oferă performanțe deosebite (în termeni de eroare pătratică medie) față de metodele consacrate, cum sunt selecția supervizată, auto-organizare de tip Kohonen sau metoda celor mai mici pătrate ortogonale.

Funcția de performanță (*evaluare*) asociată fiecărui individ este *eroarea medie pătratică* şi calculată după determinarea ponderilor λ_{ij} folosind metoda celor mai mici pătrate. Eroarea se scrie în acest caz astfel:

$$RMS = \left[\frac{1}{p}\sum_{k=1}^{p}(d_k - y_k)^2\right]^{\frac{1}{2}} \quad (6)$$

unde p este cardinalul mulțimii de instruire.

Scopul algoritmului genetic este de a mini-

miza această eroare. Instruirea urmăreşte obţinerea celui mai bun individ (având valoarea minimă a evaluării) după un număr specificat de generaţii şi rulări ale algoritmului.

Bibliografie

[1]. BLANCHARD, D., *Imagining the Future of Manufacturing*, 1995

[2]. DUMITRESCU, D., HARITON, C., *Reţele neuronale. Teorie şi aplicaţii*, Editura Teora, Bucureşti, 1996.

[3]. NEAGU, C., IONIŢĂ, C., *Reţele neuronale. Teorie şi aplicaţii în modelarea şi simularea proceselor şi sistemelor de producţie,* Editura MATRIX ROM, Bucureşti, 2004

[4]. SHIN, Y. C., VISHNUPAD, P., *Neuro-fuzzy control of complex manufacturing processes*, International Journal of Production and Research, v. 34 no. 12, S.U.A., 1996

[5]. SMITH, L., *An Introduction to Neural Network*, 1998

[6]. TEODORESCU, H. N., CHELARU, M., GÂLEA, D., NISTOR, S., TOFAN, I., *Sisteme Fuzzy şi Aplicaţii* , Institutul Politehnic Iaşi, 1989

[7]. TODERAN, G., COŞTEIU, M., GIURGIU, M., *Reţele neuronale*, Editura Microinformatica, Cluj-Napoca, 1994

[*1]. **** - *History of the Development of Neural Networks*. 1998
http://www.ncs.co.uk/nn_hstry.htm

[*2]. **** - *How a Genetic Algorithm Works*. 1998
http://www.ncs.co.uk/ga_wrks.htm

[*3]. **** - *Intelligent technologies – Fuzzy logic*.1998
http://www.ncs.co.uk/nn_fzy.htm