

Fișa suspiciunii de plagiat / Sheet of plagiarism's suspicion	Indexat la: 0131/01
--	--------------------------------

Opera suspicionată (OS) Suspicious work	Opera autentică (OA) Authentic work
--	--

OS	TRIFA, Viorel; GAURĂ, Elena Ioana. <i>Rețele neuronale artificiale. Arhitecturi fundamentale</i> . Cluj-Napoca: Mediamira. 1996.
OA	CICHOCKI, A.; UNBEHAUEN, R. <i>Neural networks for optimization and signal processing</i> . Chichester, New York: John Wiley & Sons. 1992.

Incidența minimă a suspiciunii / Minimum incidence of suspicion	
--	--

p.29: Fig.3.7	p.54: Fig.2.9
p.29:02-p.32:26	p.56:01-p.59:12
p.30: Fig.3.8	p.56: Fig.2.10
p.33:Fig.3.10	p.59:Fig.2.11

Fișa întocmită pentru includerea suspiciunii în Indexul Operelor Plagiate în România de la www.plagiate.ro

Notă: p.72:00 semnifică textul de la pag.72 de la începutul până la finele paginii.

**VIOREL TRIFA
ELENA IOANA GAURĂ**

**REȚELE
NEURONALE
ARTIFICIALE**

Arhitecturi Fundamentale

**EDITURA MEDIAMIRA
1996**




Fig. 3.7.

logice și anume funcții logice lineare separabile (AND, NOT, OR) [4].

3.1.6. Modelul Hopfield al neuronului artificial

Astăzi modelul Hopfield al neuronului este probabil cel mai popular model dinamic al celulei neuronale artificiale [6,17,18]. În figurile 3.8a și b sunt prezentate structura de circuit și structura funcțională a acestui model neuronal.

Circuitul constă într-un condensator C_j , rezistoare R_{ji} și un amplificator neliniar cu funcție de transfer sigmoid. Se presupune că amplificatorul furnizează două ieșiri simetrice (tensiunea v_j și tensiunea $-v_j$) pentru a ne asigura că toate ponderile sinaptice simulate au valori pozitive. De aici rezultă că o pondere sinaptică pozitivă este realizată prin conectarea rezistorului R_{ji} la $(+v_i)$ iar o pondere negativă prin conectarea lui R_{ji} la $(-v_i)$. Curentul I_j reprezintă biasul (sau semnalul de intrare extern independent).

Neuronul este descris de ecuația diferențială:

$$C_j \frac{du_j}{dt} = -\frac{u_j}{R_j} + \sum_{i=1}^n \frac{v_i}{R_{ji}} + I_j \quad (3.15)$$




Fig. 3.8a.

unde $v_j = \psi(u_j)$ ($j=1 \dots n$) este funcția de activare sigmoid și:

$$\frac{1}{R_j} = \frac{1}{R_{j0}} + \sum_{i=1}^n \frac{1}{R_{ji}}$$

în care cu G_{ji} s-au notat conductanțele. Varianta normalizată a setului de ecuații de mai sus este [33]:

$$\tau_j \frac{du_j}{dt} = -\alpha_j u_j + \sum_{i=1}^n w_{ji} x_i + \theta_j$$

$$x_j = \psi(u_j)$$

(3.16)

unde: $x_i = v_i$ ($i=1 \dots n$) sunt




Fig. 3.8b.

semnalele de intrare (tensiuni, potențiale); u_j este un semnal intern numit potențial intern, stimul sau potențial de acțiune; $\tau_j = r_j C_j$ este constanta de timp

de integrare; r_j este rezistența de scalare; $\alpha_j = r_j / R_j$ este un coeficient de amortizare sau atenuare, factor de scăpări sau uitare, care face semnalul intern u_j zero pentru intrări nule; $w_{ji} = \pm r_j / R_{ji} = \pm r_j G_{ji}$ sunt ponderi sinaptice; $\theta_j = r_j I_j$ este offsetul (semnal extern independent).

Diagrama bloc funcțională din figura 3.9b constă dintr-un sumator cu ponderile sinaptice w_{ji} , un integrator cu amortizare și un element neliniar de decizie sau limitare (amplificator) cu o funcție de activare sigmoid. Amplificatorul folosit în modelul Hopfield (cu două ieșiri simetrice $\pm x_j$) este caracterizat de o funcție monotonă și diferențiabilă, descrisă de relația:

$$\psi(u_j) = \frac{1}{1 + e^{-\gamma u_j}} \quad (3.17)$$

sau :

$$\psi(u_j) = \tanh(\gamma u_j) \quad (3.18)$$

unde $\gamma > 0$ determină panta sau rata de creștere, care de obicei nu este fixă, ea fiind variabilă pe parcursul procesului de calcul.

Constantele de timp ale amplificatorului sunt considerate neglijabile. Dinamica întregului neuron este determinată de capacitatea C_j și rezistența R_{ji} . Dinamica poate fi ajustată printr-o scalare corespunzătoare. Ponderile sinaptice sunt determinate de conductanțele de intrare $G_{ji} = \frac{1}{R_{ji}}$ conectate la unul dintre terminalele de ieșire $+v_j$ sau $-v_j$ ale amplificatorului j .

3.1.7. Modelul Grossberg al neuronului artificial

Neuronul artificial dezvoltat de Grossberg poate fi descris matematic de următoarele două ecuații [22]:

a) Ecuația de stare a neuronului:

$$\tau_j \frac{du_j}{dt} = -\alpha_j u_j + (\gamma_j - \beta_j \mu_j) [\sum_{i=1}^n w_{ji} \psi_i(u_i) + \theta_j] \quad (3.19)$$

b) Ecuația generală de învățare:

$$\frac{dw_{ji}}{dt} = -[b_{ji} w_{ji} + d_{ji} \psi(u_i)] h_i(u_i) \quad (3.20)$$

unde u_i este activarea internă a neuronului; starea neuronală de ieșire x_j este legată de activarea internă u_j prin relația: $x_j = \psi_j(u_j)$; α_j , β_j , γ_j sunt constantele responsabile de uitare, controlul automat al câștigului, respectiv activitatea totală de normalizare; $\alpha_j \mu_j$ reprezintă atenuarea pasivă exponențială în absența intrărilor (atât intrări sinaptice cât și intrări externe directe); θ_j este intrarea externă directă.

Funcția $x_i = \psi_i(u_i)$ reprezintă activarea neliniară; în acest model sunt folosite funcții de activare neliniară cu diferite expresii. Coeficienții w_{ji} sunt ponderile sinaptice ajustate conform ecuației de învățare. Coeficientul b_{ji} este termenul de uitare care reprezintă atenuarea pasivă joasă a ponderilor sinaptice dacă b_{ji} este constant. Pierderea memoriei este modulată dacă b_{ji} este variabil în timp. Coeficientul d_{ji} este puterea de învățare care controlează viteza de învățare și reprezintă plasticitatea sinapsei w_{ji} .

Funcția $\bar{y}_i = \bar{\psi}_i(u_i)$ este "semnalul de învățare" neuronal care descrie starea neuronului i în același mod ca și $x_i = \psi_i(u_i)$, deși este permisă utilizarea unor funcții de activare diferite pentru ieșire și pentru procesul de învățare [22]. Funcția $h_i(u_i)$ este activarea ce reprezintă forma învățării și procesul de memorare în sinapsa w_{ji} stimulată de activitatea ce vine spre celulă.

O schemă bloc funcțională simplificată a modelului Grossberg pentru neuronul artificial este prezentată în figura 3.10.

Termenii de sumare din ecuația (3.19) sunt de cele mai multe ori împărțiți în doi termeni separați, cu sinapse excitatorii (w_{jiE}) și inhibitorii (w_{jiI}), adică:

$$\tau_j \frac{du_j}{dt} = -\alpha_j \mu_j + (\gamma_{jE} - \beta_{jE} \mu_j) \left[\sum_{i=1}^{n_E} w_{jiE} \psi_{iE}(u_i) + \theta_{jE} \right] - (\gamma_{jI} + \beta_{jI} \mu_j) \left[\sum_{i=1}^{n_I} w_{jiI} \psi_{iI}(u_i) + \theta_{jI} \right] \quad (3.21)$$

Cele mai multe modele ale neuronilor artificiali pot fi considerate cazuri particulare ale acestui model.

3.1.8. Unitatea neuronală dinamică

În literatura de specialitate a fost propusă o nouă arhitectură pentru a modela neuronul biologic, numită unitate neuronală dinamică (Dynamic Neural




Fig. 3.10.

Unit - DNU), structura ei fiind analogă cu aceea a unui circuit reverberat într-un bazin neuronal al sistemului nervos central [14]. Topologia unității neuronale dinamice cuprinde elemente de întârziere, ponderi sinaptice feed-forward și de reacție și un operator neliniar.

Algoritmul de antrenare pentru unitatea neuronală dinamică a fost extins, luând în considerare ideea că principalul corp al neuronului, soma, se poate de asemenea modifica în timpul procesului de învățare sau adaptare.

A fost dezvoltat un model simplu al învățării somatice, considerându-se panta operatorului neliniar ca un parametru ajustabil al unității neuronale dinamice.

Ca unitate neuronală dinamică izolată, neuronul biologic realizează două operații matematice distincte, distribuite asupra sinapsei (punctul de joncțiune dintre un axon și dendrită) și asupra somei (principala componentă a neuronului). Cele două operații neuronale matematice pot fi numite:

- a) operația sinaptică
- b) operația somatică

Din punct de vedere biologic aceste două operații sunt fizic separate, dar în modelarea neuronului biologic ele au fost combinate (de exemplu, aplicarea funcției prag în soma este transferată operației sinaptice). Vom prezenta detaliile matematice ale unei unități neuronale dinamice izolate -

Colecția : INGINERULUI

ISBN 973-97790-4-2

5800