PETRESCU Mary-Violeta

ARHITECTURA ȘI INSTRUIREA UNEI REȚELE

Craiova
Martie, 2025

Copyright © 2025, Autor
Tehnoredactare computerizată: PETRESCU Mary-Violeta
Corectura aparţine autorului

Responsabilitatea pentru conţinutul lucrării revine în exclusivitate autorului
Studiu științific

Publicat: Martie 2025
http://www.edituraelse.ro/ped/ped.htm

ARHITECTURA ȘI INSTRUIREA UNEI REȚELE NEURONALE

Arhitectura rețelelor neuronale este mult mai apropiată de arhitectura creierului uman, creierul uman fiind alcătuit din neuroni interconectați între ei prin zeci de mii de conexiuni pentru fiecare pereche.

În vederea realizării unei reţele neuronale care poate fi antrenată pentru a rezolva o anumită problemă și pentru a avea un anumit comportament este important să se stabilească, arhitectura reţelei, modul de operare al activităților desfășurate în timpul procesării informației și algoritmul de instruire.

În construirea arhitecturii unei rețele trebuie avut în vedere faptul că într-un sistem dinamic exista o conexiune inversă, atunci când ieșirea unui element din sistem influențează intrarea acelui element prin intermediul circuitului de reacție.

Prin urmare, o rețea neuronală are o structură de tip feed forward, dacă ieșirile neuronilor trec spre straturile următoare și nu spre cele anterioare.

Având în vedere faptul că neuronii sunt organizați într-unul sau mai multe straturi, Haykin în anul 1999 a împărțit tipurile de arhitectură a rețelei în următoarele trei categorii :

- *Rețele feedforward cu un singur strat (single-layerfeed forward networks)*

În acest tip de rețea, conexiunile de la un strat de neuroni către alt strat de neuroni se realizează într-un singur sens, (a se vedea Figura 1.).

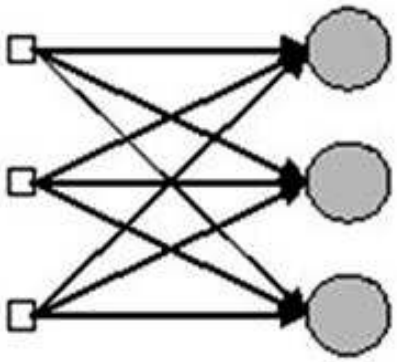


Figura 1. Arhitectura unei reţele feed forward cu un singur strat

✓ *Rețele feed forward multistrat (multilayer feed forward networks)*

Spre deosebire de rețeaua anterioară, în această rețea (a se vedea Figura 2.) avem unul sau mai multe straturi „ascunse” (hidden layers) ale căror elemente sunt neuroni ascunși care acționează între statul de intrare și cel de ieșire în vederea îmbunătățirii performanței rețelei

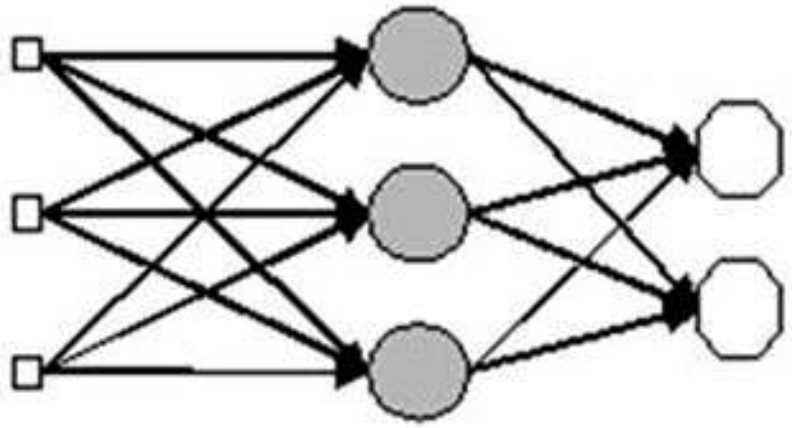


Figura 2. Arhitectura unei rețele feed forward multistrat

Principiul de funcționare al acestei arhitecturii este următorul:

- nodurile sursă din stratul de intrare sunt valori de intrare pentru funcția de activare, iar rezultatul reprezintă intrările pentru neuronii din primul strat ascuns;
- aplicarea funcției de activare pentru intrările din primul strat de neuroni determină valorile de intrare pentru neuronii din cel de-al doilea strat ascuns, etc.;
- procedeul continuă până la ultimul strat pe care se află nodurile de ieșire.

- ✓ *Rețele recurente (reccurent networks)*

Arhitectura unei reţele recurente (a se vedea Figura 3.) spre deosebire de o reţea feed forward, are conexiuni înainte şi înapoi între straturi, poate avea sau nu straturi ascunse de neuroni.

Deci, putem spune că, se deosebește prin existența a cel puțin unui circuit de reacție, care are o importanță deosebită pentru algoritmul de învățare al rețelei.

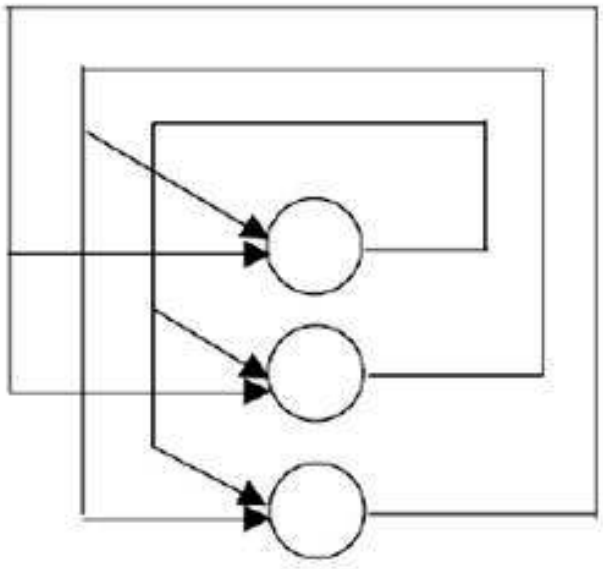


Figura 3. Arhitectura unei rețele recurente

Instruirea unei rețele neuronale necesită o succesiune de operații numite reguli de învățare, care configurează rețeaua pentru efectuarea analizei sau predicției specifice tipului de probleme pentru care a fost realizată şi instruită.

O rețea neuronală este construită sub forma unor straturi conectate în funcție de structura intrărilor și ieșirilor, iar ponderile sinaptice sunt actualizate pe baza unei analize a setului de instruire.

Regula de învățare reprezintă actualizarea şi se utilizează secvenţial sau repetat până când valorile efective de ieșire ale rețelei neuronale sunt apropiate de valorile prestabilite.

❖ Învățarea hebbiană (hebbian learning)

Această regulă de învăţare este descrisă de Hebb în anul 1949 care precizează că dacă, reţeaua răspunde corect sau greșit pentru a anumită intrare , atunci ponderile trebuie modificate astfel încât să crească sau să scadă probabilitatea unui răspuns asemănător pentru intrări similare.

În continuare, voi arăta cea mai simplă formă pentru învăţarea de tip Hebbian, scrisă de Haykin:

$$\Delta w_{kj}(n) = \eta y_k(n) x_j(n),$$

unde $w_{kj}(n)$ semnifică ponderea sinaptică dinspre neuronul j (intrare) către neuronul k (ieșire) la momentul de timp n; y_k - este ieșirea și x_j - este intrarea, η este o constanta pozitivă și reprezintă rata de învățare.

Formula obținută indică natura sinapsei Hebbiene, adică intrarea x_j aplicată în mod repetat neuronului k duce la creșterea ponderii sinaptice corespunzătoare lui.

❖ Învățarea cu corectarea erorii (error-correction learning)

Această regulă de învățarestă la baza algoritmilor de învăţare supervizată pentru reţelele de tip feedforward.

Este cunoscut faptul că, în cadrul unei rețele, ieşirea obţinută din reţea $y_k(n)$ este comparată cu o ieşire fixată, notată cu $d_k(n)$, iar eroarea obținută va fi: $e_k(n) = d_k(n) - y_k(n)$.

În vederea minimizării erorilor, vom minimiza funcţia:

$$E(n) = \frac{1}{2} e_k^2(n).$$

Această regulă de învățare a fost demonstrată de Widrow&Hoff (1960) fiind cunoscută și sub numele de regula delta, poate fi scrisă ca :

$$\Delta w_{kj}(n) = \eta e_k(n) x_j(n).$$

În concluzie, putem afirma că ajustarea ponderilor sinaptice pentru conexiunea dintre doi neuroni este proporțională cu produsul dintre eroare și valoarea de intrare pentru conexiunea respectivă:

- ✓ Învățarea bazată pe memorie (memory-basedlearning) - se bazează pe memorarea datelor de antrenament;
- ✓ Învățarea Boltzmann (Boltzmann learning) – se bazează pe date din mecanica statistică;
- ✓ Învățarea competitivă (competitive learning).

În ceea ce priveşte algoritmul de instruire a reţelei, avem două paradigme esenţiale ale procesului de învățare:

- învăţarea ”cu profesor”, din care face parte învăţarea supervizată (supervized learning) și se utilizează mai ales în problemele de clasificare;
- învăţarea ”fără profesor”, din care face parte învăţarea nesupervizată (unsupervized learning) în care rețeaua primeşte inputurile, dar nu şi ieşirile dorite şi învăţarea stimulativă (reinforcement learning) care este un tip de învățare eficient utilizat în sisteme complexe de rețele neuronale.

În continuare, introducând perceptronul ca fiind cea mai simplă formă de rețea neuronală, voi prezenta perceptronul cu un singur strat (SLP).

Perceptronul cu un singur strat are la bază neuronul McCulloch-Pitts, și este reprezentat sub forma:

$$y(k)=\begin{cases} 1, & dacă \quad \sum_{j=1}^{n} w_j(k)x_j(k)+b\geq 0 \\ -1, & altfel. \end{cases}$$

unde:

- intrările neuronului k sunt notate cu $x_1(k), x_2(k), \ldots, x_m(k)$,
- ieşirea neuronului k este notată cu $y(k)$,
- ponderile sunt notate cu $w_1(k), w_2(k), \ldots, w_m(k)$,
- deplasarea $-b$ va fi inclusă printre ponderile cu intrarea +1.

Scopul perceptronului cu un singur strat este clasificarea corectă a unui set de vectori de intrare într-una din clasele: C_1, C_2.

Ieşirea perceptronului reprezintă regula de decizie:

- dacă $y(k)=+1$, atunci $x(k)\in C_1$,
- dacă $y(k)=-1$, atunci $x(k)\in C_2$.

Din punct de vedere geometric, cele două clase de separare reprezintă două regiuni ale spaţiului m-dimensional, separate de un hiperplan a cărui ecuaţie este:

$$\sum_{i=1}^{m} w_i x_i + b = 0.$$

În cazul în care cele două clase sunt liniar separabile (a se vedea Figura 4.) atunci perceptronul cu un singur strat poate fi aplicat.

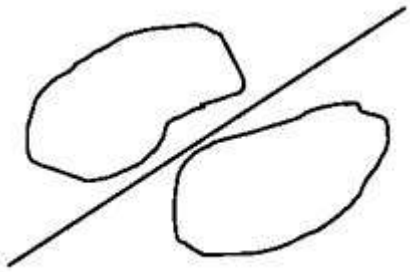


Figura 4. Două clase liniar separabile

În cazul în care cele două clase nu sunt liniar separabile (a se vedea Figura 5.), adică în anumite puncte sunt foarte apropiate una de alta şi nu există un hiperplan care să le separe, atunci perceptronul nu se poate aplica neavând capacitatea de a separa cele două clase.

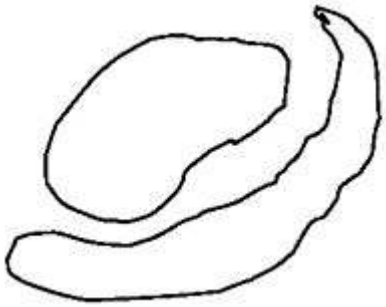


Figura 5. Două clase liniar neseparabile

Bibliografie:

1. Haykin, S., 1999. Neural Networks: A comprehensive foundation. Prentice Hall International.
2. Widrow, B. & Hoff, M.E., 1960. Adaptive switching circuits. Proceedings of WESCON Conv. Rec., part 4, pp.96-140.