

Mieczysław Jagodziński  
Politechnika Śląska

WPROWADZENIE DO SIECI NEURONOWYCH

AN INTRODUCTION TO NEURAL NETWORKS

ВВЕДЕНИЕ В НЕЙРОННЫЕ СЕТИ

Streszczenie: W pracy przedstawiono wprowadzenie do problematyki sieci neuronowych. Omówiono algorytm Kohonena i regułę Hebba ilustrujące złożoność problemów związanych ze strukturą i uczeniem sieci.

Summary: In this work the introductory problems of neural networks have been presented. The Kohonen's algorithm and Hebb's rule showing the complexity of problems concerning the structure and teaching the neural networks were discussed.

Резюме: В работе представлено введение в проблематику нейронных сетей. Описан алгоритм Кохонена и правило Хебба иллюстрирующие сложность проблем связанных со структурой и обучением сети.

1. Wprowadzenie [3][6]

Mózg człowieka jest od wielu wieków przedmiotem zainteresowania wielu naukowców. Moment, w którym człowiek będzie w stanie opanować technikę funkcjonowania mózgu, stanowić będzie przełom dla rozwoju cywilizacji.

Obecnie są prowadzone prace nad rozwiązaniem tego problemu dwukierunkowo:

- a) prace zmierzające do modelowania mózgu człowieka ze względu na pełnione przez niego funkcje,
- b) prace polegające na próbach konstrukcji systemów przetwarzania informacji bazujących na strukturze mózgu.

Sieć neuronową można poddać procesowi uczenia, podczas którego wykorzystuje ona informacje zakodowane w modelach przykładowych. Istotną zaletą sieci neuronowych jest umiejętność przechowywania informacji w obecności zakłóceń. Do przechowywania informacji służą wagi połączeń między węzłami sieci określonego typu.

Aktualnie prowadzone są intensywne badania sieci neuronowych w wielu ośrodkach w dwóch kierunkach:

- a) realizacji sprzętowej umożliwiającej wykorzystanie własności sieci neuropodobnych, np.:
  - opracowanie procesorów MARK III i MARK IV przez R. Hechta-Nielsena,
  - opracowanie procesora emulującego sieć NEP (Network Emulation Processor) przez C. Cruz-Younga,
  - opracowanie układów ANZA i ANZA Plus przez Firmę Hecht-Nielsen;

b) symulacji wykorzystującej specjalistyczne oprogramowanie pewnych struktur sieci, np.:

- symulator sieci neuronowych Neural Works opracowany przez Firmę Neural Ware Inc.
- system P3 symulujący asynchroniczne działanie sieci neuronowych, opracowany przez D. Zipsera.

Sieci neuronowe stanowią bazę do rozwiązywania wielu problemów technicznych. Wybrane przykłady zastosowania sieci neuronowych:

- w problemach kombinatorycznych:

John Hopfield wraz z Davidem Tankiem rozwiązali problem komiwojagera,

- w rozpoznawaniu wzorów pisanych:

Kuniko Fukushima jest twórcą systemu do rozpoznawania tekstów pisanych ręcznie,

- w przetwarzaniu informacji i sygnałów oraz ich ekspertyzy:


E. Czogała zastosował sieci neuronowe do filtracji szumów zawartych w sygnałach EKG,

- w konwersji tekstu pisanego na mowę:

Rosenberg i Sejnowski podali algorytm sieci NETTALK umożliwiający konwersję tekstu na mowę.

## 2. Model matematyczny neuronu [6]

Sieci neuronowe są zbudowane z podstawowych jednostek obliczeniowych zwanych węzłami sieci lub neuronami. Neuron jest prostą jednostką przetwarzającą i realizującą podstawowe działania sumowania ważonego lub funkcji progowych (rys.1).



Rys.1. Model matematyczny neuronu

Fig.1. Mathematical model of single neural cell

Na rys.1 przyjęto oznaczenia:

$wa_{ij}$  - waga połączenia, współczynnik zależności  $j$ -tego wyjścia od  $i$ -tego wejścia neuronu,


$net_i$  - suma ważona wejść dla  $i$ -tego neuronu, określona jako:

$$net_i = \sum_{j=1}^N wa_{ij} * RE_j$$


- $akt_i$  - poziom aktywacji neuronu,  
 $akt_i(t) = RE_i[akt_i(t-1), net_i(t-1)]$   
 $RE_i$  - reakcja neuronu na pobudzenie,  
 $RE_i(t) = f_i\{FA_i[akt_i(t-1), net_i(t-1)]\}$   
 w zapisie macierzowym mamy:  
 $net(t) = wa(t) * RE(t), RE(t) = f\{FA[akt(t-1), net(t-1)]\}$   
 $FA_i$  - funkcja aktywacji,  
 $f_i$  - funkcja wyjściowa,

Charakterystyki modeli neuronów w zależności od założonej funkcji aktywacji i funkcji wyjściowej neuronu mogą być przedstawione w postaci (rys.2 - 5) [6]:


- modelu liniowego,
- modelu liniowego z progiem,
- modelu binarnego z progiem,
- modelu sigmoidalnego z progiem.



Rys.2. Model liniowy  
Fig.2. Linear model




Rys.3. Model liniowy z progiem  
Fig.3. Linear model with the threshold



Rys.4. Model binarny z progiem  
Fig.4. Binary model with the threshold






Rys.5. Model sigmoidalny z progamiem  
Fig.5. Exponential model with freshold

### 3. Budowa sieci neuronowych [3][4][5][6]

Sieć neuronowa składa się z następujących rodzajów węzłów:

- węzły wejściowe,
- węzły ukryte,
- węzły wyjściowe.

W przypadku kiedy węzły mają różne charakterystyki przetwarzania mogą wystąpić problemy ze zbieżnością algorytmu uczenia sieci. Dlatego też przyjmuje się takie same charakterystyki przetwarzania dla wszystkich węzłów. Do zakodowania połączeń pomiędzy węzłami sieci służy macierz wag.



Rys.6. Przykładowa sieć neuronowa  
Fig.6. Sample neural network

Sa w niej zapisane wszystkie połączenia pomiędzy węzłami sieci. Ujemne wartości elementów tej macierzy realizują wejścia hamujące, a dodatnie wartości wejścia pobudzające neuronów. Przykładową sieć neuronową pokazano na rys.6.

#### 4. Rodzaje sieci [5]

Sieci mogą posiadać wejścia binarne lub ciągłe, mogą być uczone pod nadzorem lub bez nadzoru. Poszczególne rodzaje sieci mogą być składnikami bardziej złożonych systemów. Poniżej przedstawiono rodzaje sieci, które mogą służyć do klasyfikacji statycznych wzorów.

#### KLASYFIKATORY STATYCZNYCH WZORÓW

##### WEJŚCIA BINARNE

uczone pod nadzorem:

-sieć Hopfielda,

-sieć Hamminga

uczone bez nadzoru:

-klasyfikator Carpentnera Grossberga

##### WEJŚCIA CIĄGŁE

uczone pod nadzorem:

- perceptron,

- perceptron wielowarstwowy,

uczone bez nadzoru:

- mapy cech Kohonena

Dla przybliżenia problemu poniżej krótko omówiona zostanie struktura i algorytm działania sieci Kohonena [2]. Sieć ta posiada wejścia binarne lub ciągłe, uczona jest bez nadzoru. Węzły wyjściowe ułożone są na płaszczyźnie, umożliwiając tworzenie tzw. map cech (rys.7). Każdy z nich połączony jest z wszystkimi wejściami. Sieci te wykorzystywane są jako kwantyzatory wektorów lub do tworzenia grup cech.

#### ALGORYTM KOHONENA

Krok 1.

Ustawienie początkowych wartości wag - zakłada się, że posiadają one niewielką wartość losową.

Krok 2.

Podanie wartości wejściowych neuronu.

Krok 3.

Obliczanie odległości dla wszystkich węzłów:

$$d_i = \sum_{i=0}^{N-1} [x_i(t) - w_{ij}(t)]^2$$

gdzie:

$N$  - liczba wszystkich węzłów,

$x_i(t)$  - wejście do węzła  $j$ -tego w chwili  $t$ ,

$w_{ij}(t)$  - waga połączenia od  $i$ -tego węzła wejściowego do  $j$ -tego węzła wyjściowego w chwili  $t$ ,

Krok 4.

Wybór węzła o najmniejszej odległości ( $j^*$ ).

Krok 5.

Zmiana wag połączeń wchodzących do węzła  $j^*$ -tego oraz sąsiednich węzłów.

$$w_{ij}(t+1) = w_{ij}(t) + n(t) * [x_i(t) - w_{ij}(t)],$$

$$\text{dla } j \in NE_{j^*} \text{ oraz } 0 \leq i \leq N-1$$


gdzie:

$n(t)$  - współczynnik uzbiegający,  $0 < n(t) < 1$  malejący z czasem,

$NE_{j^*}(t)$  - sąsiedztwo węzła  $j^*$ -tego w chwili  $t$ .

Krok 6.

Powrót do kroku 2.



Rys.7. Przykładowa mapa cech [3]  
Fig.7. Example of feature map [3]



5. Uczenie sieci [3]

Iteracyjny proces modyfikacji wag połączeń między węzłami sieci nazywamy uczeniem sieci neuronowej. W wyniku tego procesu zostanie wygenerowana optymalna struktura połączeń między węzłami.

Metody uczenia sieci można podzielić na dwie grupy:

- uczenie nienadzorowane (bez nauczyciela),
- uczenie nadzorowane (z nauczycielem).

Opracowano szereg reguł uczenia sieci. Najbardziej znane reguły to:

- reguła Hebba,
- reguła Delta,
- reguła Grossberga,
- reguła Andersona-Kohonena,
- reguła propagacji błędu wstecz.

Przykładowo, jeżeli w czasie uczenia sieci dwa węzły mają wysoki poziom aktywacji, to waga ich połączenia w myśl reguły Hebba [1] powinna wzrosnąć o odpowiednią wartość.

$$\text{deltawa}_{ij} = e * \text{akt}_i * \text{akt}_j$$

gdzie:

$\text{deltawa}_{ij}$  - waga połączenia węzłów i-tego i j-tego,

$e$  - współczynnik uzbieniający,

$\text{akt}_i$  - aktywacja węzła i-tego,

$\text{akt}_j$  - aktywacja węzła j-tego,

Założenie: na początku uczenia sieci wszystkie wagi są zerowe oraz liczba serii uczących się wynosi  $L$ .

Po każdej serii uczącej wagi przyjmują następujące wartości:

$$\text{deltawa}_{ij} = e * \sum_{l=1}^L \text{akt}_{il} * \text{akt}_{jl}$$

Jeżeli przyjmiemy dalej, że węzły są liniowe, czyli:

$$\text{akt}_i = \sum_{j=1}^N \text{akt}_j * \text{wa}_{ij}, \quad N - \text{liczba wejść do węzła},$$

to wszystkie wagi opisane wzorem  $\text{akt}_i = \sum_{j=1}^N \text{akt}_j * \text{wa}_{ij}$  będą proporcjonalne do korelacji między aktywacjami węzłów i-tego i j-tego. Zaletą tego jest fakt, że aktywne węzły będą zmierzać do pobudzenia innych węzłów, które były z nimi wcześniej skorelowane. Korelacja ta często nie wystarcza do nauczenia sieci nawet prostych podobieństw między aktywacjami neuronów. Oznacza to, że reguła Hebba nie zawsze potrafi znaleźć zadany zestaw wag, nawet wtedy, gdy taki istnieje. Jedną z wad tej reguły jest nieograniczony wzrost wartości wag przy wielokrotnym powtarzaniu procesu uczenia.

## 6. Podsumowanie

W pracy autor starał się przybliżyć złożoną problematykę sieci neuronowych. Jest to bardzo interesująca dyscyplina nauki. Umiejętne wykorzystanie wiedzy z tego zakresu umożliwiłoby rozwiązanie wielu ciekawych problemów z różnych dziedzin nauki. Obecnie są szeroko rozwijane systemy ekspertowe, w których można by spróbować wykorzystać sieci neuronowe.

## LITERATURA

- [1] Hebb, D.O.: Organization of behavior. New York: Science Editions, 1961.
- [2] Kohonen T.: Self-organization and associative memory. Series in Information Sciences, vol.8. Berlin: Springer Verlag.
- [3] Lippmann R.P.: An Introduction to Computing with Neural Nets. IEEE ASSP 1987.
- [4] Tarun Khanna; Foundations of neural networks, Addison-Wesley Publishing Company, 1990.
- [5] Tadeusiewicz R.: Biocybernetyka, Ossolineum, PTC, PAN, 1988.
- [6] Wasserman P.D.: Neural Computing Theory and Practice, VNR, 1989.

Recenzent: Prof.dr h.inz. Andrzej Grzywak  
Wpłynęło do Redakcji do 30.04.1992 r.

## Abstract:

This paper contains an introduction to the topic of neural networks. Examples of practical use of neural network in technical problems are shown. Then, a mathematical model of a neuron and the structure of a neural network are described, as well as taxonomy of pattern classifying networks. Finally, the complexity of problems related to network structure and training procedures are illustrated by examples of the Kohonen network and the Hebbian learning rule.