



*Wprowadzenie*

*Matematyczny model...*

*Sieci rekurencyjne*

*Modele samoorganizacji*

*Home Page*

*Title Page*



*Page 1 of 38*

*Go Back*

*Full Screen*

*Close*

*Quit*

# Wykład 9: Sztuczne sieci neuronowe

Nguyen Hung Son

[son@mimuw.edu.pl](mailto:son@mimuw.edu.pl)

**Streszczenie**



Wprowadzenie

Matematyczny model...

Sieci rekurencyjne

Modele samoorganizacji

Home Page

Title Page



Page 2 of 38

Go Back

Full Screen

Close

Quit

# 1. Wprowadzenie

"I cannot articulate enough to express my dislike to people who think that understanding spoils your experience... How would they know?"

Marvin Minsky



## 1.1. Historia “sztucznych sieci neuronowych”:

- Dawno, dawno temu: powstały neurony ...
- 1868 J. C. Maxwell: zbadał mechanizm sprzężenia zwrotnego;
- 1942 Weiner et al.: stworzył “cybernetykę”;
- 1943 McCulloch-Pitts: Neurony
- 1949 Hebb: wskazał mechanizm biologiczny;
- 1958-1962: Perceptron Rosenblatta: “Perceptron Separated Input from Output at Computer Level.”
- 1960 Widrow and Hoff: Sieci ADALINE / MADALINE
- 1969 Minsky and Papert: Krytyczna frustracja do sieci neuronowych: “Limited Advancement”
- 1972 Amari, Anderson, Grossberg: Badanie nad “Self Organizing Network”, Symulacja modelu pamięci asocjacyjnej u człowieka.
- 1974 Werbos: Propagacja wsteczna;
- 1982 John Hopfield: sieć rekurencyjna;
- 1986 McLelland and Rumelhart: Popularyzowali metodę propagacji wstecznej w swojej książce;
- 1990 Mead: integracja sprzętowa i zastosowanie sieci w obronie i przemyśle.

Wprowadzenie

Matematyczny model...

Sieci rekurencyjne

Modele samoorganizacji

Home Page

Title Page



Page 3 of 38

Go Back

Full Screen

Close

Quit



## 1.2. Inspiracje neurofizjologiczne

- Mózg ludzki:
  - objętość  $\approx 1400 \text{ cm}^3$  i powierzchnie  $2000 \text{ cm}^2$  (kula o tej samej objętości ma zaledwie  $600 \text{ cm}^2$ ).
  - Masa mózgu wynosi 1,5 kg.
  - Są to wartości średnie, ponieważ są w tym zakresie różnice pomiędzy różnymi ludźmi.
  - Dla przykładu mózgi kobiet są z reguły mniejsze niż mężczyzn.  
**Nie udowodniono do tej pory związku między wielkością mózgu a jego intelektualną sprawnością.**
- Duże znaczenie dla intelektualnych zdolności ma natomiast kora mózgowa o grubości średnio 3 mm, zawierająca:
  - $10^{10}$  komórek nerwowych i
  - $10^{12}$  komórek glijowych.
  - Liczba połączeń między komórkami to około  $10^{15}$ .

Wprowadzenie

Matematyczny model...

Sieci rekurencyjne

Modele samoorganizacji

Home Page

Title Page



Page 4 of 38

Go Back

Full Screen

Close

Quit



- Komórki nerwowe wysyłają i przyjmują impulsy o częstotliwości 1 - 100 Hz, czas trwania 1 - 2 ms, napięciu 100 mV i szybkości propagacji 1 - 100 m/s.
- Szybkość pracy mózgu szacuje się na  $10^{18}$  operacji/s.
- Dla wykonania typowej reakcji mózg wykonuje nie więcej niż 100 elementarnych kroków, ponieważ czas reakcji jest mniejszy niż 300 ms.
- Pojemności kanałów zmysłów można szacować jako: wzrok 100 Mb/s, dotyk 1 Mb/s, słuch 15 Kb/s, węch 1 Kb/s, smak 100 b/s.

Wprowadzenie

Matematyczny model...

Sieci rekurencyjne

Modele samoorganizacji

Home Page

Title Page




Page 5 of 38

Go Back

Full Screen

Close

Quit





Wprowadzenie

Matematyczny model...

Sieci rekurencyjne

Modele samoorganizacji

Home Page

Title Page



Page 6 of 38

Go Back

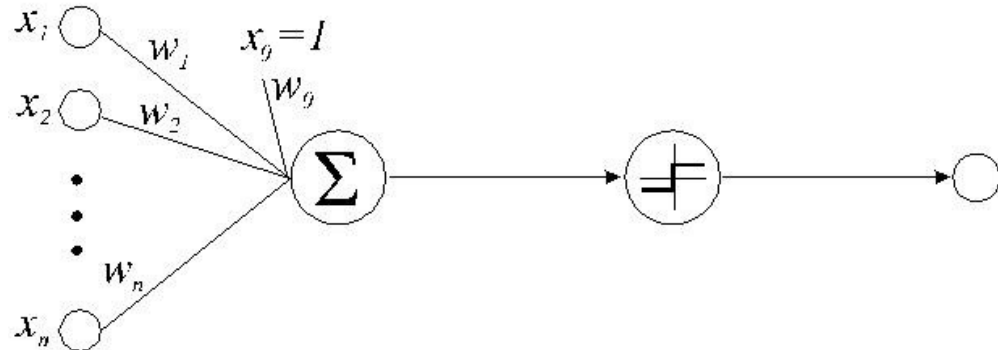
Full Screen

Close

Quit

## 1.3. Sztuczna sieć neuronowa

- Sieć neuronowa jest uproszczonym modelem mózgu. Składa się ona z pewnej liczby elementów (neuronów) przetwarzających informacje.
- Neurony są ze sobą powiązane za pomocą połączeń o parametrach (wagach) modyfikowanych w trakcie procesu uczenia.



- Większość budowanych sieci ma budowę warstwową.



## 1.4. Zastosowania sieci

- **Predykcja:** Sieci neuronowe są często wykorzystywane, aby na podstawie pewnych danych wejściowych przewidywała dane wyjściowe. Ważną zaletą jest to, że sieć może nauczyć się przewidywania sygnałów wyjściowych bez jawnego definiowania związku między danymi wejściowymi a wyjściowymi.
- **Klasyfikacja i rozpoznawanie:** Zadanie polega na przewidywaniu identyfikatora klasy, do której dany obiekt należy.
- **Kojarzenie danych:** Klasyczne systemy komputerowe mogą gromadzić duże zbiory danych bez możliwości ich kojarzenia. Sieci neuronowe, dzięki zdolności uczenia się i uogólniania doświadczeń, pozwalają zautomatyzować procesy wnioskowania i pomagają wykrywać istotne powiązania pomiędzy danymi.
- **Analiza danych:** Zadanie polega na znalezieniu związków pomiędzy danymi. Realizacja tego zadania przez sieci neuronowe daje nowe możliwości w zakresie prowadzenia analiz ekonomicznych.
- **Filtracja sygnałów** Dane gospodarcze pochodzące z różnych źródeł są zakłócone. Klasyczne metody eliminacji „szumów” pozwalają usunąć zakłócenia o charakterze losowym, lecz nie dają podstaw do eliminacji przekłamań systematycznych.
- **Optymalizacja** Sieci neuronowe - zwłaszcza sieci Hopfielda - dobrze nadają się do optymalizacji decyzji gospodarczych. Doświadczalnie potwierdzono możliwości sieci do rozwiązywania zadań optymalizacji statycznej i dynamicznej. Szczególnie ciekawe jest zastosowanie sieci do optymalizacji kombinatorycznej i zagadnień bardzo trudnych obliczeniowo (również np- zupełnych), które mogą być rozwiązane w krótkim czasie dzięki współbieżnym wyliczaniu przez wiele elementów sieci. Dobrym przykładem jest sieć rozwiązująca klasyczny problem komiwojażera.

Wprowadzenie

Matematyczny model...

Sieci rekurencyjne

Modele samoorganizacji

Home Page

Title Page



Page 7 of 38

Go Back

Full Screen

Close

Quit



Wprowadzenie

Matematyczny model...

Sieci rekurencyjne

Modele samoorganizacji

Home Page

Title Page



Page 8 of 38

Go Back

Full Screen

Close

Quit


## 1.5. właściwości sieci

- *Adaptowalność i samo-organizacja*: oparte o zasady uczenia adaptacyjnego (podstawa filozoficzna)
- *Nieliniowość* : oferuje możliwości uczenia się aproksymacji funkcji i klasyfikacji.
- *Przetwarzanie równoległe*: sprzętowa realizacja sieci pozwala przetwarzać dużą ilość obliczeń dzięki równoległym połączeniom.





## 2. Matematyczny model neuronu



$$o(x_1, \dots, x_n) = \begin{cases} 1 & \text{jeśli } w_0 + w_1x_1 + \dots + w_nx_n > 0 \\ -1 & \text{w p.p.} \end{cases}$$

Czasem stosujemy prostsze obliczenia:

$$o(\vec{x}) = \begin{cases} 1 & \text{if } \vec{w} \cdot \vec{x} > 0 \\ -1 & \text{otherwise.} \end{cases}$$

Ogólnie, perceptron realizuje pewną funkcję!

Wprowadzenie

Matematyczny model...

Sieci rekurencyjne

Modele samoorganizacji

Home Page

Title Page

◀ ▶

◀ ▶

Page 9 of 38

Go Back

Full Screen

Close

Quit



Wprowadzenie

Matematyczny model...

Sieci rekurencyjne

Modele samoorganizacji

Home Page

Title Page



Page 10 of 38



Go Back

Full Screen

Close


Quit

Perceptron ma dość ograniczone możliwości. Z powodzeniem może reprezentować funkcję OR, AND, ale już nie poradzi sobie z funkcją XOR. Ogólnie funkcje reprezentowane przez perceptron to takie, które rozdzielają liniowo obszar danych:





## 2.1. funkcja aktywacji:



- Funkcja progowa (threshold function)  $sgn(x) = \begin{cases} 1 & \text{if } x > 0 \\ 0 & \text{otherwise.} \end{cases}$
- Funkcja sigmoidalna:

$$\sigma(x) = \frac{1}{1 + e^{-x}}$$

Własności:  $\frac{d\sigma(x)}{dx} = \sigma(x)(1 - \sigma(x))$

- Funkcja tangensu hiperbolicznego:

$$th(x) = \frac{1}{2}[1 + \tanh(x)]$$

Wprowadzenie

Matematyczny model...

Sieci rekurencyjne

Modele samoorganizacji

Home Page

Title Page

◀ ▶

◀ ▶

Page 11 of 38

Go Back

Full Screen

Close

Quit



Wprowadzenie

Matematyczny model...

Sieci rekurencyjne

Modele samoorganizacji

Home Page

Title Page



Page 12 of 38

Go Back

Full Screen

Close

Quit

## 3. Uczenie perceptronu

### 3.1. Problem klasyfikacji

Przykłady:


- Klasyfikacja obrazów
- Predykcja finansowa
- Sterowanie
- funkcje boolowskie:

$x_1$	$x_2$	AND
0	0	0
1	0	0
0	1	0
1	1	1

**Problem uczenia się perceptronu:** Znaleźć wartości wag dla perceptronu, które definiują funkcję podobną do wzorców.



## Przykład funkcja AND:



AB is Decision line  
0 Bit value

AND gate with  $w = (1/2, 1/2, 3/4)$

Wprowadzenie

Matematyczny model...

Sieci rekurencyjne

Modele samoorganizacji

Home Page

Title Page

◀ ▶

◀ ▶

Page 13 of 38

Go Back

Full Screen

Close

Quit



Wprowadzenie

Matematyczny model...

Sieci rekurencyjne

Modele samoorganizacji

Home Page

Title Page



Page 14 of 38

Go Back

Full Screen

Close

Quit

## 3.2. Reguły uczenia się:

$$w_i \leftarrow w_i + \Delta w_i$$

gdzie

$$\Delta w_i = \eta(t - o)x_i$$

Oznaczenia:

- $t = c(\vec{x})$  wartość funkcji celu (wzorca)
- $o$  jest wartością wyjściową neuronu
- $\eta$  jest małą stałą, np. = 0.1, zwaną stałą uczenia się

Można wykazać teoretyczną zbieżność algorytmu uczenia się w sytuacji:

- Dane treningowe są liniowo separowalne
- $\eta$  jest dostatecznie mała.



Wprowadzenie

Matematyczny model...

Sieci rekurencyjne

Modele samoorganizacji

Home Page

Title Page



Page 15 of 38

Go Back

Full Screen

Close

Quit

**Wyjaśnienia reguł uczenia perceptronu:** rozważmy najprostszy przypadek

$$o = w_0 + w_1x_1 + \dots + w_nx_n$$

Szukajmy  $w_i$ , które minimalizują funkcję błędu:

$$E[\vec{w}] \equiv \frac{1}{2} \sum_{d \in D} (t_d - o_d)^2$$

gdzie  $D$  jest zbiorem przykładów treningowych.  
Metoda gradientu:

$$\nabla E[\vec{w}] \equiv \left[ \frac{\partial E}{\partial w_0}, \frac{\partial E}{\partial w_1}, \dots, \frac{\partial E}{\partial w_n} \right]$$



Reguły gradientu:

$$\Delta \vec{w} = -\eta \nabla E[\vec{w}]$$

i.e.,

$$\Delta w_i = -\eta \frac{\partial E}{\partial w_i}$$

$$\begin{aligned} \frac{\partial E}{\partial w_i} &= \frac{\partial}{\partial w_i} \frac{1}{2} \sum_d (t_d - o_d)^2 \\ &= \frac{1}{2} \sum_d \frac{\partial}{\partial w_i} (t_d - o_d)^2 \\ &= \frac{1}{2} \sum_d 2(t_d - o_d) \frac{\partial}{\partial w_i} (t_d - o_d) \\ &= \sum_d (t_d - o_d) \frac{\partial}{\partial w_i} (t_d - \vec{w} \cdot \vec{x}_d) \\ \frac{\partial E}{\partial w_i} &= \sum_d (t_d - o_d) (-x_{i,d}) \end{aligned}$$

Wprowadzenie

Matematyczny model...

Sieci rekurencyjne

Modele samoorganizacji

Home Page

Title Page

◀ ▶

◀ ▶

Page 16 of 38

Go Back

Full Screen

Close

Quit





Wprowadzenie

Matematyczny model...

Sieci rekurencyjne

Modele samoorganizacji

Home Page

Title Page

◀ ▶

◀ ▶

Page 17 of 38

Go Back

Full Screen

Close

Quit

### 3.3. Gradient Descent

#### Gradient-Descent(*training\_examples*, $\eta$ )

Each training example is a pair of the form  $\langle \vec{x}, t \rangle$ , where  $\vec{x}$  is the vector of input values, and  $t$  is the target output value.  $\eta$  is the learning rate (e.g., .05).

- Initialize each  $w_i$  to some small random value
- Until the termination condition is met, Do
  - Initialize each  $\Delta w_i$  to zero.
  - For each  $\langle \vec{x}, t \rangle$  in *training\_examples*, Do
    - \* Input the instance  $\vec{x}$  to the unit and compute the output  $o$
    - \* For each linear unit weight  $w_i$ , Do

$$\Delta w_i \leftarrow \Delta w_i + \eta(t - o)x_i$$

- For each linear unit weight  $w_i$ , Do

$$w_i \leftarrow w_i + \Delta w_i$$

## 3.4. Incremental (Stochastic) Gradient Descent



Wprowadzenie

Matematyczny model...

Sieci rekurencyjne

Modele samoorganizacji

Home Page

Title Page



Page 18 of 38

Go Back

Full Screen

Close

Quit

**Batch mode Gradient Descent:**

Do until satisfied

1. Compute the gradient  $\nabla E_D[\vec{w}]$
2.  $\vec{w} \leftarrow \vec{w} - \eta \nabla E_D[\vec{w}]$

**Incremental mode Gradient Descent:**

Do until satisfied

- For each training example  $d$  in  $D$ 
  1. Compute the gradient  $\nabla E_d[\vec{w}]$
  2.  $\vec{w} \leftarrow \vec{w} - \eta \nabla E_d[\vec{w}]$

$$E_D[\vec{w}] \equiv \frac{1}{2} \sum_{d \in D} (t_d - o_d)^2$$

$$E_d[\vec{w}] \equiv \frac{1}{2} (t_d - o_d)^2$$

*Incremental Gradient Descent* can approximate *Batch Gradient Descent* arbitrarily closely if  $\eta$  made small enough



Wprowadzenie

Matematyczny model...

Sieci rekurencyjne

Modele samoorganizacji

Home Page

Title Page



Page 19 of 38

Go Back

Full Screen

Close

Quit

### 3.5. Podsumowania

Reguły uczenia perceptronu gwarantuje sukces wtedy, gdy:

- Przykłady treningowe są liniowo separowane
- Dostatecznie mały jest wsp. uczenia się  $\eta$

Reguły uczenia się perceptronu stosuje zasadę maksymalnego spadku gradientu:

- Gwarantuje zbieżność do rozwiązań o (lokalnym) minimalnym błędzie
- Przy dostatecznie małym wsp. uczenia się  $\eta$
- Działa nawet na danych szumiących.
- Działa nawet wtedy, gdy dane nie są liniowo separowane.



Wprowadzenie

Matematyczny model...

Sieci rekurencyjne

Modele samoorganizacji

Home Page

Title Page



Page 20 of 38



Go Back

Full Screen

Close

Quit

## 4. Sieci wielowarstwowe





## 4.1. perceptronu z sigmoidalną funkcją aktywacji

$$\begin{aligned}\frac{\partial E}{\partial w_i} &= \frac{\partial}{\partial w_i} \frac{1}{2} \sum_{d \in D} (t_d - o_d)^2 = \frac{1}{2} \sum_d \frac{\partial}{\partial w_i} (t_d - o_d)^2 \\ &= \frac{1}{2} \sum_d 2(t_d - o_d) \frac{\partial}{\partial w_i} (t_d - o_d) = \sum_d (t_d - o_d) \left( -\frac{\partial o_d}{\partial w_i} \right) \\ &= - \sum_d (t_d - o_d) \frac{\partial o_d}{\partial net_d} \frac{\partial net_d}{\partial w_i}\end{aligned}$$

Wiemy, że

$$\frac{\partial o_d}{\partial net_d} = \frac{\partial \sigma(net_d)}{\partial net_d} = o_d(1 - o_d)$$

$$\frac{\partial net_d}{\partial w_i} = \frac{\partial (\vec{w} \cdot \vec{x}_d)}{\partial w_i} = x_{i,d}$$

Więc

$$\frac{\partial E}{\partial w_i} = - \sum_{d \in D} (t_d - o_d) o_d (1 - o_d) x_{i,d}$$

Wprowadzenie

Matematyczny model...

Sieci rekurencyjne

Modele samoorganizacji

Home Page

Title Page

◀ ▶

◀ ▶

Page 21 of 38

Go Back

Full Screen

Close

Quit



## 4.2. Backpropagation Algorithm

Initialize all weights to small random numbers.  
Until satisfied, Do

- For each training example, Do
  1. Input the training example to the network and compute the network outputs

2. For each output unit  $k$

$$\delta_k \leftarrow o_k(1 - o_k)(t_k - o_k)$$

3. For each hidden unit  $h$

$$\delta_h \leftarrow o_h(1 - o_h) \sum_{k \in \text{outputs}} w_{h,k} \delta_k$$

4. Update each network weight  $w_{i,j}$

$$w_{i,j} \leftarrow w_{i,j} + \Delta w_{i,j}$$

where

$$\Delta w_{i,j} = \eta \delta_j x_{i,j}$$

Wprowadzenie

Matematyczny model...

Sieci rekurencyjne

Modele samoorganizacji

Home Page

Title Page

◀ ▶

◀ ▶

Page 22 of 38

Go Back

Full Screen

Close

Quit



Wprowadzenie

Matematyczny model...

Sieci rekurencyjne

Modele samoorganizacji

Home Page

Title Page



Page 23 of 38

Go Back

Full Screen

Close

Quit

- Gradient descent over entire *network* weight vector
- Easily generalized to arbitrary directed graphs
- Will find a local, not necessarily global error minimum
  - In practice, often works well (can run multiple times)
- Often include weight *momentum*  $\alpha$

$$\Delta w_{i,j}(n) = \eta \delta_j x_{i,j} + \alpha \Delta w_{i,j}(n-1)$$

- Minimizes error over *training* examples
  - Will it generalize well to subsequent examples?
- Training can take thousands of iterations  $\rightarrow$  slow!
- Using network after training is very fast



Wprowadzenie

Matematyczny model...

Sieci rekurencyjne

Modele samoorganizacji

Home Page

Title Page



Page 24 of 38

Go Back


Full Screen

Close

Quit

## 5. Sieci rekurencyjne


Idea:







## 5.1. Sieci Hopfielda



- Zbadane przez Hopfielda;
- Zwane również sieciami auto-asocjacyjnymi;
- Są to jedno-warstwowe sieci z pełnym połączeniem typu “każdy z każdym”;
- Każdy neuron ma bipolarne wartość wejść i wyjść;

Wprowadzenie

Matematyczny model...

Sieci rekurencyjne

Modele samoorganizacji

Home Page

Title Page



Page 25 of 38

Go Back

Full Screen

Close

Quit



## 5.2. Operacje w sieciach Hopfielda:

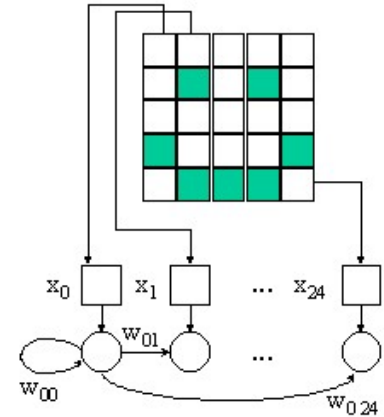
- Zainicjuj wartości początkowe do sieci;
- Czekaj aż sieć się ustabilizuje;
  - To działa w czasie dyskretnym:  
 $t_1, t_2, \dots, t_N$ ;
  - wartości neuronów w chwili  $t_n$  zależy od wartości neuronów w chwili  $t_{n-1}$ :

$$u_i(t_n) = \sum_j w_{ij} y_j(t_{n-1}) + x_i$$

$$y_i(t_n) = \begin{cases} 1 & \text{jeśli } u_i(t_n) > T_i \\ y_i(t_{n-1}) & \text{gdy } u_i(t_n) = T_i \\ -1 & \text{jeśli } u_i(t_n) < T_i \end{cases}$$

- Istnieją modele synchroniczne i asynchroniczne;

- Odczytaj wartości neuronów jako wynik obliczeń;





Wprowadzenie

Matematyczny model...

Sieci rekurencyjne

Modele samoorganizacji

Home Page

Title Page



Page 27 of 38

Go Back

Full Screen

Close

Quit

### 5.3. Ustalenie wartości wag:

UWAGA: wagi się nie zmieniają w procesie uczenia się;  
Macierz wag musi spełniać warunki:

- symetryczność:

$$w_{ij} = w_{ji}$$

- zerowa przekątna:

$$w_{ii} = 0$$

Zwykle chcemy, aby sieć ustabilizowała w jednym z wektorów:  
 $\vec{v}_1, \dots, \vec{v}_P$ , gdzie

$$v_p = (x_1^p, \dots, x_n^p)$$

Aby to zapewnić możemy stosować reguły Hebba:

$$w_{ij} = \sum_{p=1}^P x_i^p x_j^p$$



Wprowadzenie

Matematyczny model...

Sieci rekurencyjne

Modele samoorganizacji

Home Page

Title Page



Page 28 of 38

Go Back

Full Screen

Close

Quit

## 5.4. Dlaczego to działa?

- Charakterystyczną własnością dla bieżącego stanu sieci Hopfielda jest funkcja energii:

$$E = -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n w_{ij} x_i x_j - \sum_{i=1}^n x_i y_i + \sum_{i=1}^n T_i y_i$$

- Hopfield pokazał, że funkcja energii jest nierosnąca;



Wprowadzenie

Matematyczny model...

Sieci rekurencyjne

Modele samoorganizacji

Home Page

Title Page



Page 29 of 38

Go Back

Full Screen

Close

Quit

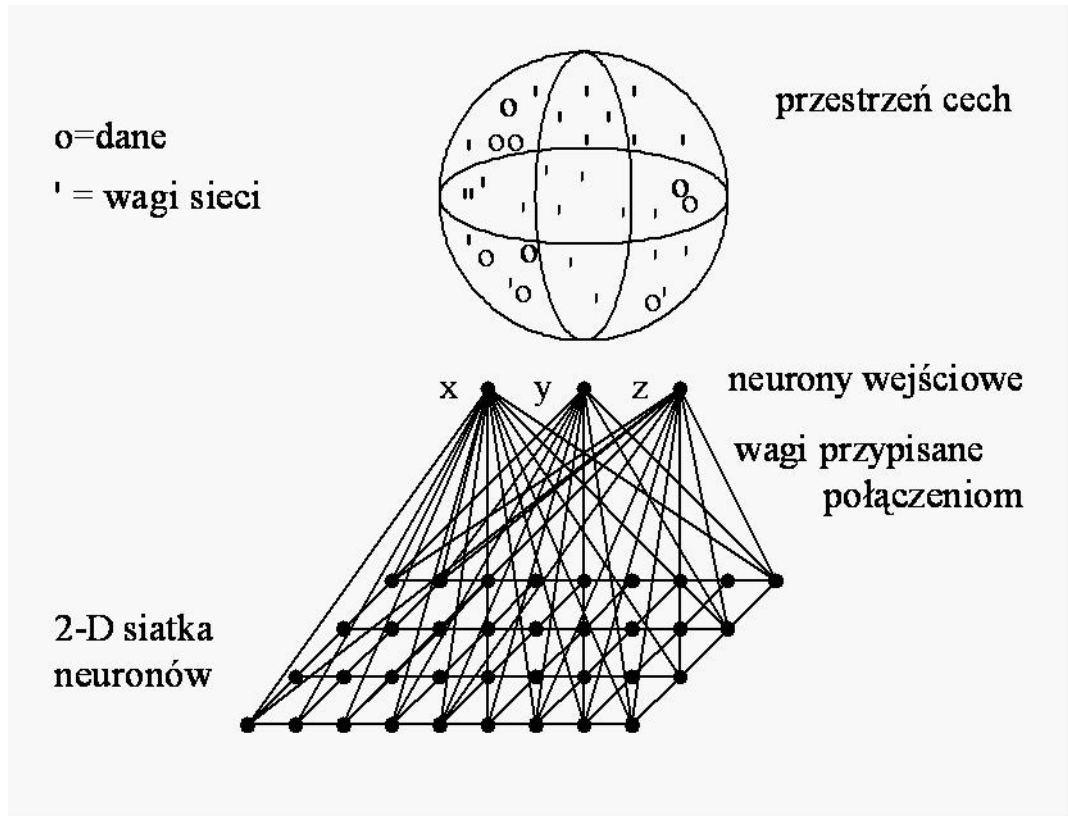
## 6. Modele samoorganizacji

- SOM (Self-Organized Maps) - samorganizująca się mapa.
- Mapy topograficzne powstaje przez połączenia lokalne: neuron silnie pobudzany przez pobliskie połączenie, słabo przez odległe, hamowany przez neurony pośrednie.
- Historia: von der Malsburg i Willshaw (1976), uczenie konkurencyjne, mechanizm Hebbowski, wzbudzenie typu Meksykańskiego kapelusza, model układu wzrokowego. Amari (1980) - model ciągłej tkanki neuronowej. Kohonen (1981) - uproszczenie, bez hamowania; dwie fazy - konkurencja i kooperacja.



## 6.1. Algorytm SOM

**Struktura:** Neurony są umieszczone (ale nie połączone ze sobą) na siatce 1,2 lub 3-wymiarowej. Każdy neuron ma  $N$  wag. Neuron  $i$ -ty ma wagi  $\vec{W}_i(t) = (w_{i1}, \dots, w_{iN})$ , a wektor wejściowy ma współrzędne:  $(x_1, \dots, x_N)$  ( $t$  - czas dyskretny)



Home Page

Title Page



Page 30 of 38

Go Back

Full Screen

Close

Quit

# Algorytm :



1. Inicjalizacja: przypadkowe  $W_i(0)$  dla wszystkich  $i = 1..K$ .  
Definiuj wokół neuronu położonego w miejscu  $r_c$  siatki obszar sąsiedztwa  $O_s(r_c, \sigma(t))$  o promieniu  $\sigma(t)$ .
2. Oblicz odległości

$$d(X, W_i) = \|X - W_i\| = \sqrt{\sum_j (x_j - w_{ij})^2}$$

3. znajdź neuron

$$c = \operatorname{argmin}_i \|X - W_i\|$$

z wagami  $W_c$  najbardziej podobnymi do  $X$  (neuron-zwycięzca).

4. Zmień wagi wszystkich neuronów  $r_i$  w sąsiedztwie  $O_s(r_c, \sigma(t))$

$$W_i(t+1) = W_i(t) + h(r_i, r_c)(X - W_i(t))$$

where

$$h(r_i, r_c) = h_0(t) \cdot e^{-\|r - r_c\|^2 / \sigma_c^2(t)}$$

5. Powoli zmniejszaj siłę  $h_0(t)$  i promień  $\sigma(t)$ .
6. Iteruj aż ustaną zmiany.

**Efekt:** podział (tesselacja) na wieloboki Voronoia.

Wprowadzenie

Matematyczny model...

Sieci rekurencyjne

Modele samoorganizacji

Home Page

Title Page



Page 31 of 38

Go Back

Full Screen

Close

Quit



Wprowadzenie

Matematyczny model...

Sieci rekurencyjne

Modele samoorganizacji

Home Page

Title Page



Page 32 of 38

Go Back

Full Screen

Close

Quit

## 6.2. Własności SOM

- Brak dowodu o zbieżności lub punktach stacjonarnych dla SOM:
- Wyniki analityczne tylko w 1D dla ciągłego czasu, proces Markova: wartości wag wzdłuż prostej porządkują się. Powolna zbieżność:  $10^4 - 10^6$  iteracji.
- Sąsiednie neurony kodują sąsiednie obszary, ale niekoniecznie odwrotnie Skręcone konfiguracje przy zbyt szybkiej redukcji sąsiedztwa. Złożoność  $O(KNn)$  dla  $K$  neuronów i  $n$  danych  $N$ -wymiarowych: konieczne porównanie wszystkich odległości; niezbyt duże mapy.
- Na komputerach wieloprocessorowych szukanie min z  $K$  będzie powolne.
- SOM działa jak metoda klasteryzacji k-średnich jeśli  $\sigma = 0$ .





Wprowadzenie

Matematyczny model...

Sieci rekurencyjne

Modele samoorganizacji

Home Page

Title Page



Page 33 of 38

Go Back

Full Screen

Close

Quit

## 6.3. Modyfikacje SOM

- Próba wprowadzenia funkcji błędu (Luttrell; Heskes i Kappen).
- Błąd lokalny neuronu  $i$  jest sumą po wszystkich neuronach:

$$E_i(X; t) = \frac{1}{2} \sum_j h(|r_i - r_j|, t) \cdot \|X - W_i(t)\|^2$$

gdzie

$$h(|r_i - r_j|, t) = \exp - \frac{|r_i - r_j|^2}{2\sigma^2(t)}; \quad \sigma(t) = \sigma_0 e^{-2\sigma_0 t / t_{\max}}$$

- Neuron-zwycięzca ma najmniejszy błąd lokalny:

$$c = \operatorname{argmin}_i E_i(X; t)$$



## 6.4. Uczenie sieci 2D

Wprowadzenie

Matematyczny model...

Sieci rekurencyjne

Modele samoorganizacji

Home Page

Title Page



Page 34 of 38

Go Back


Full Screen

Close

Quit

$x$ =dane  
 $o$ =pozycje wag  
neuronów

siatka neuronów  
w 2-D




N-wymiarowa  
przestrzeń danych

wagi wskazują  
na punkty w N-D



## 6.5. Uczenie kwadratu w sieci 2D



Wprowadzenie

Matematyczny model...

Sieci rekurencyjne

Modele samoorganizacji

Home Page

Title Page



Page 35 of 38

Go Back

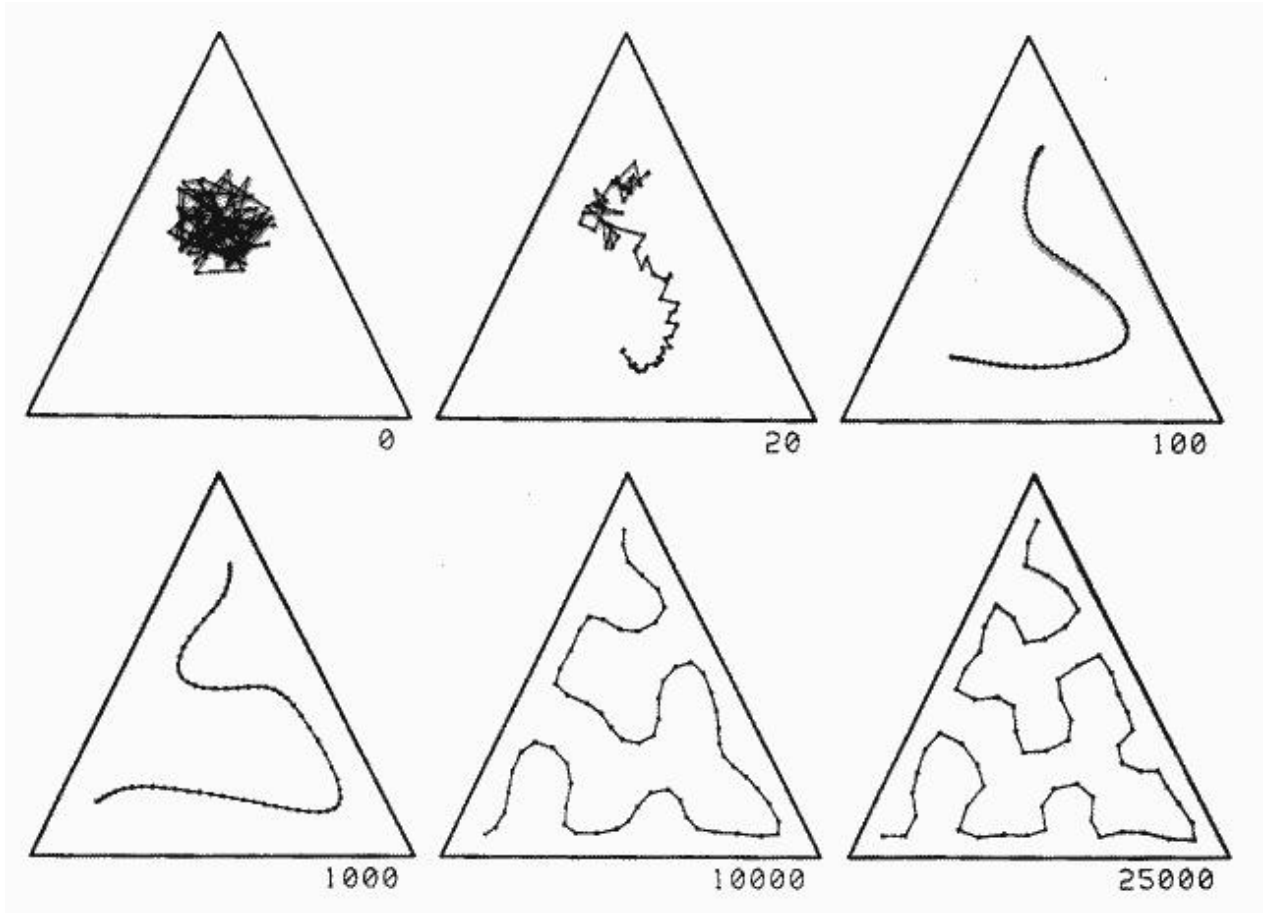
Full Screen

Close

Quit



## 6.6. Uczenie trojkąta w sieci 1D



Tworzy się fraktalne krzywe Peano.

Wprowadzenie

Matematyczny model...

Sieci rekurencyjne

Modele samoorganizacji

Home Page

Title Page



Page 36 of 38

Go Back

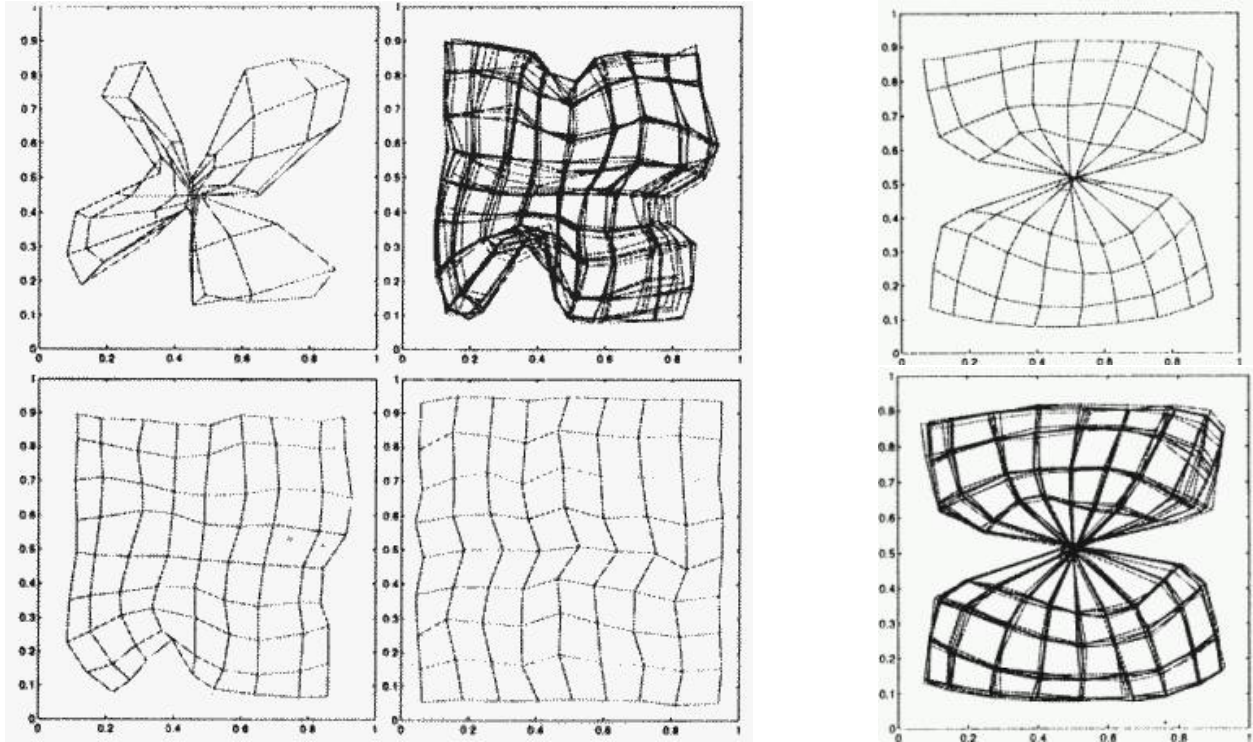
Full Screen

Close

Quit



## 6.7. Zniekształcenie



Początkowe zniekształcenia mogą zniknąć lub pozostać.

Wprowadzenie

Matematyczny model...

Sieci rekurencyjne

Modele samoorganizacji

Home Page

Title Page



Page 37 of 38

Go Back

Full Screen

Close

Quit



## 6.8. WEBSOM [websom.hut.fi/websom/](http://websom.hut.fi/websom/)

Wprowadzenie

Matematyczny model...

Sieci rekurencyjne

Modele samoorganizacji

Home Page

Title Page



Page 38 of 38

Go Back

Full Screen

Close

Quit

