

# SZTUCZNA INTELIGENCJA

## SZTUCZNE SIECI NEURONOWE – SIEĆ KOHONENA

Dr hab. inż. Grzegorz Dudek  
Wydział Elektryczny  
Politechnika Częstochowska


*Projekt finansowany w ramach programu Ministra Nauki i Szkolnictwa Wyższego pod nazwą „Regionalna Inicjatywa Doskonałości” w latach 2019 - 2022 nr projektu 020/RID/2018/19 kwota finansowania 12 000 000 PLN*

**Grupowanie danych** – inaczej rozpoznawanie obrazów bez nauczycielem (bez nadzoru), analiza skupień, klasteryzacja. Celem grupowania danych jest wykrycie ich naturalnych struktur i podział na skupiska. Wstępna informacja o przynależności obiektów do klas jest niedostępna. W fazie uczenia formuje się klasy na podstawie informacji zawartych w przykładach nieetykietowanych  $\mathbf{x} = [x_1 \ x_2 \ \dots \ x_n]$ . W rezultacie, każdemu przykładowi przyporządkowany zostaje numer klasy. Metody grupowania opierają się zwykle na pojęciu podobieństwa. Obserwacje należące do tej samej klasy cechuje wysoki stopień podobieństwa. Miary podobieństwa przy numerycznych atrybutach  $x_i$  wykorzystują funkcje odległości.

**Sieć Kohonena** (samoorganizujące się odwzorowanie cech, SOFM) używana jest do:

- grupowania danych
- niskowymiarowej reprezentacji danych wejściowych (przykładów)
- aproksymacji funkcji gęstości danych wejściowych


# ARCHITEKTURA SIECI KOHONENA



Wektory wagowe związane z poszczególnymi neuronami  $\mathbf{w}_i = [w_{i,1} \ w_{i,2} \ \dots \ w_{i,n}]$  są przyciągane przez grupy punktów uczących i w efekcie stanowią ich reprezentację.

# UCZENIE SIECI KOHONENA

Przykład. Dany jest zbiór punktów uczących (dwuwymiarowych)  $X = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_M\}$  oznaczonych na rysunku  $\times$ . Zbiór ten należy pogrupować za pomocą sieci Kohonena z dwoma neuronami. Pozycje początkowe wektorów wagowych tych neuronów  $\mathbf{w}_i = [w_{i,1} \ w_{i,2}]$  możemy nanieść w tym samym układzie współrzędnych (symbole  $\circ$ ).

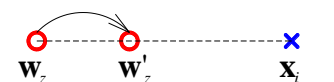


# UCZENIE SIECI KOHONENA

1. Losujemy wagi sieci.
2. Na wejście sieci prezentujemy wybrany punkt uczący  $\mathbf{x}_i = [x_{i,1} \ x_{i,2}]$ . Wyznaczamy odległości każdego wektora wag  $\mathbf{w}_j = [w_{j,1} \ w_{j,2}]$  od tego punktu. Najpopularniejszą miarą odległości jest odległość euklidesowa:


$$d(\mathbf{w}_j, \mathbf{x}_i) = \sqrt{\sum_{k=1}^n (w_{j,k} - x_{i,k})^2}$$

3. Neuron najbliższy punktowi  $\mathbf{x}_i$  wygrywa **konkurencję** i nazywany jest **zwycięzcą** (oznaczymy go symbolem "z"). Tylko ten neuron adaptuje swój wektor wag  $\mathbf{w}_z$  przybliżając go do punktu  $\mathbf{x}_i$ :

$$w'_{z,k} = w_{z,k} + \eta(x_{i,k} - w_{z,k})$$


gdzie  $\eta$  jest współczynnikiem uczenia,  $\eta \in (0, 1)$ .

4. Kroki 2-4 powtarzamy wielokrotnie. W efekcie wektory wagowe lokują się w centrach grup.



# UCZENIE SIECI KOHONENA

Przedstawiony powyżej algorytm nosi nazwę **zwycięzca bierze wszystko** (*winner takes all*). W alternatywnym algorytmie zwanym **zwycięzca bierze większość** (*winner takes most*) prawo do modyfikacji swoich wag mają również neurony z sąsiedztwa neuronu zwycięskiego.

Definiuje się funkcję sąsiedztwa  $G(j, r)$ , np.:

$$G(j, r) = \begin{cases} 1 & \text{jeśli } d(z, j) = 0 \\ 0,5 & \text{jeśli } d(z, j) \leq r \\ 0 & \text{jeśli } d(z, j) > r \end{cases}$$

gdzie:

$d(z, j)$  – odległość pomiędzy neuronem zwycięskim a neuronem  $j$ -tym mierzona w warstwie neuronów. (Możemy założyć, że neurony położone obok siebie, tzn. neuron  $j$ -ty i  $j+1$  oraz  $j$ -ty i  $j-1$ , znajdują się w umownej odległości równej 1. Wtedy neurony oddalone o  $q$  pozycji znajdują się w odległości  $d = q$ .)



$r$  – promień sąsiedztwa ( $r \geq 0$ ). Jeśli odległość  $d(z, j)$  jest mniejsza od tego promienia, oznacza to, że neuron  $j$ -ty należy do sąsiedztwa neuronu zwycięskiego  $z$ .

# TOPOLOGIE SIECI KOHONENA

## Funkcja sąsiedztwa

Wagi neuronów modyfikuje się według wzoru:

$$w'_{j,k} = w_{j,k} + \eta G(j,r)(x_{i,k} - w_{j,k})$$




## Modyfikacje położenia wektorów wagowych

Warto zauważyć, że modyfikacji ulegają wektory wag neuronów sąsiednich w stosunku do zwycięskiego niezależnie od ich odległości od punktu uczącego  $x_i$ .

# SIEĆ KOHONENA W MATLABIE

Ostatecznie prowadzi to do takiej sytuacji, że sąsiednie grupy punktów uczących są reprezentowane przez sąsiednie neurony. Tę właściwość nazywa się zachowaniem topologii, a całą sieć **samoorganizującym się odwzorowaniem cech** (*self-organizing feature map – SOFM*).

Neurony mogą być rozłożone w warstwie nie tylko liniowo, ale również planarnie. Często spotykane topologie: liniową, prostokątną (gridtop) oraz heksagonalną (hextop) pokazano poniżej (zaznaczono sąsiedztwo dla  $r = 1$ ). Topologie te różnią się sąsiedztwem, które przy tym samym promieniu obejmuje różną liczbę neuronów.






# SIEĆ KOHONENA W MATLABIE

Algorytm uczenia sieci SOFM zaimplementowany w Matlabie przebiega w dwóch fazach:

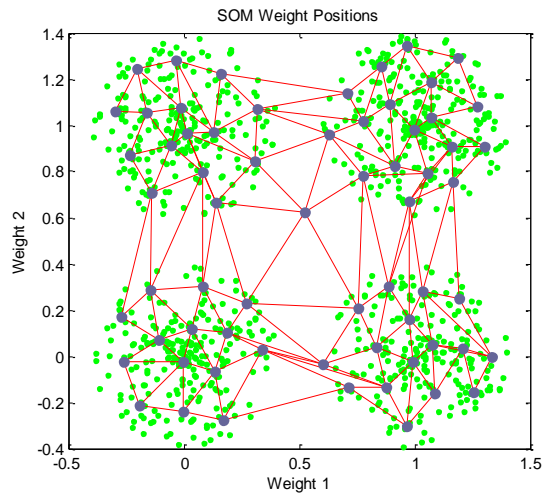
- faza porządkowania – następuje porządkowanie neuronów tak, aby sąsiednie neurony w warstwie odpowiadały sąsiednim grupom punktów uczących. Współczynnik uczenia w tej fazie maleje od  $\eta_1$  do  $\eta_2$ , a promień sąsiedztwa maleje od początkowej wartości równej maksymalnej odległości pomiędzy dwoma neuronami w warstwie do  $r$ .
- faza strojenia – następuje dokładne "dopasowanie" neuronów do danych uczących. Promień sąsiedztwa pozostaje stały, równy  $r$ , a współczynnik uczenia maleje dalej, lecz znacznie wolniej niż w fazie porządkowania.

*Rysunek. W pierwszej fazie można zaobserwować gwałtowne zmiany pozycji neuronów (porządkowanie), w fazie drugiej, która rozpoczyna się w 50 epoce, zmiany są niewielkie (strojenie).*




# SIĘĆ KOHONENA W MATLABIE

Rozmieszczenie punktów uczących i neuronów




Odległości pomiędzy sąsiednimi neuronami





# SIEĆ KOHONENA W MATLABIE

Liczba punktów uczących  
reprezentowanych przez  
neurony



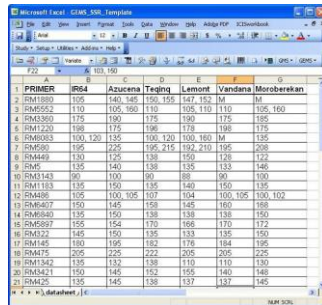
Wartości wag




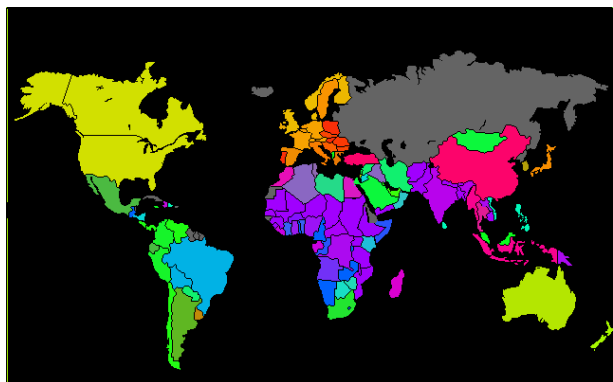

# PRZYKŁAD APLIKACYJNY

## Wizualizacja poziomu ubóstwa

Dane Banku Światowego:  
39 wskaźników jakości życia



	A	B	C	D	E	F	G
1	Probeer	RSD	Azucena	Teging	Lemont	Vandana	Morobekran
2	USA	100	140	105	100	147	102
3	USA	110	105	160	110	105	110
4	USA	115	160	175	160	175	160
5	USA	120	180	175	160	175	175
6	USA	120	135	100	120	100	135
7	USA	105	105	105	215	100	210
8	USA	110	125	138	150	128	132
9	USA	125	140	138	135	133	146
10	USA	143	90	100	88	90	100
11	USA	113	115	100	105	140	100
12	USA	105	100	105	104	100	105
13	USA	107	110	145	158	145	160
14	USA	105	115	150	138	138	150
15	USA	107	155	154	170	166	170
16	USA	122	145	150	135	133	150
17	USA	145	160	165	162	176	165
18	USA	175	205	225	205	205	225
19	USA	162	135	132	138	110	110
20	USA	121	150	145	152	155	140
21	USA	125	135	145	138	137	145



## Diagnostyka techniczna

Na siatce neuronów można obserwować trajektorię „ruchu” parametrów obiektu po zwyciężskich neuronach, którym nadano etykiety klasy stanu technicznego. Tę samą trajektorię można wykreślić na tle mapy rozkładu wartości każdej  $j$ -tej składowej wektora wagowego, która reprezentuje odpowiedni symptom. Po skojarzeniu wartości wagi z odcieniem koloru szarego mamy możliwość obserwacji w jaki sposób zmienia się wartość symptomu wzdłuż trajektorii. Ponadto podobnie ukształtowane obrazy rozkładu poszczególnych wag świadczą o korelacji między nimi, co można wykryć w prosty, wizualny sposób.

