

SZTUCZNA INTELIGENCJA

WYKŁAD 7. SZTUCZNE SIECI NEURONOWE – SIEĆ KOHONENA

Dr hab. inż. Grzegorz Dudek
Wydział Elektryczny
Politechnika Częstochowska


Częstochowa 2014

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).

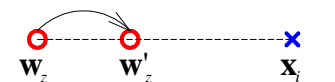


UCZENIE SIECI KOHONENA

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 η 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 .

UCZENIE 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

TOPOLOGIE SIECI KOHONENA

Warto zauważyć, że modyfikacji ulegają wektory wag neuronów sąsiednich w stosunku do zwycięskiego niezależnie od ich odległości od punktu uczącego x_i . 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 η_1 do η_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).




SIEĆ KOHONENA W MATLABIE

Rozmieszczenie punktów uczących i neuronów




Odległości pomiędzy sąsiednimi neuronami





SIEĆ KOHONENA W MATLABIE

Liczba punktów uczących
reprezentowanych przez
neurony




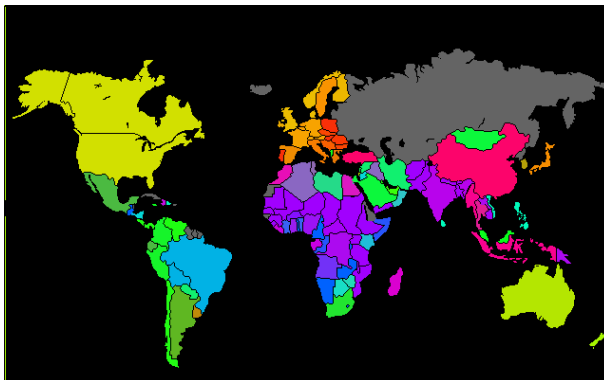
Wartości wag



Wizualizacja poziому ubóstwa

Dane Banku Światowego:
39 wskaźników jakości życia

	PRIMER	IK4	Azusa	Tegung	Lemot	Vandana	Moroberkan
2	RM18552	105	140	145	150	155	147
3	RM18582	110	150	160	110	110	110
4	RM18583	110	150	160	110	110	110
5	RM12230	158	175	196	175	198	175
6	RM12231	100	120	150	120	100	160
7	RM12232	100	120	150	120	100	160
8	RM4440	130	125	138	150	128	122
9	RM4441	130	125	138	150	128	122
10	RM4442	130	125	138	150	128	122
11	RM4443	130	125	138	150	128	122
12	RM4343	90	100	90	88	90	90
13	RM1183	135	150	135	140	150	140
14	RM4386	105	130	105	107	105	102
15	RM4367	150	145	158	145	160	168
16	RM4380	150	150	130	138	138	150
17	RM4381	145	150	138	138	138	138
18	RM4322	145	150	135	133	135	135
19	RM1145	135	132	132	132	132	132
20	RM4475	205	195	205	205	205	205
21	RM1342	135	132	138	110	110	110
22	RM1343	135	132	138	110	110	110
23	RM1344	135	132	138	110	110	110
24	RM4265	135	145	138	137	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.

