

7. SAMOORGANIZUJÍCÍ SE SÍTY

- samy se snaží objevit zákonitosti a souvislosti ve vstupních datech (tav. process sameorganizace) tzn. během učení (učení bez učitele) se snaží nastavit podobné vstupy reagovat typicky podobnými vstupy → dochází k tav. shlukování vstupních dat
- měří podobnosti se obvykle používá pomocí Eukleidovské radělosti.

Poznámka: Eukleidovská radělosť mezi vektorami a a b dimenze n

$$\|a - b\| = \sqrt{(a-b)^T \cdot (a-b)} = \sqrt{\sum_{i=1}^n (a_i - b_i)^2}$$

Důkaz:

- $\underline{w}_m(k)$... centroid shluku S_m před přidáním vektoru x
 $P_m(k)$... počet vektorů ve shluku S_m před přidáním vektoru x
 $S_m(k)$... množina vektorů, které jsou zahrnuty ve shluku S_m před přidáním vektoru x
 $\underline{w}_m(k+1)$... centroid shluku S_m po přidání vektoru x
 $P_m(k+1)$... počet vektorů ve shluku S_m po přidání vektoru x (tzn. $P_m(k+1) = P_m(k) + 1$)
 $S_m(k+1)$... množina vektorů, které jsou zahrnuty ve shluku S_m po přidání vektoru x
(tzn. $S_m(k+1) = S_m(k) \cup \underline{x}$)

Princip shlukování:

Předpokládejme, že máme množinu P vektorů dimenze n $\{x_1, x_2, \dots, x_p\}$, které chceme rozdělit do R shluků S_1, S_2, \dots, S_R , přičemž každý shluk je reprezentován svým centroidem \underline{w}_r , $r = 1, 2, \dots, R$, pro který platí

$$\underline{w}_r = \frac{1}{P_r} \sum_{x_j \in S_r} x_j ; P_r \dots \text{počet vektorů ve shluku } S_r$$

Vektor x chceme zařadit do jednoho z R shluků → zařadíme ho do toho shluku S_m , k jehož centroidu je x nejbliže → musí platit

$$\|x - \underline{w}_m\| = \min_{r=1, \dots, R} \|x - \underline{w}_r\| \quad (1)$$

Po přidání vektoru x do shluku S_m se změní poloha centroidu \underline{w}_m , centroidy ostatních shluků zůstávají bez změny.

$$\begin{aligned} \underline{w}_m(k+1) &= \frac{1}{P_m(k+1)} \sum_{x_j \in S_m(k+1)} x_j = \frac{1}{P_m(k+1)} \left[\sum_{x_j \in S_m(k)} x_j + \underline{x} \right] = \\ &= \frac{1}{P_m(k+1)} \left[\frac{P_m(k)}{P_m(k)} \cdot \sum_{x_j \in S_m(k)} x_j + \sum_{x_j \in S_m(k)} x_j + \underline{x} \right] = \\ &= \frac{1}{P_m(k+1)} \left[P_m(k) \cdot \underline{w}_m(k) + \underline{x} + \underline{w}_m(k) - \underline{w}_m(k) \right] = \\ &= \frac{1}{P_m(k+1)} \left[\underline{w}_m(k) \cdot (P_m(k)+1) + \underline{x} - \underline{w}_m(k) \right] = \\ &= \underline{w}_m(k) + \frac{\underline{x} - \underline{w}_m(k)}{P_m(k+1)} \end{aligned} \quad (2)$$

7.1. Kohonenova síť

- určena pro shlukování vstupních vektorů
- dimenze n do R shluků
- je jednorastrová nerekurentní síť s R výstupy, n vstupy a nulovým počtem vektorů
- každý řádek vahové matice je normalizován tak, že má relikost 1, tzn. že pro i -tý řádek vahové matice platí

$$\|\underline{w}_i\| = \sqrt{\sum w_{ij}^2} = 1$$

7.1.1. Učení Kohonenovy sítě

- jde o učení bez učitele
- probíhá na základě tzv. pravidla ritče ("ritč zbere vše") \rightarrow na základě vstupního vektoru x se změní vahy m-tého neuronu podle vztahu

Vlastnosti Kohonenovy sítě

- 1, vahy neuronů se při trénování blíží do středu shluků, které reprezentují
- 2, síť má pouze jednu vrstvu \rightarrow lze s ní najít pouze lineárně oddělitelné shluky.
- 3, i v případě lineárně oddělitelných shluků nemusí být tyto shluky růdy nalezeny.
- 4, vahy mění se podle vztahu (3) při konstantní hodnotě a nekonvergují ke konstantním hodnotám. Proto se tato využívá proměnná konstanta učení $c(t)$, která má po určité době t_p (např. 1000 kroků) konstantní hodnotu a pak se snižuje (např. podle vztahu

$$c(t) = c_0 \cdot e^{-\frac{t-t_p}{t_q}} \quad \text{pro } t > t_p,$$

kde t_q udává rychlosť poklesu).

$$\hat{\underline{w}}_m(k+1) = \underline{w}_m(k) + c \cdot (x - \underline{w}_m(k)) \quad (3)$$

- c ... konstanta učení, obvykle $c \in [0,1; 0,7]$
přičemž m -ty neuron je tzv. ritč, pro kterého platí

$$\underline{w}_m \cdot x = \max_{i=1,2} \underline{w}_i \cdot x \quad (4)$$

\Rightarrow minimální vahy neuronu a maximální aktivací vektoru, vahy ostatních neuronů se minimální.

Po změně vah je třeba vahový vektor m-tého neuronu normalizovat, tzn.

$$\underline{w}_m = \frac{\hat{\underline{w}}_m}{\|\hat{\underline{w}}_m\|}$$

Vahová matice $\underline{W}(0)$ se inicializuje nhl. císky, poté je třeba provést normalizaci každého řádku.

Poznámka: Pokud předem neznáme počet shluků, předpokládáme, že shluky jsou velké množství. Během trénování pak některé neurony pravděpodobně nebudu měnit své vahy \rightarrow nemají význam a lze je vypustit.

Použití Kohonenovy sítě

- hledání shluků ve vstupních datech
- vektorová klasifikace

- 5) Po natrejnrování síť bude pro zadany vstupní vektor nejdříji hodnota na výstupu toho neuronu, jehož vahy reprezentují centrum shluku, ke kterému náleží daný vstupní vektor nejblíže.

7.2 Kohonenova mapa (feature map) (67)

- speciální případ Kohonenovy sítě
- neurony jsou uspořádány tak, že tvoří jednorozměrné či dvourozměrné pole.

Učení Kohonenovy mapy

- učení bez učitele podle pravidla výše
- mění se nejen ráhy významného neuronu, ale i ráhy neuronů okolních.

Pro změnu ráh platí

$$\underline{w}_i(t+1) = \underline{w}_i(t) + c_i (\underline{x}^T - \underline{w}_i(t)) \quad \text{pro } i \in N_{\text{mv}}(L)$$

$N_{\text{mv}}(L) \dots i\text{-ty rádek maticy } \underline{W} \text{ (není normalizovaný)}$

$N_{\text{mv}}(L) \dots \text{okolí } m\text{-tého (významného) neuronu v řádku } L$

$c \dots \text{konstanta učení}$

Pro významný neuron m v případě platí

$$\|\underline{x} - \underline{w}_m^T\|_0 = \min_{i=1,\dots,R} \|\underline{x} - \underline{w}_i^T\|$$

! rádky ráhové matice se nenormalizují!

Definice okolí významného neuronu (68)

okolí o poloměru 0 - zahrnuje pouze významný neuron

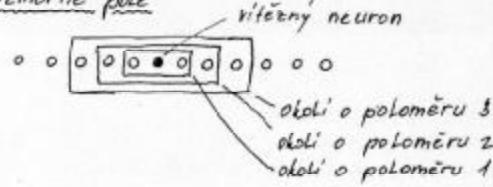
okolí o poloměru 1 - zahrnuje významný neuron a jeho bezprostřední sousedy

okolí o poloměru 2 - zahrnuje neurony z okolí o poloměru 1 a jejich bezprostřední sousedy

okolí o poloměru 3

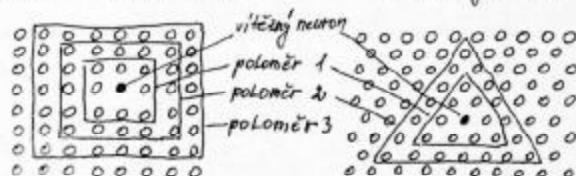
Ilustrace různých typů okolí (68)

- jednorozměrné pole

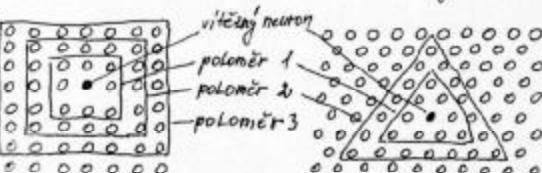


- dvourozměrné pole

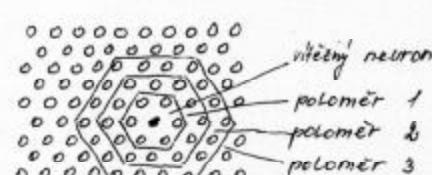
- okolí pravoúhlého traru



- okolí trojúhelníkového traru



- okolí šestúhelníkového traru



- v procesu trénování sítě se velikost okolí snižuje. Na začátku trénování se velikost okolí obvykle volí tak, že zahrnuje všechny neurony sítě. Pak se velikost okolí lineárně snižuje až na nulu, když okolí obsahuje pouze významný neuron. Doba trénování se obvykle volí tak, aby doba, po kterou je velikost okolí rovna 0, byla přibližně 3x větší než doba, po kterou docházelo ke snižování velikosti okolí.

- inicializace vah se provádí malými náhodnými čísleny, obvykle z intervalu $\langle -0,1; 0,1 \rangle$

- konstanta učení c je podobně jako u Kohonenovy sítě proměnlivá v čase.

Použití Kohonenových map

- redukce počtu příznaků pro klasifikaci
- vizualizace vektorů velké dimenze