

učení sítí lze klasifikovat následovně - s učitelem (např. BP, učení perceptronu);
 Při učení jsou k dispozici dvojice (vstup, výstup)
 výstup ~ správné odpovědi ~ učitel
 (angl. supervised learning)
 - bez učitele (unsupervised learning)
 info o správném výstupu není k dispozici
 ↓ (nebo nemá smysl)
 příkladem: samoorganizující se síť

charakteristickým rysem samoorganiz. sítí je

tzv. kompetitivní učení (soutěžní, competitive):

- po předložení vstupu výstupní neurony "soutěží" o to, který bude aktivní (vždy jen jeden), vítězný neuron tzv. rozpozná vstupní vzor (vstupní signál)
- poprvé popsáno v 60. letech 20. stol.
- existuje řada modelů, nejuznávanější jsou Kohonenovy mapy
- neurofyziologické údaje potvrzují, že některé části mozku pracují na principu soutěžního učení (termín grandmother cell - neuron, který rozpoznává babičku)

základní úkol: - dáme třímístné množina $T = \{x^p \in \mathbb{R}^n \mid p \in P\}$ vzorů

(obecněji může být záměrně rozděleni pravidelně do skupin) (např. vstup)

a parametr m (počet reprezentantů ~ výstupních neuronů)

- reprezentant $j=1, \dots, m$ je dán vektorem $\|w_j = (w_{1j}, \dots, w_{nj}) \in \mathbb{R}^n$

↓
někdy codebook words

u našem pohledu udělají spojení

- jsou-li už nějaké $\|w_j$ určeny a je-li $x \in \mathbb{R}^n$ vstup,

je mu přiřazen reprezentant c , který je mu nejbližší:

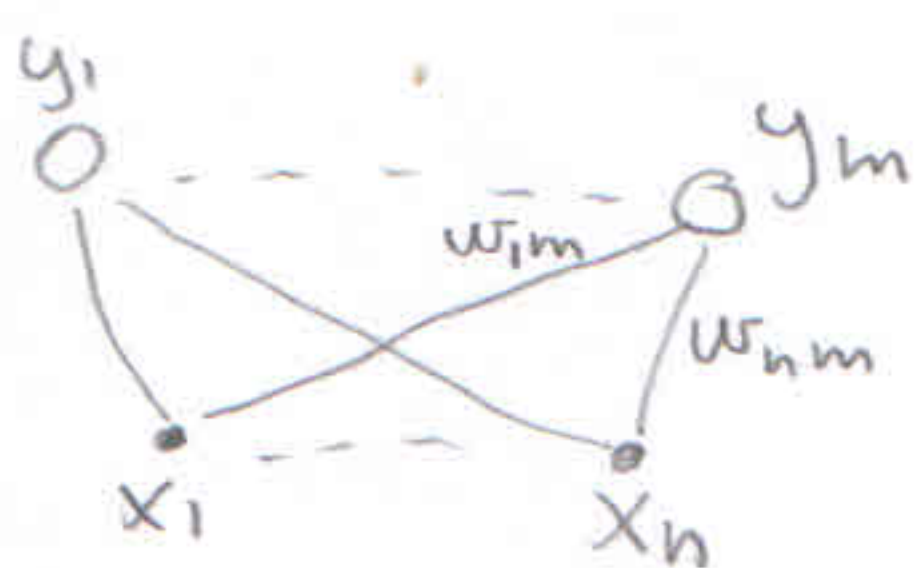
$$c = \arg \min_{j=1, \dots, m} \|x - w_j\|, \text{ kde např. } \|x - w_j\| = \sqrt{\sum_{i=1}^n (x_i - w_{ij})^2}$$

Eukl. norma

- cítem je najít m reprezentantů, pro které je

$$E = \frac{1}{|P|} \sum_{p \in P} \|x^p - w_c\|^2 \text{ minimální}$$

schéma ~ kompetitivní
neur. síť




Lloydův algoritmus učení

- inicializuj $\|w_j$ náhodně
- opakuj následující, dokud chyba měřena pod zadanou ϵ (přesnost)
 - pro každé $T \subset P \in T$ urči příslušný vítězný neuron $\|w_c$
 - pro $j=1, \dots, m$ (číslo neuronů) urči $T_j =$ množina vstupů z T , pro které byl j vítězem, tj. $T_j = \{p \in P \mid j = \text{arg min}_j \|x_p - w_j\|\}$
 - $\mu_j = \frac{1}{|T_j|} \sum_{x \in T_j} x$... těžiště T_j
 - $\|w_j\| \leftarrow \mu_j$

ke změně reprezentanti dat je až po přejetí celou T na poměrně, mnohdy, osvědčená a následující on-line verze, která mj. odpovídá předstevě neurofyzologie

Kohonenovo učení

tedy, v kontextech neur. sítí:



aktivacní dynamika

- předložen vstup $x \in \mathbb{R}^n$
- výstupy $y_j = \begin{cases} 1 & \text{pokud } j = \text{arg min}_{e=1}^m \|x - w_e\| \dots \text{zchodí} \\ 0 & \text{jinak} \dots \text{mezhoří} \end{cases}$

↓
vždyť také ell, realizováno mechanismem laterální inhibice


učení (adaptivní dynamika)

- pro každé T_j pro každé $x \in T$ proved' pro každé $j=1, \dots, m$

$$\|w_j(t+1)\| = \begin{cases} \|w_j(t)\| + \theta(x - \|w_j(t)\|) & \text{pokud } j = \text{arg min}_e \|x - w_e\| \\ \|w_j(t)\| & \text{jinak} \end{cases}$$

tedy $w_{ij}(t+1) = \begin{cases} w_{ij}(t) + \theta(x_i - w_{ij}(t)) \\ w_{ij}(t) \end{cases}$ θ ... rychlost učení, $0 < \theta < 1$, v čase se zmenšuje

geometrie postka $n=2$



+ ... vektor $x \in T$
 0 ... vektor vch W_j

tento mechanismus je známý v literatuře o šlukovník
 jako k-means clustering

Kohonenovy (samoorganizující) mapy


- Tevo Kohonen 1982
- podstatně výše uvedené jednoduché samoorganizující síti, neurony jsou navíc uspořádány do topologické struktury, např. 2D mřížky
- topol. struktura dělá vhodnou vzdálenost neuronů; k neuronu i je dělá jeho okolí:

$$N_{\sigma}(i) = \{j \mid d(i,j) \leq \sigma\}$$

↑ velikost okolí
 ↑ neuron

↑ vzdálenost neuronů i a j
 ↓ σ

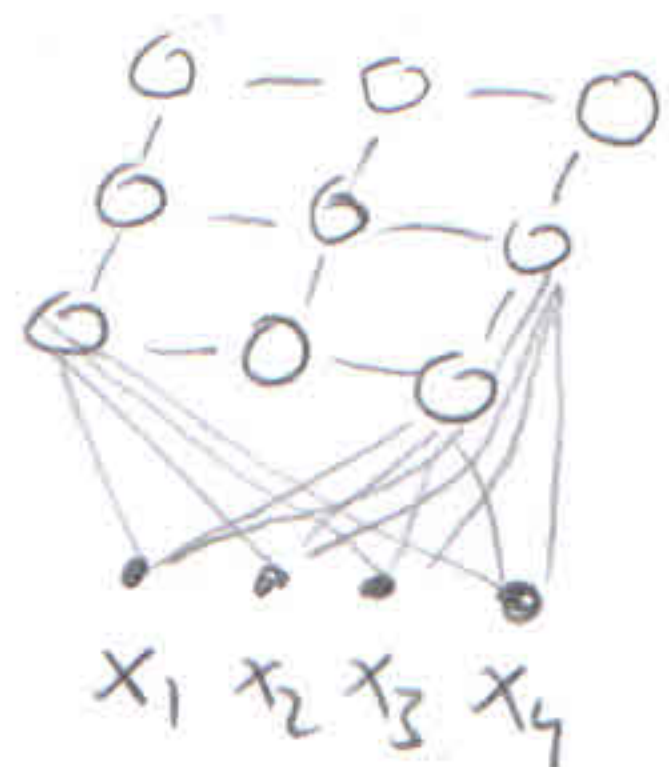
- pr.: 2D mřížka



$N_{\sigma}(i)$ pro $\sigma=1$

$d(i,j)$ = délka cesty mezi i a j

- síť



každý neuron j je připojen ke všem vstupům x_1, \dots, x_4
 velký $w_{1j}, w_{2j}, w_{3j}, w_{4j}$

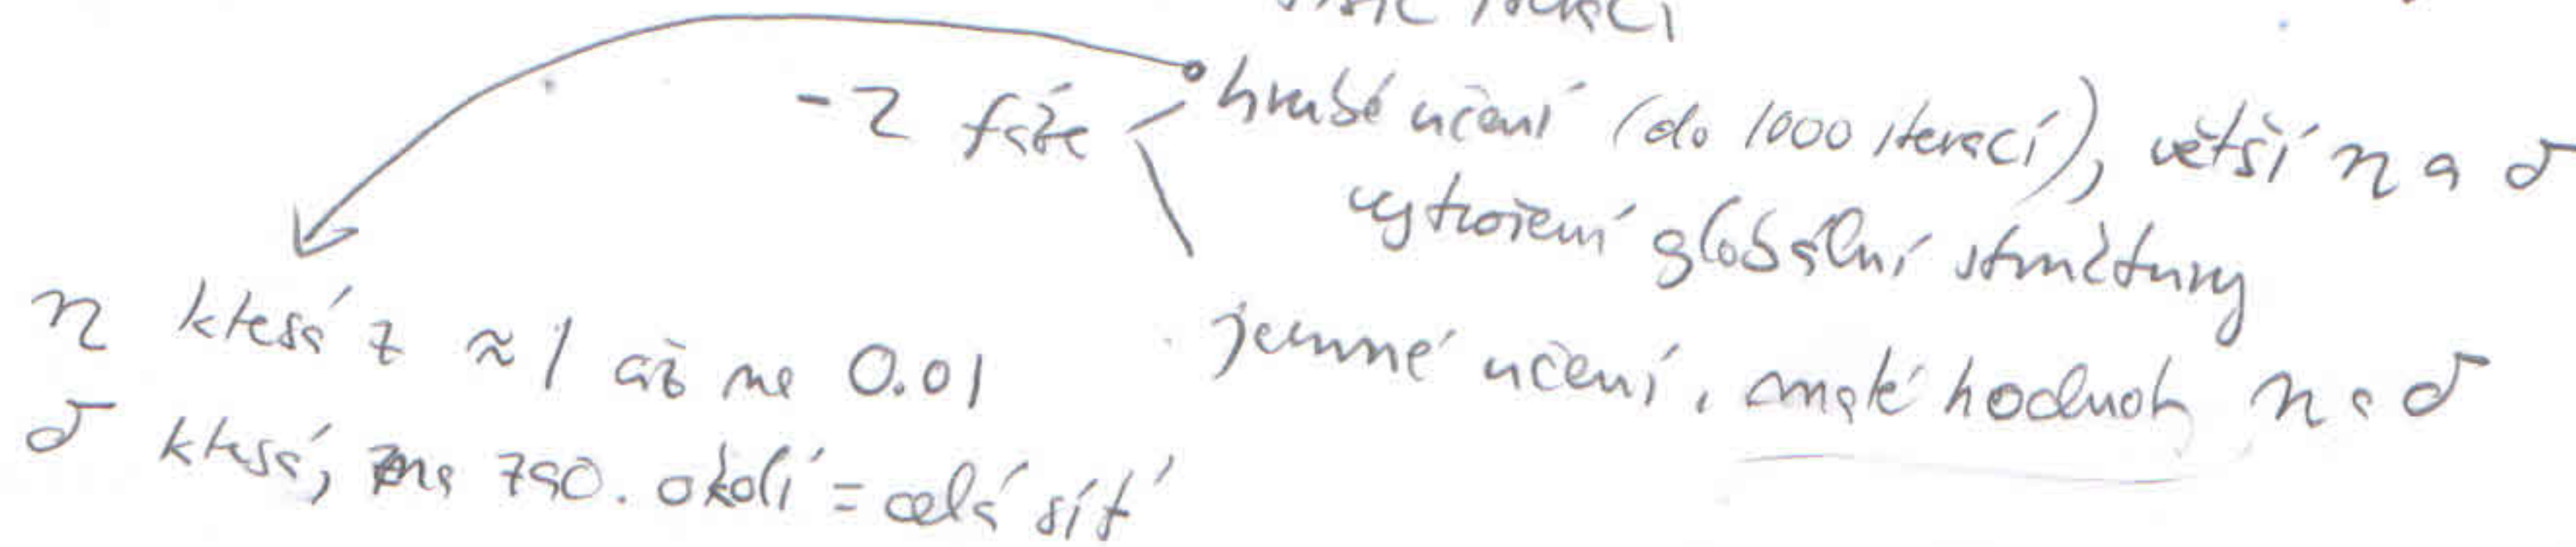
- adaptace: - jako u jednoduché samooř. síťe, se adaptují se vždy jak uítěžného neuronu, tak neuronů v jeho okolí:

$$w_j(t+1) = \begin{cases} w_j(t) + (\eta (x - w_j(t))) & \text{pro } j \in N_j(c) \\ w_j(t) & \end{cases}$$


kde $c = \arg \min_e \|x - w_e\|$

σ má začít být velká, postupně klesá
 η má začít být ≈ 1 , postupně klesá

- Popř. η klesá i má udělenosti j od c
- doplnění: - aby se vytvořila rozumná struktura, doplněje se 10-100 tisíc iterací



- Kohonenova síť umožňuje "mapovat" body ze vstupního prostoru \mathbb{R}^n (Kohonenova mapa) do 2D struktury (struktury neuronů), nebo jiné nižšídimenzionální struktury



Samorganizující se sítě a učení s učitelem

SOS lze využít pro učení s učitelem, kombinováno pro klasifikaci dat následovně.

Je dána $T = \{ \langle x^p, c^p \rangle \mid p \in P, x^p \in \mathbb{R}^n, c^p \in \{1, \dots, k\} \}$

vstup x^p má být přiřazen do třídy c^p (jedna z k tříd)

(př.: x^p popisuje parametry výrobku, $c^p = 1 \Leftrightarrow$ výrobek je ok
 $c^p = 0$ výrobek)

Postup:

a) nejprve uvažujeme $T' = \{ x^p \mid p \in P \}$, tj. ignorujeme c^p ,

a vytvoříme kompetitivním učením samorganizující se síť

s n vstupy a m neurony ve výstupní vrstvě ($k \leq m$)

b) označíme výstupní neurony třídami $1, \dots, k$, do kterých se klasifikuje:

každý výstupní neuron j označíme tou třídou $c(j) \in \{1, \dots, k\}$ s tou vlastností,

že ze všech x^p , pro které je j vítězem, jich nejvíce patří do $c(j)$

tedy: propleme celou T a pro každý $\langle x^p, c^p \rangle$ určíme vítězný neuron j pro vstup x^p , zapamätujeme $c(j)$, ...

c) doučíme síť pro T algoritmem LVQ (Learning Vector Quantization)

mápr. následujícího (známý jako LVQ1):

pro $\forall \langle x^p, c^p \rangle \in T$:

určí vítěze $j = \arg \min_e \|x^p - w_e\|$

upraví velky: $w_j(t+1) = \begin{cases} w_j(t) + \alpha(x^p - w_j(t)) & \text{pokud } c(j) = c^p \\ w_j(t) - \alpha(x^p - w_j(t)) & \text{pokud } c(j) \neq c^p \end{cases}$

Opakuj, přitom snižuj α (např. tisíce - desítktisíc iterací, během

kterých α klesne z cca 0.01-0.02 k 0)