


## 12. Samoorganizujúce sa neurónové siete, hebbovské učenie, učenie so súťažím, klasterizácia dát, vizualizácia vysokorozmerných dát.

SOM = SamoOrganizujúca sa Mapa

Zachovanie topológie – zobrazenie charakteristických črt trénovacej množiny dát – na vstupy, ktoré sú si blízke vo vstupnom priestore budú reagovať neuróny fyzicky blízke na mape

Mapa: zväčša 2 alebo 3 rozmerná mriežka (alebo reťaz), 1 políčko = 1 neurón


Biologická motivácia: mechanizmus projekcie zo sietnice na mozgovú kôru



**Obrázok 7.1.** Dva typy architektúry neurónovej siete na topologické zobrazenie príznakov. (a) Biologicky inšpirovaný model, napr. na simulovanie retinotopického problému. Vrstvy sú úplne prepojené, pre názornosť sú zakreslené len niektoré spojenia. (b) Konvenčný model s modifikovanou reprezentáciou vstupov, ktorá vo vzťahu k predchádzajúcemu prípadu môže predstavovať napr. súradnice aktuálneho stimulu (ak použijeme dvojrozmerné vstupy).

### Mechanizmus fungovania

- ⇒ okrem prepojení neurónov so vstupmi (každý s každým) aj **laterálne spojenia** medzi neurónmi
- ⇒ sila týchto spojení sa so vzdialenosťou od neurónu mení podľa profilu tvaru mexického klobúka – aktívny neurón excituje susedné a inhibuje vzdialené neuróny (čo spôsobí lepšiu profiláciu oblastí na typy vstupov, pre 1 vstup je aktívny viac než 1 neurón, čo zabezpečuje redundanciu, odolnosť voči chybe – vypadnutiu neurónu)



**Obrázok 7.2.** Profily vplyvu laterálnej interakcie: (a) Typ mexického klobúka. (b) Zjednodušený profil používaný v simuláciách. V oboch prípadoch je daný profil spätnoväzbových prepojení rovnaký pre všetky neuróny, hodnota konkrétnej váhy je funkciou vzájomnej vzdialenosti neurónov  $i$  a  $i^*$ .  $d_E$ , ( $d_I$ ) označuje dosah laterálnej excitácie (inhibície),  $\gamma_E$ , ( $\gamma_I$ ) označuje váhu excitačnej (inhibičnej) synapsy.

⇒ Hebbovské učenie: fire together wire together;

$$\text{výstup } y = \sum_{j=1}^n w_j x_j = w^T x; \text{ váhy: } w_j(t+1) = w_j(t) + \alpha y(t) x_j(t)$$


⇒ učenie bez učiteľa, lineárne neuróny, ktoré v podstate priamo reprezentujú vstupy

⇒ algoritmus **winner-take-all** (z pohľadu susedov winner-take-most) – neurón s maximálnou aktiváciou (best matching unit) vyhráva a upravujú sa mu váhy – **učenie so súťažnosťou**, tiež sa upravujú neuróny v jeho okolí (laterálna excitácia)

⇒ nevýhoda algoritmu: môžu vzniknúť mŕtve neuróny (váhy sa inicializujú náhodne, môže sa stať, že niektoré neuróny nezareagujú na žiaden vstup, teda sa nebudú vôbec adjustovať a ani ďalej reagovať = ostanú mŕtve)

⇒ simulácia laterálnej interakcie = adjustovanie váh len vo vybranom **okolí** neurónu, ktoré sa s pribúdajúcim časom zužuje

⇒ **štvorcové** (Manhattanské, na obrázku) alebo **Gaussovské okolie**



### Algoritmus (Kohonen, 1982)

1. náhodne vyber vstup  $x$

2. nájdi víťaza  $i^*$  pre  $x : i^* = \operatorname{argmin}_i \|x - w_i\|$

(víťazí neurón ktorý je najbližšie vstupu, porovnávajú sa váhy s komponentami vstupného vektora, váhy zodpovedajú vstupu)

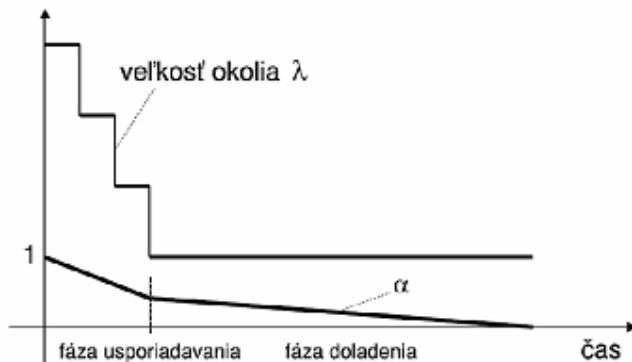
3. uprav váhy:  $w_i(t+1) = w_i(t) + \alpha(t) \cdot h(i^*, i) \cdot [x(t) - w_i(t)]$

( $w$  = matica váh,  $\alpha$  = rýchlosť učenia, zvyčajne medzi 0.01 a 0.1,  $h$  = funkcia vzdialenosti medzi 2 neurónmi)

4. uprav všeob. parametre siete (rýchlosť učenia, veľkosť okolia)


5. ak splnené kritéria: koniec (počet epoch, miera úspešnosti,...)

Ako správne nastavovať všeobecné parametre siete:



## Klasterizácia dát (??)

- ⇒ z Wikipedie: *Cluster analysis or clustering is the assignment of a set of observations into subsets (called clusters) so that observations in the same cluster are similar in some sense. Clustering is a method of unsupervised learning, and a common technique for statistical data analysis used in many fields, including machine learning, data mining, pattern recognition, image analysis and bioinformatics.*
- ⇒ Výborná vlastnosť SOM: **zachovávanie topológie dát** – sieť je po naučení usporiadaná, plne rozvinutá, bez násilného kríženia uzlov (váhových vektorov)
- ⇒ Ďalšia vlastnosť: aproximácia hustoty vstupných dát
- ⇒ **Magnifikačný faktor** = počet váhových vektorov pripadajúcich na jednotkovú plochu vstupného priestoru, funkcia pozície v mape

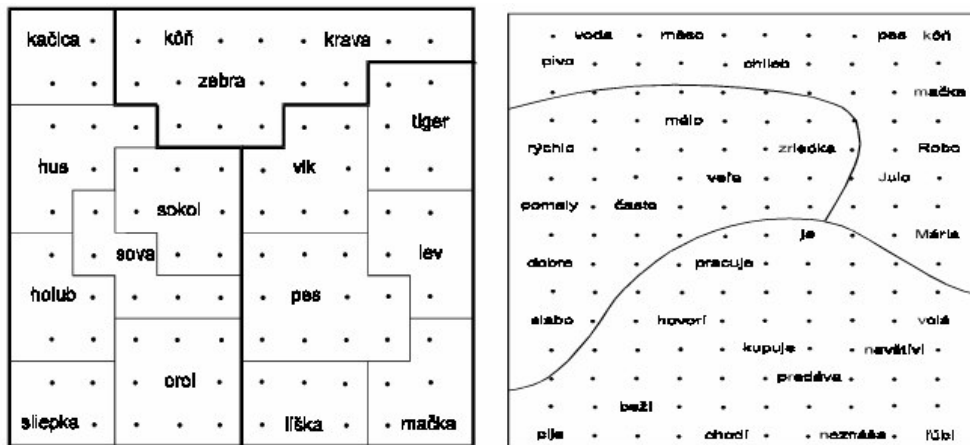


Obrázok 7.12. Ilustrácia aproximácie funkcie hustoty dát s gaussovským rozdelením v rovine pomocou SOM (20000 iterácií).

## Vizualizácia vysokorozmerných dát

SOM umožňuje topograficky zmapovať (reprezentovať) distribúciu vstupných dát, pričom častejšie prípady aplikácie sú tie, keď počet neurónov v sieti za zvolí menší ako počet vstupov. V takom prípade každý neurón sa stane reprezentantom nejakej podmnožiny navzájom podobných vstupov. V opačnom prípade množina blízkych neurónov bude reagovať na ten istý vstup, pričom jeden z nich sa stane (najaktívnejším) centrom. V oboch prípadoch susedné neuróny budú mať tendenciu reprezentovať blízke oblasti vo vstupnom priestore. V prípade nerovnomernej distribúcie vstupov SOM proporcionálne rozdelí svoje zdroje a viac zahusteným oblastiam pridelí viac neurónov, čím sa zvýši diskriminačná schopnosť siete v tejto oblasti (magnifikačný faktor). Vďaka 2D štruktúre neurónov sa SOM používa hlavne na vizualizáciu vysokorozmerných dát.

**Príklady použitia:** minimum spanning tree, lexical maps, robotic arm control



Obrázok 7.26. (a) Usporiadanie symbolov v SOM podľa ich atribútov. Ohraničené oblasti odpovedajú jednotlivým symbolom, v rámci každej z nich je neurón s maximálnou odozvou označený symbolom triedy. Usporiadanosť je evidentná medzi zvieracími druhmi (oddelenými hrubšími čiarami) i v rámci nich. (b) "Sémantická mapa" symbolov vygenerovaná na základe vzorov symbol—dvojslovný kontext. Separované oblasti označujú jednotlivé slovné druhy, v rámci ktorých je navyše evidentná usporiadanosť podľa významu zastúpených symbolov.