

Kohonenovy Mapy

Jakub Komoráš

Vysoká škola báňská – Technická univerzita Ostrava

Fakulta elektrotechniky a informatiky

16. 3. 2020

Obsah

- 1 Úvod
- 2 Kohonenovy mapy
 - Vlastnosti
 - Struktura
 - Průběh učení
 - Zobrazení průběhu učení ve 3D
 - Vyvolání informace
- 3 Paralelizace SOM
 - Popis algoritmu
- 4 Závěr

Úvod

Kohonenovy mapy patří mezi jedny ze základních typů neuronových sítí.

- Někdy nazývané také jako samoorganizující se mapy
- Self-Organizing Maps, SOM
- Učení bez učitele - snadnější získání trénovací množiny

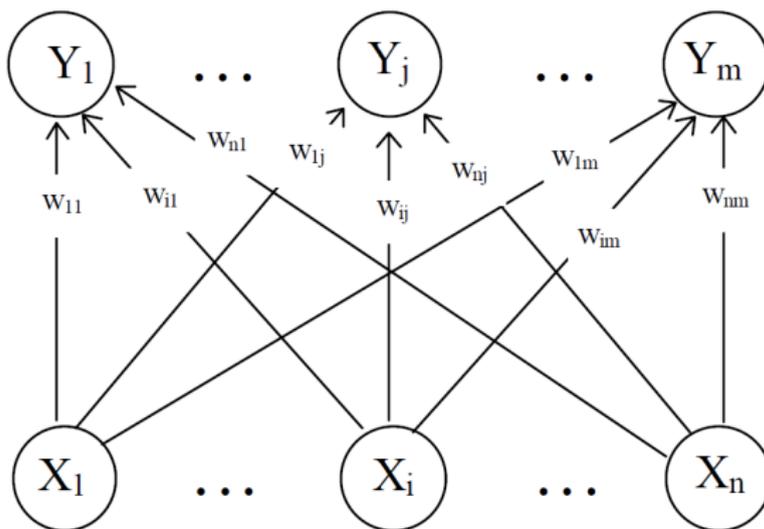
Princip fungování

Síť pracuje na principu zjišťování podobnosti mezi vstupními daty, kdy hledá společné znaky a odlišnosti podle kterých se pak rozhoduje ve své aktivační fázi.

- Příklady použití
 - Detekce objektů na fotografiích
 - Zpracování řeči na psaný text
 - Zpracování obrazu
 - Hledání podobností v neznámých signálech

Struktura

- Kohonenovy mapy jsou dvouvrstvé sítě
 - Vstupní vrstva, na obrázku $X_1 \dots X_n$
 - Výstupní vrstva, na obrázku $Y_1 \dots Y_m$
 - Neurony vstupní vrstvy plně propojeny s neurony výstupní vrstvy



Struktura

Topologie výstupní vrstvy

- Výstupní vrstva - nejčastěji jedno nebo dvourozměrná mřížka
- Ovlivňuje proces učení pomocí sousedství

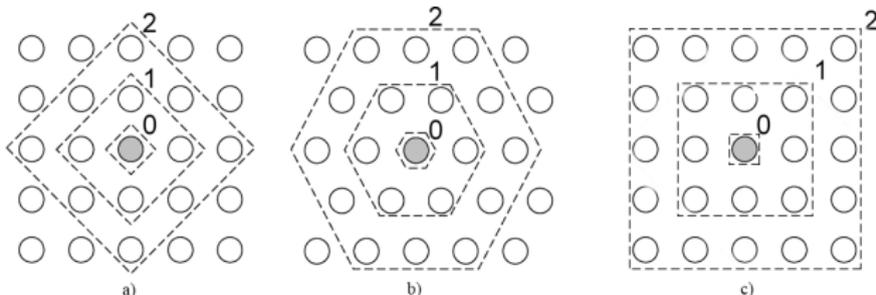
Sousedství J lze definovat jako podmnožinu všech neuronů, jejichž vzdálenost je od neuronu j^* menší nebo rovna R .

$$J = \{j; d(j, j^*) \leq R\}$$

Struktura

Typ sousedství

- Různé typy sousedství jsou zobrazeny na obrázku níže
- V tabulce je vidět, jak ovlivní typ sousedství počet sousedů pro $R = 1$



Typ sousedství	Počet sousedů
čtvercové, obrázek a)	4
hexagonální, obrázek b)	6
čtvercové, obrázek c)	8

Průběh učení

a) Inicializace

Inicializace vah (malá náhodná čísla), nastavení parametru učení α a poloměru sousedství R

Průběh učení

b) Pro každý trénovací vstup $x = (x_1, \dots, x_n)$

- Najdeme neuron (BMU) s nejmenší vzdáleností $D(j)$ od vstupního vektoru, dle rovnice 1, a jeho sousedy

$$D(j) = \sum_i^n (w_{ij} - x_i)^2 \quad (1)$$

- Pro všechny sousedy a BMU aktualizujeme váhy dle rovnice:

$$w_{ij}^{new} = w_{ij}^{old} + \alpha(x_i - w_{ij}^{old}) \quad (2)$$

- Snížení hodnoty parametrů α a R

Průběh učení

c) Kontrola ukončovací podmínky

Pokud jsou splněny ukončovací podmínky je fáze učení ukončena. Pokud nejsou splněny podmínky pro ukončení opakuje se krok b).

Průběh učení - Pseudokód

- Na zobrazeném pseudokódu, lze vidět učení Kohonenovy mapy
- Učení probíhá dokud je parametr α větší než 0,01

```
initWeights()
initParameters()
while( $\alpha > 0.01$ )
{
    foreach( $x = (x_1, \dots, x_n)$  in trainset)
    {
        find  $j^*$  where  $d(x, j^*) = \min\{d(x, j) \mid j \in \text{Neurons}\}$ 
         $w_{j^*}^{new} = w_{j^*}^{old} + \alpha(x - w_{j^*}^{old})$ 
        for all  $j = \{d(j, j^*) \leq R\}$  do
        {
             $w_j^{new} = w_j^{old} + \alpha(x - w_j^{old})$ 
        }
    }
}
```

Průběh učení - chování sítě

Zobrazení průběhu učení ve 2D

- Červeně je zobrazená výstupní vrstva neuronů
- Černé body představují trénovací množinu

Zobrazení průběhu učení ve 3D

Vyvolání informace

- Stejně jako v učící fázi se po předložení vstupního vektoru vyhledá BMU
- BMU zastupuje definovanou skupinu, která je předloženému vstupu nejbližší, proto se dá předpokládat, že i neznámý vstup patří do této skupiny.
- Dva režimy
 - **Adaptační režim** - v tomto případě dochází k mírné aktualizaci vah pro každý předložený vstup
 - **Neadaptivní režim** - váhy se již po dokončení učící fáze nijak nemění

Global-Merged SOM (GM-SOM)

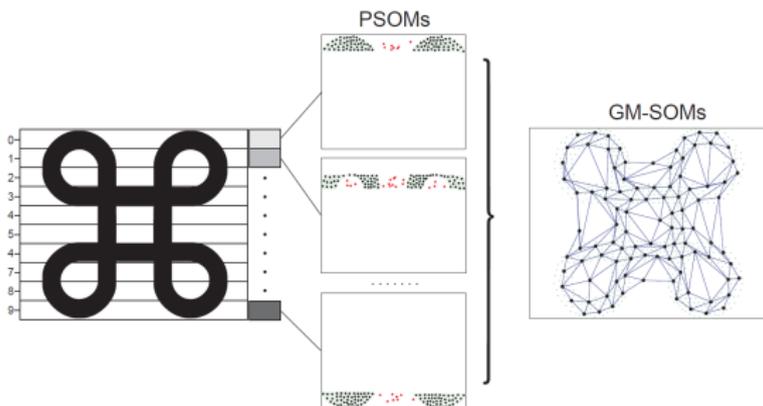
- GM-SOM - způsob paralelní implementace Kohonenových map
- Na základě datového paralelismu - rozdělení trénovací množiny
- Autoři Petr Gajdoš a Pavel Moravec
- Výhody
 - Vzájemná nezávislost jednotlivých uzlů v průběhu výpočtu
 - Na každém uzlu je možné volit jiné nastavení parametrů

GM-SOM

Kroky paralelizace

a) Rozdělení trénovací množiny

V tomto kroku dojde k rozdělení vstupní trénovací množiny na určitý počet částí. Každá část je distribuována na jiný výpočetní uzel.



GM-SOM

Kroky paralelizace

b) Výpočet v jednotlivých uzlech

- Na každou část trénovací množiny je aplikován klasický proces učení SOM
- Všechny uzly mají na začátku váhy inicializované na stejné hodnoty a stejnou strukturu sítě

c) Spojení jednotlivých částí

- Vytvoření nové trénovací množiny z váhových vektorů jednotlivých uzlů
- Nová trénovací množina se použije k naučení nové Kohonenovy mapy

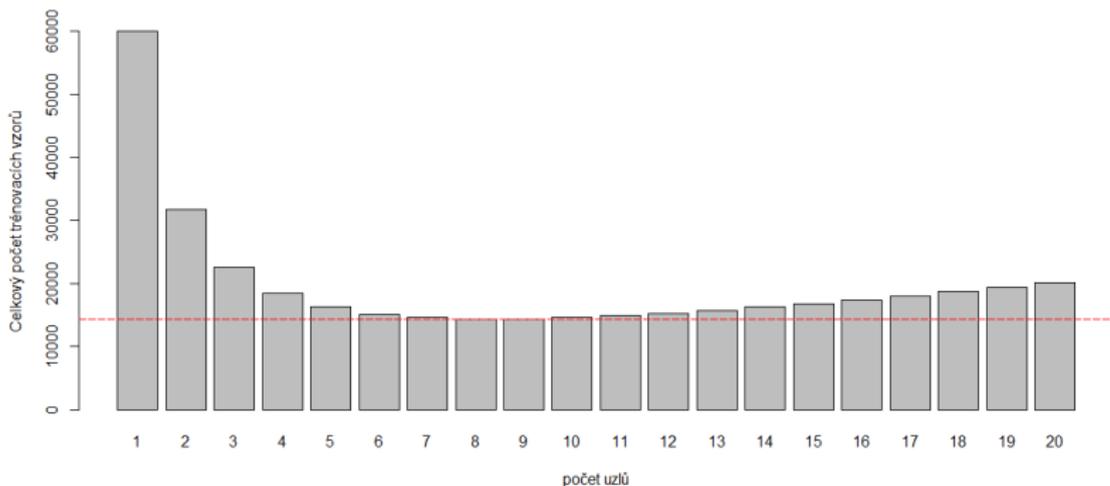
Počet výpočetních uzlů pro GM-SOM

- S počtem výpočetních uzlů narůstá také velikost trénovací množiny v posledním kroku
- Doporučený počet uzlů proto určuje rovnice 3, kde N označuje počet neuronů výstupní vrstvy, k je počet vzorů trénovací množiny a p značí zvolený počet částí.

$$k \gg N * p \quad (3)$$

Počet výpočetních uzlů pro GM-SOM

- Závislost počtu uzlů na celkové velikosti trénovací množiny je vidět na grafu níže
- Trénovací množina o 60 000 vstupech, velikost výstupní vrstvy 900 neuronů



Děkuji za pozornost.

Literatura

- [1] Eva Volná. Neuronové sítě 1. Ostrava: Ostravská univerzita v Ostravě. Vydání: druhé, 2008.
- [2] Ivo VONDRÁK. Neuronové sítě. Fakulta elektrotechniky a informatiky VŠB. Učební text. Ostrava, 2009.
- [3] A VOJÁČEK. Samoučící se neuronová síť. pages 05–14, 2006.
- [4] Petr Gajdoš and Pavel Moravec. Two-step modified som for parallel calculation. In Proceedings of DATESO, pages 13–21. Citeseer, 2010.