

# Vytěžování Dat

## Přednáška 5 – Self Organizing Map

Miroslav Čepek

Katedra počítačů, Computational Intelligence Group



Evropský sociální fond Praha & EU:  
Investujeme do vaší budoucnosti

16.10.2012

# Shlukovací algoritmy a nevýhody

- Jaké znáte shlukovací algoritmy?
  - KMeans
  - Hierarchické shlukování
  - KMeans – nedopadne pokaždé stejně, musím zkoušet počet centroidů.
  - Hierarchické shlukování – musím spočítat  $N^2$  vzdáleností. Což pro větší N není jednoduché.

# Shlukovací algoritmy a nevýhody

- Jaké znáte shlukovací algoritmy?
- KMeans
- Hierarchické shlukování
  - KMeans – nedopadne pokaždé stejně, musím zkoušet počet centroidů.
  - Hierarchické shlukování – musím spočítat  $N^2$  vzdáleností. Což pro větší N není jednoduché.

# Shlukovací algoritmy a nevýhody

- Jaké znáte shlukovací algoritmy?
- KMeans
- Hierarchické shlukování
- KMeans – nedopadne pokaždé stejně, musím zkoušet počet centroidů.
- Hierarchické shlukování – musím spočítat  $N^2$  vzdáleností. Což pro větší N není jednoduché.

# Další shlukovací algoritmy

- Existuje spousta dalších algoritmů pro shlukování dat.
- Ukáži vám ještě jeden – **Self Organizing Map (SOM)**.

# Kompetitivní učení

- Jedinci (reprezentanti, centroidy, neurony, jedinci) spolu soutěží – o něco :).
- Nepotřebuji žádného arbitra (učitele), který by říkal, kam se mají jedinci přesunout. Každý jedinec to umí zjistit sám.
- Jedinci se učí z příkladů.
- Systém (populace jedinců) se v průběhu času **samoorganizuje** sám.
- A teď to zkusíme použít na shlukování.

# Kompetitivní učení

- Jedinci (reprezentanti, centroidy, neurony, jedinci) spolu soutěží – o něco :).
- Nepotřebuji žádného arbitra (učitele), který by říkal, kam se mají jedinci přesunout. Každý jedinec to umí zjistit sám.
- Jedinci se učí z příkladů.
- Systém (populace jedinců) se v průběhu času **samoorganizuje** sám.
- A teď to zkusíme použít na shlukování.

# Kompetitivní učení v pohádce

- Vzpomínáte si na pohádku o Králích z minulé přednášky?
- Do země s  $N$  domy přijelo  $K$  králů a někde se usídlili. A každý král zabral domy, které mu byli nejblíž a z nich vybíral daně. A protože lidé chtěli, aby jim byl král co nejblíž, král se přestěhoval do geometrického středu domů.
- Tím se ale některé domy ocitly blíže jinému králi a tak z nich daně začal vybírat jiný král. Králové se opět přesunout a tak dále.
- Nejblížší král tedy získá všechny daně z domů, které jsem mu nejblíž.

# Kompetitivní učení v KMeans

- KMeans také používá kompetitivní učení. Jak?
- KMeans je trochu skromější.
- Reprezentanti (centroidy) soutěží o data. A nejbližší reprezentant vyhraje – zabere celou instanci a jiného reprezentanta k ní nepustí. "Bere vše".

# Kompetitivní učení v KMeans

- KMeans také používá kompetitivní učení. Jak?
- KMeans je trochu skromější.
- Reprezentanti (centroidy) soutěží o data. A nejbližší reprezentant vyhraje – zabere celou instanci a jiného reprezentanta k ní nepustí. "Bere vše".

# Kvantizační chyba

- Minule jsem v souvislosti s KMeans mluvil o optimalizaci (minimalizaci) chyby.
- Této chybě se říká **kvantizační chyba**. A vyjadřuje průměrnou vzdálenost mezi daty a odpovídajícími reprezentanty.
- Průměrná vzdálenost mezi krály a jejich poddanými.

$$\text{kvantizační chyba} = \frac{1}{\text{počet instancí}} \sum_{i=0}^k \sum_{x \in \text{nearest}(r_i)} \text{dist}(r_i, x)$$

- $r_i$  je i-tý reprezentant. A  $\text{nearest}(r_i)$  je množina instancí, které jsou mu nejblíž.
- $x$  je jedna z instancí.

# Vektorová kvantizace

- A cílem (nejen) KMeans je minimalizovat tuto chybu.
- Tím že minimalizuju kvantizační chybu tlačím reprezentanty do míst, kde se nachází hodně instancí.
- Snažím se tím approximovat hustotu instancí pomocí (menší hustoty) reprezentantů.
- Do míst, kde je vysoká hustota instancí, se snažím dostat hodně reprezentativní a naopak – do míst s málo instancemi dávám málo reprezentativní.
- Cílem kvantizace vektorů je approximace hustotu pravděpodobnosti  $p(x)$  výskytu instancí  $x$  pomocí konečného počtu reprezentantů  $w_i$ .

# Vektorová kvantizace

- A cílem (nejen) KMeans je minimalizovat tuto chybu.
- Tím že minimalizuji kvantizační chybu tlačím reprezentanty do míst, kde se nachází hodně instancí.
- Snažím se tím approximovat hustotu instancí pomocí (menší hustoty) reprezentantů.
- Do míst, kde je vysoká hustota instancí, se snažím dostat hodně reprezentativní a naopak – do míst s málo instancemi dávám málo reprezentativní.
- Cílem kvantizace vektorů je approximace hustotu pravděpodobnosti  $p(x)$  výskytu instancí  $x$  pomocí konečného počtu reprezentantů  $w_i$ .

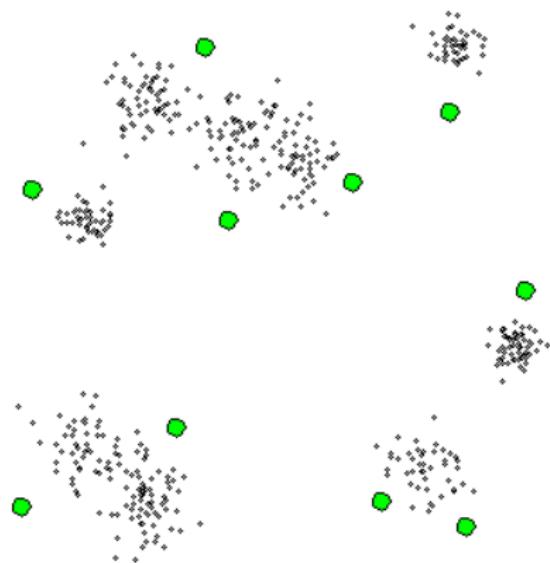
# Vítěz NEbere vše

- U KMeans z domu vybírá daně jen nejbližší král. "Winner takes all".
- Co když platí, že část daní může vybírat i jiný blízký král?
- Pak už neplatí, že vítěz bere vše a něco zbude i na ostatní.
- Zde je důležité okolí – tj. jak daleko se králi ještě vyplatí jet pro svůj díl daní.
  - ▶ Malé okolí – vítěz bere vše - daně vybírá jen jeden král
  - ▶ Velké okolí – komunismus - každý král dostane z každého domu kousek.

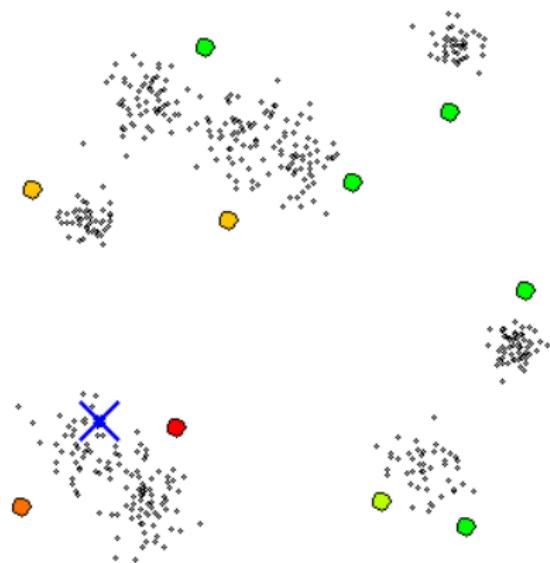
# Neuronový plyn

- Jiný způsob, jakým lze minimalizovat kvantizační chybu.
  - Na rozdíl od KMeans používám okolí a jinak počítám nové pozice středů.
- 1 Náhodně rozmísti reprezentanty a zvol velké okolí.
  - 2 Vyber *nějakou* vstupní instanci  $x_j$ .
  - 3 Spočítej vzdálenost mezi  $x_j$  a všemi reprezentanty  $w_i \forall i$ .
  - 4 Uprav pozice všech středů v závislosti na vzdálenosti od instance a okolí.
  - 5 Zmenší okolí.
  - 6 Pokud ještě chceš pokračovat, pokačuj bodem 2.

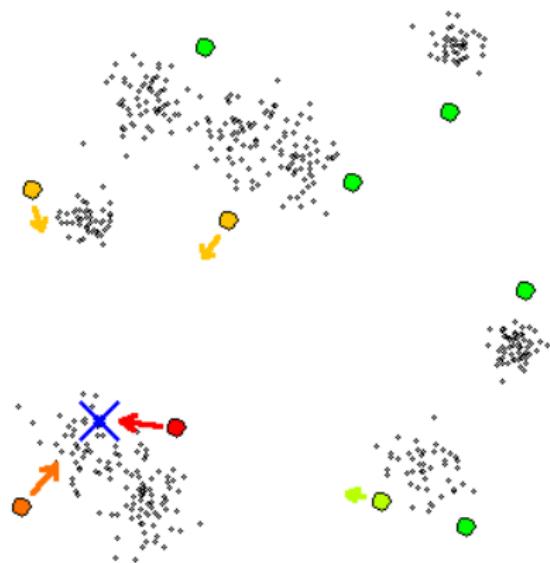
# Ilustrace iterace Neuronového plynu



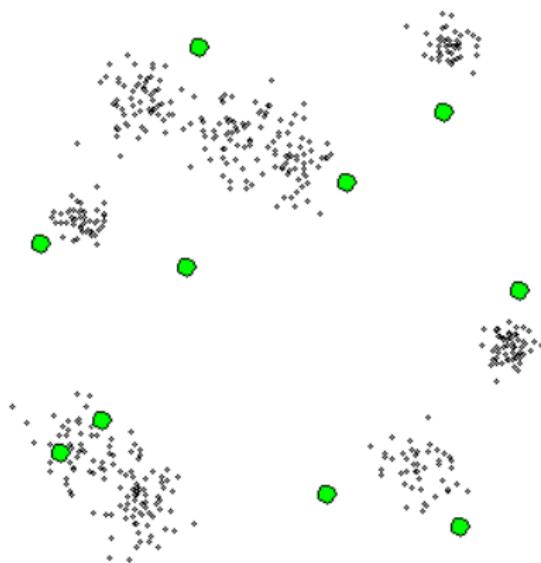
# Ilustrace iterace Neuronového plynu



# Ilustrace iterace Neuronového plynu



# Ilustrace iterace Neuronového plynu



# Neuronový plyn (II)

- V algoritmu je několik stupňů volnosti.
- "Vyber nějakou vstupní instanci"
  - ▶ Procházíme postupně jednotlivé instance postupně v pevném pořadí.
    - ★ Nevhodné protože výstup může záviset na pořadí předkládání instancí.
  - ▶ Projde všechny instance jednou, pak v jiném pořadí podruhé, atd...
  - ▶ Vybírá skutečně náhodně. Čili nezaručuje, že počet předložení sítí bude pro všechny instance stejný.
    - ★ Nepoužívá se, protože není zaručeno, že nepředložím  $x_1$  10x, pak  $x_2$  12x, atd...

# Neuronový plyn (II)

- V algoritmu je několik stupňů volnosti.
- "Vyber nějakou vstupní instanci"
  - ▶ Procházíme postupně jednotlivé instance postupně v pevném pořadí.
    - ★ Nevhodné protože výstup může záviset na pořadí předkládání instancí.
  - ▶ Projde všechny instance jednou, pak v jiném pořadí podruhé, atd...
  - ▶ Vybírá skutečně náhodně. Čili nezaručuje, že počet předložení sítí bude pro všechny instance stejný.
    - ★ Nepoužívá se, protože není zaručeno, že nepředložím  $x_1$  10x, pak  $x_2$  12x, atd...

# Neuronový plyn (II)

- V algoritmu je několik stupňů volnosti.
- "Vyber nějakou vstupní instanci"
  - ▶ Procházíme postupně jednotlivé instance postupně v pevném pořadí.
    - ★ Nevhodné protože výstup může záviset na pořadí předkládání instancí.
  - ▶ Projde všechny instance jednou, pak v jiném pořadí podruhé, atd...
  - ▶ Vybírá skutečně náhodně. Čili nezaručuje, že počet předložení sítí bude pro všechny instance stejný.
    - ★ Nepoužívá se, protože není zaručeno, že nepředložím  $x_1$  10x, pak  $x_2$  12x, atd...

# Neuronový plyn (II)

- V algoritmu je několik stupňů volnosti.
- "Vyber nějakou vstupní instanci"
  - ▶ Procházíme postupně jednotlivé instance postupně v pevném pořadí.
    - ★ Nevhodné protože výstup může záviset na pořadí předkládání instancí.
  - ▶ Projde všechny instance jednou, pak v jiném pořadí podruhé, atd...
  - ▶ Vybírá skutečně náhodně. Čili nezaručuje, že počet předložení sítí bude pro všechny instance stejný.
    - ★ Nepoužívá se, protože není zaručeno, že nepředložím  $x_1$  10x, pak  $x_2$  12x, atd...

# Neuronový plyn (II)

- V algoritmu je několik stupňů volnosti.
- "Vyber nějakou vstupní instanci"
  - ▶ Procházíme postupně jednotlivé instance postupně v pevném pořadí.
    - ★ Nevhodné protože výstup může záviset na pořadí předkládání instancí.
  - ▶ Projde všechny instance jednou, pak v jiném pořadí podruhé, atd...
  - ▶ Vybírá skutečně náhodně. Čili nezaručuje, že počet předložení sítí bude pro všechny instance stejný.
    - ★ Nepoužívá se, protože není zaručeno, že nepředložím  $x_1$  10x, pak  $x_2$  12x, atd...

# Neuronový plyn (II)

- V algoritmu je několik stupňů volnosti.
- "Vyber nějakou vstupní instanci"
  - ▶ Procházíme postupně jednotlivé instance postupně v pevném pořadí.
    - ★ Nevhodné protože výstup může záviset na pořadí předkládání instancí.
  - ▶ Projde všechny instance jednou, pak v jiném pořadí podruhé, atd...
  - ▶ Vybírá skutečně náhodně. Čili nezaručuje, že počet předložení sítí bude pro všechny instance stejný.
    - ★ Nepoužívá se, protože není zaručeno, že nepředložím  $x_1$  10x, pak  $x_2$  12x, atd...

# Neuronový plyn (III)

- "Uprav pozice všech středů v závislosti..."
- Čím vzdálenější reprezentant, tím se posouvá méně.
- $w_i^{t+1} = w_i^t + \eta^t e^{-k/\lambda^t} (x - w_i^t)$ 
  - ▶  $\eta^t$  je adaptační krok v kroku  $t$  a určuje o kolik se maximálně může reprezentant posunout. (Typicky o dost menší než 1 a s rostoucím  $t$  klesá k 0).
  - ▶  $k$  pořadí ve vzdálenosti reprezentanta od instance.
  - ▶  $\lambda^t$  definuje velikost okolí a s rostoucím  $t$  klesá.

# Neuronový plyn (III)

- "Uprav pozice všech středů v závislosti..."
- Čím vzdálenější reprezentant, tím se posouvá méně.
- $w_i^{t+1} = w_i^t + \eta^t e^{-k/\lambda^t} (x - w_i^t)$ 
  - ▶  $\eta^t$  je adaptační krok v kroku  $t$  a určuje o kolik se maximálně může reprezentant posunout. (Typicky o dost menší než 1 a s rostoucím  $t$  klesá k 0).
  - ▶  $k$  pořadí ve vzdálenosti reprezentanta od instance.
  - ▶  $\lambda^t$  definuje velikost okolí a s rostoucím  $t$  klesá.

# Neuronový plyn (IV)

- "Zmenši okolí"
  - ▶ Okolí ( $\lambda^t$ ) se typicky postupně zmenšuje o nějaký násobek. Např.  
 $\lambda^{t+1} = \lambda^t * 0.95$
  - ▶ Při zmenšování okolí se podobným způsobem zmenšuje i adaptační krok.  $\eta^{t+1} = \eta^t * 0.95$ .
- "Pokud ještě chceš pokračovat..."
  - ▶ Dopředu určím, že chci pokračovat dokud je  $\lambda > 0.05$  nebo skončí poté, co předložíš všechny instance 10x.

Kontrolní otázka: Za jakých podmínek se přesune nejbližší reprezentant na pozici právě předložené instance?

# Neuronový plyn (IV)

- "Zmenši okolí"
  - ▶ Okolí ( $\lambda^t$ ) se typicky postupně zmenšuje o nějaký násobek. Např.  
 $\lambda^{t+1} = \lambda^t * 0.95$
  - ▶ Při zmenšování okolí se podobným způsobem zmenšuje i adaptační krok.  $\eta^{t+1} = \eta^t * 0.95$ .
- "Pokud ještě chceš pokračovat..."
  - ▶ Dopředu určím, že chci pokračovat dokud je  $\lambda > 0.05$  nebo skončí poté, co předložíš všechny instance 10x.

Kontrolní otázka: Za jakých podmínek se přesune nejbližší reprezentant na pozici právě předložené instance?

# Neuronový plyn (IV)

- "Zmenší okolí"
  - ▶ Okolí ( $\lambda^t$ ) se typicky postupně zmenšuje o nějaký násobek. Např.  
 $\lambda^{t+1} = \lambda^t * 0.95$
  - ▶ Při zmenšování okolí se podobným způsobem zmenšuje i adaptační krok.  $\eta^{t+1} = \eta^t * 0.95$ .
- "Pokud ještě chceš pokračovat..."
  - ▶ Dopředu určím, že chci pokračovat dokud je  $\lambda > 0.05$  nebo skončí poté, co předložíš všechny instance 10x.

Kontrolní otázka: Za jakých podmínek se přesune nejbližší reprezentant na pozici právě předložené instance?

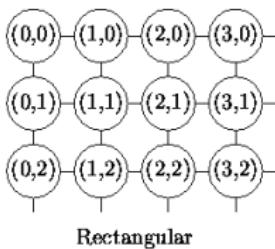
# Neuronový plyn (IV)

- "Zmenši okolí"
  - ▶ Okolí ( $\lambda^t$ ) se typicky postupně zmenšuje o nějaký násobek. Např.  
 $\lambda^{t+1} = \lambda^t * 0.95$
  - ▶ Při zmenšování okolí se podobným způsobem zmenšuje i adaptační krok.  $\eta^{t+1} = \eta^t * 0.95$ .
- "Pokud ještě chceš pokračovat..."
  - ▶ Dopředu určím, že chci pokračovat dokud je  $\lambda > 0.05$  nebo skončí poté, co předložíš všechny instance 10x.

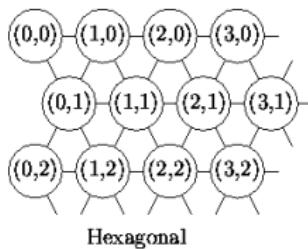
Kontrolní otázka: Za jakých podmínek se přesune nejbližší reprezentant na pozici právě předložené instance?

# Vylepšení Neuronového plynu

- Jak by se dal neuronový plyn vylepšit dál?
- Co kdyby se neposouvali všechni reprezentanti blízko instance?
- Vytvoříme "přátelské" vztahy mezi reprezentanty. A budou se posouvat jen "kamarádi" vítězného reprezentanta.
- Když vizualizujeme "přátelství" mezi reprezentanty získáme pravidelnou mřížku (sít).
- Typicky se používá čtvercová nebo hexagonální síť.



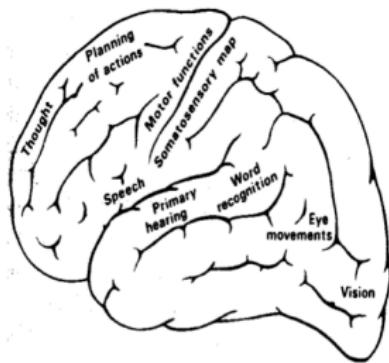
Rectangular



Hexagonal

# Inspirace pro SOM

- Inspirací nejsou králové, ale oblasti v lidském mozku.
- Řídící centra jednotlivých končetin spolu souvisí a navzájem se ovlivňují.

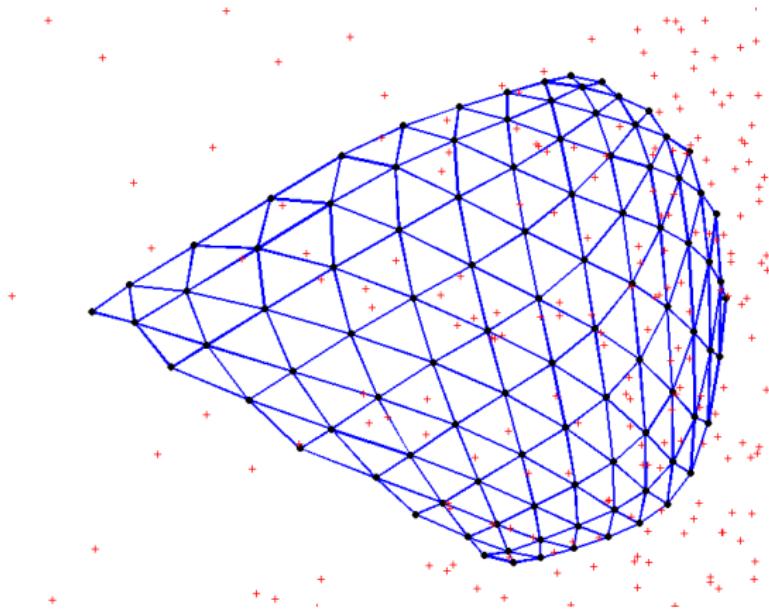


- Neuronová síť SOM je vynálezem prof. Kohonena z Finska.
- Původně vznikla jako model motorického cortexu a její první aplikace byl fontetický psací stroj.
- A protože se prof. Kohonen zabýval umělými neuronovými sítěmi, převzal i SOM jejich terminologii.

# SOM - Pozice neuronů

- Každý reprezentant – v terminologii SOMu **neuron** – je opět reprezentován jeho souřadnicemi v prostoru.
- Souřadnice každého neuronu (reprezentanta) se označují jako váhy.
- Když si zkusím takovou síť vizualizovat, dostaneme například:

# SOM - Pozice neuronů (II)



- WTF? Ještě před chvílí byla ta síť přece pravidelná!
- To ano, ale to byla idealizovaná projekce, aby bylo názorně vidět vztahy!

# SOM - Algoritmus

- Celý SOM algoritmus vypadá pak takto:
- 1 Inicializuj váhy všech neuronů (souřadnice všech reprezentantů).
  - 2 Vyber *nějakou* vstupní instanci  $x_j$ .
  - 3 Spočítej vzdálenost mezi  $x_j$  a všemi neurony  $w_i \forall i$ .
  - 4 Urči nejbližší neuron – BMU (Best Matching Unit).
  - 5 Uprav váhy (pozici) BMU a jeho okolí.
  - 6 Pokud ještě chceš pokračovat, pokačuj bodem 2.

# Detaile algoritmu

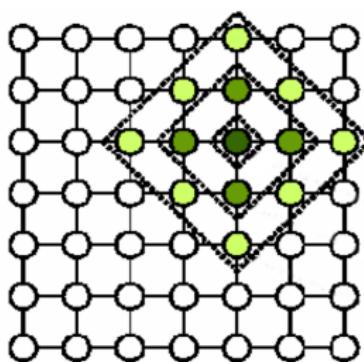
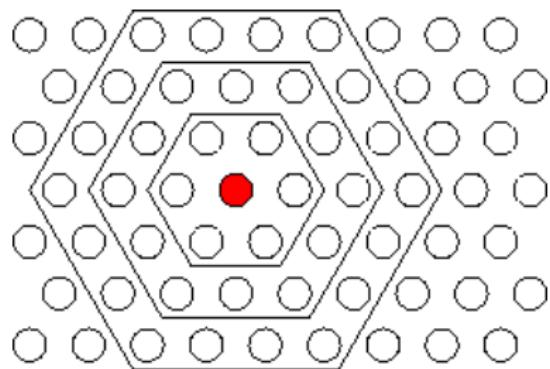
- Inicializace vah:
  - ▶ Rovnoměrné rozprostření pro prostoru.
  - ▶ Náhodně.
- Výběr instancí:
  - ▶ Opět můžeme vybírat instance úplně náhodně.
  - ▶ Ale mnohem častější je vybrat všechny instance jednou, pak všechny podruhé (v jiném pořadí), atd... Prochází se permutace vstupní množiny.

# Detaile algoritmu

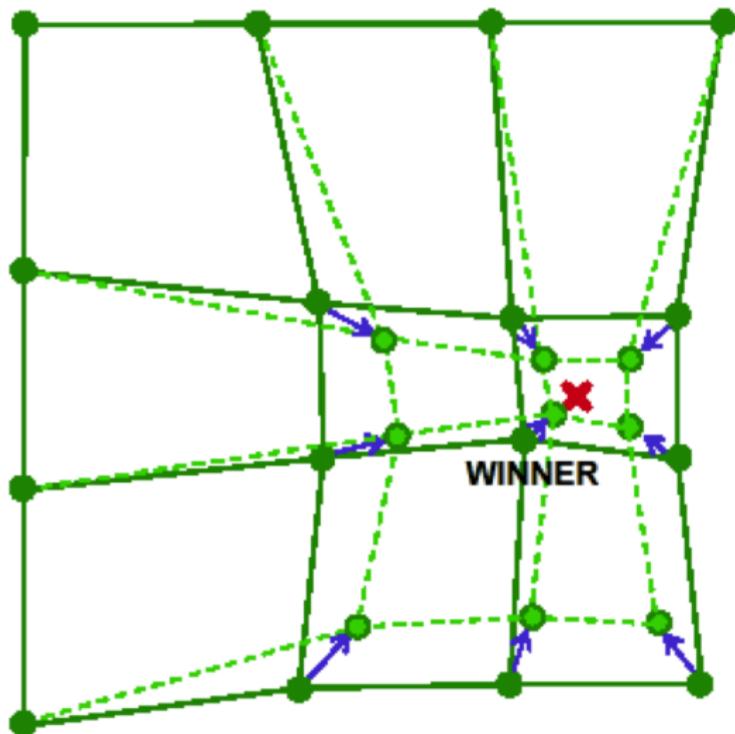
- Inicializace vah:
  - ▶ Rovnoměrné rozprostření pro prostoru.
  - ▶ Náhodně.
- Výběr instancí:
  - ▶ Opět můžeme vybírat instance úplně náhodně.
  - ▶ Ale mnohem častější je vybrat všechny instance jednou, pak všechny podruhé (v jiném pořadí), atd... Prochází se permutace vstupní množiny.

## Detaile algoritmu (II)

- Výpočet vzdáleností a určení BMU je celkem jednoduchá záležitost.
- Určím si metriku, kterou budu využívat a tu aplikuji.
- Mnohem zajímavější je úprava pozice BMU a jeho okolí :).
- Jak vlastně určím neurony v okolí?



# Změna vah graficky



## Detaile algoritmu (III)

- Novou pozici neuronu  $w_i$  v kroku  $t + 1$  (po předložení vzoru  $x_j$ ) určím jako:
- $w_i^{t+1} = w_i^t + \mu(t)(x_j - w_i^t)$
- Kde  $\mu(t)$  je sdružený učící koeficient, který v sobě sdružuje jak vzdálenost neuronu od BMU tak i maximální možnou změnu vah (pozice).
- $\mu(t)$  s postupujícím časem klesá k nule.

## Detaile algoritmu (IV)

$$\mu(t) = \alpha(t) e^{-\frac{dist(w_i, BMU)}{2\sigma^2(t)}}$$

- $\alpha(t)$  představuje učící krok (tedy jak moc se maximálně mohou změnit váhy neuronu).
- $e^{blabla}$  určuje, že okolí neuron má tvar gausovky.
- $\sigma^2(t)$  určuje velikost okolí a postupně s časem klesá.

# Příklad

Máme 3 neurony  $w_1 = (0, 0)$ ,  $w_2 = (2, 1)$ ,  $w_3 = (0, 3)$  a ty jsou na lince.  $w_1$  je sousedem  $w_2$ ,  $w_2$  je sousedem  $w_3$  a  $w_1$ ,  $w_2$  je sousedem  $w_3$ .

A instanci  $x = (1, 1)$

Který neuron je BMU? (Použijeme eukleidovskou metriku)

$$d(w_1, x) = \sqrt{(0 - 1)^2 + (0 - 1)^2} = \sqrt{2} = 1.41\dots$$

$$d(w_2, x) = \sqrt{(2 - 1)^2 + (1 - 1)^2} = \sqrt{1} = 1$$

$$d(w_3, x) = \sqrt{(0 - 1)^2 + (3 - 1)^2} = \sqrt{5} = 2.23\dots$$

# Příklad

Máme 3 neurony  $w_1 = (0, 0)$ ,  $w_2 = (2, 1)$ ,  $w_3 = (0, 3)$  a ty jsou na lince.  $w_1$  je sousedem  $w_2$ ,  $w_2$  je sousedem  $w_3$  a  $w_1$ ,  $w_2$  je sousedem  $w_3$ .  
A instanci  $x = (1, 1)$   
Který neuron je BMU? (Použijeme eukleidovskou metriku)

$$d(w_1, x) = \sqrt{(0 - 1)^2 + (0 - 1)^2} = \sqrt{2} = 1.41\dots$$

$$d(w_2, x) = \sqrt{(2 - 1)^2 + (1 - 1)^2} = \sqrt{1} = 1$$

$$d(w_3, x) = \sqrt{(0 - 1)^2 + (3 - 1)^2} = \sqrt{5} = 2.23\dots$$

## Příklad (II)

BMU je tedy  $w_2$ . Řekněme, že  $\sigma(t) = 1$  a  $\alpha(t) = 0.25$   
A zkusme vypočítat novou pozici BMU ( $w_2$ ).

$$\mu(t) = \alpha(t)e^{-\frac{dist(w_i, BMU)}{2\sigma^2(t)}} = 0.25 * e^{-\frac{dist(w_2, w_2)}{2*1^2}} = 0.25 * e^0 = 0.25$$

$$\begin{aligned}w_2^{t+1} &= w_2^t + \mu(t)(x - w_2^t) = (2, 1) + 0.25 * ((1, 1) - (2, 1)) = \\&= (2, 1) + 0.25(-1, 0) = (1.75, 1)\end{aligned}$$

Pro  $w_1$  se posune do pozice:

$$\mu(t) = \alpha(t)e^{-\frac{dist(w_1, w_2)}{2\sigma^2(t)}} = 0.25 * e^{-\frac{1}{2}} = 0.25 * 0.606 = 0.151$$

$$\begin{aligned}w_1^{t+1} &= w_1^t + \mu(t)(x - w_1^t) = (0, 0) + 0.151 * ((1, 1) - (0, 0)) = \\&= (0, 0) + (0.151, 0.151) = (0.151, 0.151)\end{aligned}$$

## Příklad (II)

BMU je tedy  $w_2$ . Řekněme, že  $\sigma(t) = 1$  a  $\alpha(t) = 0.25$   
A zkusme vypočítat novou pozici BMU ( $w_2$ ).

$$\mu(t) = \alpha(t)e^{-\frac{dist(w_i, BMU)}{2\sigma^2(t)}} = 0.25 * e^{-\frac{dist(w_2, w_2)}{2*1^2}} = 0.25 * e^0 = 0.25$$

$$\begin{aligned}w_2^{t+1} &= w_2^t + \mu(t)(x - w_2^t) = (2, 1) + 0.25 * ((1, 1) - (2, 1)) = \\&= (2, 1) + 0.25(-1, 0) = (1.75, 1)\end{aligned}$$

Pro  $w_1$  se posune do pozice:

$$\mu(t) = \alpha(t)e^{-\frac{dist(w_1, w_2)}{2\sigma^2(t)}} = 0.25 * e^{-\frac{1}{2}} = 0.25 * 0.606 = 0.151$$

$$\begin{aligned}w_1^{t+1} &= w_1^t + \mu(t)(x - w_1^t) = (0, 0) + 0.151 * ((1, 1) - (0, 0)) = \\&= (0, 0) + (0.151, 0.151) = (0.151, 0.151)\end{aligned}$$

# Chyba SOM

- Stejně jako v Hierarchickém shlukování a K-Means potřebujeme nějakou míru "dobrého shluknutí".
- Kvantizační chyba
  - ▶ Ale tu už známe! To je přece chyba, o které jsme mluvili na začátku přednášky!
  - ▶ Průměrná vzdálenost mezi instancemi a nejbližšími neuronami.
- Topografická chyba
  - ▶ Popisuje kvalitu "natažení" mřížky sítě na vstupní data.
  - ▶ Procento instancek, pro které platí, že jejich BMU a druhý nejbližší neuron nejsou sousedy v mřížce sítě.

$$err_{topo} = \frac{1}{n} \sum_{i=1}^n u(x_i)$$

$u(x_i) = 1 \iff$  BMU a druhý nejbližší neuron pro  $x_i$  nejsou sousedé v mřížce.

# Chyba SOM

- Stejně jako v Hierarchickém shlukování a K-Means potřebujeme nějakou míru "dobrého shluknutí".
- Kvantizační chyba
  - ▶ Ale tu už známe! To je přece chyba, o které jsme mluvili na začátku přednášky!
  - ▶ Průměrná vzdálenost mezi instancemi a nejbližšími neuronami.
- Topografická chyba
  - ▶ Popisuje kvalitu "natažení" mřížky sítě na vstupní data.
  - ▶ Procento instancek, pro které platí, že jejich BMU a druhý nejbližší neuron nejsou sousedy v mřížce sítě.

$$err_{topo} = \frac{1}{n} \sum_{i=1}^n u(x_i)$$

$u(x_i) = 1 \iff$  BMU a druhý nejbližší neuron pro  $x_i$  nejsou sousedé v mřížce.

# Chyba SOM

- Stejně jako v Hierarchickém shlukování a K-Means potřebujeme nějakou míru "dobrého shluknutí".
- Kvantizační chyba
  - ▶ Ale tu už známe! To je přece chyba, o které jsme mluvili na začátku přednášky!
  - ▶ Průměrná vzdálenost mezi instancemi a nejbližšími neurony.
- Topografická chyba
  - ▶ Popisuje kvalitu "natažení" mřížky sítě na vstupní data.
  - ▶ Procento instancí, pro které platí, že jejich BMU a druhý nejbližší neuron nejsou sousedy v mřížce sítě.

$$err_{topo} = \frac{1}{n} \sum_{i=1}^n u(x_i)$$

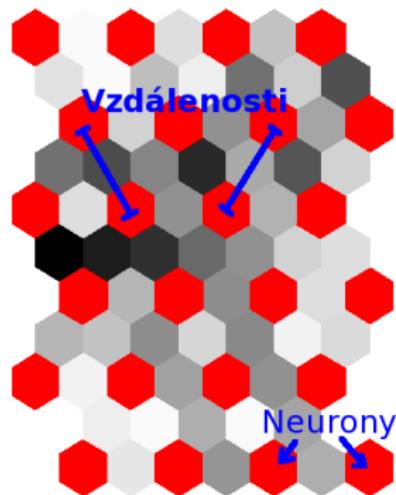
$u(x_i) = 1 \iff$  BMU a druhý nejbližší neuron pro  $x_i$  nejsou sousedé v mřížce.

# Vizualizace SOM

- Dokud máme jen 2D data, tak s vizualizací není problém. Ale co když máme více dimenzí?
  - ▶ U-Matice
  - ▶ Analýza hlavních komponent
  - ▶ Sammonova projekce

# U-Matice

- Matice vzdáleností mezi váhovými vektory jednotlivých neuronů, typicky se vizualizuje, vzdálenosti vyjádřeny barvou – světlá barva = malá vzdálenost.
- Zobrazuje strukturu vzdáleností v prostoru dat.



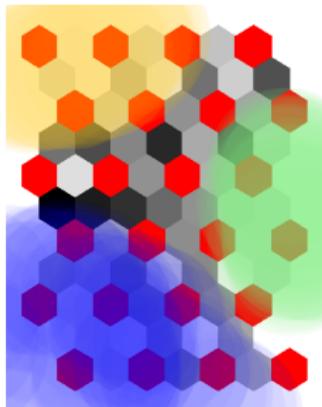
# U-Matice

- Barva neuronu je vzdálenost je váhového vektoru od všech ostatních váhových vektorů.
- Tmavé váhové vektory jsou vzdáleny od ostatních datových vektorů ve vstupním prostoru.
- Světlé váhové vektory jsou obklopeny cizími vektory ve vstupním prostoru.



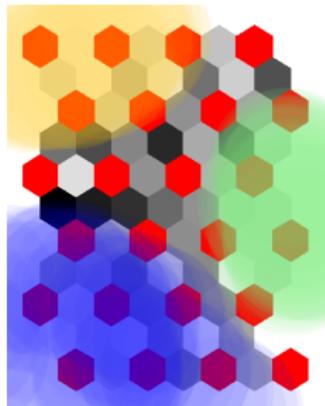
# U-Matice (III)

- Jak z U-Matice poznám shluky?
- Ze vzdáleností mezi neurony.
- Kopce oddělují clustery (údolí).



# U-Matice (III)

- Jak z U-Matice poznám shluky?
- Ze vzdáleností mezi neurony.
- Kopce oddělují clustery (údolí).

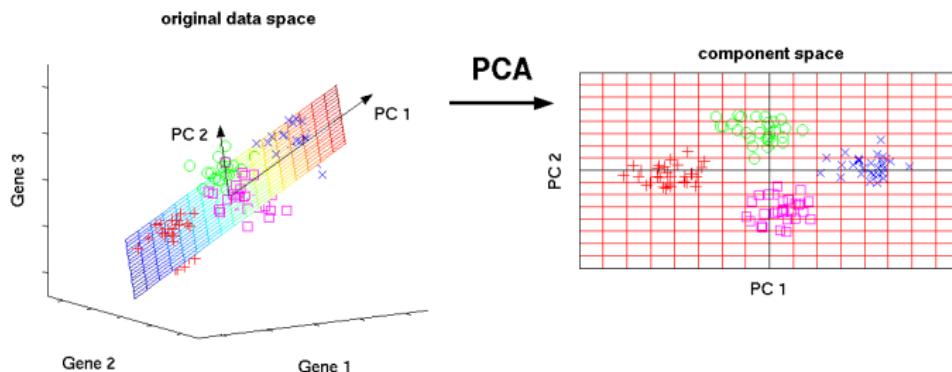


# Analýza hlavních komponent

- Jde o statistickou metodu pro redukci dimenzionality.
- Označuje se jako PCA z anglického Principal Component Analysis.
- Snaží se najít nové osy, které lépe popisují data s minimální ztrátou informace.
- První osa vede směrem, který má největší rozptyl hodnot, druhá osa směrem, kde je druhý největší rozptyl, atd...
- Vždy mi vrátí stejný počet nových os, jako mají původní data dimenzí, ale já se mohu rozhodnout některé nepoužít.

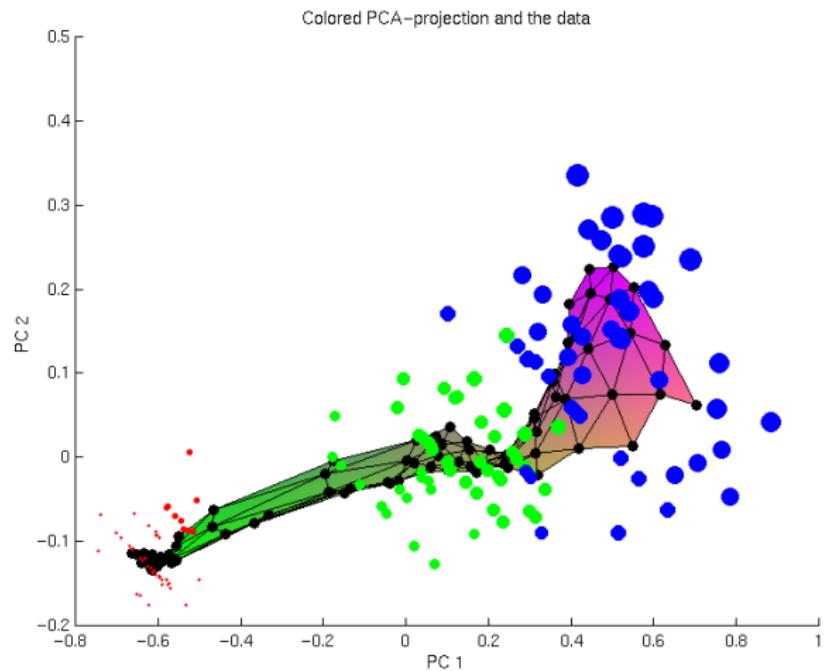
# Analýza hlavních komponent (II)

- Výpočet nových souřadnic pomocí
  - ▶ kovariance, vlastních čísel a vlastních vektorů.
- [http://www.cs.otago.ac.nz/cosc453/student\\_tutorials/principal\\_components.pdf](http://www.cs.otago.ac.nz/cosc453/student_tutorials/principal_components.pdf)



# Využití PCA v SOM

- Nyní můžu provést PCA projekci SOM sítě do 2D a zobrazit si ji.



# Využití PCA mimo SOM

- PCA není limitována jen na použití v SOM, ale můžu ji použít například pro průzkum dat.
- Stejně tak, některé metody vytěžování dat nemají rády příliš mnoho dimenzí a PCA jim můžete pomoci k lepším výsledkům.
- Nevýhodou je umělost nových os, která znesnadňuje interpretaci získaných výsledků.
- $0.125 * petal\_length + 0.578 * petal\_width + 0.934 * sepal\_length - .0346 * sepal\_width$

# Sammonova projekce

- Jinou možností je Sammonova projekce.
- Ta netransformuje osy, ale znovu umísťuje objekty v novém (méně dimenzionálním) prostoru.
- Při umisťování se snaží zachovat vztahy v datech (data, která byla blízko v původním prostoru, budou blízko i v novém prostoru).

## Sammonova projekce (2)

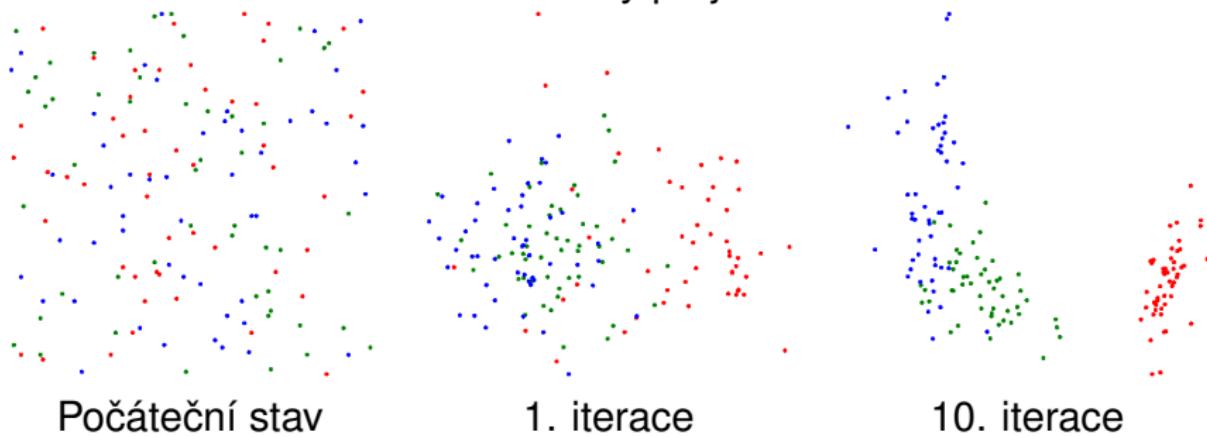
- Sammonova projekce se snaží minimalizovat následující funkci:

$$E = \frac{1}{\sum_{i < j} dist^*(x_i, x_j)} \sum_{i < j} \frac{(dist^*(x_i, x_j) - dist(x_i, x_j))^2}{dist^*(x_i, x_j)}$$

- $dist^*(x_i, x_j)$  je vzdálenost  $x_i$  a  $x_j$  v původním prostoru.
- $dist(x_i, x_j)$  je vzdálenost  $x_i$  a  $x_j$  v novém prostoru (v projekci).
- Pro minimalizaci se používají standardní optimalizační metody – pro tuto úlohu typicky iterační metody.
- Při minimalizaci se pohybujete body v novém prostoru (v projekci). Tím ovlivníte  $dist(x_i, x_j)$  a můžete dosáhnout zmenšení  $E$ .

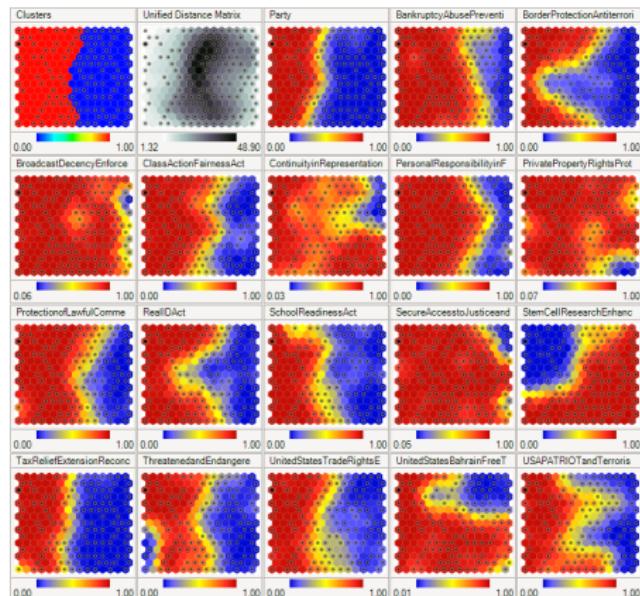
# Sammonova projekce - ukázka

Ukázka několika iterací Sammonovy projekce na Iris datech.



# Další vizualizace – Příznakové grafy

- Vychází z U-Matice, ale místo vzdálenosti jednotlivých vektorů se do šestiúhelníčků kreslí hodnoty vybrané proměnné.



- [http://www.cis.hut.fi/somtoolbox/theory/  
somalgorithm.shtml](http://www.cis.hut.fi/somtoolbox/theory/somalgorithm.shtml)
- <http://www.cis.hut.fi/research/som-research/>
- <http://www.ai-junkie.com/ann/som/som1.html>
- [www.cs.bham.ac.uk/~jxb/NN/l16.pdf](http://www.cs.bham.ac.uk/~jxb/NN/l16.pdf)