



# Analýza a klasifikace dat – přednáška 3

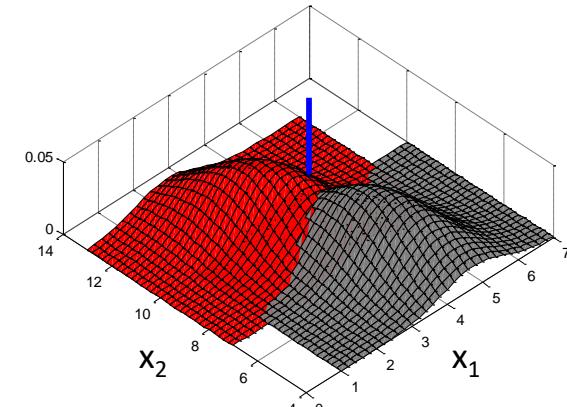


RNDr. Eva Koritáková

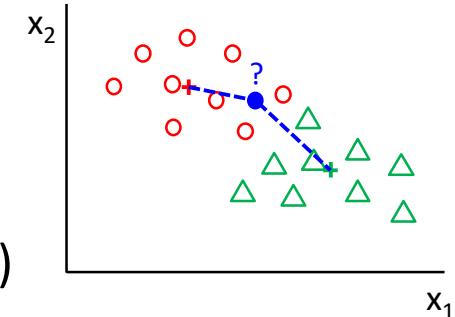
Podzim 2016

# Typy klasifikátorů – podle principu klasifikace

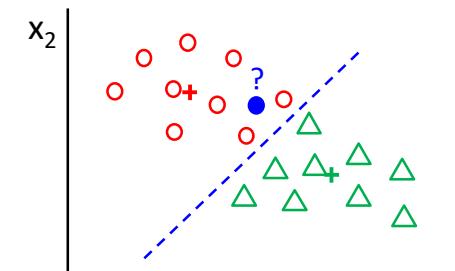
- **klasifikace pomocí diskriminačních funkcí:**
  - diskriminační funkce určují míru příslušnosti k dané klasifikační třídě
  - pro danou třídu má daná diskriminační funkce nejvyšší hodnotu



- **klasifikace pomocí vzdálenosti od etalonů klasif. tříd:**
  - etalon = reprezentativní objekt(y) klasifikační třídy
  - počet etalonů klasif. třídy různý – od jednoho vzorku (např. centroidu) po úplný výčet všech objektů dané třídy (např. u klasif. pomocí metody průměrné vazby)



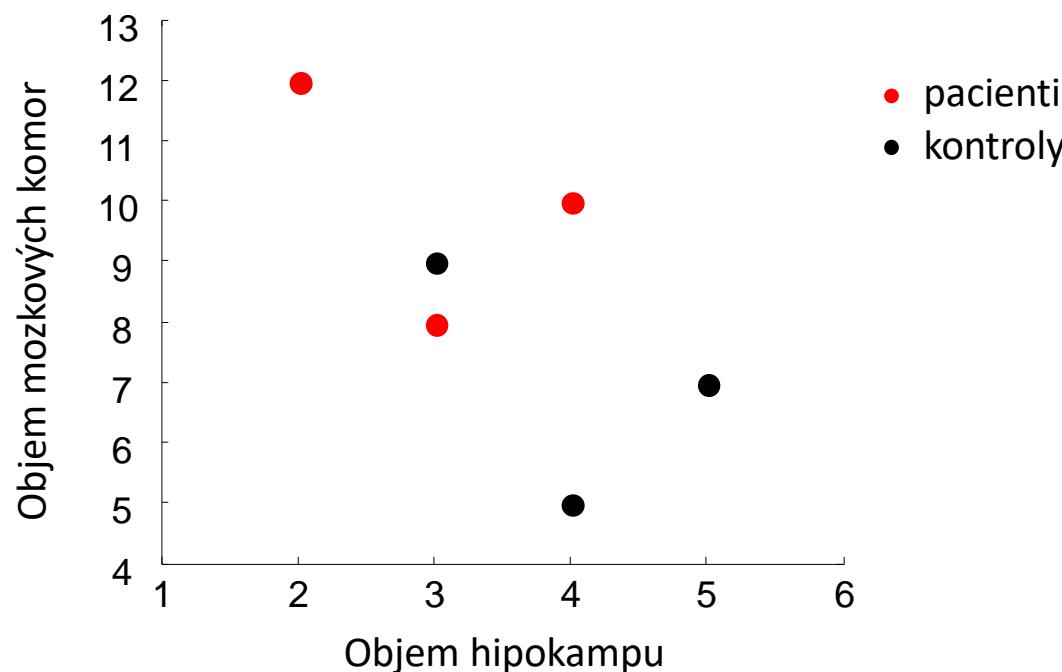
- **klasifikace pomocí hranic v obrazovém prostoru:**
  - stanovení hranic (hraničních ploch) oddělujících klasifikační třídy



# Poznámka

- jednotlivé objekty je možno znázornit pomocí bodů v  $p$ -rozměrném prostoru ( $p$  je počet proměnných)

$$\mathbf{X}_D = \begin{bmatrix} 2 & 12 \\ 4 & 10 \\ 3 & 8 \end{bmatrix}, \mathbf{X}_H = \begin{bmatrix} 5 & 7 \\ 3 & 9 \\ 4 & 5 \end{bmatrix}$$



# Metrika – vzdálenost

---

**Metrika**  $D$  na  $X$  je funkce  $D: X \times X \rightarrow \mathbb{R}$ , kde  $\mathbb{R}$  je množina reálných čísel taková, že:

$$\exists D_0 \in \mathbb{R}: -\infty < D_0 \leq D(x, y) < +\infty, \forall x, y \in X$$

$$D(x, x) = D_0, \forall x \in X$$

a

$$D(x, y) = D(y, x), \forall x, y \in X \text{ (symetrie)}$$

$$D(x, y) = D_0 \text{ když a jen když } x = y \text{ (totožnost)}$$

$$D(x, z) \leq D(x, y) + D(y, z), \forall x, y, z \in X \text{ (Δ nerovnost)}$$

Prostor  $X$ , ve kterém metrika  $D$  definována, nazýváme **metrickým prostorem**.

**Vzdálenost** je hodnota určená podle metriky.

Poznámka: zpravidla  $D_0=0$ .

# Metrika – podobnost

**Metrická míra podobnosti**  $S$  na  $X$  je funkce  $S: X \times X \rightarrow \mathbb{R}$ , taková, že:

$$\exists S_0 \in \mathbb{R}: -\infty < S(x, y) \leq S_0 < +\infty, \forall x, y \in X$$

$$S(x, x) = S_0, \forall x \in X$$

a

$$S(x, y) = S(y, x), \forall x, y \in X \text{ (symetrie)}$$

$$S(x, y) = S_0 \text{ když a jen když } x = y \text{ (totožnost)}$$

$$S(x, y) \cdot S(y, z) \leq [S(x, y) + S(y, z)] \cdot S(x, z), \forall x, y, z \in X$$

**Podobnost** je hodnota určená podle metrické míry podobnosti.

Poznámka: zpravidla  $S_0=1$  (ale neplatí to vždy, u některých metrik je maximální hodnota podobnosti jiná než 1)

# Metriky podobnosti vs. metriky vzdálenosti

---

Vzdálenostní míry (míry nepodobnosti) mohou být transformovány na podobnostní míry různými transformacemi, např.:

$$S_{ij} = 1/D_{ij}$$

$$S_{ij} = 1/(1+ D_{ij})$$

$$S_{ij} = c - D_{ij}, \quad c \geq \max D_{ij}, \quad \forall i,j$$

# Typy měr vzdálenosti (podobnosti)

---

- podle **typu proměnné** (kvalitativní proměnné, kvantitativní proměnné)
- podle **počtu objektů**, jejichž vztah hodnotíme – objekty (vektory), množiny objektů (vektorů)
- **deterministické** (nepravděpodobnosti) vs. **pravděpodobnosti míry**
- výběr konkrétní metriky závisí na:
  - výpočetních náročích
  - charakteru rozložení dat
  - dosažení optimálních výsledků (klasifikační chyba, ztráta,...)
- obecně bohužel není možné dopředu doporučit vhodnou metriku pro danou situaci
- chybný výběr metriky může vést k chybných závěrům analýzy (stejně jako v klasické statistické analýze výběr nevhodného testu)

# Typy metrik a konkrétní příklady

## MEZI DVĚMA OBJEKTY

### Metriky pro určení vzdálenosti mezi 2 objekty s kvantitativními proměnnými

Euklidova m., Hammingova (manhattanská) m., Minkovského m., Čebyševova m., Mahalanobisova m., Canberrská m.

### Metriky pro určení vzdálenosti mezi 2 objekty s kvalitativními proměnnými

Hammingova m.

### Metriky pro určení podobnosti 2 objektů s kvantitativními proměnnými

Skalární součin, m. kosinové podobnosti, Pearsonův korelační koeficient, Tanimotova m.

### Metriky pro určení podobnosti 2 objektů s kvalitativními proměnnými

Tanimotova m., Jaccardův-Tanimotův a.k., Russelův-Raovův a.k., Sokalův-Michenerův a.k., Dicův k., Rogersův-Tanimotův k., Hamanův k.

## MEZI DVĚMA SKUPINAMI OBJEKTŮ

### Deterministické metriky pro určení vzdálenosti mezi 2 množinami objektů

Metoda nejbližšího souseda, k nejbližším sousedům, nejvzdálenějšího souseda, centroidová metoda, m. průměrné vazby, Wardova metoda

### Metriky pro určení vzdálenosti mezi 2 množinami objektů používající jejich pravděpodobnostní charakteristiky

Chernoffova m., Bhattacharyyova m. atd.

# Metriky pro určení vzdálenosti mezi dvěma objekty

# Typy metrik a konkrétní příklady

## MEZI DVĚMA OBJEKTY

### Metriky pro určení vzdálenosti mezi 2 objekty s kvantitativními proměnnými

Euklidova m., Hammingova (manhattanská) m., Minkovského m., Čebyševova m., Mahalanobisova m., Canberrská m.

### Metriky pro určení vzdálenosti mezi 2 objekty s kvalitativními proměnnými

Hammingova m.

### Metriky pro určení podobnosti 2 objektů s kvantitativními proměnnými

Skalární součin, m. kosinové podobnosti, Pearsonův korelační koeficient, Tanimotova m.

### Metriky pro určení podobnosti 2 objektů s kvalitativními proměnnými

Tanimotova m., Jaccardův-Tanimotův a.k., Russelův-Raovův a.k., Sokalův-Michenerův a.k., Dicův k., Rogersův-Tanimotův k., Hamanův k.

## MEZI DVĚMA SKUPINAMI OBJEKTŮ

### Deterministické metriky pro určení vzdálenosti mezi 2 množinami objektů

Metoda nejbližšího souseda, k nejbližším sousedům, nejvzdálenějšího souseda, centroidová metoda, m. průměrné vazby, Wardova metoda

### Metriky pro určení vzdálenosti mezi 2 množinami objektů používající jejich pravděpodobnostní charakteristiky

Chernoffova m., Bhattacharyyova m. atd.

# Nejpoužívanější metriky pro určení vzdálenosti mezi dvěma objekty s kvantitativními proměnnými

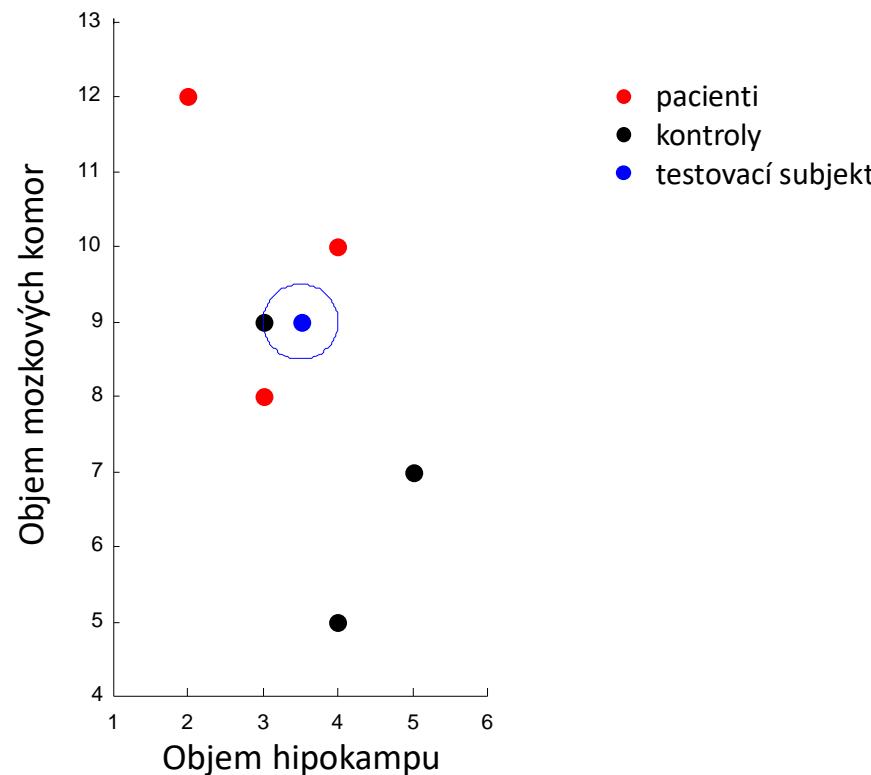
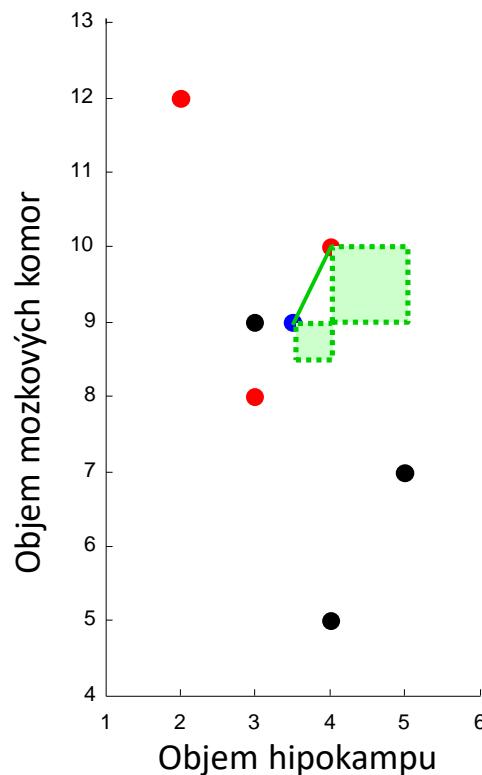
---

- Euklidova metrika
- Hammingova (manhattanská) metrika
- Minkovského metrika
- Čebyševova metrika
- Mahalanobisova metrika
- Canberrská metrika

# Euklidova metrika

- zřejmě nejpoužívanější metrika s velmi názornou geometrickou interpretací

$$D_E(\mathbf{x}_1, \mathbf{x}_2) = \sqrt{\sum_{i=1}^n (x_{1i} - x_{2i})^2}$$



# Euklidova metrika

- zřejmě nejpoužívanější metrika s velmi názornou geometrickou interpretací

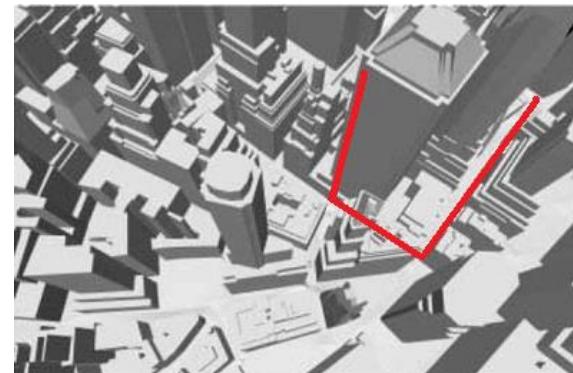
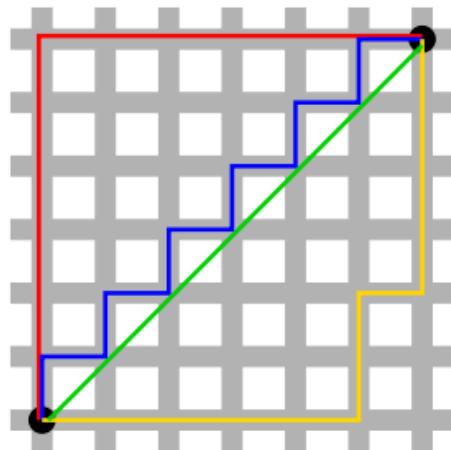
$$D_E(\mathbf{x}_1, \mathbf{x}_2) = \sqrt{\sum_{i=1}^n (x_{1i} - x_{2i})^2}$$

- geometrickým místem bodů s toutéž Euklidovou vzdáleností od daného bodu je povrch hyperkoule (ve dvourozměrném prostoru kružnice)
- dává větší důraz na větší rozdíly mezi souřadnicemi  
žádoucí nebo nežádoucí?
- občas se používá čtverec euklidovské vzdálenosti, protože se lépe počítá než euklidovská vzdálenost (není to ale pravá metrika vzdálenosti)

# Hammingova (manhattanská) metrika

- v AJ názvy: Manhattan distance, city-block distance, taxi driver distance

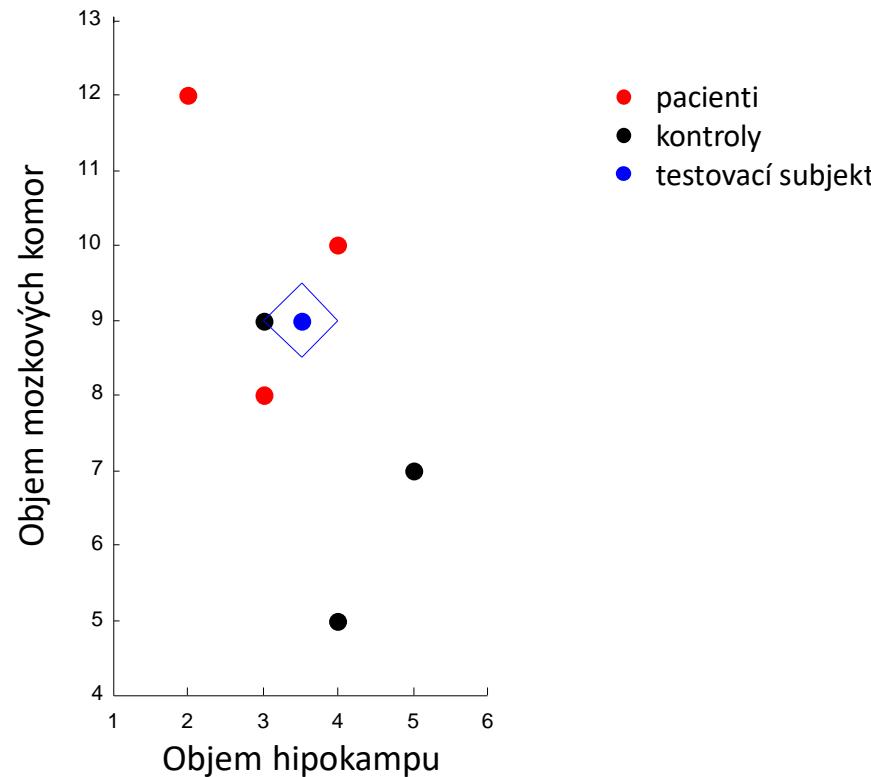
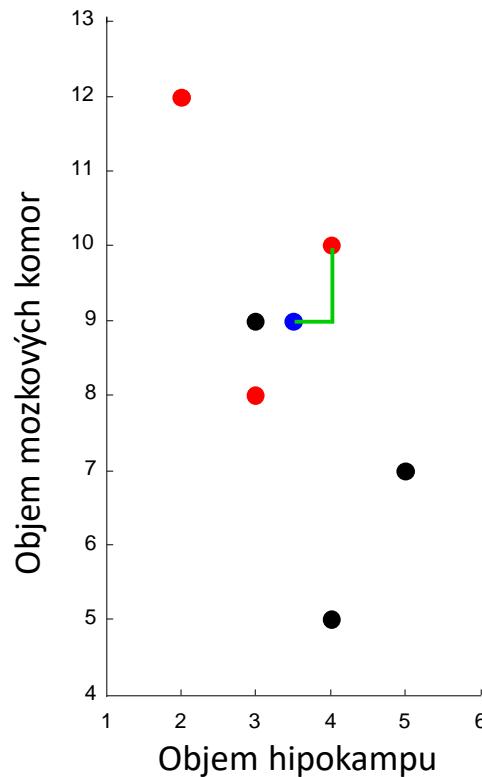
$$D_H(\mathbf{x}_1, \mathbf{x}_2) = \sum_{i=1}^n |\mathbf{x}_{1i} - \mathbf{x}_{2i}|$$



- nižší výpočetní nároky než Euklidova metrika → použití v úlohách s vysokou výpočetní náročností

# Hammingova (manhattanská) metrika

$$D_H(\mathbf{x}_1, \mathbf{x}_2) = \sum_{i=1}^n |\mathbf{x}_{1i} - \mathbf{x}_{2i}|$$



- geometrickým místem bodů s toutéž manhattanskou vzdáleností od daného bodu je hyperkrychle (ve dvourozměrném prostoru čtverec)

# Minkovského metrika

- zobecněním Euklidovy a Hammingovy (manhattanské) metriky

$$D_M(\mathbf{x}_1, \mathbf{x}_2) = \left( \sum_{i=1}^n |\mathbf{x}_{1i} - \mathbf{x}_{2i}|^m \right)^{1/m}$$

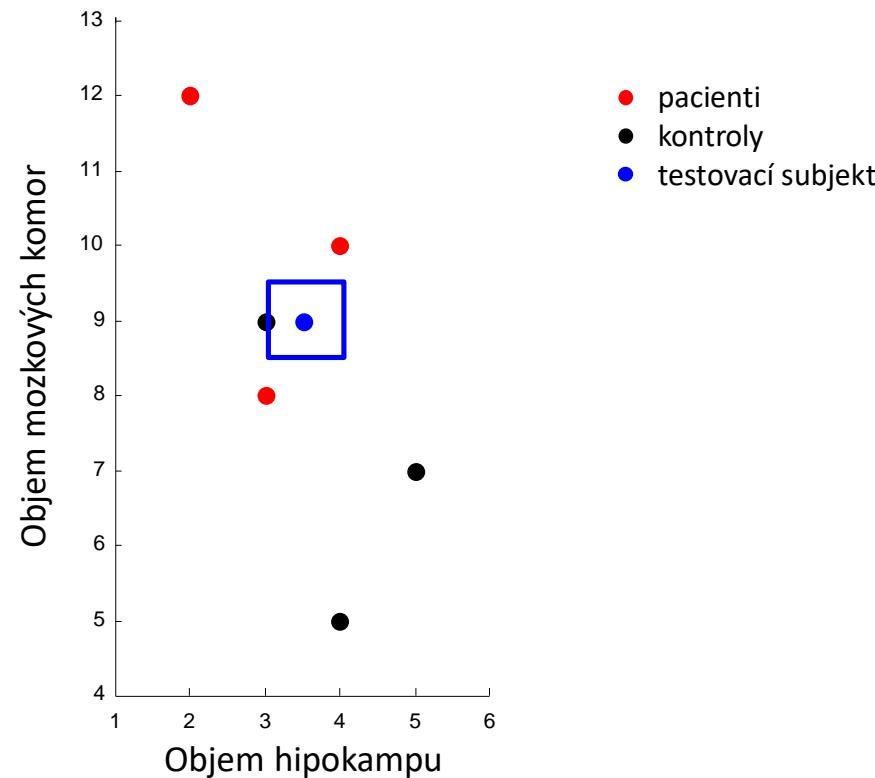
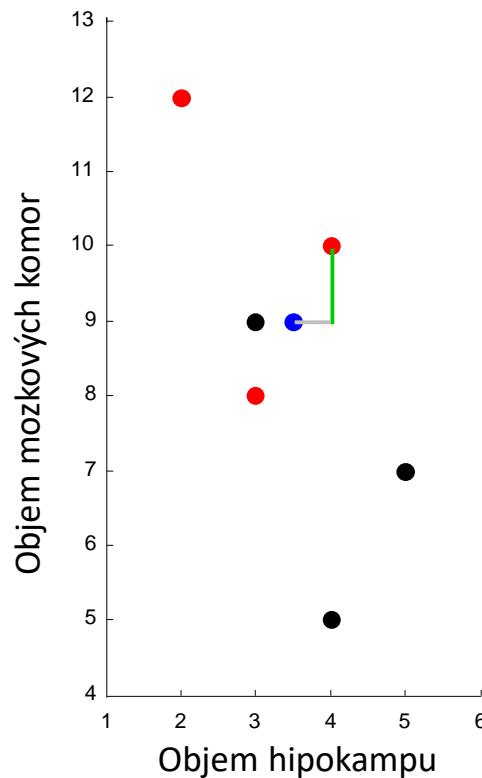
- Euklidova metrika pro  $m = 2$ , Hammingova (manhattanská) metrika pro  $m = 1$
- volba  $m$  závisí na tom, jak moc chceme váhovat velké rozdíly mezi proměnnými (čím větší  $m$ , tím větší váha na velké rozdíly mezi proměnnými)
- pro  $m \rightarrow \infty$  metrika konverguje k **Čebyševově metrice**

$$D_C(\mathbf{x}_1, \mathbf{x}_2) = \lim_{m \rightarrow \infty} D_M(\mathbf{x}_1, \mathbf{x}_2) = \max_{\forall i} |\mathbf{x}_{1i} - \mathbf{x}_{2i}|$$

# Čebyševova metrika

- odvozena z Minkovského metriky pro  $m \rightarrow \infty$

$$D_C(\mathbf{x}_1, \mathbf{x}_2) = \max_{\forall i} |\mathbf{x}_{1i} - \mathbf{x}_{2i}|$$



# Čebyševova metrika

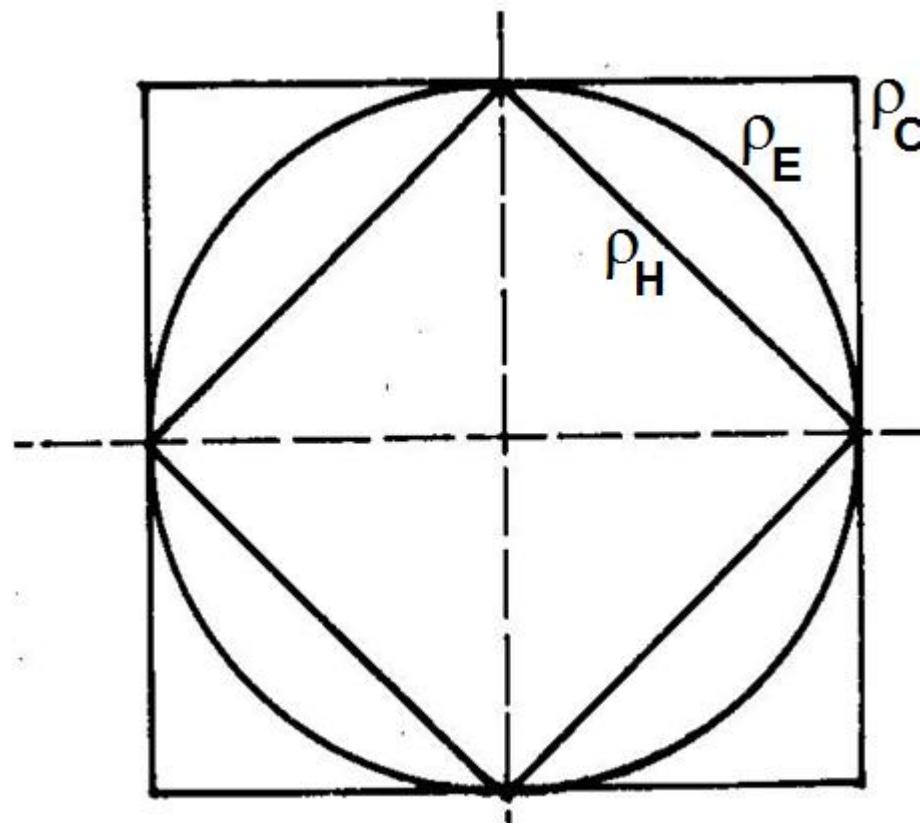
---

- odvozena z Minkovského metriky pro  $m \rightarrow \infty$

$$D_C(\mathbf{x}_1, \mathbf{x}_2) = \max_{\forall i} |\mathbf{x}_{1i} - \mathbf{x}_{2i}|$$

- používá se ve výpočetně kriticky náročných případech, kdy je pracnost výpočtu pomocí Euklidovy metriky nepřijatelná
- geometrickým místem bodů s toutéž Čebyševovou vzdáleností od daného bodu je hyperkrychle (ve dvourozměrném prostoru čtverec), ale jinak orientovaná než v případě Hammingovy (manhattanské) vzdálenosti

# Srovnání metrik



$\rho_C$  ... Čebyševova metrika

$\rho_E$  ... Euklidova metrika

$\rho_H$  ... Hammingova (manhattanská) metrika

# Srovnání metrik

---

- pokud je potřeba použít „euklidovskou“ metriku, ale s nižší výpočetní náročností, používá se v první řadě Hammingova nebo Čebyševova metrika
- případně kombinace obou metrik:

$$D_A(\mathbf{x}_1, \mathbf{x}_2) = \max(2D_H/3; D_C)$$

- geometrickým místem bodů s toutéž vzdáleností je pak ve dvourozměrném prostoru osmiúhelník

# Nevýhody metrik

- je zpravidla problematické vytvářet součet rozdílů veličin s různým rozsahem
- při začlenění korelovaných veličin se zvyšuje jejich vliv na výslednou hodnotu
- řešení:
  1. transformace proměnných:
    - vztažení k nějakému vyrovnávacímu faktoru (střední hodnotě, směrodatné odchylce, rozpětí  $\Delta_i = \max_j x_{ij} - \min_j x_{ij}$ ) či pomocí standardizace  $u_{ij} = \frac{x_{ij} - \bar{x}_j}{\sigma_j}; i = 1, \dots, n; j = 1, \dots, p$ ; kde  $n$  je počet subjektů a  $p$  je počet proměnných
  2. váhování:
    - např. **Minkovského váhovaná metrika**:  $D_{WM}(\mathbf{x}_1, \mathbf{x}_2) = (\sum_{i=1}^n a_i \cdot |x_{1i} - x_{2i}|^p)^{1/p}$
  3. začlenění kovarianční matice do výpočtu:
    - začleněním inverze kovarianční matice získáváme **Mahalanobisovu metriku** (což je Euklidova metrika váhovaná inverzí kovarianční matice):
$$D_{MA}(\mathbf{x}_1, \mathbf{x}_2) = \sqrt{(\mathbf{x}_1 - \mathbf{x}_2)^T \cdot \mathbf{S}^{-1} \cdot (\mathbf{x}_1 - \mathbf{x}_2)}$$

# Canberrská metrika

---

- relativizovaná varianta Hammingovy (manhattanské) metriky

$$D_{CA}(\mathbf{x}_1, \mathbf{x}_2) = \sum_{i=1}^n \frac{|\mathbf{x}_{1i} - \mathbf{x}_{2i}|}{|\mathbf{x}_{1i}| + |\mathbf{x}_{2i}|}$$

- vhodná pro proměnné s nezápornými hodnotami
- pokud se vyskytují nulové hodnoty:
  - pokud jsou obě hodnoty  $\mathbf{x}_{1i}$  a  $\mathbf{x}_{2i}$  nulové, potom předpokládáme, že hodnota zlomku je nulová
  - je-li jenom jedna hodnota nulová, pak je zlomek roven 1 bez ohledu na velikost druhé hodnoty
  - někdy se nulové hodnoty nahrazují malým kladným číslem (menším než nejmenší naměřené hodnoty)
- velice citlivá na malé změny souřadnic, pokud se oba objekty nacházejí v blízkosti počátku souřadnicové soustavy; naopak méně citlivá na změny hodnot proměnných, pokud jsou tyto hodnoty velké

# Příklad 1a

Jsou dány dva vektory  $\mathbf{x}_1 = (0,001; 0,001)^T$  a  $\mathbf{x}_2 = (0,01; 0,01)^T$ . Předpokládejme, že se souřadnice prvního vektoru změní na  $\mathbf{x}'_1 = (0,002; 0,001)^T$ . Jaká je Hammingova (manhattanská) a canberrská vzdálenost v obou případech a jaká je relativní změna vzdáleností, vyvolaná uvedenou modifikací?

$$d_H(\mathbf{x}_1, \mathbf{x}_2) = |0,001 - 0,01| + |0,001 - 0,01| = 0,009 + 0,009 = 0,018$$

$$d_H(\mathbf{x}'_1, \mathbf{x}_2) = |0,002 - 0,01| + |0,001 - 0,01| = 0,008 + 0,009 = 0,017$$

$$d_{CA}(\mathbf{x}_1, \mathbf{x}_2) = \frac{|0,001 - 0,01|}{|0,001| + |0,01|} + \frac{|0,001 - 0,01|}{|0,001| + |0,01|} = \frac{0,009}{0,011} + \frac{0,009}{0,011} = 1,6364$$

$$d_{CA}(\mathbf{x}'_1, \mathbf{x}_2) = \frac{|0,002 - 0,01|}{|0,002| + |0,01|} + \frac{|0,001 - 0,01|}{|0,001| + |0,01|} = \frac{0,008}{0,012} + \frac{0,009}{0,011} = 1,4849$$

Relativní změny vzdáleností, určující citlivost té které metriky, které jsou způsobeny změnou hodnoty první souřadnice, jsou:

$$\Delta d_H = \frac{|d_H(\mathbf{x}_1, \mathbf{x}_2) - d_H(\mathbf{x}'_1, \mathbf{x}_2)|}{d_H(\mathbf{x}_1, \mathbf{x}_2)} = \frac{|0,018 - 0,017|}{0,018} = \frac{0,001}{0,018} = 0,056$$

$$\Delta d_{CA} = \frac{|d_{CA}(\mathbf{x}_1, \mathbf{x}_2) - d_{CA}(\mathbf{x}'_1, \mathbf{x}_2)|}{d_{CA}(\mathbf{x}_1, \mathbf{x}_2)} = \frac{|1,6364 - 1,4849|}{1,6364} = \frac{0,1515}{1,6364} = 0,093$$

Ze získaných výsledků je zřejmé, že relativní změna vzdáleností je v případě canberrské metriky pro toto zadání téměř dvakrát větší.

## Příklad 1b

Nyní mějme dány dva vektory  $\mathbf{x}_1 = (1000; 1000)^T$  a  $\mathbf{x}_2 = (100; 100)^T$  a předpokládejme, že se souřadnice prvního vektoru změní na  $\mathbf{x}'_1 = (1002; 1000)^T$ . Jaká je Hammingova (manhattanská) a canberrská vzdálenost v obou případech a jaká je relativní změna vzdáleností, vyvolaná uvedenou modifikací?

$$d_H(\mathbf{x}_1, \mathbf{x}_2) = |1000 - 100| + |1000 - 100| = 900 + 900 = 1800$$

$$d_H(\mathbf{x}'_1, \mathbf{x}_2) = |1002 - 100| + |1000 - 100| = 902 + 900 = 1802$$

$$d_{CA}(\mathbf{x}_1, \mathbf{x}_2) = \frac{|1000-100|}{|\mathbf{x}_1|+|\mathbf{x}_2|} + \frac{|1000-100|}{|\mathbf{x}_1|+|\mathbf{x}_2|} = \frac{900}{1100} + \frac{900}{1100} = 1,6364$$

$$d_{CA}(\mathbf{x}'_1, \mathbf{x}_2) = \frac{|1002-100|}{|\mathbf{x}'_1|+|\mathbf{x}_2|} + \frac{|1000-100|}{|\mathbf{x}_1|+|\mathbf{x}_2|} = \frac{902}{1102} + \frac{900}{1100} = 1,6367$$

Relativní změny vzdáleností, určující citlivost té které metriky, které jsou způsobeny změnou hodnoty první souřadnice, jsou:

$$\Delta d_H = \frac{|d_H(\mathbf{x}_1, \mathbf{x}_2) - d_H(\mathbf{x}'_1, \mathbf{x}_2)|}{d_H(\mathbf{x}_1, \mathbf{x}_2)} = \frac{|1800 - 1802|}{1800} = \frac{2}{1800} = 0,0011$$

$$\Delta d_{CA} = \frac{|d_{CA}(\mathbf{x}_1, \mathbf{x}_2) - d_{CA}(\mathbf{x}'_1, \mathbf{x}_2)|}{d_{CA}(\mathbf{x}_1, \mathbf{x}_2)} = \frac{|1,6364 - 1,6367|}{1,6364} = 0,00018$$

Ze získaných výsledků je zřejmé, že citlivost canberrské metriky je v tomto případě řádově nižší.

# Nelineární metrika

$$\rho_N(\mathbf{x}_1, \mathbf{x}_2) = \begin{cases} 0 & \text{když } \rho_E(\mathbf{x}_1, \mathbf{x}_2) < D \\ H & \text{když } \rho_E(\mathbf{x}_1, \mathbf{x}_2) \geq D \end{cases}$$

- kde  $D$  je prahová hodnota a  $H$  je nějaká konstanta
- i když existují doporučení, jak volit obě hodnoty na základě statistických vlastností vektorového prostoru (např. pomocí  $H = \frac{\Gamma(n/2)}{D^n \sqrt{\pi^n}}$ ), výhodnější je volit obě hodnoty na základě expertní analýzy řešeného problému
- ve vztahu může figurovat jakákoli metrika vzdálenosti, nejen Euklidova metrika

# Typy metrik a konkrétní příklady

## MEZI DVĚMA OBJEKTY

### Metriky pro určení vzdálenosti mezi 2 objekty s kvantitativními proměnnými

Euklidova m., Hammingova (manhattanská) m., Minkovského m., Čebyševova m., Mahalanobisova m., Canberrská m.

### Metriky pro určení vzdálenosti mezi 2 objekty s kvalitativními proměnnými

Hammingova m.

### Metriky pro určení podobnosti 2 objektů s kvantitativními proměnnými

Skalární součin, m. kosinové podobnosti, Pearsonův korelační koeficient, Tanimotova m.

### Metriky pro určení podobnosti 2 objektů s kvalitativními proměnnými

Tanimotova m., Jaccardův-Tanimotův a.k., Russelův-Raovův a.k., Sokalův-Michenerův a.k., Dicův k., Rogersův-Tanimotův k., Hamanův k.

## MEZI DVĚMA SKUPINAMI OBJEKTŮ

### Deterministické metriky pro určení vzdálenosti mezi 2 množinami objektů

Metoda nejbližšího souseda, k nejbližším sousedům, nejvzdálenějšího souseda, centroidová metoda, m. průměrné vazby, Wardova metoda

### Metriky pro určení vzdálenosti mezi 2 množinami objektů používající jejich pravděpodobnostní charakteristiky

Chernoffova m., Bhattacharyyova m. atd.

# Příklad

Předpokládejme, že množina  $F$  obsahuje symboly  $\{0, 1, 2\}$ , tj.  $k = 3$  a vektory  $\mathbf{x}$  a  $\mathbf{y}$  jsou následující 6-prvkové vektory (tj.  $p = 6$ ):

$$\mathbf{x} = (0, 1, 2, 1, 2, 1)^T$$

$$\mathbf{y} = (1, 0, 2, 1, 0, 1)^T$$

Spočtěte vzdálenost obou vektorů.

Kontingenční matice  $\mathbf{A}(\mathbf{x}, \mathbf{y})$  je:

$$\mathbf{A}(\mathbf{x}, \mathbf{y}) = \begin{bmatrix} 0 & 1 & 0 \\ 1 & 2 & 0 \\ 1 & 0 & 1 \end{bmatrix}$$

Součet hodnot všech prvků matice  $\mathbf{A}(\mathbf{x}, \mathbf{y})$  je roven délce  $p$  obou vektorů, tj. v našem případě:

$$\sum_{i=0}^2 \sum_{j=0}^2 a_{ij} = 6$$

# Hammingova metrika vzdálenosti

$$D_{HQ}(\mathbf{x}, \mathbf{y}) = \sum_{i=0}^{k-1} \sum_{\substack{j=0 \\ i \neq j}}^{k-1} a_{ij}$$

- definována počtem pozic, v nichž se oba vektory liší
- tzv. je dána součtem všech prvků matice  $\mathbf{A}$ , které leží mimo hlavní diagonálu.

Příklad:

$$\mathbf{x} = (0, 1, 2, 1, 2, 1)^T$$

$$\mathbf{y} = (1, 0, 2, 1, 0, 1)^T$$



liší se ve 3 souřadnicích



$$d_{HQ}(\mathbf{x}, \mathbf{y}) = 3$$

$$\mathbf{A}(\mathbf{x}, \mathbf{y}) = \begin{bmatrix} 0 & 1 & 0 \\ 1 & 2 & 0 \\ 1 & 0 & 1 \end{bmatrix}$$



3 prvky mimo diagonálu



$$d_{HQ}(\mathbf{x}, \mathbf{y}) = 3$$

# Hammingova metrika vzdálenosti

- pro  $k = 2$ , kdy jsou hodnoty obou vektorů binární, se definiční vztah Hammingovy vzdálenosti transformuje na:

$$D_{HQB}(\mathbf{x}, \mathbf{y}) = \sum_{i=1}^p (x_i + y_i - 2x_i y_i)$$

kde třetí člen v závorce kompenzuje případ, kdy jsou hodnoty  $x_i$  i  $y_i$  rovny jedné a součet prvních členů v závorce je tím pádem roven dvěma, nicméně nastává shoda hodnot, která k celkové vzdálenosti nemůže přispět.

- protože  $x_i$  a  $y_i$  nabývají hodnot pouze 0 a 1, můžeme také psát:

$$D_{HQB}(\mathbf{x}, \mathbf{y}) = \sum_{i=1}^p (x_i^2 + y_i^2 - 2x_i y_i) = \sum_{i=1}^p (x_i - y_i)^2$$

- díky speciálnímu případu hodnot  $x_i$  a  $y_i$  je možná i nejjednodušší forma:

$$D_{HQB}(\mathbf{x}, \mathbf{y}) = \sum_{i=1}^p |x_i - y_i|$$

# Hammingova metrika vzdálenosti – příklad 2

Určete Hammingovu vzdálenost binárních vektorů

$$\mathbf{x} = (0, 1, 1, 0, 1)^T \text{ a}$$

$$\mathbf{y} = (1, 0, 0, 0, 1)^T.$$

Podle definičního principu (tzn. počet pozic, ve kterých se oba vektory liší):

$$d_{HQB}(\mathbf{x}, \mathbf{y}) = 3$$

Dle jiného vztahu:  $d_{HQB}(\mathbf{x}, \mathbf{y}) = \sum_{i=1}^p (x_i + y_i - 2x_i y_i) =$

$$= (0+1-2\cdot 0\cdot 1) + (1+0-2\cdot 1\cdot 0) + (1+0-2\cdot 1\cdot 0) + (0+0-2\cdot 0\cdot 0) + (1+1-2\cdot 1\cdot 1) = 3$$

Dle dalšího vztahu:  $d_{HQB}(\mathbf{x}, \mathbf{y}) = \sum_{i=1}^p (x_i - y_i)^2 =$

$$= (0-1)^2 + (1-0)^2 + (1-0)^2 + (0-0)^2 + (1-1)^2 = 1+1+1+0+0 = 3$$

Dle posledního vztahu:  $d_{HQB}(\mathbf{x}, \mathbf{y}) = \sum_{i=1}^p |x_i - y_i| =$

$$= |0-1| + |1-0| + |1-0| + |0-0| + |1-1| =$$
$$= 1+1+1+0+0 = 3$$

# Hammingova metrika vzdálenosti

V případě bipolárních vektorů, kdy jednotlivé složky vektorů nabývají hodnot +1 a -1, je Hammingova vzdálenost určena vztahem:

$$D_{HQP}(\mathbf{x}, \mathbf{y}) = \frac{\left( p - \sum_{i=1}^p x_i y_i \right)}{2}$$

## Příklad 3:

Určete Hammingovu vzdálenost bipolárních vektorů

$$\mathbf{x} = (1, 1, 1, -1, 1)^T \text{ a}$$

$$\mathbf{y} = (1, -1, 1, -1, -1)^T.$$

Podle definičního principu (tzn. počet pozic, ve kterých se liší):  $d_{HQP}(\mathbf{x}, \mathbf{y}) = 2$

Z kontingenční matici (součet prvků mimo hlavní diagonálu):  $\mathbf{A}(\mathbf{x}, \mathbf{y}) = \begin{bmatrix} 2 & 2 \\ 0 & 1 \end{bmatrix}$

Pomocí vztahu:

$$d_{HQP}(\mathbf{x}, \mathbf{y}) = \frac{5 - ((1 \cdot 1) + (1 \cdot (-1)) + (1 \cdot 1) + ((-1) \cdot (-1)) + (1 \cdot (-1)))}{2} = \frac{5 - (1 - 1 + 1 + 1 - 1)}{2} = \frac{5 - 1}{2} = 2$$

# Metriky pro určení podobnosti mezi dvěma objekty

# Typy metrik a konkrétní příklady

## MEZI DVĚMA OBJEKTY

### Metriky pro určení vzdálenosti mezi 2 objekty s kvantitativními proměnnými

Euklidova m., Hammingova (manhattanská) m., Minkovského m., Čebyševova m., Mahalanobisova m., Canberrská m.

### Metriky pro určení vzdálenosti mezi 2 objekty s kvalitativními proměnnými

Hammingova m.

### Metriky pro určení podobnosti 2 objektů s kvantitativními proměnnými

Skalární součin, m. kosinové podobnosti, Pearsonův korelační koeficient, Tanimotova m.

### Metriky pro určení podobnosti 2 objektů s kvalitativními proměnnými

Tanimotova m., Jaccardův-Tanimotův a.k., Russelův-Raovův a.k., Sokalův-Michenerův a.k., Dicův k., Rogersův-Tanimotův k., Hamanův k.

## MEZI DVĚMA SKUPINAMI OBJEKTŮ

### Deterministické metriky pro určení vzdálenosti mezi 2 množinami objektů

Metoda nejbližšího souseda, k nejbližším sousedům, nejvzdálenějšího souseda, centroidová metoda, m. průměrné vazby, Wardova metoda

### Metriky pro určení vzdálenosti mezi 2 množinami objektů používající jejich pravděpodobnostní charakteristiky

Chernoffova m., Bhattacharyyova m. atd.

# Skalární součin

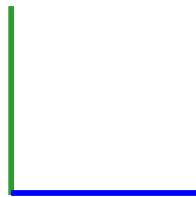
$$S_{ss}(\mathbf{x}_1, \mathbf{x}_2) = \mathbf{x}_1^T \cdot \mathbf{x}_2 = \sum_{i=1}^n x_{1i} x_{2i}$$

Většinou pro vektory  $\mathbf{x}_1$  a  $\mathbf{x}_2$  o stejné délce (např.  $a$ ); záleží na úhlu, který svírají:



úhel  $0^\circ$

$$S_{ss} = a^2$$



úhel  $90^\circ$

$$S_{ss} = 0$$



úhel  $180^\circ$

$$S_{ss} = -a^2$$

- skalární součin invariantní vůči rotaci – absolutní orientace nepodstatná, důležitý pouze úhel
- skalární součin není invariantní vůči lineární transformaci (tzn. závisí na délce vektorů)

odvození metriky vzdálenosti:

$$D_{ss}(\mathbf{x}_1, \mathbf{x}_2) = a^2 - S_{ss}(\mathbf{x}_1, \mathbf{x}_2)$$

# Metrika kosinové podobnosti

$$S_{\cos}(\mathbf{x}_1, \mathbf{x}_2) = \frac{\mathbf{x}_1^T \cdot \mathbf{x}_2}{\|\mathbf{x}_1\| \cdot \|\mathbf{x}_2\|}$$

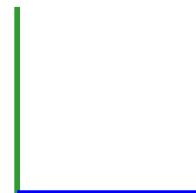
kde  $\|\mathbf{x}_i\|$  je norma (délka) vektoru  $\mathbf{x}_i$   
= skalárni součin vektorů o jednotkové délce

- vhodná v případě, pokud je informativní pouze relativní hodnota příznaků
- hodnoty  $S_{\cos}(\mathbf{x}_1, \mathbf{x}_2)$  jsou rovny kosinu úhlu mezi oběma vektory



úhel 0°

$$S_{\cos} = 1$$



úhel 90°

$$S_{\cos} = 0$$



úhel 180°

$$S_{\cos} = -1$$

# Pearsonův korelační koeficient

## Pearsonův korelační koeficient

$$S_{PC}(\mathbf{x}_1, \mathbf{x}_2) = \frac{\mathbf{x}_{d1}^T \cdot \mathbf{x}_{d2}}{\|\mathbf{x}_{d1}\| \cdot \|\mathbf{x}_{d2}\|}$$

kde  $\mathbf{x}_{di} = (x_{i1} - \bar{x}_i, x_{i2} - \bar{x}_i, \dots, x_{ip} - \bar{x}_i)^T$

$\mathbf{x}_{di}$  jsou tzv. **diferenční vektory**

také nabývá hodnot z intervalu  $\langle -1;1 \rangle$

odvození metriky vzdálenosti:

$$D_{PC}(\mathbf{x}_1, \mathbf{x}_2) = \frac{1 - S_{PC}(\mathbf{x}_1, \mathbf{x}_2)}{2}$$

- hodnoty se (díky dělení dvěma) vyskytují v intervalu  $\langle 0;1 \rangle$
- používá se např. při analýze dat genové exprese

# Tanimotova metrika podobnosti

$$S_T(\mathbf{x}_1, \mathbf{x}_2) = \frac{\mathbf{x}_1^T \mathbf{x}_2}{\|\mathbf{x}_1\|^2 + \|\mathbf{x}_2\|^2 - \mathbf{x}_1^T \mathbf{x}_2}$$

Přičteme-li a odečteme-li ve jmenovateli výraz  $\mathbf{x}_1^T \mathbf{x}_2$  a podělíme-li čitatele i jmenovatele zlomku toutéž hodnotou, dostaneme

$$S_T(\mathbf{x}_1, \mathbf{x}_2) = \frac{1}{1 + \frac{(\mathbf{x}_1 - \mathbf{x}_2)^T (\mathbf{x}_1 - \mathbf{x}_2)}{\mathbf{x}_1^T \mathbf{x}_2}}$$

Tanimotova podobnost vektorů  $\mathbf{x}_1$  a  $\mathbf{x}_2$  je nepřímo úměrná kvadrátu Euklidovy vzdálenosti vektorů  $\mathbf{x}_1$  a  $\mathbf{x}_2$  vztažené k jejich skalárnímu součinu. Pokud skalární součin považujeme za míru korelace obou vektorů, můžeme formulovat výše uvedený vztah tak, že  $S_T(\mathbf{x}_1, \mathbf{x}_2)$  je nepřímo úměrná kvadrátu Euklidovy vzdálenosti podělené velikostí jejich korelace, což znamená, že je korelací, jako míře podobnosti přímo úměrná.

# „Bezejmenná“ metrika podobnosti

---

$$S_C(\mathbf{x}_1, \mathbf{x}_2) = 1 - \frac{D_E(\mathbf{x}_1, \mathbf{x}_2)}{\|\mathbf{x}_1\| + \|\mathbf{x}_2\|}$$

Vzdálenost podle metriky je rovna jedné,

$$\text{když } \mathbf{x}_1 = \mathbf{x}_2$$

a svého minima (tj.  $S_C(\mathbf{x}_1, \mathbf{x}_2) = -1$ ) nabývá,

$$\text{když } \mathbf{x}_1 = -\mathbf{x}_2.$$

# Typy metrik a konkrétní příklady

## MEZI DVĚMA OBJEKTY

### Metriky pro určení vzdálenosti mezi 2 objekty s kvantitativními proměnnými

Euklidova m., Hammingova (manhattanská) m., Minkovského m., Čebyševova m., Mahalanobisova m., Canberrská m.

### Metriky pro určení vzdálenosti mezi 2 objekty s kvalitativními proměnnými

Hammingova m.

### Metriky pro určení podobnosti 2 objektů s kvantitativními proměnnými

Skalární součin, m. kosinové podobnosti, Pearsonův korelační koeficient, Tanimotova m.

### Metriky pro určení podobnosti 2 objektů s kvalitativními proměnnými

Tanimotova m., Jaccardův-Tanimotův a.k., Russelův-Raovův a.k., Sokalův-Michenerův a.k., Dicův k., Rogersův-Tanimotův k., Hamanův k.

## MEZI DVĚMA SKUPINAMI OBJEKTŮ

### Deterministické metriky pro určení vzdálenosti mezi 2 množinami objektů

Metoda nejbližšího souseda, k nejbližším sousedům, nejvzdálenějšího souseda, centroidová metoda, m. průměrné vazby, Wardova metoda

### Metriky pro určení vzdálenosti mezi 2 množinami objektů používající jejich pravděpodobnostní charakteristiky

Chernoffova m., Bhattacharyyova m. atd.

# Metriky pro určení podobnosti 2 objektů s kvalitativními prom.

---

1. případy obecné
2. případy s dichotomickými příznaky, pro které je definována celá řada tzv.  
**asociačních koeficientů**.

(Asociační koeficienty až na výjimky nabývají hodnot z intervalu  $\langle 0, 1 \rangle$ ,  
hodnoty 1 v případě shody vektorů, 0 pro případ nepodobnosti.)

# Obecné metriky – Hammingova metrika podobnosti

$$S_{HQ}(\mathbf{x}, \mathbf{y}) = p - D_{HQ}(\mathbf{x}, \mathbf{y})$$

Příklad:

$$\mathbf{x} = (0, 1, 2, 1, 2, 1)^T$$

$$\mathbf{y} = (1, 0, 2, 1, 0, 1)^T$$



liší se ve 3 souřadnicích



$$d_{HQ}(\mathbf{x}, \mathbf{y}) = 3$$



shoda ve 3 souřadnicích



$$s_{HQ}(\mathbf{x}, \mathbf{y}) = 6 - 3 = 3$$

$$\mathbf{A}(\mathbf{x}, \mathbf{y}) = \begin{bmatrix} 0 & 1 & 0 \\ 1 & 2 & 0 \\ 1 & 0 & 1 \end{bmatrix}$$



3 prvky mimo diagonálu



$$d_{HQ}(\mathbf{x}, \mathbf{y}) = 3$$



součet prvků na diagonále roven 3



$$s_{HQ}(\mathbf{x}, \mathbf{y}) = 6 - 3 = 3$$

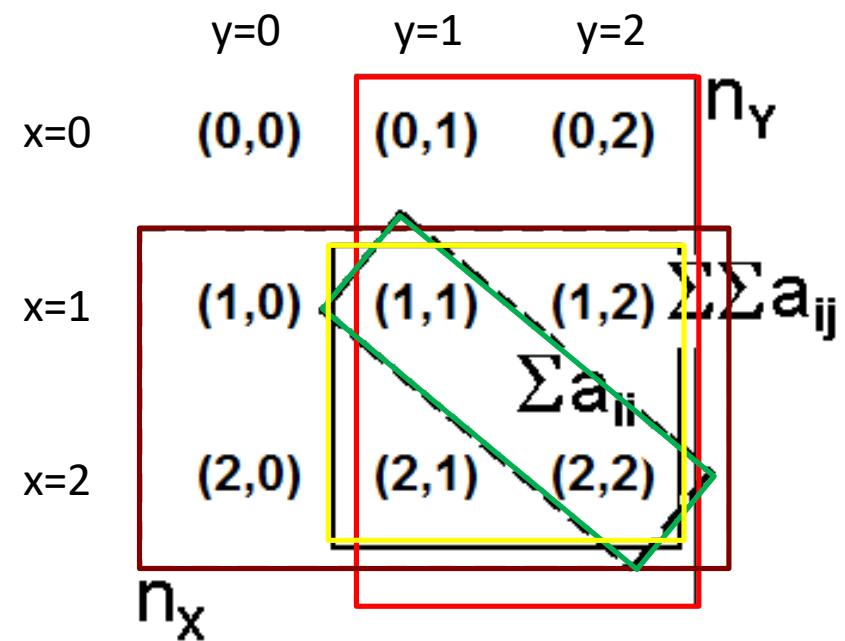
# Obecné metriky – Tanimotova metrika

$$S_{TQ}(\mathbf{x}, \mathbf{y}) = \frac{n_{X \cap Y}}{n_x + n_y - n_{X \cap Y}} = \frac{\sum_{i=1}^{k-1} a_{ii}}{n_x + n_y - \sum_{i=1}^{k-1} \sum_{j=1}^{k-1} a_{ij}}$$

$$n_x = \sum_{i=1}^{k-1} \sum_{j=0}^{k-1} a_{ij}$$

$$n_y = \sum_{i=0}^{k-1} \sum_{j=1}^{k-1} a_{ij}$$

Pro výpočet Tanimotovy podobnosti dvou vektorů s kvalitativními příznaky jsou použity všechny páry složek srovnávaných vektorů, kromě těch, jejichž hodnoty jsou obě nulové.



# Obecné metriky – Tanimotova metrika – příklad

Určete hodnoty Tanimotových podobností  $s_{TQ}(\mathbf{x}, \mathbf{x})$ ,  $s_{TQ}(\mathbf{x}, \mathbf{y})$  a  $s_{TQ}(\mathbf{x}, \mathbf{z})$ , když:

$$\mathbf{x} = (0, 1, 2, 1, 2, 1)^T \text{ a}$$

$$\mathbf{y} = (1, 0, 2, 1, 0, 1)^T \text{ a}$$

$$\mathbf{z} = (2, 0, 0, 0, 0, 2)^T.$$

Ze zadání je množina symbolů  $F = \{0, 1, 2\}$ ,  $k = 3$ ,  $p = 6$ .

Kontingenční tabulky jsou:

$$\mathbf{A}(\mathbf{x}, \mathbf{x}) = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 3 & 0 \\ 0 & 0 & 2 \end{bmatrix}$$

$$\mathbf{A}(\mathbf{x}, \mathbf{y}) = \begin{bmatrix} 0 & 1 & 0 \\ 1 & 2 & 0 \\ 1 & 0 & 1 \end{bmatrix}$$

$$\mathbf{A}(\mathbf{x}, \mathbf{z}) = \begin{bmatrix} 0 & 0 & 1 \\ 2 & 0 & 1 \\ 2 & 0 & 0 \end{bmatrix}$$

$$s_{TQ}(\mathbf{x}, \mathbf{x}) = \frac{5}{5+5-5} = 1$$

$$s_{TQ}(\mathbf{x}, \mathbf{y}) = \frac{3}{5+4-3} = 0,5$$

$$s_{TQ}(\mathbf{x}, \mathbf{z}) = \frac{0}{5+2-1} = 0$$

# Další obecné metriky

- definovány pomocí různých prvků kontingenční matici  $\mathbf{A}(\mathbf{x}, \mathbf{y})$
- některé z nich používají pouze počet shodných pozic v obou vektorech (ovšem s nenulovými hodnotami):

$$S_1(\mathbf{x}, \mathbf{y}) = \frac{\sum_{i=1}^{k-1} a_{ii}}{p} \quad S_2(\mathbf{x}, \mathbf{y}) = \frac{\sum_{i=1}^{k-1} a_{ii}}{p - a_{00}}$$

- některé z nich používají i shodu s nulovými hodnotami:

$$S_3(\mathbf{x}, \mathbf{y}) = \frac{\sum_{i=0}^{k-1} a_{ii}}{p}$$

# Asociační koeficienty

		$x_j$	
		false/0	true/1
$x_i$	false/0	D	C
	true/1	B	A

- A** - u obou objektů sledovaný jev nastal (obě odpovídající si proměnné mají hodnotu true, resp.1) – ***pozitivní shoda***;
- B** - u objektu  $x_i$  jev nastal ( $x_{ik} = \text{true}$ ), zatímco u objektu  $x_j$  nikoliv ( $x_{jk} = \text{false}$ , resp.0);
- C** - u objektu  $x_i$  jev nenastal ( $x_{ik} = \text{false}$ ), zatímco u objektu  $x_j$  ano ( $x_{jk} = \text{true}$ );
- D** - sledovaný jev nenastal ani u jednoho z objektů (obě odpovídající si proměnné mají hodnotu false, resp. 0) – ***negativní shoda***.

Při výpočtu podobnosti dvou objektů sledujeme, kolikrát pro všechny souřadnice obou vektorů  $x_j$  a  $x_i$  nastaly případy shody či neshody:

- **A+D** určuje celkový počet shod
- **B+C** celkový počet neshod
- **A+B+C+D = p** (tj. celk. počet souřadnic obou vektorů – tzn. počet proměnných)

# Jaccardův – Tanimotův asociační koeficient

$$S_{JT}(\mathbf{x}, \mathbf{y}) = \frac{A}{A + B + C}$$

		$\mathbf{x}_j$	
		false/0	true/1
$\mathbf{x}_i$	false/0	D	C
	true/1	B	A

což je díky zjednodušení i dichotomická varianta metriky podle vztahu:

$$S_{TQ}(\mathbf{x}, \mathbf{y}) = \frac{\sum_{i=1}^{k-1} a_{ii}}{n_x + n_y - \sum_{i=1}^{k-1} \sum_{j=1}^{k-1} a_{ij}}$$

Tento vztah se dominantně používá v ekologických studiích.

# Další asociační koeficienty I

		$x_j$	
		false/0	true/1
$x_i$	false/0	D	C
	true/1	B	A

## Russelův – Raoův asociační koeficient

$$S_{RR}(\mathbf{x}, \mathbf{y}) = \frac{A}{A + B + C + D}$$

dichotomická varianta  
metriky:

$$S_1(\mathbf{x}, \mathbf{y}) = \frac{\sum_{i=1}^{k-1} a_{ii}}{p}$$

## Sokalův – Michenerův asociační koeficient

$$S_{SM}(\mathbf{x}, \mathbf{y}) = \frac{A + D}{A + B + C + D}$$

dichotomická varianta  
metriky:

$$S_3(\mathbf{x}, \mathbf{y}) = \frac{\sum_{i=0}^{k-1} a_{ii}}{p}$$

# Další asociační koeficienty II

		x <sub>j</sub>	
		false/0	true/1
x <sub>i</sub>	false/0	D	C
	true/1	B	A

## Diceův (Czekanowského) asociační koeficient

$$S_{DC}(\mathbf{x}, \mathbf{y}) = \frac{2A}{2A + B + C} = \frac{2A}{(A + B) + (A + C)}$$

V případě Jaccardova a Diceova koeficientu pokud nastane úplná negativní shoda (tzn. A = B = C = 0), pak často:  $S_{JT}(\mathbf{x}, \mathbf{y}) = S_{DC}(\mathbf{x}, \mathbf{y}) = 1$ .

## Rogersův – Tanimotův asociační koeficient

$$S_{RT}(\mathbf{x}, \mathbf{y}) = \frac{A + D}{A + D + 2 \cdot (B + C)} = \frac{A + D}{(B + C) + (A + B + C + D)}$$

## Hamanův asociační koeficient

$$S_{HA}(\mathbf{x}, \mathbf{y}) = \frac{A + D - (B + C)}{A + B + C + D}$$

nabývá na rozdíl od všech dříve uvedených koeficientů hodnot z intervalu  $\langle -1, 1 \rangle$ . Hodnoty -1, pokud se příznaky pouze neshodují; hodnoty 0, když je počet shod a neshod v rovnováze; +1 v případě úplné shody všech příznaků

# Asociační koeficienty – poznámka

		$x_j$	
		false/0	true/1
$x_i$	false/0	D	C
	true/1	B	A

Na základě četností A až D lze pro případ binárních příznaků vytvářet i zajímavé vztahy pro již dříve uvedené míry:

**Hammingova metrika**

$$D_H(\mathbf{x}, \mathbf{y}) = B + C$$

**Euklidova metrika**

$$D_H(\mathbf{x}, \mathbf{y}) = \sqrt{B + C}$$

**Pearsonův korelační koeficient**

$$S_{PC}(\mathbf{x}, \mathbf{y}) = \frac{A \cdot D - B \cdot C}{\sqrt{(A + B) \cdot (C + D) \cdot (A + C) \cdot (B + D)}}$$

# Výpočet vzdáleností z asociačních koeficientů

---

Z asociačních koeficientů, které vyjadřují míru podobnosti, lze jednoduše odvodit i míry nepodobnosti (vzdálenosti) pomocí:

$$D_X(\mathbf{x}, \mathbf{y}) = 1 - S_X(\mathbf{x}, \mathbf{y})$$

# Výpočet vzdáleností v Matlabu

---

Funkce:

- pdist (vzdálenost mezi páry objektů matice X či páry proměnných matice  $X^T$ )
- pdist2 (vzdálenost mezi maticemi X a Y)

Výběr metrik vzdáleností u obou těchto funkcí:

- 'euclidean' – Euklidova metrika vzdálenosti
- 'squaredeuclidean' – čtverec Euklidovy metriky vzdálenosti
- 'seuclidean' – standardizovaná Euklidova metrika vzdálenosti
- 'cityblock' – Hammingova (manhattanská) metrika vzdálenosti
- 'minkowski' – Minkovského metrika vzdálenosti
- 'chebychev' – Čebyševova metrika vzdálenosti
- 'mahalanobis' – Mahalanobisova metrika vzdálenosti
- 'cosine' – 1 minus kosinová podobnost
- 'correlation' – 1 minus Pearsonův korelační koeficient
- 'spearman' – 1 minus Spearmanův korelační koeficient
- 'hamming' – Hamminova vzdálenost (pro kvalitativní proměnné)
- 'jaccard' – 1 minus Jaccardův koeficient
- lze případně nadefinovat i jinou metriku

# Metriky pro určení vzdálenosti mezi dvěma skupinami objektů

# Vzdálenost mezi skupinami objektů

- vzdálenost mezi skupinami dána:
  - „vzdáleností“ jednoho objektu s jedním či více objekty jedné skupiny (třídy) – použitelné při klasifikaci
  - „vzdáleností“ skupin (třídy, shluku) objektů či „vzdáleností“ jednoho objektu z každé skupiny – použitelné při shlukování
- zavedeme funkci, která ke každé dvojici skupin objektů ( $C_i, C_j$ ) přiřazuje číslo  $D(C_i, C_j)$ , které podobně jako míry podobnosti či nepodobnosti (metriky) jednotlivých objektů musí splňovat minimálně podmínky:
  - (S1)  $D(C_i, C_j) \geq 0$
  - (S2)  $D(C_i, C_j) = D(C_j, C_i)$
  - (S3)  $D(C_i, C_i) = \max_{i,j} D(C_i, C_j)$  (pro míry podobnosti)
  - (S3')  $D(C_i, C_i) = 0$  pro všechna i (pro míry vzdálenosti)

# Typy metrik a konkrétní příklady

## MEZI DVĚMA OBJEKTY

### Metriky pro určení vzdálenosti mezi 2 objekty s kvantitativními proměnnými

Euklidova m., Hammingova (manhattanská) m., Minkovského m., Čebyševova m., Mahalanobisova m., Canberrská m.

### Metriky pro určení vzdálenosti mezi 2 objekty s kvalitativními proměnnými

Hammingova m.

### Metriky pro určení podobnosti 2 objektů s kvantitativními proměnnými

Skalární součin, m. kosinové podobnosti, Pearsonův korelační koeficient, Tanimotova m.

### Metriky pro určení podobnosti 2 objektů s kvalitativními proměnnými

Tanimotova m., Jaccardův-Tanimotův a.k., Russelův-Raovův a.k., Sokalův-Michenerův a.k., Dicův k., Rogersův-Tanimotův k., Hamanův k.

## MEZI DVĚMA SKUPINAMI OBJEKTŮ

### Deterministické metriky pro určení vzdálenosti mezi 2 množinami objektů

Metoda nejbližšího souseda, k nejbližším sousedům, nejvzdálenějšího souseda, centroidová metoda, m. průměrné vazby, Wardova metoda

### Metriky pro určení vzdálenosti mezi 2 množinami objektů používající jejich pravděpodobnostní charakteristiky

Chernoffova m., Bhattacharyyova m. atd.

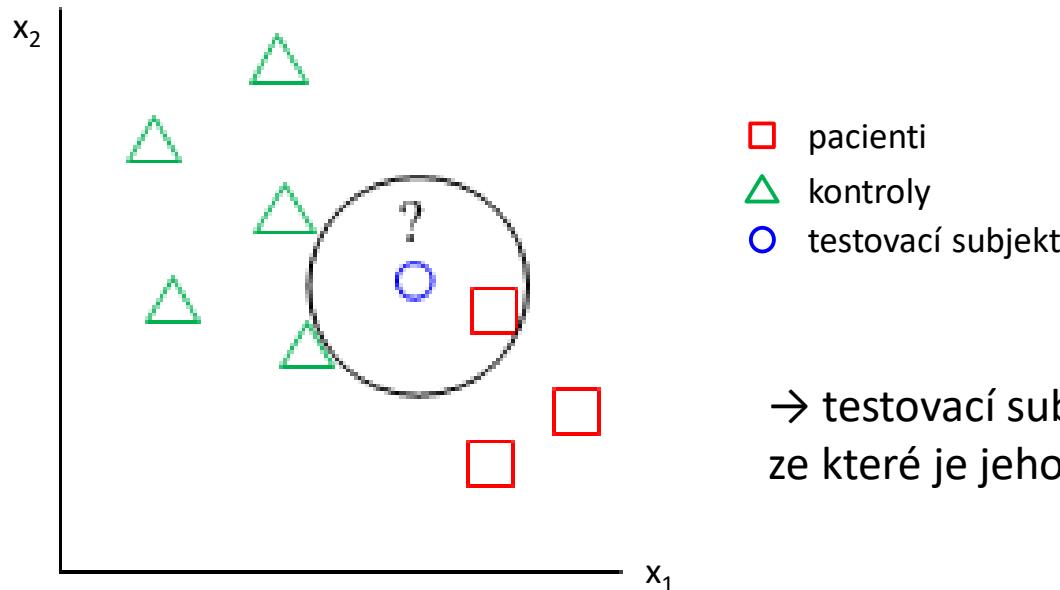
# Nejpoužívanější metriky pro určení vzdálenosti mezi dvěma množinami objektů

---

- Metoda nejbližšího souseda
- Metoda  $k$  nejbližších sousedů
- Metoda nejvzdálenějšího souseda
- Metoda průměrné vazby
- Wardova metoda

# Metoda nejbližšího souseda

- je-li  $d$  libovolná míra nepodobnosti (vzdálenosti) dvou objektů a  $\omega_i$  a  $\omega_j$  jsou libovolné skupiny objektů, potom metoda nejbližšího souseda definuje mezi skupinami  $\omega_i$  a  $\omega_j$  vzdálenost  $D_{NN}(\omega_i, \omega_j) = \min_{\substack{x_p \in \omega_i \\ x_q \in \omega_j}} d(x_p, x_q)$

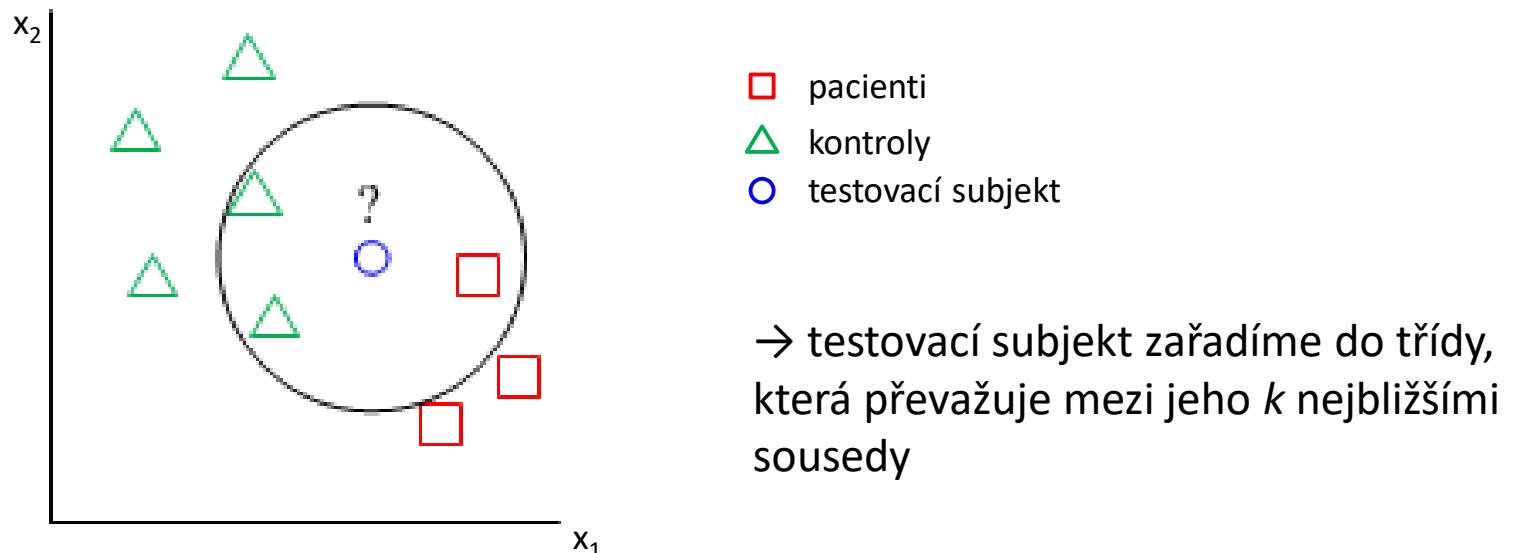


→ testovací subjekt zařadíme do třídy, ze které je jeho nejbližší soused

- výhody a nevýhody použití této metody pro klasifikaci:
  - + žádné předpoklady o rozložení
  - citlivé na odlehlé hodnoty
  - zpravidla nevhodné při nevyvážených počtech objektů ve skupinách

# Metoda k nejbližším sousedů

- zobecněním metody nejbližšího souseda
- definována vztahem  $D_{NNk}(\omega_i, \omega_j) = \min_{\substack{x_p \in \omega_i \\ x_q \in \omega_j}} \sum^k d(x_p, x_q)$ , tzn. vzdálenost dvou shluků je definována součtem nejkratších vzdáleností mezi objekty obou skupin



- výhody a nevýhody použití této metody pro klasifikaci:
  - + žádné předpoklady o rozložení
  - + méně citlivé na odlehlé hodnoty
  - zpravidla nevhodné při nevyvážených počtech objektů ve skupinách

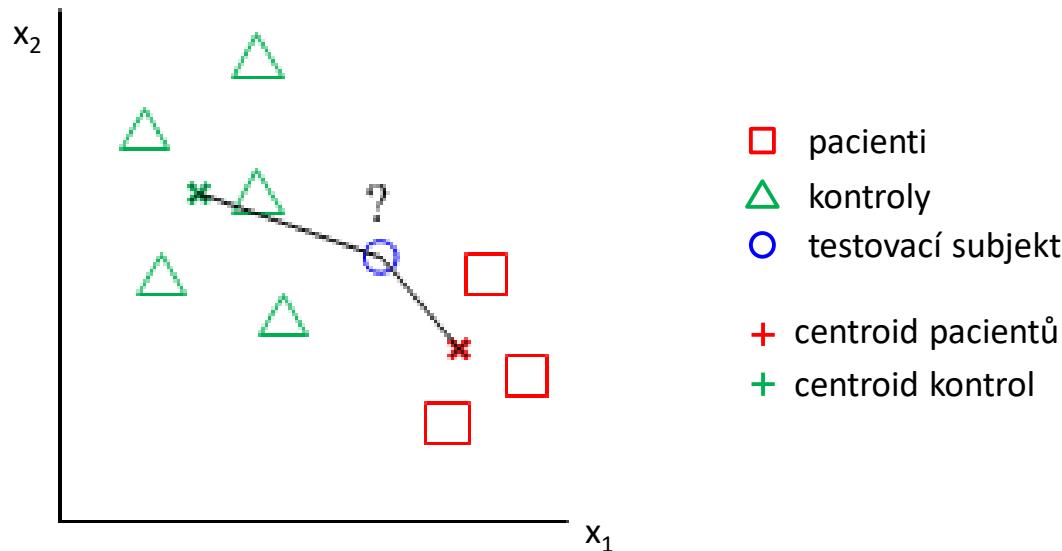
# Metoda nejvzdálenějšího souseda

- opačný princip než metoda nejbližšího souseda:  $D_{FN}(C_i, C_i) = \max_{\substack{x_p \in C_i \\ x_q \in C_j}} d(x_p, x_q)$
- pozn.: pro klasifikaci je obtížně použitelná
- pozn. 2: je možné zobecnění i pro více nejvzdálenějších sousedů

$$D_{FNk}(C_i, C_i) = \max_{\substack{x_p \in C_i \\ x_q \in C_j}} \sum^k d(x_p, x_q),$$

# Centroidová metoda

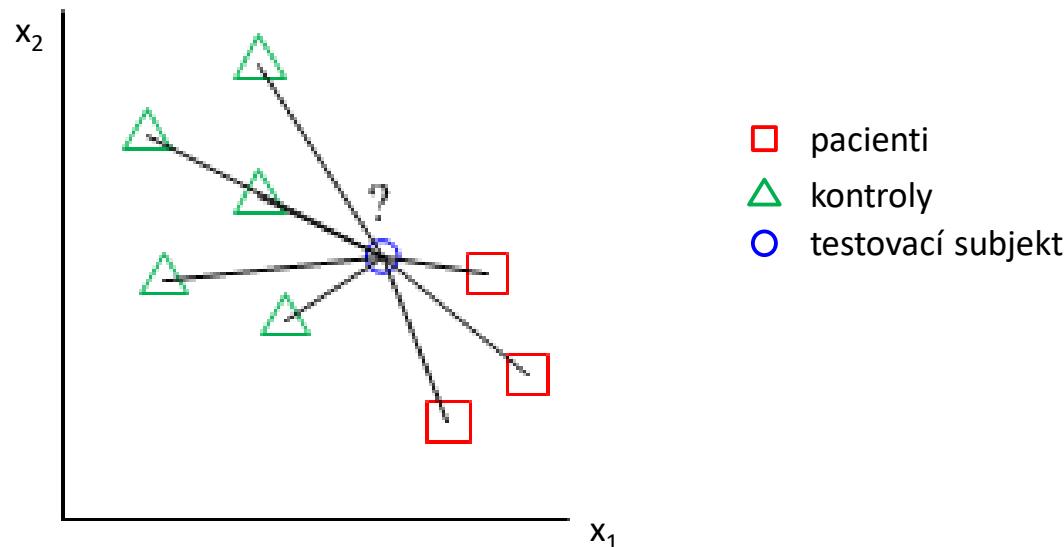
- vychází z výpočtu centroidů pro jednotlivé skupiny
- při klasifikaci: zařazení objektu do skupiny s nejbližším centroidem



- výhody a nevýhody použití této metody pro klasifikaci:
  - + žádné předpoklady o rozložení (pokud je však centroid počítán jako vícerozměrný průměr, může nenormalita působit trochu problémy)
  - + méně citlivé na odlehlé hodnoty než metoda nejbližšího souseda
  - + nebývá problém při nevyvážených počtech objektů ve skupinách

# Metoda průměrné vazby

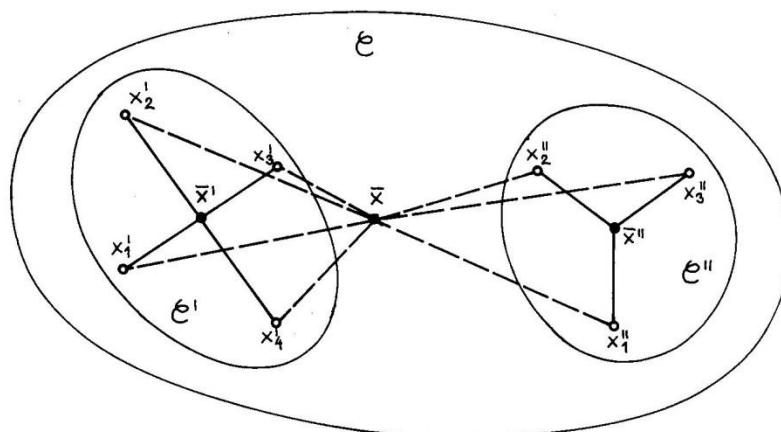
- vzdálenost dvou tříd je průměrná vzdálenost mezi všemi objekty těchto tříd
- při klasifikaci: zařazení subjektu do skupiny s nejmenší průměrnou vzdáleností od všech objektů dané skupiny



- výhody a nevýhody použití této metody pro klasifikaci:
  - + žádné předpoklady o rozložení
  - + méně citlivé na odlehlé hodnoty než metoda nejbližšího souseda
  - + nebývá problém při nevyvážených počtech objektů ve skupinách
  - časově náročnější než centroidová metoda při větším počtu objektů

# Wardova metoda

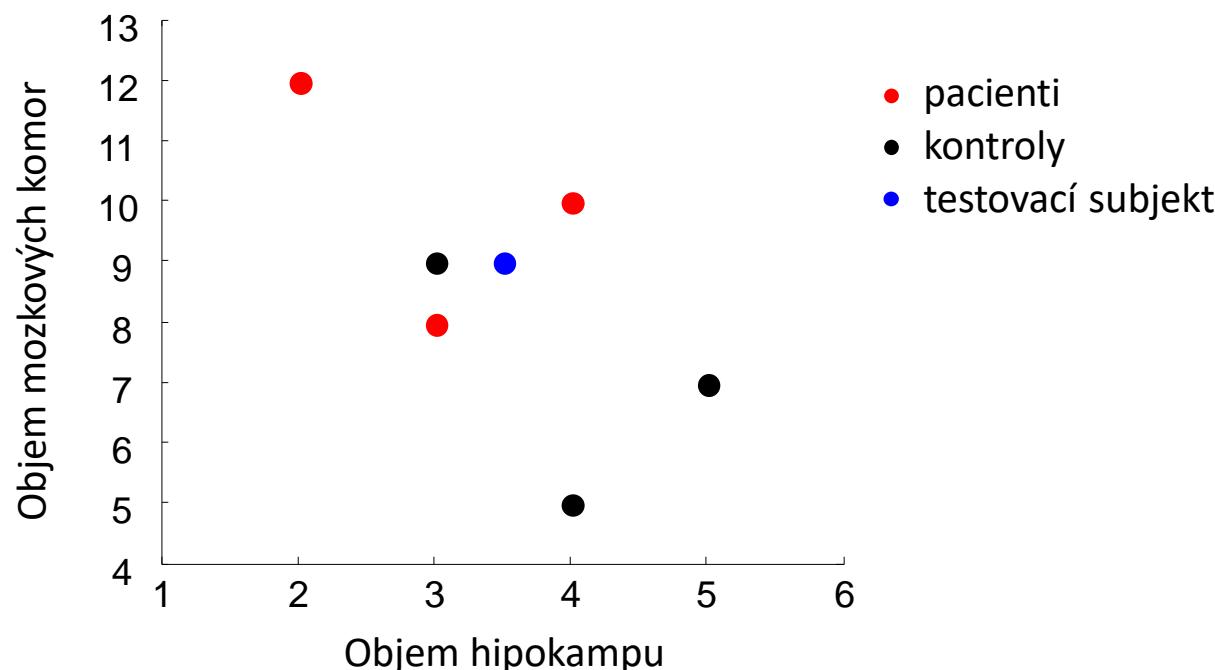
- vzdálenost mezi třídami (shluky) je definována přírůstkem součtu čtverců odchylek mezi těžištěm a objekty shluku vytvořeného z obou uvažovaných shluků  $C_i$  a  $C_j$  oproti součtu čtverců odchylek mezi objekty a těžišti v obou shlucích  $C_i$  a  $C_j$ .
- pozn. (při použití Wardovy metody pro shlukování): Metoda má tendenci vytvářet shluky zhruba stejné velikosti, tedy odstraňovat shluky malé, resp. velké.
- pozn. 2: pro klasifikaci se používá zřídka



## Příklad 2

Bylo provedeno měření objemu hipokampu a mozkových komor (v cm<sup>3</sup>) u 3 pacientů se schizofrenií a 3 kontrol:  $\mathbf{X}_D = \begin{bmatrix} 2 & 12 \\ 4 & 10 \\ 3 & 8 \end{bmatrix}$ ,  $\mathbf{X}_H = \begin{bmatrix} 5 & 7 \\ 3 & 9 \\ 4 & 5 \end{bmatrix}$ .

Určete, zda testovací subjekt  $\mathbf{x} = [3,5 \quad 9]$  patří do skupiny pacientů či kontrolních subjektů pomocí různých metod klasifikace podle minimální vzdálenosti.



# Typy metrik a konkrétní příklady

## MEZI DVĚMA OBJEKTY

### Metriky pro určení vzdálenosti mezi 2 objekty s kvantitativními proměnnými

Euklidova m., Hammingova (manhattanská) m., Minkovského m., Čebyševova m., Mahalanobisova m., Canberrská m.

### Metriky pro určení vzdálenosti mezi 2 objekty s kvalitativními proměnnými

Hammingova m.

### Metriky pro určení podobnosti 2 objektů s kvantitativními proměnnými

Skalární součin, m. kosinové podobnosti, Pearsonův korelační koeficient, Tanimotova m.

### Metriky pro určení podobnosti 2 objektů s kvalitativními proměnnými

Tanimotova m., Jaccardův-Tanimotův a.k., Russelův-Raovův a.k., Sokalův-Michenerův a.k., Dicův k., Rogersův-Tanimotův k., Hamanův k.

## MEZI DVĚMA SKUPINAMI OBJEKTŮ

### Deterministické metriky pro určení vzdálenosti mezi 2 množinami objektů

Metoda nejbližšího souseda, k nejbližším sousedům, nejvzdálenějšího souseda, centroidová metoda, m. průměrné vazby, Wardova metoda

### Metriky pro určení vzdálenosti mezi 2 množinami objektů používající jejich pravděpodobnostní charakteristiky

Chernoffova m., Bhattacharyyova m. atd.

# Metriky založené na pstrních charakteristikách

---

Klasifikační třídy (množiny objektů se společnými charakteristikami) nemusí být definovány jen výčtem objektů, ale i vymezením obecnějších vlastností:

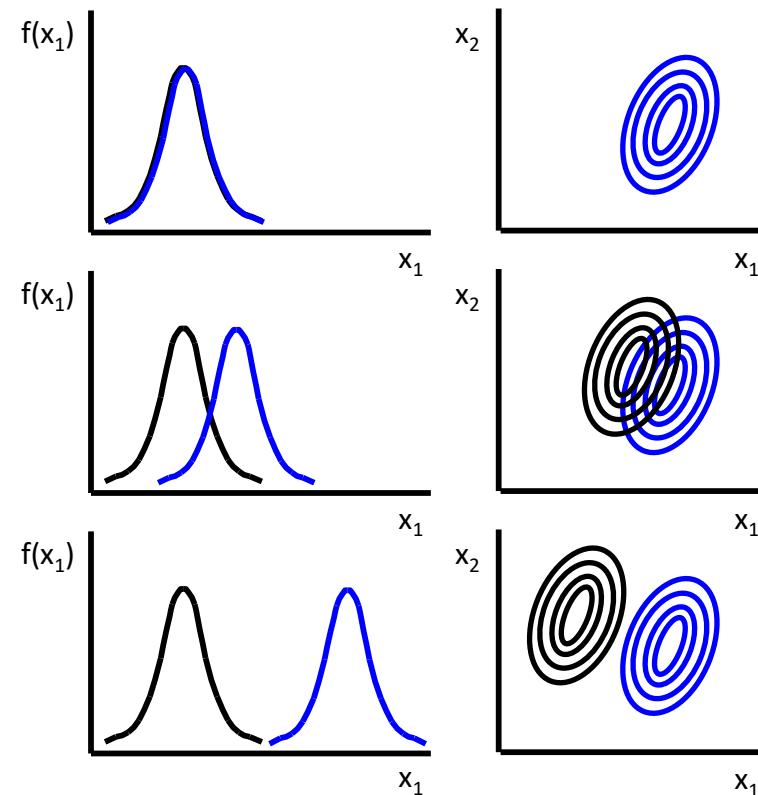
- definicí hranic oddělujících část obrazového prostoru náležející dané klasifikační třídě
- diskriminační funkcí
- **pravděpodobnostními charakteristikami výskytu objektů v dané třídě**
- atd.

# Metriky založené na pstranných charakteristikách

Základní myšlenkou je využití pravděpodobnosti způsobené chyby při klasifikaci (tzn. zařazení objektu do skupiny). Čím více se hustoty pravděpodobnosti výskytu objektů  $\mathbf{x}$  v jednotlivých množinách překrývají, tím je větší pravděpodobnost chyby.

Tzn. tyto metriky splňují následující vlastnosti:

1.  $J = 0$ , pokud jsou hustoty pravděpodobnosti obou množin identické, tj. když  
 $p(\mathbf{x}|\omega_1) = p(\mathbf{x}|\omega_2)$



2.  $J > 0$

3.  $J$  nabývá maxima, pokud jsou obě množiny disjunktní, tj. když

$$\int_{-\infty}^{\infty} p(\mathbf{x}|\omega_1) \cdot p(\mathbf{x}|\omega_2) d\mathbf{x} = 0$$

(Jak vidíme, není mezi vlastnostmi pravděpodobnostních metrik uvedena trojúhelníková nerovnost, jejíž splnění by se zajišťovalo obtížně.)

# Typy metrik a konkrétní příklady

## MEZI DVĚMA OBJEKTY

### Metriky pro určení vzdálenosti mezi 2 objekty s kvantitativními proměnnými

Euklidova m., Hammingova (manhattanská) m., Minkovského m., Čebyševova m., Mahalanobisova m., Canberrská m.

### Metriky pro určení vzdálenosti mezi 2 objekty s kvalitativními proměnnými

Hammingova m.

### Metriky pro určení podobnosti 2 objektů s kvantitativními proměnnými

Skalární součin, m. kosinové podobnosti, Pearsonův korelační koeficient, Tanimotova m.

### Metriky pro určení podobnosti 2 objektů s kvalitativními proměnnými

Tanimotova m., Jaccardův-Tanimotův a.k., Russelův-Raovův a.k., Sokalův-Michenerův a.k., Dicův k., Rogersův-Tanimotův k., Hamanův k.

## MEZI DVĚMA SKUPINAMI OBJEKTŮ

### Deterministické metriky pro určení vzdálenosti mezi 2 množinami objektů

Metoda nejbližšího souseda, k nejbližším sousedům, nejvzdálenějšího souseda, centroidová metoda, m. průměrné vazby, Wardova metoda

### Metriky pro určení vzdálenosti mezi 2 množinami objektů používající jejich pravděpodobnostní charakteristiky

Chernoffova m., Bhattacharyyova m. atd.

# Příprava nových učebních materiálů pro obor Matematická biologie

je podporována projektem OPVK

č. CZ.1.07/2.2.00/28.0043

„Interdisciplinární rozvoj studijního  
oboru Matematická biologie“



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ