

# Analýza a klasifikace dat – přednáška 2



RNDr. Eva Koriťáková, Ph.D.

Podzim 2017

# Typy klasifikátorů – podle reprezentace vstupních dat

## 1. Podle reprezentace vstupních dat:

- **příznakové klasifikátory:** paralelní (s pevným počtem proměnných) x sekvenční
- **strukturální (syntaktické) klasifikátory**
- **kombinované klasifikátory**

## 2. Podle jednoznačnosti zařazení do skupin:

- **deterministické klasifikátory**
- **pravděpodobnostní klasifikátory**

## 3. Podle typů klasifikačních a učících algoritmů:

- **parametrické klasifikátory**
- **neparametrické klasifikátory**

## 4. Podle způsobu učení:

- **učení s učitelem:** dokonalým x nedokonalým
- **učení bez učitele**

## 5. Podle principu klasifikace:

- **klasifikace pomocí diskriminačních funkcí**
- **klasifikace pomocí vzdálenosti od etalonů klasifikačních tříd**
- **klasifikace pomocí hranic v obrazovém prostoru**

# Typy klasifikátorů – podle reprezentace vstupních dat

## 1. Podle reprezentace vstupních dat:

- **příznakové klasifikátory: paralelní** (s pevným počtem proměnných) x sekvenční
- strukturální (syntaktické) klasifikátory
- kombinované klasifikátory

## 2. Podle jednoznačnosti zařazení do skupin:

- deterministické klasifikátory
- pravděpodobnostní klasifikátory

→ budeme se věnovat paralelním příznakovým klasifikátorům

## 3. Podle typů klasifikačních a učících algoritmů:

- parametrické klasifikátory
- neparametrické klasifikátory

## 4. Podle způsobu učení:

- učení s učitelem: dokonalým x nedokonalým
- učení bez učitele


## 5. Podle principu klasifikace:

- klasifikace pomocí diskriminačních funkcí
- klasifikace pomocí vzdálenosti od etalonů klasifikačních tříd
- klasifikace pomocí hranic v obrazovém prostoru

# 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



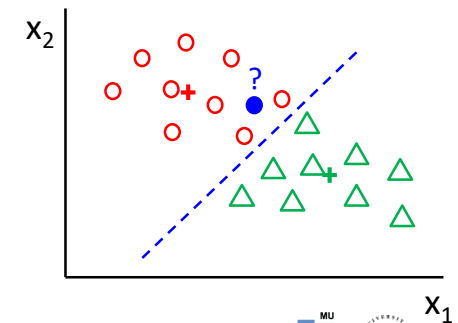
- **klasifikace pomocí vzdálenosti od etalonů klasif. tříd:**

- 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




# Vícerozměrné normální rozdělení

# Motivace

Dvourozměrný histogram



Hustota dvourozměrného normálního rozdělení



# Vícerozměrné normální rozdělení

**Hustota jednozměrného normálního rozdělení:**

$$f(x) = \frac{1}{\sqrt{(2\pi)\sigma^2}} \cdot \exp\left(-\frac{(x - \mu)^2}{2\sigma^2}\right)$$

$\mu$  - střední hodnota       $\sigma^2$  - rozptyl

**Hustota vícerozměrného normálního rozdělení:**

$$f(x_1, \dots, x_k) = \frac{1}{\sqrt{(2\pi)^k |\Sigma|}} \cdot \exp\left(-\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu})^T \Sigma^{-1}(\mathbf{x} - \boldsymbol{\mu})\right)$$

$\boldsymbol{\mu}$  - vektor středních hodnot       $\Sigma$  - kovarianční matice


**Hustota dvourozměrného normálního rozdělení:**

$$f(x, y) = \frac{1}{2\pi\sigma_x\sigma_y\sqrt{1-\rho^2}} \exp\left(-\frac{1}{2(1-\rho^2)} \left[ \frac{(x - \mu_x)^2}{\sigma_x^2} + \frac{(y - \mu_y)^2}{\sigma_y^2} - \frac{2\rho(x - \mu_x)(y - \mu_y)}{\sigma_x\sigma_y} \right]\right),$$



$$\boldsymbol{\mu} = \begin{pmatrix} \mu_x \\ \mu_y \end{pmatrix}, \quad \Sigma = \begin{pmatrix} \sigma_x^2 & \rho\sigma_x\sigma_y \\ \rho\sigma_x\sigma_y & \sigma_y^2 \end{pmatrix}$$

$\rho$  - korelace mezi X a Y;  
 $\sigma$  - směrodatná odchylka

# Je normalita v jednorozměrném prostoru jedinou podmínkou vícerozměrné normality?




+








# Je normalita v jednorozměrném prostoru jedinou podmínkou vícerozměrné normality?





+



# Je normalita v jednorozměrném prostoru jedinou podmínkou vícerozměrné normality?




+



Vícerozměrný outlier

# Ověření dvourozměrné normality


Bagplot = „bivariate boxplot“ (tzn. „dvourozměrný krabicový graf“)



v softwaru Statistica: Graphs – 2D Graphs – Bag Plots

# Ověření dvourozměrné normality


Vykreslení regulační elipsy („control“ ellipse):



v softwaru Statistica: Graphs – Scatterplots – na záložce Advanced zvolit Elipse Normal

# Normalizace dat

- Převod na normální rozdělení (normalita je předpokladem řady statistických testů).
- Např. **logaritmická transformace**:  $X = \ln(Y)$  nebo  $X = \ln(Y+1)$ , pokud data obsahují hodnotu 0



- Další příklady:
  - **odmocninová transf.** (pro proměnné s Poissonovým rozložením nebo obecně data typu počet jedinců, buněk apod.:  $X = \sqrt{Y}$  nebo  $X = \sqrt{Y + 1}$ )
  - **arcsin transformace** (pro proměnné s binomickým rozložením)
  - **Box-Coxova transformace**


# Klasifikace pomocí diskriminačních funkcí

# Příznakový klasifikátor

- klasifikátor je algoritmus (stroj, *machine*) s tolika vstupy, kolik je proměnných (příznaků) a s jedním diskretním výstupem, který udává třídu, do které klasifikátor zařadil rozpoznávaný objekt:

$$\omega_r = d(\mathbf{x})$$


- $\mathbf{x}$  je vektor hodnot jednotlivých proměnných pro daný subjekt, tedy  $\mathbf{x} = (x_1, x_2, \dots, x_n)^T$
- $d(\mathbf{x})$  je skalární funkce vektorového argumentu  $\mathbf{x}$ , kterou nazýváme **rozhodovací pravidlo klasifikátoru**
- $\omega_r$  je **identifikátor klasifikační třídy**



# Klasifikace pomocí diskriminačních funkcí

- rozhodovací pravidlo klasifikátoru  $d(\mathbf{x})$  založeno na výpočtu diskriminačních funkcí
- **diskriminační funkce  $g_i(\mathbf{x})$**  – vyjadřují míru příslušnosti objektu  $\mathbf{x}$  do jednotlivých klasifikačních tříd
- zařadíme  $\mathbf{x}$  do takové třídy  $\omega_i$ , pro kterou je  $g_i(\mathbf{x})$  maximální
- matematicky: pro objekt  $\mathbf{x}$  z třídy  $\omega_r$  platí, že


$$g_r(\mathbf{x}) > g_s(\mathbf{x}), \text{ pro } s = 1, 2, \dots, R \text{ a } r \neq s$$






# Blokové schéma klasifikátoru

- obecné blokové schéma klasifikátoru:



- blokové schéma klasifikátoru pomocí diskriminačních funkcí:




# Dichotomický klasifikátor

- pro klasifikaci do dvou tříd
- rozhodovací pravidlo klasifikátoru lze zapsat jako:



$$\omega_k = d(\mathbf{x}) = \text{sign}(g_1(\mathbf{x}) - g_2(\mathbf{x}))$$

- pokud  $d(\mathbf{x}) \geq 0 \rightarrow$  zařazení  $\mathbf{x}$  do třídy  $\omega_1$
- pokud  $d(\mathbf{x}) < 0 \rightarrow$  zařazení  $\mathbf{x}$  do třídy  $\omega_2$



# Souvislost klasifikace pomocí diskriminačních funkcí s klasifikací pomocí hranic

Hranice mezi dvěma sousedními třídami  $\omega_1$  a  $\omega_2$  je určena průmětem průsečíku funkcí  $g_r(\mathbf{x})$  a  $g_s(\mathbf{x})$ , definovaného rovnicí  $g_r(\mathbf{x}) = g_s(\mathbf{x})$ , do obrazového prostoru.



# Příklady diskriminačních funkcí

- nejjednodušším tvarem diskriminační funkce je lineární funkce:

$$g_r(\mathbf{x}) = a_{r0} + a_{r1}x_1 + a_{r2}x_2 + \dots + a_{rp}x_p$$

- diskriminační funkce na základě statistických vlastností množiny objektů:

$$g_r(\mathbf{x}) = P(\omega_r|\mathbf{x})$$


kde  $P(\omega_r|\mathbf{x})$  je pravděpodobnost zatřídění  $\mathbf{x}$  do třídy  $\omega_r$

→ **Bayesův klasifikátor**

# Lineární diskriminační funkce

$$g_r(\mathbf{x}) = a_{r0} + a_{r1}x_1 + a_{r2}x_2 + \dots + a_{rp}x_p,$$


kde  $a_{r0}$  je práh diskriminační funkce posouvající počátek souřadného systému a  $a_{ri}$  jsou váhové koeficienty  $i$ -tého příznaku  $x_i$



# Lineární diskriminační funkce

$$g_r(\mathbf{x}) = a_{r0} + a_{r1}x_1 + a_{r2}x_2 + \dots + a_{rp}x_p,$$


kde  $a_{r0}$  je práh diskriminační funkce posouvající počátek souřadného systému  
a  $a_{ri}$  jsou váhové koeficienty  $i$ -tého příznaku  $x_i$



# Lineární diskriminační funkce

$$g_r(\mathbf{x}) = a_{r0} + a_{r1}x_1 + a_{r2}x_2 + \dots + a_{rp}x_p,$$


kde  $a_{r0}$  je práh diskriminační funkce posouvající počátek souřadného systému a  $a_{ri}$  jsou váhové koeficienty  $i$ -tého příznaku  $x_i$



# Lineární diskriminační funkce

$$g_r(\mathbf{x}) = a_{r0} + a_{r1}x_1 + a_{r2}x_2 + \dots + a_{rp}x_p,$$

kde  $a_{r0}$  je práh diskriminační funkce posouvající počátek souřadného systému a  $a_{ri}$  jsou váhové koeficienty  $i$ -tého příznaku  $x_i$





# Bayesův klasifikátor

- diskriminační funkce určeny na základě statistických vlastností množiny objektů
- vyjdeme z **Bayesova vzorce**:  $P(\omega_k|\mathbf{x}) = \frac{p(\mathbf{x}|\omega_k) \cdot P(\omega_k)}{p(\mathbf{x})}$ , kde
  - $P(\omega_k|\mathbf{x})$  je aposteriorní podmíněná pravděpodobnost zatřídění objektu  $\mathbf{x}$  do třídy  $\omega_k$
  - $p(\mathbf{x}|\omega_k)$  je podmíněná hustota pravděpodobnosti výskytu objektu  $\mathbf{x}$  ve třídě  $\omega_k$ ,  $k = 1, 2$
  - $P(\omega_k)$  je apriorní pravděpodobnost třídy  $\omega_k$
  - $p(\mathbf{x})$  je celková hustota pravděpodobnosti rozložení objektu  $\mathbf{x}$  v celém obrazovém prostoru

# Bayesův klasifikátor – kritéria

---

- Kritérium maximální a posteriorní pravděpodobnosti
- Kritérium minimální pravděpodobnosti chybného rozhodnutí
- Kritérium minimální střední ztráty
- Kritérium maximální pravděpodobnosti


# Bayesův klasifikátor – kritéria

---

- Kritérium maximální a posteriorní pravděpodobnosti
- Kritérium minimální pravděpodobnosti chybného rozhodnutí
- Kritérium minimální střední ztráty
- Kritérium maximální pravděpodobnosti

# Bayesův kl. – kritérium maximální aposteriori psti

- zatřídění obrazu  $\mathbf{x}$  do třídy s větší aposteriori pravděpodobností, tedy:  
když  $P(\omega_1|\mathbf{x}) \geq P(\omega_2|\mathbf{x}) \rightarrow$  zařazení  $\mathbf{x}$  do třídy  $\omega_1$   
když  $P(\omega_1|\mathbf{x}) < P(\omega_2|\mathbf{x}) \rightarrow$  zařazení  $\mathbf{x}$  do třídy  $\omega_2$




# Bayesův kl. – kritérium maximální aposteriorní psti

**Příklad:** 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  $\mathbf{x} = [3,5 \ 9]$  patří do skupiny pacientů či kontrolních subjektů pomocí Bayesova klasifikátoru.



# Bayesův kl. – kritérium maximální aposteriorní psti

**Příklad:** 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 Bayesova klasifikátoru.

$$P(\omega_k|\mathbf{x}) = \frac{p(\mathbf{x}|\omega_k) \cdot P(\omega_k)}{p(\mathbf{x})}$$

**Označení a pomocné výpočty:**

$$n_D = 3; \quad n_H = 3; \quad n = 6$$

Apriorní psti:

$$P(\omega_D) = \frac{n_D}{n} = \frac{3}{6} = 0,5$$

$$P(\omega_H) = \frac{n_H}{n} = \frac{3}{6} = 0,5$$

Podmíněné hustoty psti:  $p(\mathbf{x}|\omega_k) = \frac{1}{\sqrt{(2\pi)^2 |\mathbf{S}_k|}} \cdot \exp\left(-\frac{1}{2}(\mathbf{x} - \bar{\mathbf{x}})^T \mathbf{S}_k^{-1}(\mathbf{x} - \bar{\mathbf{x}})\right)$

Potřebujeme vypočítat: vícerozměrné průměry  $\bar{\mathbf{x}}_D$  a  $\bar{\mathbf{x}}_H$ ; kovarianční matice  $\mathbf{S}_D$  a  $\mathbf{S}_H$ .

# Bayesův kl. – kritérium maximální aposteriorní psti

**Příklad:** 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 Bayesova klasifikátoru.

$$P(\omega_k|\mathbf{x}) = \frac{p(\mathbf{x}|\omega_k) \cdot P(\omega_k)}{p(\mathbf{x})}$$

**Označení a pomocné výpočty:**

Vícerozměrné průměry:  $\bar{\mathbf{x}}_D =$

$$\left[ \frac{1}{n_D} \sum_{i=1}^{n_D} x_{i1} \quad \frac{1}{n_D} \sum_{i=1}^{n_D} x_{i2} \right] = [3 \quad 10]$$

$$\bar{\mathbf{x}}_H = \left[ \frac{1}{n_H} \sum_{i=1}^{n_H} x_{i1} \quad \frac{1}{n_H} \sum_{i=1}^{n_H} x_{i2} \right] = [4 \quad 7]$$

Výběrové kovarianční matice:


$$\mathbf{S}_D = \begin{bmatrix} s_{11}^D & s_{12}^D \\ s_{21}^D & s_{22}^D \end{bmatrix} = \begin{bmatrix} 1 & -1 \\ -1 & 4 \end{bmatrix}$$

$$\mathbf{S}_H = \begin{bmatrix} s_{11}^H & s_{12}^H \\ s_{21}^H & s_{22}^H \end{bmatrix} = \begin{bmatrix} 1 & -1 \\ -1 & 4 \end{bmatrix}$$

# Bayesův kl. – kritérium maximální aposteriorní psti

Příklad:

## 1. Klasifikace podle objemu mozkových komor:



$$P(\omega_D|x_2) = \frac{0,176 \cdot 0,5}{0,1485} = 0,593$$

$$P(\omega_H|x_2) = \frac{0,121 \cdot 0,5}{0,1485} = 0,407$$


→ subjekt zařazen do třídy pacientů



# Bayesův kl. – kritérium maximální aposteriorní psti

Příklad:


## 2. Klasifikace podle objemu hipokampu:



$$P(\omega_D|x_1) = \frac{0,352 \cdot 0,5}{0,352} = 0,5$$

$$P(\omega_H|x_1) = \frac{0,352 \cdot 0,5}{0,352} = 0,5$$



→ nelze jednoznačně určit, kam subjekt zařadíme



# Bayesův kl. – kritérium maximální aposteriorní psti

Příklad:

## 3. Klasifikace podle obou proměnných:





$$P(\omega_D|\mathbf{x}) = \frac{0,078 \cdot 0,5}{0,067} = 0,582$$

$$P(\omega_H|\mathbf{x}) = \frac{0,056 \cdot 0,5}{0,067} = 0,418$$

→ subjekt zařazen do třídy pacientů

# Bayesův kl. – kritérium maximální aposteriorní psti

Příklad - klasifikace podle obou proměnných:



# Bayesův kl. – kritérium maximální aposteriori psti

**Příklad** - Výpočet hranice pomocí diskriminačních funkcí:

Pro hranici je rozdíl diskriminačních funkcí roven 0:

$$P(\omega_D|\mathbf{x}) - P(\omega_H|\mathbf{x}) = 0$$

$$P(\omega_D|\mathbf{x}) = P(\omega_H|\mathbf{x})$$

$$\frac{P(\omega_D|\mathbf{x})}{P(\omega_H|\mathbf{x})} = 1 \rightarrow \text{kritérium maximální aposteriori pravděpodobnosti}$$

Levá strana je rovna:  $\frac{P(\omega_D|\mathbf{x})}{P(\omega_H|\mathbf{x})} = \frac{0,582}{0,418} = 1,4$

Pravá strana je rovna: 1

→ protože věrohodnostní poměr (na levé straně) je větší než výraz na pravé straně, subjekt zařadíme do třídy pacientů

# Bayesův klasifikátor – kritéria

---

- Kritérium maximální a posteriorní pravděpodobnosti
- Kritérium minimální pravděpodobnosti chybného rozhodnutí
- Kritérium minimální střední ztráty
- Kritérium maximální pravděpodobnosti

# Bayesův kl. – kritérium min. psti chybného rozhodnutí

- Vyjdeme z výpočtu hranice pomocí diskriminačních funkcí:

$$P(\omega_D|\mathbf{x}) - P(\omega_H|\mathbf{x}) = 0$$

$$\frac{p(\mathbf{x}|\omega_D) \cdot P(\omega_D)}{p(\mathbf{x})} - \frac{p(\mathbf{x}|\omega_H) \cdot P(\omega_H)}{p(\mathbf{x})} = 0$$

- Můžeme vykrátit  $p(\mathbf{x})$ , protože celková hustota pravděpodobnosti je stejná pro obě diskriminační funkce:

$$p(\mathbf{x}|\omega_D) \cdot P(\omega_D) - p(\mathbf{x}|\omega_H) \cdot P(\omega_H) = 0$$

- $\frac{p(\mathbf{x}|\omega_D)}{p(\mathbf{x}|\omega_H)} = \frac{P(\omega_H)}{P(\omega_D)} \rightarrow$  kritérium minimální psti chybného rozhodnutí

# Bayesův kl. – kritérium min. psti chybného rozhodnutí

$$\frac{p(\mathbf{x}|\omega_D)}{p(\mathbf{x}|\omega_H)} = \frac{P(\omega_H)}{P(\omega_D)} \rightarrow \text{kritérium minimální psti chybného rozhodnutí}$$

## Pro náš příklad:

$$\text{Levá strana je rovna: } \frac{p(\mathbf{x}|\omega_D)}{p(\mathbf{x}|\omega_H)} = \frac{0,078}{0,056} = 1,4$$


$$\text{Pravá strana rovna } \frac{P(\omega_H)}{P(\omega_D)} = \frac{0,5}{0,5} = 1$$

→ protože věrohodnostní poměr (na levé straně) je větší než výraz na pravé straně, subjekt zařadíme do třídy pacientů


Poznámka: Kdyby byly apriorní pravděpodobnosti jiné, např.  $\frac{P(\omega_H)}{P(\omega_D)} = \frac{6/9}{3/9} = 2$ , byl by testovací subjekt zařazen do třídy kontrolních subjektů.

# Bayesův kl. – kritérium min. psti chybného rozhodnutí

Poznámka: Kdyby byly apriorní pravděpodobnosti jiné, např.  $\frac{P(\omega_H)}{P(\omega_D)} = \frac{6/9}{3/9} = 2$ ,  
byl by testovací subjekt zařazen do třídy kontrolních subjektů.



→ zařazení objektu do červené třídy



→ zařazení objektu do černé třídy



# Bayesův klasifikátor – kritéria

---

- Kritérium maximální aposteriorní pravděpodobnosti
- Kritérium minimální pravděpodobnosti chybného rozhodnutí
- **Kritérium minimální střední ztráty**
- Kritérium maximální pravděpodobnosti

# Bayesův kl. – kritérium minimální střední ztráty

- chceme do výpočtů zahrnout ztrátu při chybné klasifikaci objektu ze třídy  $\omega_s$  do třídy  $\omega_r$  - ztráta definována pomocí **ztrátové funkce**  $\lambda(\omega_r | \omega_s)$

- ztrátové funkce zapíšeme do **matice ztrátových funkcí**:

$$\lambda = \begin{bmatrix} \lambda(\omega_1 | \omega_1) & \lambda(\omega_1 | \omega_2) & \cdots & \lambda(\omega_1 | \omega_K) \\ \lambda(\omega_2 | \omega_1) & \lambda(\omega_2 | \omega_2) & \cdots & \lambda(\omega_2 | \omega_K) \\ \vdots & \vdots & \ddots & \vdots \\ \lambda(\omega_K | \omega_1) & \lambda(\omega_K | \omega_2) & \cdots & \lambda(\omega_K | \omega_K) \end{bmatrix}$$

- prvky na diagonále  $\lambda(\omega_1 | \omega_1)$  bývají zpravidla nulové, protože při správném zařazení objektu ze třídy  $\omega_1$  do třídy  $\omega_1$  nevzniká žádná ztráta
- např.  $\lambda = \begin{bmatrix} \lambda(\omega_D | \omega_D) & \lambda(\omega_D | \omega_H) \\ \lambda(\omega_H | \omega_D) & \lambda(\omega_H | \omega_H) \end{bmatrix} = \begin{bmatrix} 0 & 1 \\ 2 & 0 \end{bmatrix} \rightarrow$  víc penalizují, když je pacient nesprávně zařazen do třídy kontrolních subjektů ( $\omega_2$ ), než když je kontrolní subjekt nesprávně zařazen do třídy pacientů ( $\omega_1$ )
- např.  $\lambda = \begin{bmatrix} 0 & 2 \\ 1 & 0 \end{bmatrix} \rightarrow$  víc penalizují, když je kontrolní subjekt nesprávně zařazen do třídy pacientů ( $\omega_1$ ), než když je pacient nesprávně zařazen do třídy kontrolních subjektů ( $\omega_2$ )

# Bayesův kl. – kritérium minimální střední ztráty

Odvození kritéria minimální střední ztráty:

- Celková střední ztráta  $J(\mathbf{a})$  je průměrná hodnota z dílčích středních ztrát:

$$J(\mathbf{a}) = \int \sum_{s=1}^R \lambda(\omega_r | \omega_s) \cdot p(\mathbf{x} | \omega_s) \cdot P(\omega_s) d\mathbf{x}$$

- Chceme minimalizovat střední ztrátu:

$$J(\mathbf{a}^*) = \min_r \int \sum_{s=1}^R \lambda(\omega_r | \omega_s) \cdot p(\mathbf{x} | \omega_s) \cdot P(\omega_s) d\mathbf{x}$$

- Hledáme minimální střední ztrátu, pokud ale chceme využít principu diskriminačních funkcí, budeme hledat maximum z výrazu se záporným znaménkem  $\rightarrow$  diskriminační funkce potom bude tvaru:

$$g_r(\mathbf{x}) = - \sum_{s=1}^R \lambda(\omega_r | \omega_s) \cdot p(\mathbf{x} | \omega_s) \cdot P(\omega_s)$$

# Bayesův kl. – kritérium minimální střední ztráty

Diskriminační funkce obecně:  $g_r(\mathbf{x}) = - \sum_{s=1}^R \lambda(\omega_r|\omega_s) \cdot p(\mathbf{x}|\omega_s) \cdot P(\omega_s)$

Diskriminační funkce pro dichotomický klasifikátor:

$$g_1(\mathbf{x}) = -\lambda(\omega_1|\omega_1) \cdot p(\mathbf{x}|\omega_1) \cdot P(\omega_1) - \lambda(\omega_1|\omega_2) \cdot p(\mathbf{x}|\omega_2) \cdot P(\omega_2)$$

$$g_2(\mathbf{x}) = -\lambda(\omega_2|\omega_1) \cdot p(\mathbf{x}|\omega_1) \cdot P(\omega_1) - \lambda(\omega_2|\omega_2) \cdot p(\mathbf{x}|\omega_2) \cdot P(\omega_2)$$

Výpočet hranice pomocí diskriminačních funkcí:

$$g_1(\mathbf{x}) - g_2(\mathbf{x}) = 0$$

$$-\lambda(\omega_1|\omega_1) \cdot p(\mathbf{x}|\omega_1) \cdot P(\omega_1) - \lambda(\omega_1|\omega_2) \cdot p(\mathbf{x}|\omega_2) \cdot P(\omega_2) + \lambda(\omega_2|\omega_1) \cdot p(\mathbf{x}|\omega_1) \cdot P(\omega_1) + \lambda(\omega_2|\omega_2) \cdot p(\mathbf{x}|\omega_2) \cdot P(\omega_2) = 0$$

$$(\lambda(\omega_2|\omega_1) - \lambda(\omega_1|\omega_1)) \cdot p(\mathbf{x}|\omega_1) \cdot P(\omega_1) + (\lambda(\omega_2|\omega_2) - \lambda(\omega_1|\omega_2)) \cdot p(\mathbf{x}|\omega_2) \cdot P(\omega_2) = 0$$


$$(\lambda(\omega_2|\omega_1) - \lambda(\omega_1|\omega_1)) \cdot p(\mathbf{x}|\omega_1) \cdot P(\omega_1) = (\lambda(\omega_1|\omega_2) - \lambda(\omega_2|\omega_2)) \cdot p(\mathbf{x}|\omega_2) \cdot P(\omega_2)$$

$$\frac{p(\mathbf{x}|\omega_1)}{p(\mathbf{x}|\omega_2)} = \frac{(\lambda(\omega_1|\omega_2) - \lambda(\omega_2|\omega_2))P(\omega_2)}{(\lambda(\omega_2|\omega_1) - \lambda(\omega_1|\omega_1))P(\omega_1)} \rightarrow \text{kritérium minimální střední ztráty}$$

# Bayesův kl. – kritérium minimální střední ztráty

Celková střední ztráta v případě dvou tříd je:

$$\begin{aligned}
 J(\mathbf{a}) &= \int_{\mathcal{R}_1} \sum_{s=1}^2 \lambda(\omega_1|\omega_s) \cdot p(\mathbf{x}|\omega_s) \cdot P(\omega_s) d\mathbf{x} + \int_{\mathcal{R}_2} \sum_{s=1}^2 \lambda(\omega_2|\omega_s) \cdot p(\mathbf{x}|\omega_s) \cdot P(\omega_s) d\mathbf{x} = \\
 &= \lambda(\omega_1|\omega_1) \cdot P(\omega_1) \int_{\mathcal{R}_1} p(\mathbf{x}|\omega_1) \cdot d\mathbf{x} + \lambda(\omega_1|\omega_2) \cdot P(\omega_2) \int_{\mathcal{R}_1} p(\mathbf{x}|\omega_2) \cdot d\mathbf{x} + \\
 &+ \lambda(\omega_2|\omega_1) \cdot P(\omega_1) \int_{\mathcal{R}_2} p(\mathbf{x}|\omega_1) \cdot d\mathbf{x} + \lambda(\omega_2|\omega_2) \cdot P(\omega_2) \int_{\mathcal{R}_2} p(\mathbf{x}|\omega_2) \cdot d\mathbf{x} = \\
 &= \lambda(\omega_1|\omega_1) \cdot P(\omega_1) \cdot (1 - \alpha) + \lambda(\omega_1|\omega_2) \cdot P(\omega_2) \cdot \beta + \lambda(\omega_2|\omega_1) \cdot P(\omega_1) \cdot \alpha + \lambda(\omega_2|\omega_2) \cdot P(\omega_2) \cdot (1 - \beta)
 \end{aligned}$$



# Bayesův kl. – kritérium minimální střední ztráty

$$\frac{p(\mathbf{x}|\omega_D)}{p(\mathbf{x}|\omega_H)} = \frac{(\lambda(\omega_D|\omega_H) - \lambda(\omega_H|\omega_H))P(\omega_H)}{(\lambda(\omega_H|\omega_D) - \lambda(\omega_D|\omega_D))P(\omega_D)} \rightarrow \text{kritérium minimální střední ztráty}$$

## Pro náš příklad:

Levá strana je rovna:  $\frac{p(\mathbf{x}|\omega_D)}{p(\mathbf{x}|\omega_H)} = \frac{0,078}{0,056} = 1,4$

Pravá strana je při různém nastavení vah rovna:

- $\lambda = \begin{bmatrix} 0 & 1 \\ 2 & 0 \end{bmatrix}$  (tzn., více penalizují, pokud je pacient nesprávně zařazen do třídy kontrolních subjektů, než když je kontrolní subjekt nesprávně zařazen do třídy pacientů), pak pravá strana je rovna  $\frac{(1-0) \cdot 0,5}{(2-0) \cdot 0,5} = 0,5$  a subjekt zařadím do třídy pacientů.
- $\lambda = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix}$  (penalizují shodně nesprávné zařazení do třídy kontrolních subjektů i pacientů – kritérium minimální pravděpodobnosti chybného rozhodnutí), pak pravá strana je rovna  $\frac{(1-0) \cdot 0,5}{(1-0) \cdot 0,5} = 1$  a subjekt zařadím do třídy pacientů.
- $\lambda = \begin{bmatrix} 0 & 2 \\ 1 & 0 \end{bmatrix}$  (tzn., více penalizují, pokud je kontrolní subjekt nesprávně zařazen do třídy pacientů, než když je pacient nesprávně zařazen do třídy kontrolních subjektů), pak pravá strana je rovna  $\frac{(2-0) \cdot 0,5}{(1-0) \cdot 0,5} = 2$  a subjekt zařadím do třídy kontrolních subjektů.

# Bayesův kl. – kritérium minimální střední ztráty

- **Poznámka:** pokud nastavíme matici ztrátových funkcí ve tvaru  $\lambda = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix}$ , dostáváme kritérium minimální psti chybného rozhodnutí:

$$\frac{p(\mathbf{x}|\omega_D)}{p(\mathbf{x}|\omega_H)} = \frac{(\lambda(\omega_D|\omega_H) - \lambda(\omega_H|\omega_H))P(\omega_H)}{(\lambda(\omega_H|\omega_D) - \lambda(\omega_D|\omega_D))P(\omega_D)}$$

$$\frac{p(\mathbf{x}|\omega_D)}{p(\mathbf{x}|\omega_H)} = \frac{(1 - 0)P(\omega_H)}{(1 - 0)P(\omega_D)}$$

- $\frac{p(\mathbf{x}|\omega_D)}{p(\mathbf{x}|\omega_H)} = \frac{P(\omega_H)}{P(\omega_D)} \rightarrow$  kritérium minimální psti chybného rozhodnutí

# Bayesův klasifikátor – kritéria

---

- Kritérium maximální a posteriori pravděpodobnosti
- Kritérium minimální pravděpodobnosti chybného rozhodnutí
- Kritérium minimální střední ztráty
- **Kritérium maximální pravděpodobnosti**



# Bayesův kl. – kritérium maximální psti

- Předpoklady:
  - rovnoměrné zastoupení  $K$  tříd, tzn.  $P(\omega_D) = P(\omega_H) = \frac{1}{K} = \frac{1}{2} = 0,5$
  - nulové ztráty při správném rozhodnutí, tzn.  $\lambda(\omega_D|\omega_D) = \lambda(\omega_H|\omega_H) = 0$
- pak získáváme po dosazení do obecného vzorce pro výpočet věrohodnostního poměru:

$$\frac{p(\mathbf{x}|\omega_D)}{p(\mathbf{x}|\omega_H)} = \frac{(\lambda(\omega_D|\omega_H) - 0) \cdot 0,5}{(\lambda(\omega_H|\omega_D) - 0) \cdot 0,5}$$

- $\frac{p(\mathbf{x}|\omega_D)}{p(\mathbf{x}|\omega_H)} = \frac{\lambda(\omega_D|\omega_H)}{\lambda(\omega_H|\omega_D)} \rightarrow$  kritérium maximální pravděpodobnosti

# Bayesův kl. – kritérium maximální psti

$$\frac{p(\mathbf{x}|\omega_D)}{p(\mathbf{x}|\omega_H)} = \frac{\lambda(\omega_D|\omega_H)}{\lambda(\omega_H|\omega_D)} \rightarrow \text{kritérium maximální pravděpodobnosti}$$

## Pro náš příklad:

Levá strana je rovna:  $\frac{p(\mathbf{x}|\omega_D)}{p(\mathbf{x}|\omega_H)} = \frac{0,078}{0,056} = 1,4$

Pravá strana je při různém nastavení vah rovna:

- $\lambda = \begin{bmatrix} 0 & 1 \\ 2 & 0 \end{bmatrix}$  (tzn., více penalizuji, pokud je pacient nesprávně zařazen do třídy kontrolních subjektů, než když je kontrolní subjekt nesprávně zařazen do třídy pacientů), pak pravá strana je rovna  $\frac{1}{2} = 0,5$  a subjekt zařadím do třídy pacientů.
- $\lambda = \begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix}$  (penalizuji shodně nesprávné zařazení do třídy kontrolních subjektů i pacientů), pak pravá strana je rovna  $\frac{1}{1} = 1$  a subjekt zařadím do třídy pacientů.
- $\lambda = \begin{bmatrix} 0 & 2 \\ 1 & 0 \end{bmatrix}$  (tzn., více penalizuji, pokud je kontrolní subjekt nesprávně zařazen do třídy pacientů, než když je pacient nesprávně zařazen do třídy kontrolních subjektů), pak pravá strana je rovna  $\frac{2}{1} = 2$  a subjekt zařadím do třídy kontrolních subjektů.

# Bayesův klasifikátor – kritéria

- Kritérium maximální a posteriorní pravděpodobnosti:

$$\frac{P(\omega_D|\mathbf{x})}{P(\omega_H|\mathbf{x})} = 1$$

- Kritérium minimální pravděpodobnosti chybného rozhodnutí

$$\frac{p(\mathbf{x}|\omega_D)}{p(\mathbf{x}|\omega_H)} = \frac{P(\omega_H)}{P(\omega_D)}$$

- Kritérium minimální střední ztráty

$$\frac{p(\mathbf{x}|\omega_D)}{p(\mathbf{x}|\omega_H)} = \frac{(\lambda(\omega_D|\omega_H) - \lambda(\omega_H|\omega_H))P(\omega_H)}{(\lambda(\omega_H|\omega_D) - \lambda(\omega_D|\omega_D))P(\omega_D)}$$

- Kritérium maximální pravděpodobnosti

$$\frac{p(\mathbf{x}|\omega_D)}{p(\mathbf{x}|\omega_H)} = \frac{\lambda(\omega_D|\omega_H)}{\lambda(\omega_H|\omega_D)}$$

# 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“



MINISTERSTVO ŠKOLSTVÍ,  
MLÁDEŽE A TĚLOVÝCHOVY



OP Vzdělávání  
pro konkurenceschopnost

INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ