



# ANALÝZA A KLASIFIKACE BIOMEDICÍNSKÝCH DAT



**prof. Ing. Jiří Holčík, CSc.**

# III. PŘÍZNAKOVÁ KLASIFIKACE - ÚVOD

# PŘÍZNAKOVÝ POPIS

**Příznakový obraz**  $\mathbf{x}$  zpracovávaných dat je vyjádřen  $n$ -rozměrným (sloupcovým) vektorem hodnot  $x_i$ ,  $i=1,2,\dots,n$  příznakových proměnných (veličin) charakterizujících vlastnosti těchto dat, tj. platí

$$\mathbf{x} = (x_1, x_2, \dots, x_n)^T.$$

# PŘÍZNAKOVÝ POPIS

**Příznakové proměnné** mohou popisovat kvantitativní i kvalitativní vlastnosti souboru dat. Jejich hodnoty nazýváme příznaky.

Podle definičního oboru rozlišujeme proměnné:

- spojité
- nespojité, diskrétní, vyjmenovatelné
- logické, binární, alternativní, dichotomické

# PŘÍZNAKOVÝ POPIS

Vrchol každého příznakového vektoru (obrazu) představuje bod  $n$ -rozměrného prostoru  $\mathcal{X}^n$ , který nazýváme **obrazovým prostorem**.


Obrazový prostor je definován kartézským součinem definičních oborů všech příznakovým proměnných, tzn. že jej tvoří všechny možné obrazy zpracovávaného souboru dat.

# PŘÍZNAKOVÝ POPIS

Při vhodném výběru příznakových veličin je **podobnost** signálů jedné klasifikační třídy vyjádřena **blízkostí** jejich obrazů v obrazovém prostoru.

Vymezení klasifikační třídy:

- etalony - charakteristické reprezentativní obrazy
- hranice




# PŘÍZNAKOVÝ KLASIFIKÁTOR

**Příznakový klasifikátor** je stroj s tolika vstupy, kolik je příznaků a s jedním diskretním výstupem, který udává třídu, do které klasifikátor zařadil rozpoznávaný obraz.

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

$d(\mathbf{x})$  je skalární funkce vektorového argumentu  $\mathbf{x}$ , kterou nazýváme **rozhodovací pravidlo klasifikátoru**;

$\omega_r$  je **identifikátor klasifikační třídy**



# PŘÍZNAKOVÝ KLASIFIKÁTOR

- ☑ deterministický a nedeterministický
- ☑ s pevným a proměnným počtem příznaků
- ☑ bez učení a s učení




# PŘÍZNAKOVÝ KLASIFIKÁTOR

- ☑ deterministický a nedeterministický
- ☑ s pevným a proměnným počtem příznaků
- ☑ bez učení a s učení

Nadále se nějaký čas věnujme deterministickým klasifikátorům s pevným počtem příznaků.

# PŘÍZNAKOVÝ KLASIFIKÁTOR

- ☑ Obrazový prostor je rozhodovacím pravidlem rozdělen na  $R$  disjunktních prostorů  $\mathcal{R}_r$ ,  $r=1, \dots, R$ , přičemž každá podmnožina  $\mathcal{R}_r$  obsahuje ty obrazy  $\mathbf{x}$ , pro které je  $\omega_r = d(\mathbf{x})$ .
- ☑ Návrh rozhodovacího pravidla je základním problémem návrhu klasifikátoru.



# KLASIFIKACE PODLE DISKRIMINAČNÍCH FUNKCÍ

## DISKRIMINAČNÍ ANALÝZA

týká se obecně vztahu mezi kategoriální proměnnou a množinou vzájemně vázaných příznakových proměnných.


Konkrétně, předpokládejme že existuje konečný počet, řekněme  $R$ , různých a priori známých populací, kategorií, tříd nebo skupin, které označujeme  $\omega_r$ ,  $r=1, \dots, R$  a úkolem diskriminační analýzy je nalézt vztah, na základě kterého pro daný vektor příznaků popisujících konkrétní objekt tomuto vektoru přiřadíme hodnotu  $\omega_r$ .

# KLASIFIKACE PODLE DISKRIMINAČNÍCH FUNKCÍ

- ✓ hranice klasifikačních tříd definujeme pomocí  $R$  skalárních funkcí  $g_1(\mathbf{x}), g_2(\mathbf{x}), \dots, g_R(\mathbf{x})$  takových, že pro obraz  $\mathbf{x}$  z podmnožiny  $\mathcal{R}_r$  pro všechna  $r$  platí


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

- ✓ funkce  $g_r(\mathbf{x})$  mohou vyjadřovat např. míru výskytu obrazu  $\mathbf{x}$  patřícího do  $r$ -té klasifikační třídy v daném místě obrazového prostoru – nazýváme je **diskriminační funkce**




# KLASIFIKACE PODLE DISKRIMINAČNÍCH FUNKCÍ

- ☑ hranice mezi dvěma sousedními podmnožinami  $\mathcal{R}_r$  a  $\mathcal{R}_s$  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.




# BLOKOVÉ SCHÉMA KLASIFIKÁTORU POMOCÍ DISKRIMINAČNÍCH FUNKCÍ



# BLOKOVÉ SCHÉMA KLASIFIKÁTORU POMOCÍ DISKRIMINAČNÍCH FUNKCÍ

☑ u dichotomického klasifikátoru (dvě třídy) je

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




# KLASIFIKACE PODLE DISKRIMINAČNÍCH FUNKCÍ

- ☑ nejjednodušším tvarem diskriminační funkce je funkce lineární, která má tvar

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

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

- ☑ lineárně separabilní třídy






# KLASIFIKACE PODLE DISKRIMINAČNÍCH FUNKCÍ

## LINEÁRNĚ NESEPARABILNÍ TŘÍDY

- ☑ zachováme původní obrazový prostor a zvolíme nelineární diskriminační funkci
  - definovanou obecně
  - složenou po částech z lineárních úseků
- ☑ zobrazíme původní  $n$ -rozměrný obrazový prostor  $X^n$  nelineární transformací  $\Phi: X^n \rightarrow X^m$  do nového  $m$ -rozměrného prostoru  $X^m$ , obecně je  $m \neq n$ , tak, aby v novém prostoru byly klasifikační třídy lineárně separabilní a v novém prostoru použijeme lineární klasifikátor ( $\Phi$  převodník)



# KLASIFIKACE PODLE MINIMÁLNÍ VZDÁLENOSTI

- ☑ reprezentativní obrazy klasifikačních tříd - etalony
- ☑ je-li v obrazovém prostoru zadáno  $R$  poloh etalonů vektory  $\mathbf{x}_{1E}, \mathbf{x}_{2E}, \dots, \mathbf{x}_{RE}$ , zařadí klasifikátor podle minimální vzdálenosti klasifikovaný obraz  $\mathbf{x}$  do té třídy, jejíž etalon má od bodu  $\mathbf{x}$  minimální vzdálenost. Rozhodovací pravidlo je určeno vztahem

$$d(\mathbf{x}) = \|\mathbf{x}_{rE} - \mathbf{x}\| = \min_{\forall s} \|\mathbf{x}_{sE} - \mathbf{x}\|$$

# KLASIFIKACE PODLE MINIMÁLNÍ VZDÁLENOSTI


- ☑ uvažme případ dvou tříd reprezentovaných etalony  $\mathbf{x}_{1E} = (x_{11E}, x_{12E})$  a  $\mathbf{x}_{2E} = (x_{21E}, x_{22E})$  ve dvoupríznakovém euklidovském prostoru;
- ☑ vzdálenost mezi obrazem  $\mathbf{x} = (x_1, x_2)$  a libovolným z obou etalonů je pak definována

$$v(\mathbf{x}_{sE}, \mathbf{x}) = \|\mathbf{x}_{sE} - \mathbf{x}\| = \sqrt{(x_{s1E} - x_1)^2 + (x_{s2E} - x_2)^2}$$

- ☑ hledáme menší z obou vzdáleností, tj.  $\min_{s=1,2} v(\mathbf{x}_{sE}, \mathbf{x})$ , ale také  $\min_{s=1,2} v^2(\mathbf{x}_{sE}, \mathbf{x})$ ;

$$\begin{aligned} \min_{\forall s} v(\mathbf{x}_{sE}, \mathbf{x}) &\approx \min_{\forall s} v^2(\mathbf{x}_{sE}, \mathbf{x}) = \min_{\forall s} \left( (x_{s1E} - x_1)^2 + (x_{s2E} - x_2)^2 \right) = \\ &\min_{\forall s} \left( x_1^2 + x_2^2 - 2[x_{s1E}x_1 + x_{s2E}x_2 - (x_{s1E}^2 + x_{s2E}^2)/2] \right) \end{aligned}$$

# KLASIFIKACE PODLE MINIMÁLNÍ VZDÁLENOSTI



# KLASIFIKACE PODLE MINIMÁLNÍ VZDÁLENOSTI

- ☑ diskriminační kuželové plochy se protínají v parabole a její průmět do obrazové roviny je přímka definovaná vztahem


$$x_1(x_{11E} - x_{21E}) + x_2(x_{12E} - x_{22E}) - (x_{12E}^2 + x_{11E}^2 - x_{21E}^2 - x_{22E}^2)/2 = 0$$

Tato hraniční přímka mezi klasifikačními třídami je vždy kolmá na spojnici obou etalonů a tuto spojnici půlí



klasifikátor pracující na základě kritéria minimální vzdálenosti je ekvivalentní lineárnímu klasifikátoru s diskriminačními funkcemi.

# KLASIFIKACE PODLE MINIMÁLNÍ VZDÁLENOSTI



- ☑ Klasifikace podle minimální vzdálenosti s třídami reprezentovanými více etalony je ekvivalentní klasifikaci podle diskriminační funkce s po částech lineární hraniční plochou

# URČENÍ DISKRIMINAČNÍCH FUNKCÍ ZE STATISTICKÝCH VLASTNOSTÍ MNOŽINY OBRAZŮ

# ZÁKLADNÍ POJMY A PŘEDPOKLADY

- ✓ při řešení praktických úloh je třeba předpokládat, že obrazy signálů jsou ovlivněny víceméně náhodnými fluktuacemi zdroje signálu, v přenosové cestě, při předzpracování i analýze, které se nepodaří zcela eliminovat.
- ✓ ztrátová funkce  $\lambda(\omega_r|\omega_s)$  udává ztrátu při chybné klasifikaci obrazu ze třídy  $\omega_s$  do třídy  $\omega_r$ .
- ✓ matice ztrátových funkcí

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

- ✓ střední ztráta  $J(\mathbf{a})$  udává průměrnou ztrátu při chybné klasifikaci obrazu  $\mathbf{x}$



# KRITÉRIUM MINIMÁLNÍ STŘEDNÍ ZTRÁTY

- ☑ pokud se soustředíme na obrazy pouze ze třídy  $\omega_s$ , je střední ztráta dána průměrnou hodnotou z  $\lambda(d(\mathbf{x}, \mathbf{a})|\omega_s)$  vzhledem ke všem obrazům ze třídy  $\omega_s$ , tj.

$$J_s(\mathbf{a}) = \int \lambda(d(\mathbf{x}, \mathbf{a})|\omega_s) \cdot p(\mathbf{x}|\omega_s) d\mathbf{x}$$

kde  $p(\mathbf{x}|\omega_s)$  je podmíněná hustota  
pravděpodobnosti výskytu obrazu  $\mathbf{x}$  ve třídě  $\omega_s$

# KRITÉRIUM MINIMÁLNÍ STŘEDNÍ ZTRÁTY

- ☑ Celková střední ztráta  $J(\mathbf{a})$  je průměrná hodnota ze ztrát  $J_s(\mathbf{a})$

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

- ☑ nebo podle Bayesova vzorce (  $P(\omega_s | \mathbf{x}) \cdot p(\mathbf{x}) = p(\mathbf{x} | \omega_s) \cdot P(\omega_s)$  )

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

kde  $p(\mathbf{x})$  je hustota pravděpodobnosti výskytu obrazu  $\mathbf{x}$  v celém obrazovém prostoru a  $P(\omega_s | \mathbf{x})$  je podmíněná pravděpodobnost, že daný obraz patří do třídy  $\omega_s$  (tzv. a posteriorní pravděpodobnost třídy  $\omega_s$ ).

# KRITÉRIUM MINIMÁLNÍ STŘEDNÍ ZTRÁTY

- ☑ Návrh optimálního klasifikátoru, který by minimalizoval střední ztrátu, spočívá v nalezení takové množiny parametrů rozhodovacího pravidla  $\mathbf{a}^*$ , že platí

$$J(\mathbf{a}^*) = \min_{\mathbf{a}} J(\mathbf{a})$$

- ☑ Dosadíme-li za  $J(\mathbf{a})$  z předchozího vztahu, je

$$J(\mathbf{a}^*) = \min_{\mathbf{a}} \int_{\mathcal{X}} \sum_{s=1}^R \lambda(d(\mathbf{x}, \mathbf{a}) | \omega_s) \cdot p(\mathbf{x} | \omega_s) \cdot P(\omega_s) d\mathbf{x}$$

- ☑ Je-li ztrátová funkce  $\lambda(\omega_r | \omega_s)$  konstantní pro všechny obrazy z  $\omega_s$ , je dále

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

# KRITÉRIUM MINIMÁLNÍ STŘEDNÍ ZTRÁTY

- ☑ Označíme-li ztrátu při klasifikaci obrazu  $\mathbf{x}$  do třídy  $\omega_r$

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

tak po dosazení dostaneme

$$J(\mathbf{a}^*) = \int \min_r L_x(\omega_r) d\mathbf{x}$$

Úloha nalezení minima celkové střední ztráty se tak převedla na minimalizaci funkce  $L_x(\omega_r)$ . Optimální rozhodovací pravidlo  $d(\mathbf{x}, \mathbf{a}^*)$  podle kritéria minimální celkové střední ztráty je

$$L_x(d_{ME}(\mathbf{x}, \mathbf{a}^*)) = \min_r L_x(\omega_r)$$

# KRITÉRIUM MINIMÁLNÍ STŘEDNÍ ZTRÁTY

- ☑ Chceme-li využít principu diskriminačních funkcí

$$\min L_x(\omega_r) = \max(-L_x(\omega_r))$$


- ☑ Diskriminační funkci optimálního klasifikátoru podle kritéria minimální chyby pak definujeme

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

# KRITÉRIUM MINIMÁLNÍ STŘEDNÍ ZTRÁTY DICHOTOMICKÝ KLASIFIKÁTOR

Celková střední ztráta v případě dvou tříd je

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



# KRITÉRIUM MINIMÁLNÍ STŘEDNÍ ZTRÁTY DICHOTOMICKÝ KLASIFIKÁTOR

Diskriminační funkce pro dichotomický klasifikátor bude

$$\begin{aligned}g(\mathbf{x}) &= g_1(\mathbf{x}) - g_2(\mathbf{x}) = -L_{\mathbf{x}}(\omega_1) + L_{\mathbf{x}}(\omega_2) = \\&= -\lambda(\omega_1|\omega_1) \cdot p(\mathbf{x}|\omega_1) \cdot P(\omega_1) - \lambda(\omega_1|\omega_2) \cdot p(\mathbf{x}|\omega_2) \cdot P(\omega_2) + \\&+ \lambda(\omega_2|\omega_1) \cdot p(\mathbf{x}|\omega_1) \cdot P(\omega_1) + \lambda(\omega_2|\omega_2) \cdot p(\mathbf{x}|\omega_2) \cdot P(\omega_2) = \\&= (\lambda(\omega_2|\omega_1) - \lambda(\omega_1|\omega_1)) \cdot p(\mathbf{x}|\omega_1) \cdot P(\omega_1) + (\lambda(\omega_2|\omega_2) - \lambda(\omega_1|\omega_2)) \cdot p(\mathbf{x}|\omega_2) \cdot P(\omega_2)\end{aligned}$$

Položíme-li tento výraz nule dostaneme vztah pro hraniční plochu dichotomického klasifikátoru, ze kterého můžeme určit poměr hustot pravděpodobnosti výskytu obrazu  $\mathbf{x}$  v každé z obou klasifikačních tříd - **věrohodnostní poměr**

$$\Lambda_{12} = \frac{p(\mathbf{x}|\omega_1)}{p(\mathbf{x}|\omega_2)} = \frac{(\lambda(\omega_1|\omega_2) - \lambda(\omega_2|\omega_2)) \cdot P(\omega_2)}{(\lambda(\omega_2|\omega_1) - \lambda(\omega_1|\omega_1)) \cdot P(\omega_1)}$$

Obraz  $\mathbf{x}$  zařadíme do třídy  $\omega_1$ , když je věrohodnostní poměr větší než výraz na pravé straně, je-li menší pak obraz  $\mathbf{x}$  zařadíme do třídy  $\omega_2$ .

# KRITÉRIUM MINIMÁLNÍ PRAVDĚPODOBNOTI CHYBNÉHO ROZHODNUTÍ

Díky obtížnému stanovení hodnot ztrátových funkcí  $\lambda(\omega_r|\omega_s)$  se kritérium minimální chyby zjednodušuje použitím jednotkových ztrátových funkcí definovaných

$$\lambda(\omega_r|\omega_s) = \begin{cases} 0 & \text{pro } r = s \\ 1 & \text{pro } r \neq s \end{cases}$$

Matrice jednotkových ztrátových funkcí má pak tvar

$$\lambda = \begin{bmatrix} 0 & 1 & \dots & 1 \\ 1 & 0 & \dots & 1 \\ \vdots & \vdots & \ddots & \vdots \\ 1 & 1 & \dots & 0 \end{bmatrix}$$

a celková ztráta je

$$J(\mathbf{a}) = \sum_{\substack{s=1 \\ s \neq r}}^R \int_{X - \mathcal{R}_s} p(\mathbf{x}|\omega_s) \cdot P(\omega_s) d\mathbf{x}$$

což je hodnota pravděpodobnosti chybného rozhodnutí.



# KRITÉRIUM MINIMÁLNÍ PRAVDĚPODOBNOTI CHYBNÉHO ROZHODNUTÍ

Dosadíme-li hodnoty jednotkových ztrátových funkcí do vztahu pro ztrátu při klasifikaci obrazu do chybné třídy

$$L_{\mathbf{x}}(\omega_r) = \sum_{\substack{s=1 \\ s \neq r}}^R p(\mathbf{x}|\omega_r) \cdot P(\omega_s) = \sum_{s=1}^R p(\mathbf{x}|\omega_s) \cdot P(\omega_s) - p(\mathbf{x}|\omega_r) \cdot P(\omega_r)$$

a s využitím Bayesova vztahu

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

$p(\mathbf{x})$  nezávisí na klasifikační třídě a tedy neovlivňuje výběr minima.

Diskriminační funkci tedy můžeme určit jako

$$g(\mathbf{x}) = p(\mathbf{x}|\omega_r) \cdot P(\omega_r)$$

# KRITÉRIUM MINIMÁLNÍ PRAVDĚPODOBNOTI CHYBNÉHO ROZHODNUTÍ

V případě dichotomického klasifikátoru je diskriminační funkce

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

A věrohodnostní poměr je potom

$$\Lambda_{12} = \frac{p(\mathbf{x}|\omega_1)}{p(\mathbf{x}|\omega_2)} = \frac{P(\omega_2)}{P(\omega_1)}$$

# KRITÉRIUM MAXIMÁLNÍ APOSTERIORNÍ PRAVDĚPODOBNOSTI

- ✓ Modifikujeme-li vztah pro ztrátu při chybné klasifikaci obrazu podle Bayesova vztahu (  $P(\omega_s|\mathbf{x}).p(\mathbf{x}) = p(\mathbf{x}|\omega_s).P(\omega_s)$  ) platí

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

- ✓ Hustota pravděpodobnosti  $p(\mathbf{x})$  nezávisí na klasifikační třídě a tedy místo  $L_x(\omega_r)$  lze použít

$$L'_x(\omega_r) = \frac{L_x(\omega_r)}{p(\mathbf{x})} = \sum_{s=1}^R \lambda(\omega_r|\omega_s).P(\omega_s|\mathbf{x})$$

a s jednotkovými ztrátovými funkcemi je

$$L'_x(\omega_r) = \sum_{\substack{s=1 \\ s \neq r}}^R P(\omega_s|\mathbf{x}) = \sum_{s=1}^R P(\omega_s|\mathbf{x}) - P(\omega_r|\mathbf{x}) = 1 - P(\omega_r|\mathbf{x})$$

# KRITÉRIUM MAXIMÁLNÍ APOSTERIORNÍ PRAVDĚPODOBNOTI

- ☑ Minimum ztráty  $L'_x(\omega_r)$  je právě tehdy, když  $P(\omega_r|\mathbf{x})$  je maximální. Tzn. že jako diskriminační funkci můžeme zvolit právě hodnotu aposteriorní pravděpodobnosti třídy  $\omega_r$ , tj.

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

- ☑ Pro případ dichotomického klasifikátoru je diskriminační funkce

$$g(\mathbf{x}) = P(\omega_1|\mathbf{x}) - P(\omega_2|\mathbf{x}) = 0.$$

Z toho plyne, že hranicí mezi třídami určuje vztah

$$P(\omega_1|\mathbf{x}) = P(\omega_2|\mathbf{x})$$

nebo

$$\frac{P(\omega_1|\mathbf{x})}{P(\omega_2|\mathbf{x})} = 1$$

Podle tohoto kritéria zařídíme obraz do té třídy, jejíž aposteriorní pravděpodobnost je při výskytu obrazu  $\mathbf{x}$  větší.

# KRITÉRIUM MAXIMÁLNÍ PRAVDĚPODOBNOTI (MINIMAX)

Neznáme-li apriorní pravděpodobnosti všech tříd, předpokládáme rovnoměrné rozložení (pravděpodobnost všech tříd je táž ( $P(\omega_s) = P(\omega) = 1/R$ ). Potom celková střední ztráta

$$J(\mathbf{a}) = \frac{1}{R} \sum_{s=1}^R \int_{\mathcal{X}} \lambda(\omega_r | \omega_s) \cdot p(\mathbf{x} | \omega_s) d\mathbf{x}$$

dosáhne minima, když

$$J(\mathbf{a}^*) = \frac{1}{R} \min_{\forall \mathbf{a}} \int_{\mathcal{X}} \sum_{s=1}^R \lambda(\omega_r | \omega_s) \cdot p(\mathbf{x} | \omega_s) d\mathbf{x}$$

Diskriminační funkci lze jako v předchozích případech definovat jako

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

# KRITÉRIUM MAXIMÁLNÍ PRAVDĚPODOBNOСТИ (MINIMAX)

- ✓ V případě dichotomie je věrohodnostní poměr

$$\Lambda_{12} = \frac{p(\mathbf{x}|\omega_1)}{p(\mathbf{x}|\omega_2)} = \frac{(\lambda(\omega_1|\omega_2) - \lambda(\omega_2|\omega_2))}{(\lambda(\omega_2|\omega_1) - \lambda(\omega_1|\omega_1))}$$

- ✓ Pokud jsou ceny správného rozhodnutí nulové, tj.  $\lambda(\omega_1|\omega_1) = \lambda(\omega_2|\omega_2) = 0$ , je

$$\Lambda_{12} = \frac{p(\mathbf{x}|\omega_1)}{p(\mathbf{x}|\omega_2)} = \frac{(\lambda(\omega_1|\omega_2))}{(\lambda(\omega_2|\omega_1))}$$

- ✓ Obraz je zařazen do třídy  $\omega_1$ , když je věrohodnostní poměr než poměr cen ztrát chybných zatřídění. Jsou-li obě ceny stejné, je obraz zařazen do té třídy, pro kterou je hodnota  $p(\mathbf{x}|\omega_s)$  větší.

# KRITÉRIUM MAXIMÁLNÍ PRAVDĚPODOBNOTI (MINIMAX)

