



ANALÝZA A KLASIFIKACE 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 diskrétním 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**;

ω_r je **identifikátor klasifikační třídy**



PŘÍZNAKOVÝ KLASIFIKÁTOR

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


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

- ✓ 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 s 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.



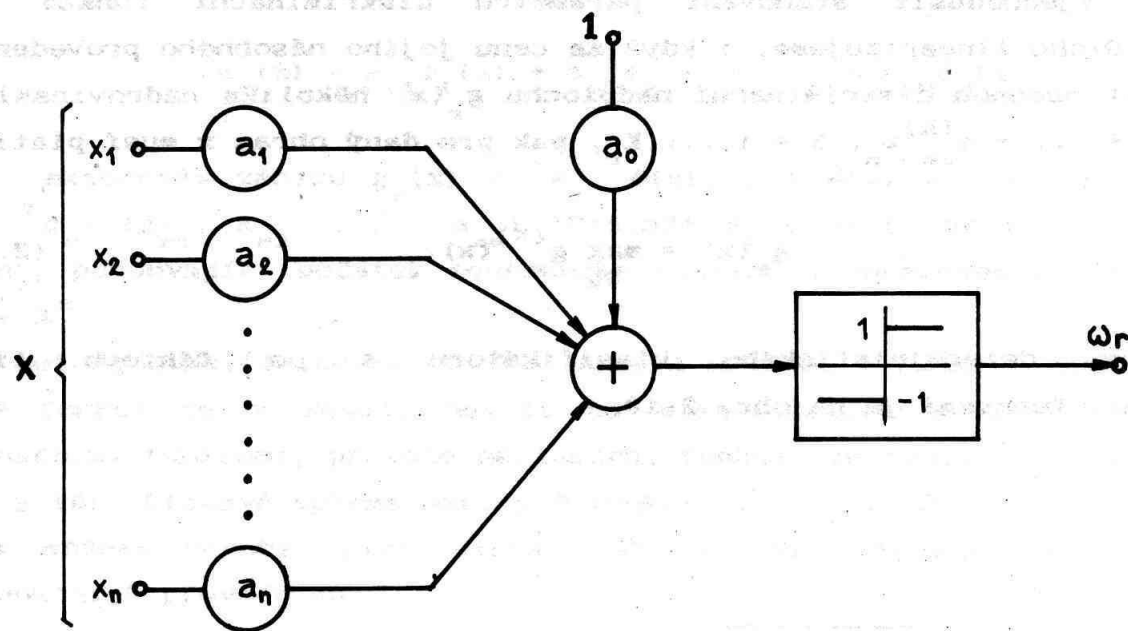
BLOKOVÉ SCHÉMA KLASIFIKÁTORU POMOCÍ DISKRIMINAČNÍCH FUNKCÍ



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 (Φ 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

$$d(\mathbf{x}) = \underset{r \in E}{\text{arg min}} \|\mathbf{x} - \mathbf{x}_{rE}\|$$

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 dvoupříznakovém euklidovském prostoru;
- ☑ vzdálenost mezi obrazem $\mathbf{x} = (x_1, x_2)$ a libovolným z obou etalonů je pak definována

$$v(\mathbf{x}_{sE}, \mathbf{x}) = \sqrt{(x_{sE1} - x_1)^2 + (x_{sE2} - x_2)^2}$$

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

$$\min_{\mathbf{x}} v(\mathbf{x}_{sE}, \mathbf{x}) \approx \min_{\mathbf{x}} v^2(\mathbf{x}_{sE}, \mathbf{x}) = \min_{\mathbf{x}} \left[(x_{sE1} - x_1)^2 + (x_{sE2} - x_2)^2 \right] = \min_{\mathbf{x}} \left[(x_1 - x_{sE1})^2 + (x_2 - x_{sE2})^2 \right]$$

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 ω_s do třídy ω_r .

- ✓ matice ztrátových funkcí

$$\mathbf{\Lambda} = \begin{bmatrix} \lambda \begin{pmatrix} 1 & 1 \\ 2 & 1 \\ \vdots & \vdots \end{pmatrix} & \lambda \begin{pmatrix} 1 & 2 \\ 2 & 2 \\ \vdots & \vdots \end{pmatrix} & \cdots & \lambda \begin{pmatrix} 1 & R \\ 2 & R \\ \vdots & \vdots \end{pmatrix} \\ \lambda \begin{pmatrix} R & 1 \\ R & 2 \\ \vdots & \vdots \end{pmatrix} & \lambda \begin{pmatrix} R & 2 \\ R & 2 \\ \vdots & \vdots \end{pmatrix} & \cdots & \lambda \begin{pmatrix} R & R \\ R & R \\ \vdots & \vdots \end{pmatrix} \end{bmatrix}^i$$

- ✓ 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 ω_s , je střední ztráta dána průměrnou hodnotou z $\lambda(d(\mathbf{x}, \mathbf{a}) | \omega_s)$ vzhledem ke všem obrazům ze třídy ω_s , tj.

$$J_s(\mathbf{a}) = \int_{\mathcal{X}} d(\mathbf{x}, \mathbf{a}) p(\mathbf{x} | \omega_s) d\mathbf{x}$$

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

KRITÉRIUM MINIMÁLNÍ STŘEDNÍ ZTRÁTY

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

$$J(\mathbf{a}) = \sum_{s=1}^D P(\omega_s) \sum_{\mathbf{x} \in \mathcal{X}} J_s(\mathbf{a}) p(\mathbf{x} | \omega_s)$$

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

$$J(\mathbf{a}) = \sum_{\mathbf{x} \in \mathcal{X}} J(\mathbf{a} | \omega_s) P(\omega_s | \mathbf{x}) p(\mathbf{x})$$

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 ω_s (tzv. a posteriori pravděpodobnost třídy ω_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

$$J(\mathbf{a}^*) = \int_{\mathcal{X}} \sum_{\omega \in \Omega} \lambda(\omega_r | \omega_s) \mathbf{1}(\mathbf{a}(\omega) \neq \omega) p(\omega) d\mathbf{x}$$

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

$$J(\mathbf{a}^*) = \int_{\mathcal{X}} \sum_{\omega \in \Omega} \lambda(\omega_r | \omega_s) \mathbf{1}(\mathbf{a}(\omega) \neq \omega) p(\omega) d\mathbf{x}$$

KRITÉRIUM MINIMÁLNÍ STŘEDNÍ ZTRÁTY

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

$$L_{\mathbf{x}}(\omega_r) = \sum_{s=1}^R \lambda(r, s) p(\mathbf{x} | \omega_s) R_{\omega_s}$$

tak po dosazení dostaneme

$$J(\mathbf{a}^*) = \int_{\mathcal{X}} L_{\mathbf{x}}(\omega_r) p(\mathbf{x}) d\mathbf{x}$$

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

$$L_{\mathbf{x}}(d(\mathbf{x}, \mathbf{a}^*)) = \min_{\omega_r} L_{\mathbf{x}}(\omega_r)$$

KRITÉRIUM MINIMÁLNÍ STŘEDNÍ ZTRÁTY

- ☑ Chceme-li využít principu diskriminačních funkcí

$$\min_{\omega} L_{\mathbf{x}}(\omega) = \int_{\mathcal{R}} \ell(\mathbf{x}, \omega) p(\mathbf{x}) d\mathbf{x}$$


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

$$g(\mathbf{x}) = \underset{\omega}{\operatorname{arg\,min}} L_{\mathbf{x}}(\omega) = \underset{\omega}{\operatorname{arg\,min}} \int_{\mathcal{R}} \ell(\mathbf{x}, \omega) p(\mathbf{x}) d\mathbf{x}$$

KRITÉRIUM MINIMÁLNÍ STŘEDNÍ ZTRÁTY DICHOTOMICKÝ KLASIFIKÁTOR

Celková střední ztráta v případě dvou tříd je

$$\begin{aligned}
 J(a) &= \int_{R_1} p(x|\omega_1) \sum_{j=1}^2 \omega_j \min_{i=1,2} |x - \dot{x}_i| + \int_{R_2} p(x|\omega_2) \sum_{j=1}^2 \omega_j \min_{i=1,2} |x - \dot{x}_i| \\
 &= \omega_1 \int_{R_1} p(x|\omega_1) \sum_{j=1}^2 \omega_j \min_{i=1,2} |x - \dot{x}_i| + \omega_2 \int_{R_1} p(x|\omega_2) \sum_{j=1}^2 \omega_j \min_{i=1,2} |x - \dot{x}_i| \\
 &+ \omega_1 \int_{R_2} p(x|\omega_1) \sum_{j=1}^2 \omega_j \min_{i=1,2} |x - \dot{x}_i| + \omega_2 \int_{R_2} p(x|\omega_2) \sum_{j=1}^2 \omega_j \min_{i=1,2} |x - \dot{x}_i| \\
 &= \omega_1 \int_{R_1} p(x|\omega_1) \sum_{j=1}^2 \omega_j \min_{i=1,2} |x - \dot{x}_i| + \omega_2 \int_{R_1} p(x|\omega_2) \sum_{j=1}^2 \omega_j \min_{i=1,2} |x - \dot{x}_i| \\
 &+ \omega_1 \int_{R_2} p(x|\omega_1) \sum_{j=1}^2 \omega_j \min_{i=1,2} |x - \dot{x}_i| + \omega_2 \int_{R_2} p(x|\omega_2) \sum_{j=1}^2 \omega_j \min_{i=1,2} |x - \dot{x}_i|
 \end{aligned}$$



KRITÉRIUM MINIMÁLNÍ STŘEDNÍ ZTRÁTY DICHOTOMICKÝ KLASIFIKÁTOR

Diskriminační funkce pro dichotomický klasifikátor bude

$$g(\mathbf{x}) = \frac{1}{n} \sum_{\omega_1} (\mathbf{x} - \mathbf{x}_{\omega_1})^T (\mathbf{x} - \mathbf{x}_{\omega_2}) = \frac{1}{n} \sum_{\omega_1} (\mathbf{x} - \mathbf{x}_{\omega_1})^T (\mathbf{x} - \mathbf{x}_{\omega_2}) + \frac{1}{n} \sum_{\omega_2} (\mathbf{x} - \mathbf{x}_{\omega_1})^T (\mathbf{x} - \mathbf{x}_{\omega_2})$$

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**

$$\Lambda = \frac{n(\mathbf{x} - \mathbf{x}_{\omega_1})^T (\mathbf{x} - \mathbf{x}_{\omega_2})}{n(\mathbf{x} - \mathbf{x}_{\omega_2})^T (\mathbf{x} - \mathbf{x}_{\omega_1})}$$

Obraz \mathbf{x} zařadíme do třídy ω_1 , když je věrohodnostní poměr větší než výraz na pravé straně, je-li menší pak obraz \mathbf{x} zařadíme do třídy ω_2 .

VĚROHODNOSTNÍ POMĚR I.

- ✓ Sumarizuje veškerou informaci získanou experimentem.
- ✓ Pravděpodobnost, že jev (data) nastane za daných podmínek (hypotéza) děleno pravděpodobností, že stejný jev nastane za jiných podmínek. Podmínky jsou vzájemně se vylučující.

VĚROHODNOSTNÍ POMĚR II.

Věrohodnostní poměr (*likelihood ratio*) LR udává podíl pravděpodobnosti, že se vyskytne nějaký jev A za určité podmínky (jev B), k pravděpodobnosti, že se jev A vyskytne, když podmínka neplatí (jev $\text{non}B$). Má-li například pacient náhlou ztrátu paměti (jev A), chceme znát věrohodnostní poměr výskytu jevu A v případě, že má mozkový nádor (jev B), tj. podíl pravděpodobnosti, s jakou ztráta paměti vzniká při nádoru mozku, k pravděpodobnosti, s jakou vzniká v ostatních případech. Věrohodnostní poměr je tedy podíl podmíněných pravděpodobností

$$LR = \frac{P(A|B)}{P(A|\text{non}B)}$$

KRITÉRIUM MINIMÁLNÍ PRAVDĚPODOBNOSTI CHYBNÉHO ROZHODNUTÍ

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

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

Matrice jednotkových ztrátových funkcí má pak tvar

$$\Lambda = \begin{pmatrix} 0 & 1 & \dots & 1 \\ 1 & 0 & \dots & 1 \\ \vdots & \vdots & \ddots & \vdots \\ 1 & 1 & \dots & 0 \end{pmatrix}$$

a celková ztráta je

$$J(\mathbf{a}) = \sum_{s=1}^S \int_{\mathcal{X}} \rho(\mathbf{x}|\omega_s) R(\omega_s) d\mathbf{x}$$

což je hodnota pravděpodobnosti chybného rozhodnutí.

KRITÉRIUM MINIMÁLNÍ PRAVDĚPODOBNOSTI CHYBNÉHO ROZHODNUTÍ

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

$$L_{\mathbf{x}}(\omega) = \sum_{s=1}^R p(\mathbf{x}_{\omega}) R_{\omega s} = \sum_{s=1}^R p(\mathbf{x}_{\omega s}) R_{\omega s} = p(\mathbf{x}_{\omega}) R_{\omega \omega}$$

a s využitím Bayešova vztahu

$$L_{\mathbf{x}}(\omega) = \sum_{s=1}^R p(\mathbf{x}_{\omega}) R_{\omega s} = p(\mathbf{x}_{\omega}) R_{\omega \omega}$$

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

Diskriminační funkci tedy můžeme určit jako

$$g(\mathbf{x}) = \mathbf{x}_{\omega} - \mathbf{x}_{\omega}$$

KRITÉRIUM MINIMÁLNÍ PRAVDĚPODOBNOSTI CHYBNÉHO ROZHODNUTÍ

V případě dichotomického klasifikátoru je diskriminační funkce

$$g(\mathbf{x}) = \mathbf{x}^T \boldsymbol{\omega} - \omega$$

A věrohodnostní poměr je potom

$$\Lambda = \frac{\sum_{\omega} \mathbf{x}^T \boldsymbol{\omega}}{\sum_{\omega} \boldsymbol{\omega}}$$

KRITÉRIUM MAXIMÁLNÍ APOSTERIORNÍ PRAVDĚPODOBNOTI

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

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

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

$$L'_{\mathbf{x}}(\omega_r) = \frac{L_{\mathbf{x}}(\omega_r)}{p(\mathbf{x})} = \sum_{s=1}^R \lambda(r, s) P(\omega_s|\mathbf{x})$$

a s jednotkovými ztrátovými funkcemi je

$$L'_{\mathbf{x}}(\omega_r) = \sum_{s=1}^R \lambda(r, s) P(\omega_s|\mathbf{x}) = \sum_{s=1}^R \delta_{rs} P(\omega_s|\mathbf{x}) = P(\omega_r|\mathbf{x})$$

KRITÉRIUM MAXIMÁLNÍ APOSTERIORNÍ PRAVDĚPODOBNOSTI

- ☑ 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 ω_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

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

Podle tohoto kritéria zatřídíme 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

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

dosáhne minima, když

$$J(\mathbf{a}^*) = \frac{1}{R} \min_{\mathbf{a}} \sum_{s=1}^R \int \lambda(r, s) p(\mathbf{x} | \omega_s) d\mathbf{x}$$

Diskriminační funkci lze jako v předchozích případech definovat jako

$$g(\mathbf{x}) = L_{\mathbf{x}}(\omega_r) : \sum_{s=1}^R \lambda(r, s) p(\mathbf{x} | \omega_s)$$

KRITÉRIUM MAXIMÁLNÍ PRAVDĚPODOBNOTI (MINIMAX)

- ☑ V případě dichotomie je věrohodnostní poměr

$$\Lambda = \frac{p(\mathbf{x}|\omega_1)}{p(\mathbf{x}|\omega_2)} = \frac{c_1}{c_2}$$

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

$$\Lambda = \frac{p(\mathbf{x}|\omega_1)}{p(\mathbf{x}|\omega_2)} = \frac{c_1}{c_2}$$

- ☑ Obraz je zařazen do třídy ω_1 , když je věrohodnostní poměr než poměr cen ztratit chybných zařídění. 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)

