

Moderní metody diskriminační analýzy

3) Neparametrická diskriminační analýza

skutečné hustoty n_j -lé stupně $P_j(x)$ obecně neznáme \rightarrow odhadneme je z matic (trénovacích) dat $\leadsto \widehat{P_j(x)}$ - jádrový odhad p -rozměrné hustoty

• Měření hustoty jsou p -rozměrné \rightarrow problém ve více dimenzích (problemi dimensionalit)

Bayesovo rozhodovací pravidlo: x^* zařadí do třídy $\operatorname{argmax}_{j=1, \dots, J} \pi_j \cdot \widehat{P_j(x^*)}$.

4) Metoda k nejbližších sousedů (k NN)

- zvolíme vhodnou metrickou a počet nejbližších sousedů $k \in \mathbb{N}$

Bayesovo pravidlo: $\operatorname{argmax}_{j=1, \dots, J} \widehat{\pi_j} \cdot \widehat{P_j(x^*)} = \operatorname{argmax}_{j=1, \dots, J} \frac{m_j}{m} \cdot \frac{k_j}{m_j} = \operatorname{argmax}_{j=1, \dots, J} k_j$
konst.

$\widehat{\pi_j} = \frac{m_j}{m}$, $\widehat{P_j(x^*)} = \frac{k_j}{m_j}$
 k_j \leftarrow počet pozorování ve třídě j mezi k nejbližšími sousedy x^
 m_j \leftarrow počet pozorování ve třídě j*

5) Diskriminační analýza založená na hloubce dat

- hloubka dat = zohlednění kvantitativní a pořadí ve stejných dimenzích

• Poloparametrická (Tuleyho) hloubka bodu x vzhledem k dat. souboru X : $d(x, X) = \min_{\|u\|=1} \frac{1}{m} \left| \{i : x_i^T u \leq x^T u, i=1, \dots, m\} \right|$

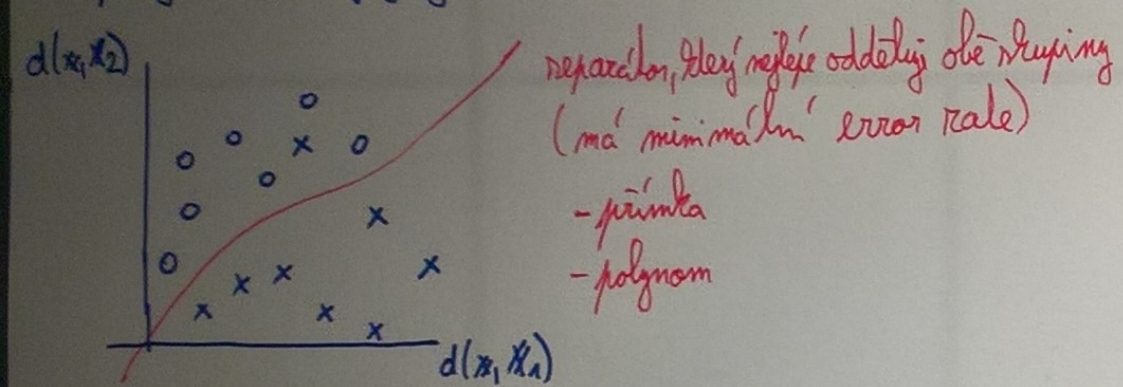
• Mahalanobisova hloubka: $d(x, X) = \frac{1}{1 + (x - \hat{\mu})^T \hat{\Sigma}^{-1} (x - \hat{\mu})}$
 *kde $\hat{\mu}$ je střední průměr
 $\hat{\Sigma}$ je střední kovarianční matice*

Klasifikátor maximální hloubky:

x^* patří do třídy argmax $\prod_j d(x^*, X_j)$, kde X_j je datová matice obsahující pozorování ze skupiny j .

necht $J=2$ (2 skupiny)

DD platí 2-rozměrný graf $[d(x, X_1), d(x, X_2)]$ pro všechny body x z datového souboru



DDd - klasifikátor: rozšíříme hloubkový protokol pro polynom do řádu r („kromě jiných čísel, které vedou k minimalizaci pravid. chyby klasifikace“)

že klasifikátor se vezme lineární kombinací výše uvedených protokolů.

outlier = bod, který má nulovou hloubku vůči oběma skupinám (speciální zacházení)

Pro více skupin ($J > 2$): uvažujeme všechny dvojice a vybereme některou z výsledků

6.) DA měří (míra DA)

$P_j(x)$ je měří Bernsteinův rozklad

$P_j(x)$ je hustota

$$\sum_{g=1}^{K_j} \pi_{jg} \cdot \underbrace{N_p(\mu_{jg}, \Sigma)}_{\text{prototyp}}$$

↑
velký měří

$$0 < \pi_{jg} < 1 \quad \pi_{j1} + \pi_{j2} + \dots + \pi_{jK_j} = 1 \quad K_j$$

$K_j =$ počet prototypů (zvané)

Bayesovské rozhodovací pravidlo - EM algoritmus

7. Regularizovaná DA

- kompromis mezi LDA a QDA

$P_j(x)$ je hustota $N_p(\hat{\mu}_j, \hat{\Sigma}_j(\lambda))$

$$\hat{\Sigma}_j(\lambda) = (1-\lambda) \hat{\Sigma}_j + \lambda \cdot \hat{\Sigma}$$

případně rovněž $\hat{\Sigma}_j(\lambda, \gamma_j) = (1-\gamma_j) \hat{\Sigma}_j(\lambda) + \frac{\gamma_j}{p} \cdot \text{tr}(\hat{\Sigma}_j(\lambda)) \cdot \mathbb{I}_p$.

označíme $\hat{\Sigma}_1, \dots, \hat{\Sigma}_J$ symetrické kovarianční matice

$$\hat{\Sigma} = \frac{1}{m-J} \left(m_1 \hat{\Sigma}_1 + m_2 \hat{\Sigma}_2 + \dots + m_J \hat{\Sigma}_J \right)$$