

Analýza a klasifikace dat – přednáška 5



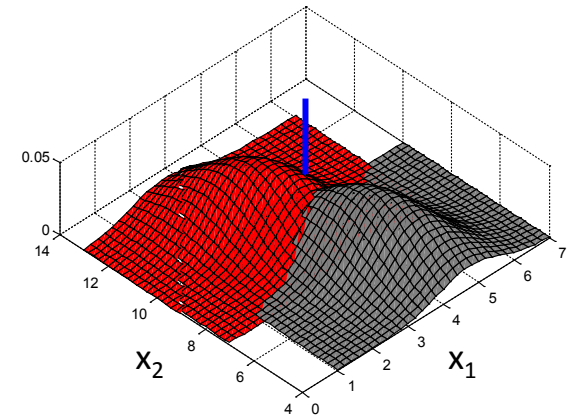
RNDr. Eva Janoušová

Podzim 2014

Typy klasifikátorů – podle principu klasifikace

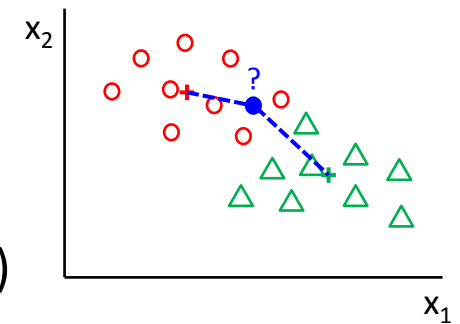
- **klasifikace pomocí diskriminačních funkcí:**

- diskriminační funkce určují míru příslušnosti k dané klasifikační třídě
- pro danou třídu má daná diskriminační funkce nejvyšší hodnotu



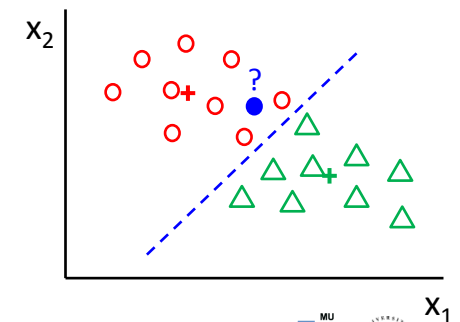
- **klasifikace pomocí vzdálenosti od etalonů klasif. tříd:**

- 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)



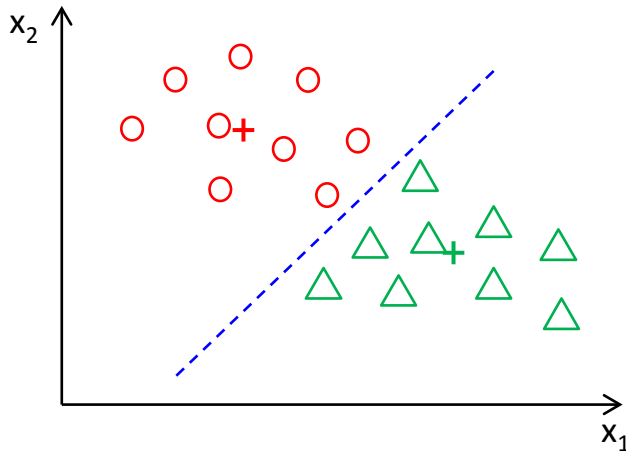
- **klasifikace pomocí hranic v obrazovém prostoru:**

- stanovení hranic (hraničních ploch) oddělujících klasifikační třídy

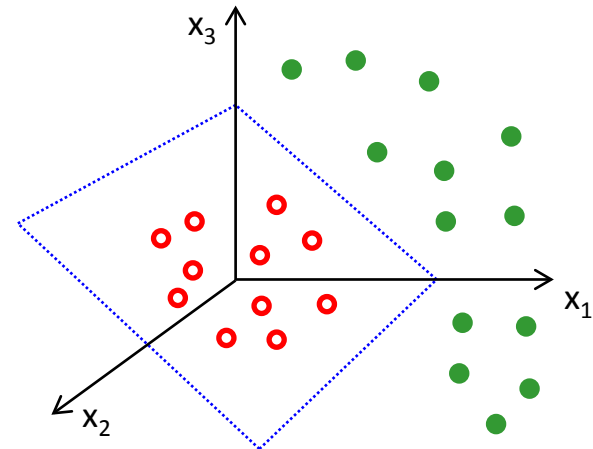


Motivace

2-rozměrný prostor



3-rozměrný prostor



Hranice je nadplocha o rozměru o jedna menší než je rozměr prostoru

- ve 2-rozměrném prostoru je hranicí křivka (v lineárním případě přímka)
- v 3-rozměrném prostoru plocha (v lineárním případě rovina)

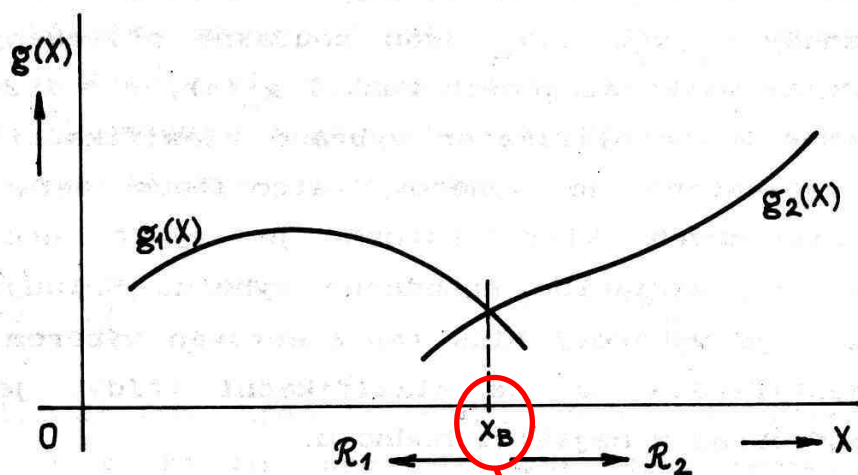
Hranice je tedy dána rovnicí: $h(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + w_0 = 0$

Výpočet hranice různými metodami (např. Fisherova LDA, SVM apod. – viz dále)

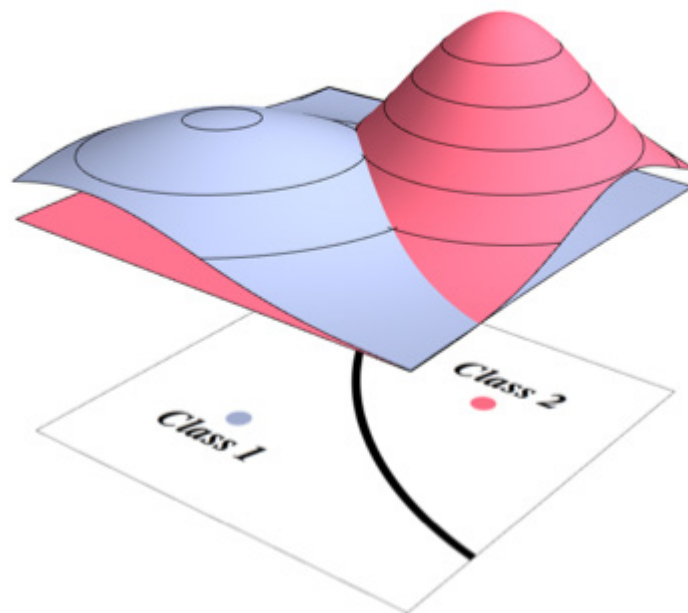
Souvislost klasifikace pomocí diskriminačních funkcí s klasifikací pomocí hranic

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, tzn.: $h(\mathbf{x}) = g_1(\mathbf{x}) - g_2(\mathbf{x}) = 0$

např. u Bayesova klasifikátoru: $h(\mathbf{x}) = P(\omega_D|\mathbf{x}) - P(\omega_H|\mathbf{x}) = 0$



hraniční bod



Souvislost klasifikace podle minimální vzdálenosti s klasifikací pomocí hranic

- zařazení objektu \mathbf{x} do té třídy, jejíž etalon má od bodu \mathbf{x} minimální vzdálenost – tzn. $d(\mathbf{x}) = \|\mathbf{x}_{rE} - \mathbf{x}\| = \min_{\forall s} \|\mathbf{x}_{sE} - \mathbf{x}\|$

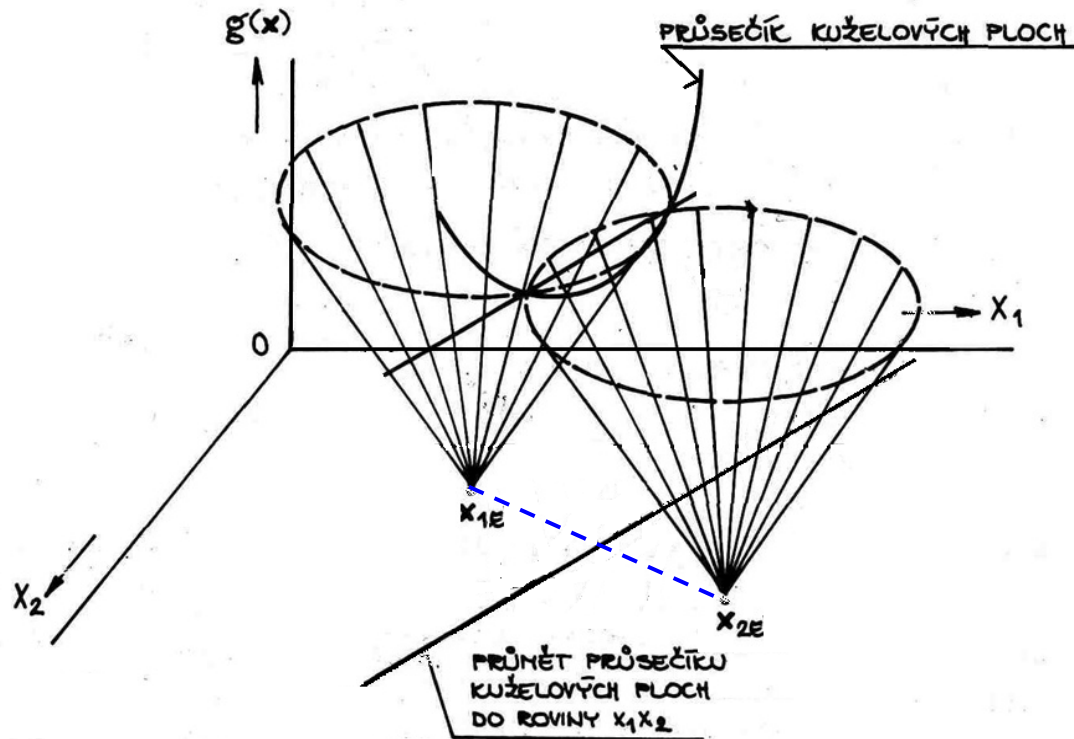
- v případě dvou tříd reprezentovaných etalony $\mathbf{x}_{1E} = (x_{11E}, x_{12E})$ a $\mathbf{x}_{2E} = (x_{21E}, x_{22E})$ ve dvoupríznakovém euklidovském prostoru je vzdálenost mezi obrazem $\mathbf{x} = (x_1, x_2)$ a libovolným z obou etalonů definována:

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

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

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

Souvislost klasifikace podle minimální vzdálenosti s klasifikací pomocí hranic



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

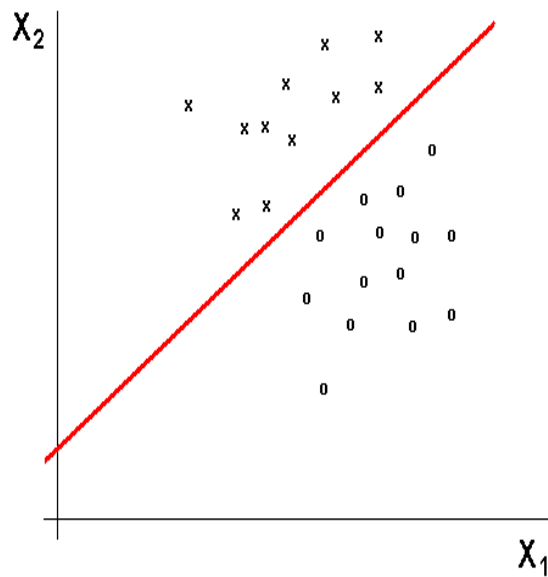
$$x_1(x_{11E} - x_{21E}) + x_2(x_{12E} - x_{22E}) - (x_{12E}^2 + x_{11E}^2 - x_{21E}^2 - x_{22E}^2)/2 = 0$$

- tato hraniční přímka mezi klasifikačními třídami je vždy **kolmá** na spojnici obou etalonů a tuto spojnici **půlí**
- souvislost s klasifikací podle diskriminačních funkcí

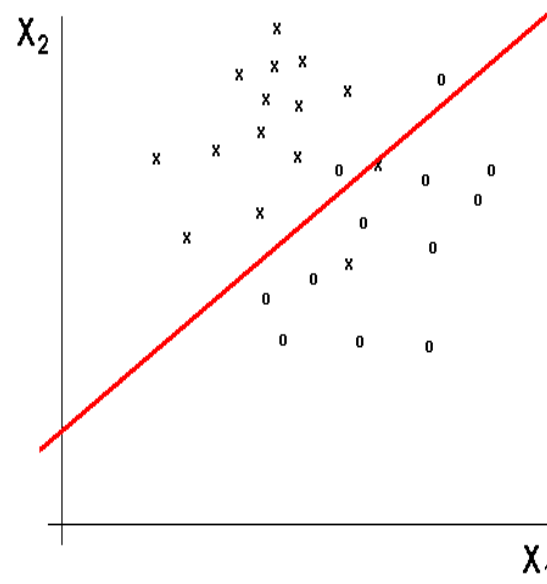
Souvislost jednotlivých principů klasifikace - shrnutí

- Hranice mezi klasifikačními třídami jsou dány průmětem diskriminačních funkcí do obrazového prostoru.
- Klasifikace podle minimální vzdálenosti definuje hranici, která je kolmá na spojnici etalonů klasifikačních tříd a půlí ji.
- Princip klasifikace dle minimální vzdálenosti vede buď přímo, nebo prostřednictvím využití metrik podobnosti k definici diskriminačních funkcí a ty dle prvního ze zde uvedených pravidel k určení hranic mezi klasifikačními třídami.

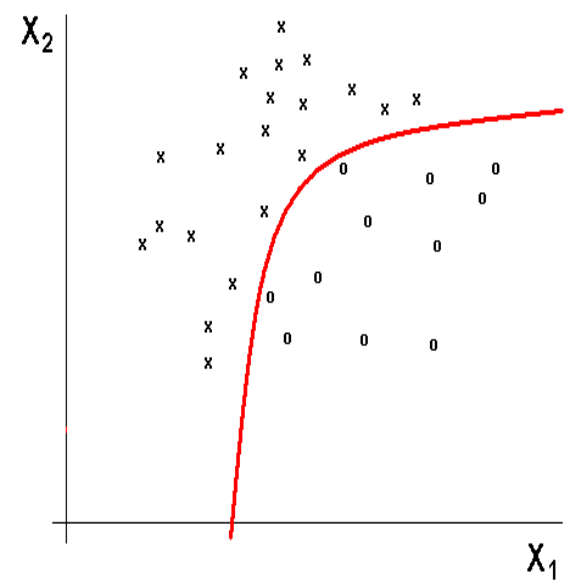
Lineární separabilita



lineárně separabilní
úloha



lineárně neseparabilní
úloha
lineárně separované
klasifikační třídy

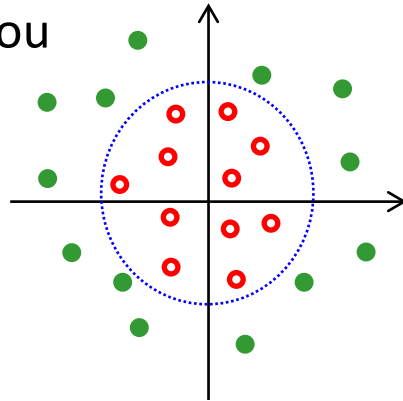


nelineárně
separabilní úloha

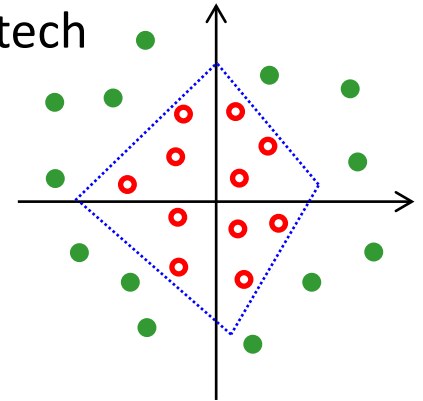
Lineárně neseparabilní třídy – způsoby řešení

1. zachováme původní obrazový prostor a zvolíme nelineární hranici:

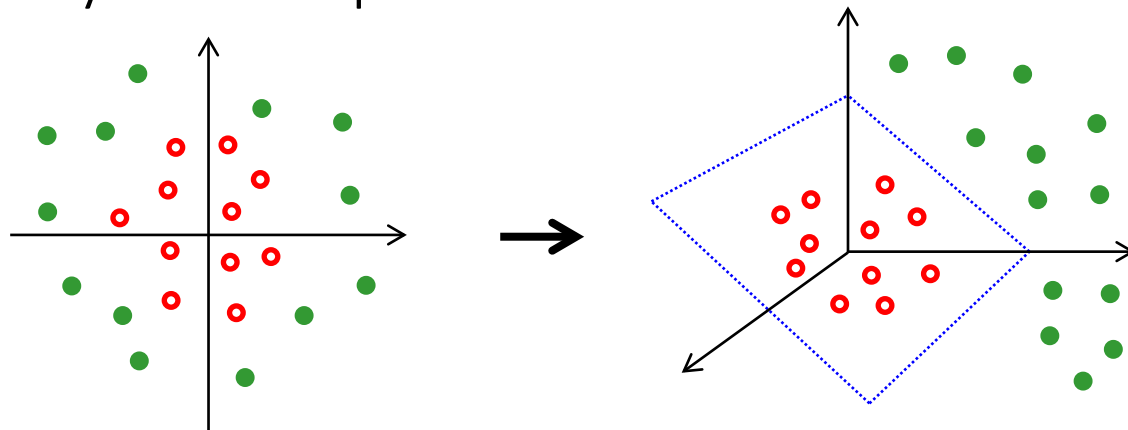
a) definovanou
obecně



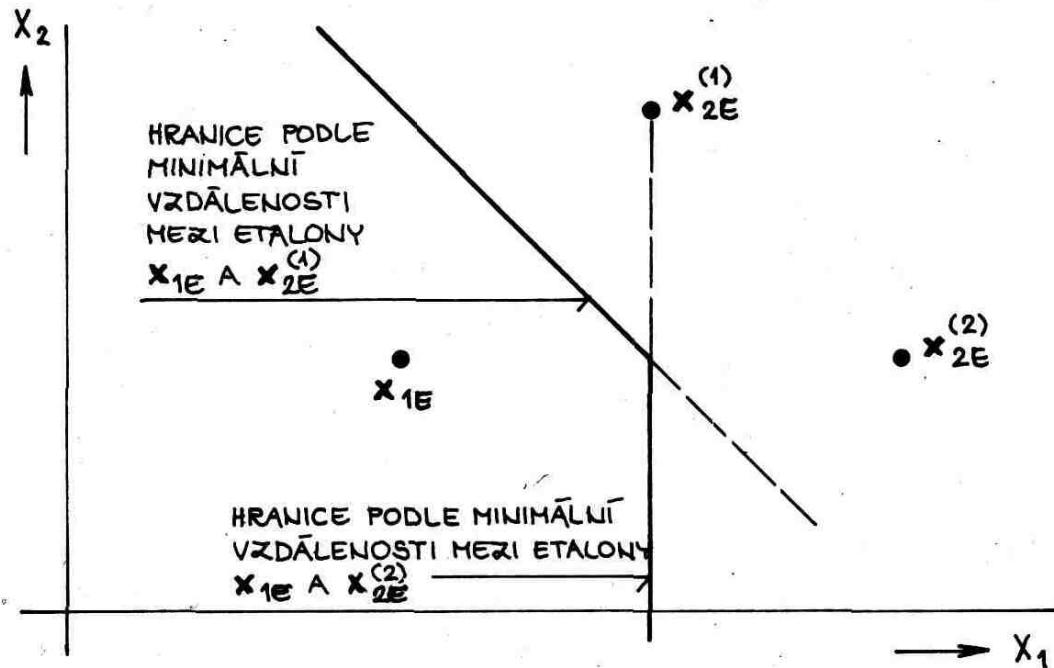
b) složenou po částech
z lineárních úseků



2. zobrazíme původní p -rozměrný obrazový prostor nelineární transformací do nového m -rozměrného prostoru tak, aby v novém prostoru byly klasifikační třídy lineárně separabilní



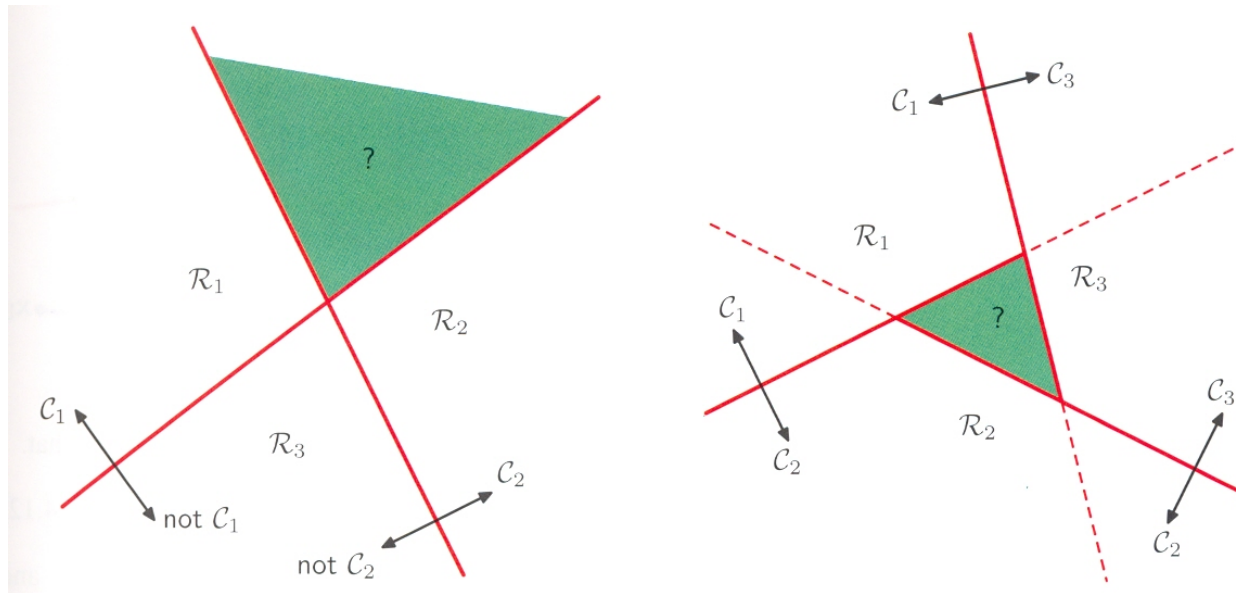
Lineárně neseparabilní třídy – souvislost klasifikace dle minimální vzdálenosti s klasifikací pomocí hranic



Klasifikace podle minimální vzdálenosti s třídami reprezentovanými více etalony je „ekvivalentní“ klasifikaci s po částech lineární hraniční plochou

Klasifikace s více třídami

1. klasifikace „jedna versus zbytek“
R-1 hranice oddělí jednu klasifikační třídu od všech dalších
2. klasifikace „jedna versus jedna“
 $R(R-1)/2$ binárních hranic mezi každými dvěma třídami



- problematickým úsekům se můžeme vyhnout použitím diskriminačních funkcí (do r-té třídy w_r zařadíme obraz x za předpokladu, že $g_r(\mathbf{x}) > g_s(\mathbf{x})$ pro $\forall r \neq s$)
→ klasifikační hranice je průmět průsečíku $g_r(\mathbf{x}) = g_s(\mathbf{x})$ do obrazového prostoru
– takto definovaný klasifikační prostor je vždy spojitý a konvexní

Metody stanovení klasifikačních hranic

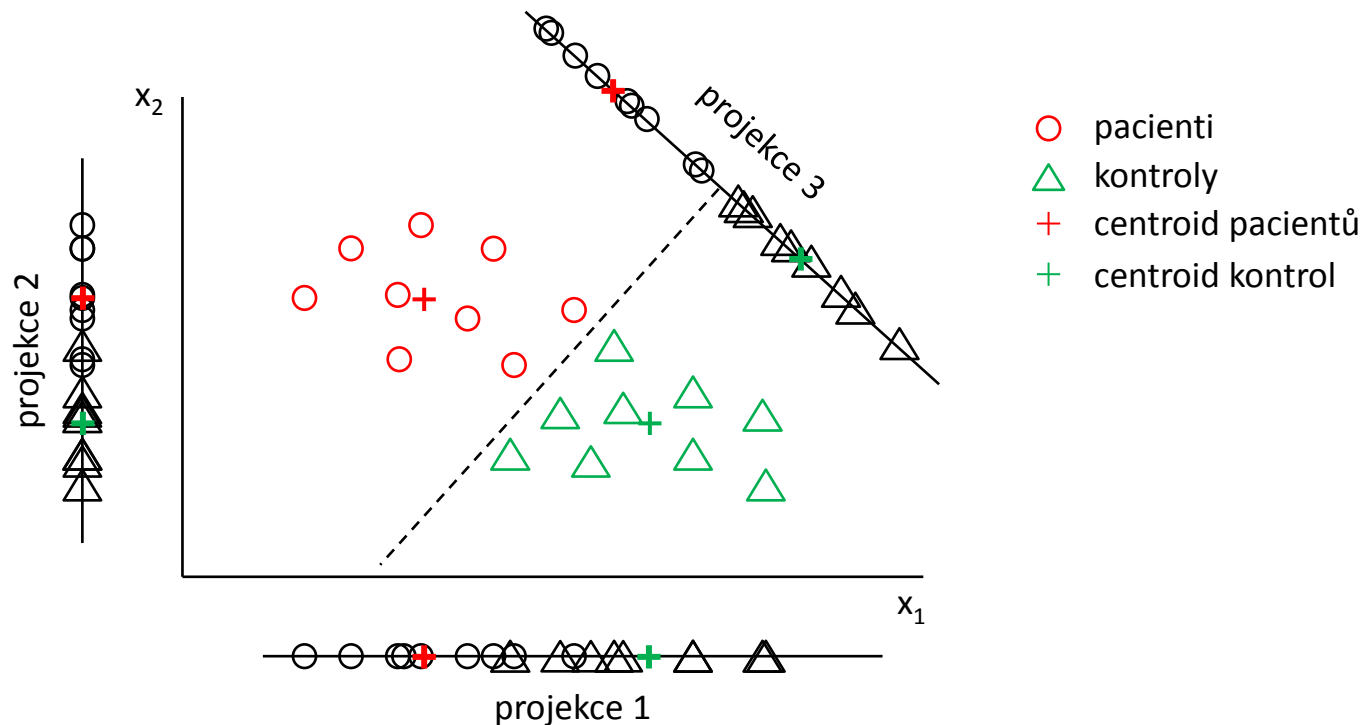
- Fisherova lineární diskriminace (FLDA)
- Algoritmus podpůrných vektorů
- Metoda nejmenších čtverců
- Perceptron

Metody stanovení klasifikačních hranic

- Fisherova lineární diskriminace (FLDA)
- Algoritmus podpůrných vektorů
- Metoda nejmenších čtverců
- Perceptron

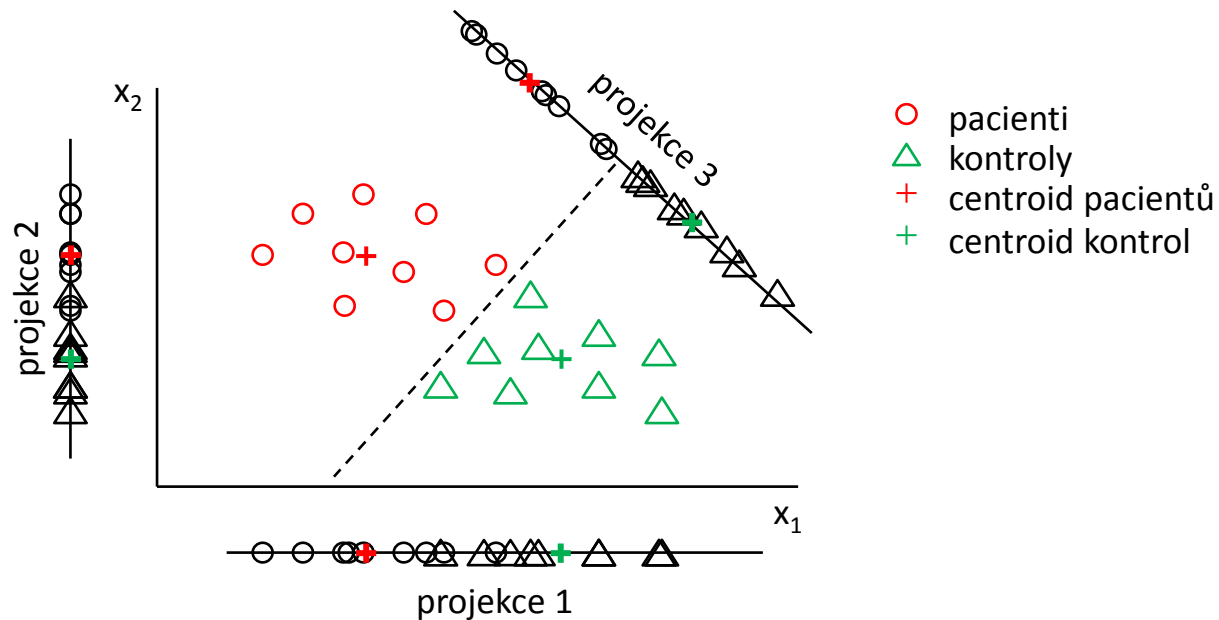
Fisherova lineární diskriminace

- jiný název: Fisherova lineární diskriminační analýza (FLDA)
- použití pro lineární klasifikaci
- princip: transformace do jednorozměrného prostoru tak, aby se třídy od sebe maximálně oddělily



- předpoklad: vícerozměrné normální rozdělení u jednotlivých skupin

Fisherova lineární diskriminace – princip



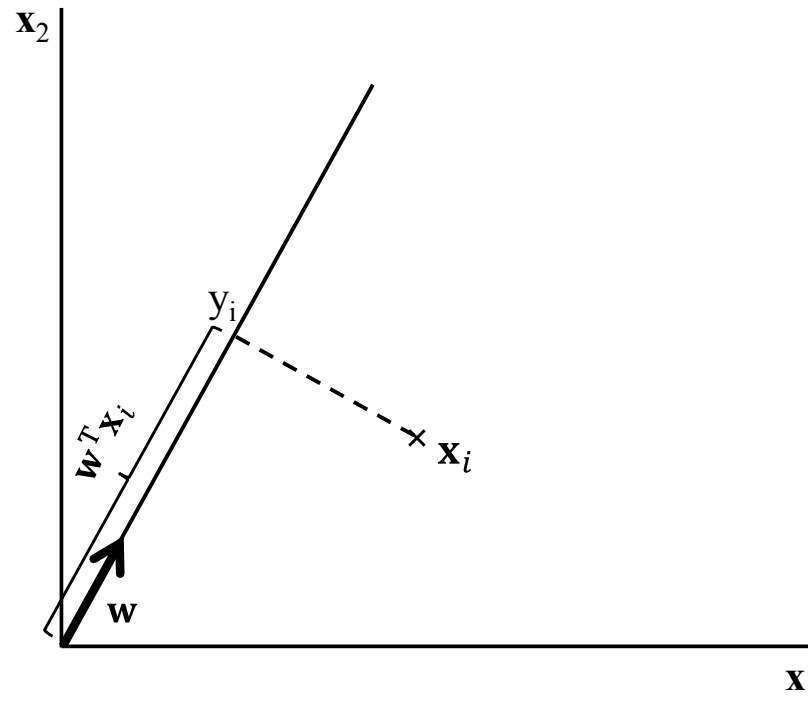
- podstatou FLDA tedy projekce do 1-D prostoru tak, že chceme:

- maximalizovat vzdálenost skupin
- minimalizovat variabilitu uvnitř skupin

- Fisherovo diskriminační kritérium je tedy ve tvaru: $J(\mathbf{w}) = \frac{(\bar{y}_D - \bar{y}_H)^2}{s_D^2 + s_H^2}$

kde s_D^2 a s_H^2 jsou rozptyly uvnitř třídy pacientů resp. kontrol po projekci do 1-D prostoru a \bar{y}_D a \bar{y}_H jsou projekce centroidu třídy pacientů resp. kontrol

Projekce do 1-D prostoru



- bod x_i reprezentuje i -tý subjekt
- y_i je projekce bodu x_i
- w je váhový vektor udávající směr 1-D prostoru

Projekce do 1-D prostoru

- projekce centroidů skupiny pacientů a kontrolních subjektů:

$$\bar{\mathbf{x}}_D = \left[\frac{1}{n_D} \sum_{i=1}^{n_D} x_{i1} \quad \frac{1}{n_D} \sum_{i=1}^{n_D} x_{i2} \quad \cdots \quad \frac{1}{n_D} \sum_{i=1}^{n_D} x_{ip} \right] \rightarrow \bar{y}_D = \mathbf{w}^T \bar{\mathbf{x}}_D$$

$$\bar{\mathbf{x}}_H = \left[\frac{1}{n_H} \sum_{i=1}^{n_H} x_{i1} \quad \frac{1}{n_H} \sum_{i=1}^{n_H} x_{i2} \quad \cdots \quad \frac{1}{n_H} \sum_{i=1}^{n_H} x_{ip} \right] \rightarrow \bar{y}_H = \mathbf{w}^T \bar{\mathbf{x}}_H$$

- výpočet rozptylu uvnitř třídy pacientů po projekci do 1-D prostoru:

$$\begin{aligned} s_D^2 &= \frac{1}{n_D-1} \sum_{i=1}^{n_D} (y_i - \bar{y}_D)^2 = \frac{1}{n_D-1} \sum_{i=1}^{n_D} (\mathbf{w}^T \mathbf{x}_i - \mathbf{w}^T \bar{\mathbf{x}}_D)^2 = \frac{1}{n_D-1} \sum_{i=1}^{n_D} (\mathbf{w}^T (\mathbf{x}_i - \bar{\mathbf{x}}_D))^2 \\ &= \mathbf{w}^T \left(\frac{1}{n_D-1} \sum_{i=1}^{n_D} (\mathbf{x}_i - \bar{\mathbf{x}}_D)(\mathbf{x}_i - \bar{\mathbf{x}}_D)^T \right) \mathbf{w} = \mathbf{w}^T \mathbf{S}_D \mathbf{w} \end{aligned}$$

- analogicky výpočet rozptylu uvnitř třídy kontrol po projekci do 1-D prostoru:

$$s_H^2 = \cdots = \mathbf{w}^T \mathbf{S}_H \mathbf{w}$$

Fisherovo diskriminační kritérium – rozepsání

- Fisherovo diskriminační kritérium: $J(\mathbf{w}) = \frac{(\bar{y}_D - \bar{y}_H)^2}{s_D^2 + s_H^2}$
- rozepsání součtu rozptylů uvnitř jednotlivých tříd po transformaci do 1-D prostoru (tzn. rozepsání jmenovatele Fisherova diskř. kritéria):
$$s_D^2 + s_H^2 = \mathbf{w}^T \mathbf{S}_D \mathbf{w} + \mathbf{w}^T \mathbf{S}_H \mathbf{w} = \mathbf{w}^T (\mathbf{S}_D + \mathbf{S}_H) \mathbf{w} = \mathbf{w}^T \mathbf{S}_W \mathbf{w},$$
kde \mathbf{S}_W je suma čtverců variability uvnitř skupin a lze ji vypočítat jako: $\mathbf{S}_W = \mathbf{S}_D + \mathbf{S}_H$ v obecném případě (při nevyvážených počtech subjektů ve skupinách) – vážená suma čtverců variability uvnitř skupin:
$$\mathbf{S}_W = \frac{(n_D - 1)\mathbf{S}_D + (n_H - 1)\mathbf{S}_H}{(n_D + n_H - 2)}$$
- rozepsání rozdílu centroidů promítnutých do 1-D prostoru (tzn. rozepsání čitatele Fisherova diskř. kritéria):
$$(\bar{y}_D - \bar{y}_H)^2 = (\mathbf{w}^T \bar{\mathbf{x}}_D - \mathbf{w}^T \bar{\mathbf{x}}_H)^2 = (\mathbf{w}^T (\bar{\mathbf{x}}_D - \bar{\mathbf{x}}_H))^2 = \mathbf{w}^T (\bar{\mathbf{x}}_D - \bar{\mathbf{x}}_H) (\bar{\mathbf{x}}_D - \bar{\mathbf{x}}_H)^T \mathbf{w} = \mathbf{w}^T \mathbf{S}_B \mathbf{w},$$
kde \mathbf{S}_B je suma čtverců variability mezi skupinami
- Fisherovo diskř. kritérium lze tedy vyjádřit jako:
$$J(\mathbf{w}) = \frac{(\bar{y}_D - \bar{y}_H)^2}{s_D^2 + s_H^2} = \frac{\mathbf{w}^T \mathbf{S}_B \mathbf{w}}{\mathbf{w}^T \mathbf{S}_W \mathbf{w}}$$

Fisherovo diskriminační kritérium – maximalizace

- Fisherovo diskriminační kritérium: $J(\mathbf{w}) = \frac{(\bar{y}_D - \bar{y}_H)^2}{s_D^2 + s_H^2} = \frac{\mathbf{w}^T \mathbf{S}_B \mathbf{w}}{\mathbf{w}^T \mathbf{S}_W \mathbf{w}}$
- Chceme maximalizovat $J(\mathbf{w})$, proto $J(\mathbf{w})$ zderivujeme a položíme výraz roven 0:

$$\frac{\partial}{\partial \mathbf{w}} J(\mathbf{w}) = 0$$

$$\frac{\left(\frac{\partial}{\partial \mathbf{w}} \mathbf{w}^T \mathbf{S}_B \mathbf{w} \right) \mathbf{w}^T \mathbf{S}_W \mathbf{w} - \mathbf{w}^T \mathbf{S}_B \mathbf{w} \left(\frac{\partial}{\partial \mathbf{w}} \mathbf{w}^T \mathbf{S}_W \mathbf{w} \right)}{(\mathbf{w}^T \mathbf{S}_W \mathbf{w})^2} = 0$$

$$\frac{(2\mathbf{S}_B \mathbf{w}) \mathbf{w}^T \mathbf{S}_W \mathbf{w} - \mathbf{w}^T \mathbf{S}_B \mathbf{w} (2\mathbf{S}_W \mathbf{w})}{(\mathbf{w}^T \mathbf{S}_W \mathbf{w})^2} = 0$$

$$(\mathbf{w}^T \mathbf{S}_B \mathbf{w}) \mathbf{S}_W \mathbf{w} = (\mathbf{w}^T \mathbf{S}_W \mathbf{w}) \mathbf{S}_B \mathbf{w}$$

- u vektoru \mathbf{w} nás nezajímá jeho modul (tzn. velikost), jen jeho směr, proto můžeme pominout skalární členy $\mathbf{w}^T \mathbf{S}_B \mathbf{w}$ a $\mathbf{w}^T \mathbf{S}_W \mathbf{w}$, čímž dostáváme:

$$\mathbf{S}_W \mathbf{w} \sim \mathbf{S}_B \mathbf{w}$$

Fisherovo diskriminační kritérium – maximalizace

$$\mathbf{S}_W \mathbf{w} \sim \mathbf{S}_B \mathbf{w}$$

- protože $\mathbf{S}_B \mathbf{w} = (\bar{\mathbf{x}}_D - \bar{\mathbf{x}}_H)(\bar{\mathbf{x}}_D - \bar{\mathbf{x}}_H)^T \mathbf{w} = (\bar{\mathbf{x}}_D - \bar{\mathbf{x}}_H) \cdot \alpha$, kde α je nějaký skalár $\rightarrow \mathbf{S}_B \mathbf{w}$ má tedy směr $(\bar{\mathbf{x}}_D - \bar{\mathbf{x}}_H)$ a jeho modul α nás nezajímá, proto:

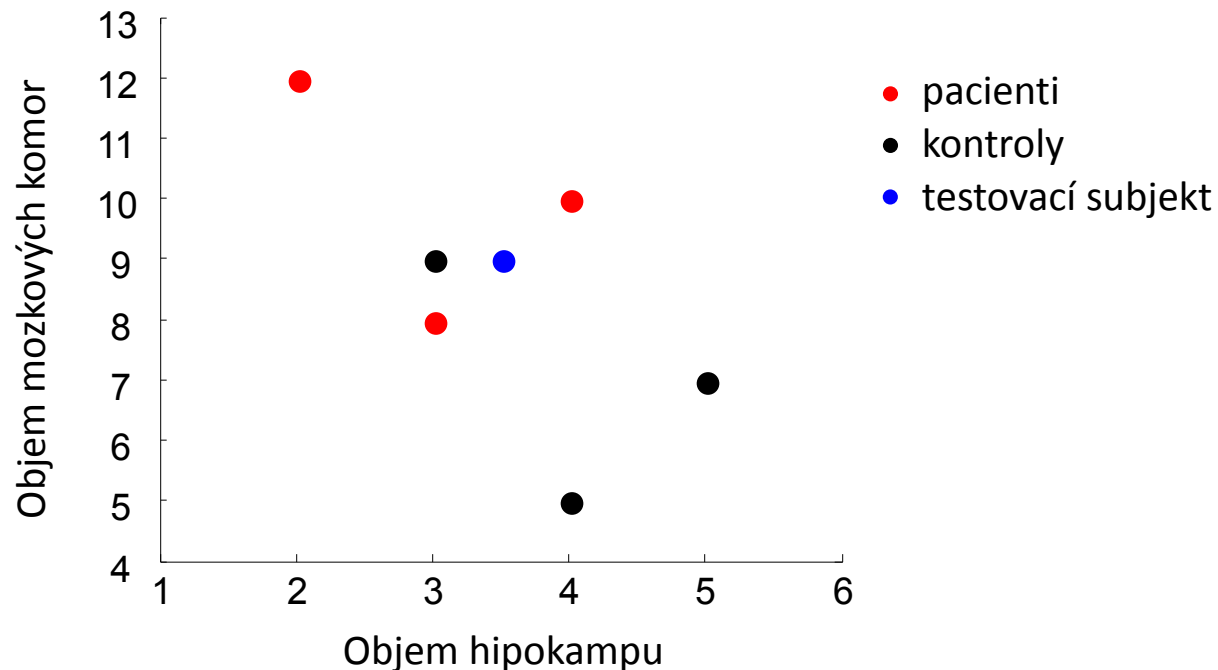
$$\mathbf{S}_W \mathbf{w} \sim (\bar{\mathbf{x}}_D - \bar{\mathbf{x}}_H)$$

- z čehož vypočteme váhový vektor \mathbf{w} jako: $\mathbf{w} \sim \mathbf{S}_W^{-1}(\bar{\mathbf{x}}_D - \bar{\mathbf{x}}_H)$
- hranice je pak dána: $\mathbf{w}^T \mathbf{x} - \tilde{y} = 0$, kde \tilde{y} je průmět hraničního bodu v 1-D prostoru a lze ho vypočítat jako: $\tilde{y} = \frac{\bar{y}_D + \bar{y}_H}{2}$
- pokud chceme zařadit nový subjekt \mathbf{x}_0 do jedné z daných tříd, jeho průmět do 1-D prostoru ($y_0 = \mathbf{w}^T \mathbf{x}_0$) srovnáme s průmětem hraničního bodu \tilde{y} :
 - Pokud $y_0 < \tilde{y}$ (příčemž $\bar{y}_H < \tilde{y}$), subjekt zařadíme do skupiny kontrolních subjektů
 - Pokud $y_0 > \tilde{y}$ (příčemž $\bar{y}_H < \tilde{y}$), subjekt zařadíme do skupiny pacientů

Příklad

Příklad: Bylo provedeno měření objemu hipokampu a mozkových komor (v cm^3) 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 $\mathbf{x}_0 = [3,5 \quad 9]$ patří do skupiny pacientů či kontrolních subjektů pomocí Fisherovy lineární diskriminace.



Příprava nových učebních materiálů pro obor Matematická biologie

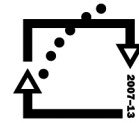
je podporována projektem OPVK

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