

Analýza a klasifikace dat – přednáška 6



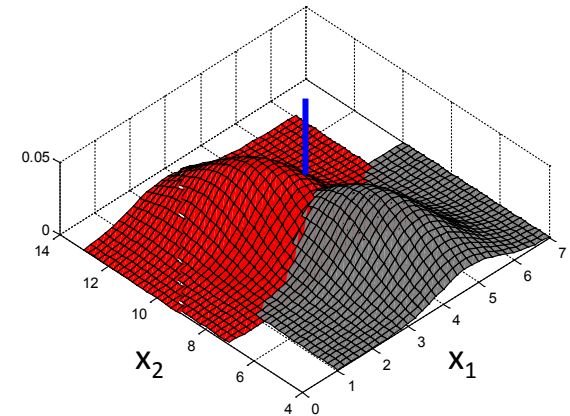
RNDr. Eva Janoušová

Podzim 2014

Typy klasifikátorů – podle principu klasifikace

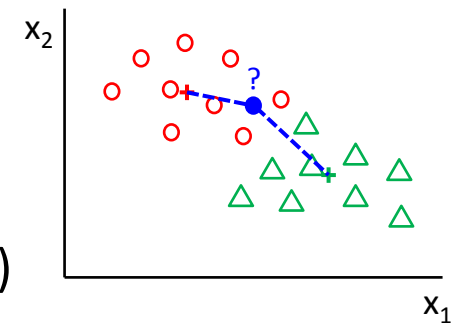
- **klasifikace pomocí diskriminačních funkcí:**

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



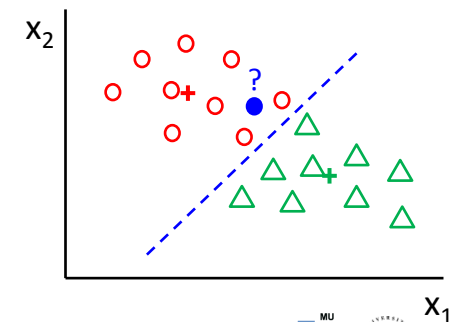
- **klasifikace pomocí vzdálenosti od etalonů klasif. tříd:**

- 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

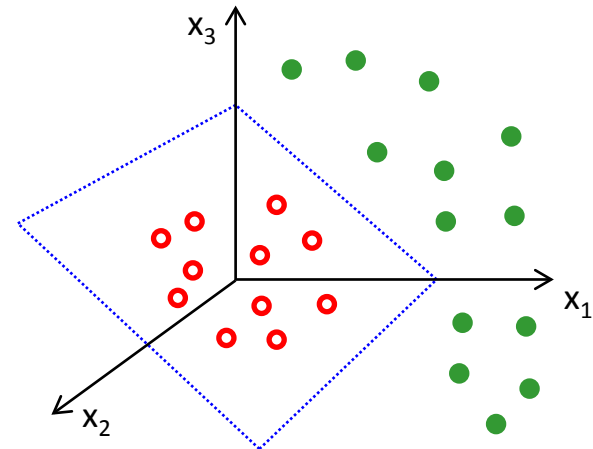


Motivace

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)

Fisherova lineární diskriminace (FLDA)


- použití pro lineární klasifikaci
- princip: transformace do jednorozměrného prostoru tak, aby se třídy od sebe maximálně oddělily (maximalizace vzdálenosti skupin a minimalizace variability uvnitř skupin)



- předpoklad: vícerozměrné normální rozdělení u jednotlivých skupin

Metoda podpůrných vektorů (SVM)

Princip: Proložení klasifikační hranice (nadroviny) tak, aby byla v co největší vzdálenosti od subjektů z obou tříd.




Varianty SVM (support vectore machine) metody:


- **Lineární SVM** – oproti LDA nevyžaduje normalitu dat.
- **Nelineární SVM** – využití jader (např. polynomiální nebo radiální bázová funkce) k transformaci do prostoru, kde je možné subjekty oddělit lineárně.

Nelineární SVM


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



Nelineární SVM – ukázka 2




dvourozměrný prostor s
oddělovací hranicí ve tvaru
 $x_1^2 + x_2^2 \leq 1$




tatáž situace zobrazená do
trojrozměrného prostoru
($x_1^2, x_2^2, \sqrt{2}x_1x_2$) – **kruhová
hranice se stane lineární**

Nelineární SVM – ukázka 3




Lineární SVM



- Proložení klasifikační hranice (nadroviny) tak, aby byla v co největší vzdálenosti od subjektů z obou tříd → tzn. aby byl okolo hranice co nejširší pruh bez bodů
- Na popis hranice (nadroviny) stačí pouze nejbližší body, kterých je obvykle málo a nazývají se **podpůrné vektory** (support vectors)

Lineární SVM – lineárně separabilní třídy

- hranice: $h(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + w_0 = 0$ (kde \mathbf{w} a w_0 je orientace a poloha hranice)
- klasifikace subjektu \mathbf{x} do třídy ω_D , resp. ω_H , bude dána tím, jestli je výraz $\mathbf{w}^T \mathbf{x} + w_0$ větší, resp. menší, než 0
- vzdálenost jakéhokoliv bodu od klasifikační hranice je: $d = \frac{|\mathbf{w}^T \mathbf{x} + w_0|}{\|\mathbf{w}\|}$, kde $\|\mathbf{w}\|$ je velikost vektoru \mathbf{w}
- pro nejbližší bod \mathbf{x}_i ze třídy ω_D zvolíme hodnotu výrazu $\mathbf{w}^T \mathbf{x}_i + w_0$ rovnu +1 a pro nejbližší bod \mathbf{x}_j ze třídy ω_H zvolíme hodnota výrazu $\mathbf{w}^T \mathbf{x}_j + w_0$ rovnu -1
- pak na každé straně od dělicí přímky máme toleranční pásmo o šířce $\frac{1}{\|\mathbf{w}\|}$, ve kterém se nenachází žádný bod



Lineární SVM – lineárně separabilní třídy

- Pro všechny body z trénovací množiny platí:

$$\mathbf{w}^T \mathbf{x} + w_0 \geq 1 \quad \text{pro všechna } \mathbf{x} \text{ z } \omega_D,$$

$$\mathbf{w}^T \mathbf{x} + w_0 \leq -1 \quad \text{pro všechna } \mathbf{x} \text{ z } \omega_H,$$

- což můžeme stručněji zapsat jako

$$\delta_{x_k} (\mathbf{w}^T \mathbf{x}_k + w_0) \geq 1, \text{ pro } k=1, \dots, N,$$

- kde $\delta_{x_k} = 1$ pro \mathbf{x}_k ze třídy ω_D a $\delta_{x_k} = -1$ pro \mathbf{x}_k ze třídy ω_H

- hledáme takové hodnoty \mathbf{w} a w_0 , aby byla celková šířka tolerančního pásma

$$\frac{1}{\|\mathbf{w}\|} + \frac{1}{\|\mathbf{w}\|} = \frac{2}{\|\mathbf{w}\|} \text{ co největší}$$

- hledat maximum funkce $\frac{2}{\|\mathbf{w}\|}$ je to stejné, jako hledat minimum funkce $\frac{\|\mathbf{w}\|}{2}$ a toto minimum se nezmění, když kladnou hodnotu v čitateli umocníme na druhou (což nám zjednoduší výpočty), takže dostáváme následující kritériální funkci, jejíž hodnotu se snažíme minimalizovat:

$$J(\mathbf{w}, w_0) = \frac{\|\mathbf{w}\|^2}{2}$$

→ řešení pomocí metody
Lagrangeova součinitele

Lineární SVM – lineárně neseparabilní třídy


- zavedeme relaxační proměnné $\xi_k \geq 0$ vyjadřující, jak moc každý bod porušuje podmínku $\delta_{x_k}(\mathbf{w}^T \mathbf{x}_k + w_0) \geq 1$

- 3 situace:

- obraz leží **vně** pásma a je **správně** klasifikován: $\xi_k = 0$
- obraz leží **uvnitř** pásma a je **správně** klasifikován (body s čtverečky): $0 < \xi_k \leq 1$
- obraz leží na **opačné straně** hranice a je **chybně** klasifikován (body s kolečky): $\xi_k > 1$

- podmínky jsou pak ve tvaru:

$$\delta_{x_k}(\mathbf{w}^T \mathbf{x}_k + w_0) \geq 1 - \xi_k$$



Lineární SVM – lineárně neseparabilní třídy

- když chceme najít hranici poskytující co nejrobustnější klasifikaci, musíme se snažit:
 - maximalizovat šířku tolerančního pásma
 - minimalizovat počet subjektů z trénovací množiny, které leží v tolerančním pásmu nebo jsou dokonce špatně klasifikovány (tj. těch, pro které $\xi_k > 0$)
- to můžeme vyjádřit jako minimalizaci kriteriální funkce:

$$J(\mathbf{w}, w_0, \xi) = \frac{\|\mathbf{w}\|^2}{2} + C \sum_{k=1}^N \xi_k$$

- kde C vyjadřuje poměr vlivu obou členů kriteriální funkce
- řešíme opět pomocí metody **Lagrangeova součinitele**

Lineární SVM – metoda Lagrangeova součinitele

- Zavedeme vektor Lagrangeových součinitelů $\boldsymbol{\lambda} = [\lambda_1, \lambda_2, \dots, \lambda_N]$, kde $\lambda_k \geq 0$, a pomocí nich vyjádříme optimalizovanou funkci jako:

$$L(\mathbf{w}, w_0, \boldsymbol{\xi}, \boldsymbol{\lambda}, \boldsymbol{\mu}) = \frac{\|\mathbf{w}\|^2}{2} + C \sum_{k=1}^N \xi_k - \sum_{k=1}^N \lambda_k [\delta_{x_k} (\mathbf{w}^T \mathbf{x}_k + w_0) - 1 + \xi_k] - \sum_{k=1}^N \mu_k \xi_k$$

- za podmínek $\lambda_k [\delta_{x_k} (\mathbf{w}^T \mathbf{x}_k + w_0) - 1 + \xi_k] = 0$ a $\mu_k \xi_k \geq 0$, pro $k = 1, \dots, N$.
- tuto Lagrangeovu funkci zderivujeme podle proměnných \mathbf{w}, w_0 a $\boldsymbol{\xi}$ a derivace položíme rovny nule \rightarrow po dalších úpravách dostaneme:

$$\mathbf{w} = \sum_{k=1}^N \lambda_k \delta_{x_k} \mathbf{x}_k$$


\rightarrow patrné, že pro výpočet orientace hranice důležité jen ty body, pro které platí $\lambda_k > 0$ (takovým bodům říkáme podpůrné vektory a jen na nich závisí umístění a orientace dělící přímky)

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 metody podpůrných vektorů.



Příklad – řešení pro parametr $C = 1$

- výsledkem jsou hodnoty $\lambda = \left[0, \frac{1}{2}, 1, \frac{1}{2}, 1, 0\right]$
- podpůrnými vektory jsou tedy body $\mathbf{x}_2, \mathbf{x}_3, \mathbf{x}_4$ a \mathbf{x}_5 , protože jim příslušející $\lambda_2, \lambda_3, \lambda_4$ a λ_5 jsou nenulové. Vypočítáme orientaci hranice:

$$\begin{aligned}\mathbf{w} &= \sum_{k=1}^6 \lambda_k \delta_{x_k} \mathbf{x}_k = \frac{1}{2} \mathbf{x}_2 + \mathbf{x}_3 - \frac{1}{2} \mathbf{x}_4 - \mathbf{x}_5 = \frac{1}{2} \begin{bmatrix} 4 \\ 10 \end{bmatrix} + \begin{bmatrix} 3 \\ 8 \end{bmatrix} - \frac{1}{2} \begin{bmatrix} 5 \\ 7 \end{bmatrix} - \begin{bmatrix} 3 \\ 9 \end{bmatrix} \\ &= \begin{bmatrix} -1/2 \\ 1/2 \end{bmatrix}\end{aligned}$$


- Pokud zvolíme takový \mathbf{x}_k , pro který platí $0 < \lambda_k < C$, tak podle vztahu $\lambda_k + \mu_k = C$ musí být $\mu_k > 0$ a odtud podle vztahu $\mu_k \xi_k = 0$ plyne, že $\xi_k = 0$. Vzorec se tak zjednoduší na $\delta_{x_k} (\mathbf{w}^T \mathbf{x}_k + w_0) = 1$. Tedy například pro \mathbf{x}_2 ($0 < \lambda_2 = \frac{1}{2} < C = 1$):

$$\mathbf{w}^T \mathbf{x}_2 + w_0 = 1 \Rightarrow w_0 = 1 - \begin{bmatrix} -\frac{1}{2} & \frac{1}{2} \end{bmatrix} \begin{bmatrix} 4 \\ 10 \end{bmatrix} = 1 - 3 = -2$$

- hranice je tedy dána rovnicí: $\mathbf{w}^T \mathbf{x} + w_0 = \begin{bmatrix} -\frac{1}{2} & \frac{1}{2} \end{bmatrix} \mathbf{x} - 2$

Příklad – řešení pro parametr $C = 1$

- hranice je dána rovnicí: $\mathbf{w}^T \mathbf{x} + w_0 = \left[-\frac{1}{2} \quad \frac{1}{2} \right] \mathbf{x} - 2$



Příklad – řešení pro parametr $C = 1$

- můžeme klasifikovat subjekt $\mathbf{x} = [3,5 \quad 9]$:

$$\mathbf{w}^T \mathbf{x} + w_0 = \begin{bmatrix} -\frac{1}{2} & \frac{1}{2} \end{bmatrix} \begin{bmatrix} 3,5 \\ 9 \end{bmatrix} - 2 = -1,75 + 4,5 - 2 = 0,75$$

- protože $0,75 > 0$, testovací subjekt bude zařazen do třídy pacientů
- ověříme, že natrénovaný klasifikátor zařadí subjekty z trénovací množiny tak, jak to odpovídá situaci na obrázku; tj. správně subjekty $\mathbf{x}_1, \mathbf{x}_2, \mathbf{x}_3, \mathbf{x}_4$ a chybně subjekt \mathbf{x}_5 :

$$\mathbf{w}^T \mathbf{x}_1 + w_0 = \begin{bmatrix} -\frac{1}{2} & \frac{1}{2} \end{bmatrix} \begin{bmatrix} 2 \\ 12 \end{bmatrix} - 2 = -1 + 6 - 2 = 3$$

$$\mathbf{w}^T \mathbf{x}_2 + w_0 = \begin{bmatrix} -\frac{1}{2} & \frac{1}{2} \end{bmatrix} \begin{bmatrix} 4 \\ 10 \end{bmatrix} - 2 = -2 + 5 - 2 = 1$$

$$\mathbf{w}^T \mathbf{x}_3 + w_0 = \begin{bmatrix} -\frac{1}{2} & \frac{1}{2} \end{bmatrix} \begin{bmatrix} 3 \\ 8 \end{bmatrix} - 2 = -1,5 + 4 - 2 = 0,5$$

$$\mathbf{w}^T \mathbf{x}_4 + w_0 = \begin{bmatrix} -\frac{1}{2} & \frac{1}{2} \end{bmatrix} \begin{bmatrix} 5 \\ 7 \end{bmatrix} - 2 = -2,5 + 3,5 - 2 = -1$$

$$\mathbf{w}^T \mathbf{x}_5 + w_0 = \begin{bmatrix} -\frac{1}{2} & \frac{1}{2} \end{bmatrix} \begin{bmatrix} 3 \\ 9 \end{bmatrix} - 2 = -1,5 + 4,5 - 2 = 1$$

$$\mathbf{w}^T \mathbf{x}_6 + w_0 = \begin{bmatrix} -\frac{1}{2} & \frac{1}{2} \end{bmatrix} \begin{bmatrix} 4 \\ 5 \end{bmatrix} - 2 = -2 + 2,5 - 2 = -1,5$$

Příklad – řešení pro parametr $C = 10$

- výsledkem jsou hodnoty
 $\lambda = [0, 3,6371, 8,7629, 2,0371, 10, 0,3629]$
- podpůrnými vektory jsou tedy body $\mathbf{x}_2, \mathbf{x}_3, \mathbf{x}_4, \mathbf{x}_5$ a \mathbf{x}_6 , protože jim příslušející $\lambda_2, \lambda_3, \lambda_4, \lambda_5$ a λ_6 jsou nenulové. Vypočítáme orientaci hranice:

$$\begin{aligned}\mathbf{w} &= \sum_{k=1}^6 \lambda_k \delta_{x_k} \mathbf{x}_k = 3,6371\mathbf{x}_2 + 8,7629\mathbf{x}_3 - 2,0371\mathbf{x}_4 - 10\mathbf{x}_5 - 0,3629\mathbf{x}_6 \\ &= 3,6371 \begin{bmatrix} 4 \\ 10 \end{bmatrix} + 8,7629 \begin{bmatrix} 3 \\ 8 \end{bmatrix} - 2,0371 \begin{bmatrix} 5 \\ 7 \end{bmatrix} - 10 \begin{bmatrix} 3 \\ 9 \end{bmatrix} - 0,3629 \begin{bmatrix} 4 \\ 5 \end{bmatrix} \\ &= \begin{bmatrix} -4/5 \\ 2/5 \end{bmatrix}\end{aligned}$$


- Polohu dělicí přímky určíme opět ze $\delta_{x_k} (\mathbf{w}^T \mathbf{x}_k + w_0) = 1$. Tedy například pro \mathbf{x}_2 ($0 < \lambda_2 = 3,6371 < C = 10$):

$$\mathbf{w}^T \mathbf{x}_2 + w_0 = 1 \Rightarrow w_0 = 1 - \begin{bmatrix} -\frac{4}{5} & \frac{2}{5} \end{bmatrix} \begin{bmatrix} 4 \\ 10 \end{bmatrix} = 1 - \frac{4}{5} = \frac{1}{5}$$

- hranice je tedy dána rovnicí: $\mathbf{w}^T \mathbf{x} + w_0 = \begin{bmatrix} -\frac{4}{5} & \frac{2}{5} \end{bmatrix} \mathbf{x} + \frac{1}{5}$

Příklad – řešení pro parametr $C = 10$

- hranice je tedy dána rovnicí: $\mathbf{w}^T \mathbf{x} + w_0 = \begin{bmatrix} -\frac{4}{5} & \frac{2}{5} \end{bmatrix} \mathbf{x} + \frac{1}{5}$



Příklad – řešení pro parametr $C = 10$

- můžeme klasifikovat subjekt $\mathbf{x} = [3,5 \quad 9]$:

$$\mathbf{w}^T \mathbf{x} + w_0 = \begin{bmatrix} -\frac{4}{5} & \frac{2}{5} \end{bmatrix} \begin{bmatrix} 3,5 \\ 9 \end{bmatrix} + \frac{1}{5} = -2,8 + 3,6 + 0,2 = 1$$

- protože $1 > 0$, testovací subjekt bude zařazen do třídy pacientů
- ověříme, že natrénovaný klasifikátor zařadí subjekty z trénovací množiny tak, jak to odpovídá situaci na obrázku; tj. správně subjekty $\mathbf{x}_1, \mathbf{x}_2, \mathbf{x}_3, \mathbf{x}_4$ a \mathbf{x}_6 a chybně subjekt \mathbf{x}_5 :

$$\mathbf{w}^T \mathbf{x}_1 + w_0 = \begin{bmatrix} -\frac{4}{5} & \frac{2}{5} \end{bmatrix} \begin{bmatrix} 2 \\ 12 \end{bmatrix} + \frac{1}{5} = -\frac{8}{5} + \frac{24}{5} + \frac{1}{5} = \frac{17}{5} = 3,4$$

$$\mathbf{w}^T \mathbf{x}_2 + w_0 = \begin{bmatrix} -\frac{4}{5} & \frac{2}{5} \end{bmatrix} \begin{bmatrix} 4 \\ 10 \end{bmatrix} + \frac{1}{5} = -\frac{16}{5} + \frac{20}{5} + \frac{1}{5} = \frac{5}{5} = 1$$

$$\mathbf{w}^T \mathbf{x}_3 + w_0 = \begin{bmatrix} -\frac{4}{5} & \frac{2}{5} \end{bmatrix} \begin{bmatrix} 3 \\ 8 \end{bmatrix} + \frac{1}{5} = -\frac{12}{5} + \frac{16}{5} + \frac{1}{5} = \frac{5}{5} = 1$$


$$\mathbf{w}^T \mathbf{x}_4 + w_0 = \begin{bmatrix} -\frac{4}{5} & \frac{2}{5} \end{bmatrix} \begin{bmatrix} 5 \\ 7 \end{bmatrix} + \frac{1}{5} = -\frac{20}{5} + \frac{14}{5} + \frac{1}{5} = -\frac{5}{5} = -1$$

$$\mathbf{w}^T \mathbf{x}_5 + w_0 = \begin{bmatrix} -\frac{4}{5} & \frac{2}{5} \end{bmatrix} \begin{bmatrix} 3 \\ 9 \end{bmatrix} + \frac{1}{5} = -\frac{12}{5} + \frac{18}{5} + \frac{1}{5} = \frac{7}{5} = 1,4$$


$$\mathbf{w}^T \mathbf{x}_6 + w_0 = \begin{bmatrix} -\frac{4}{5} & \frac{2}{5} \end{bmatrix} \begin{bmatrix} 4 \\ 5 \end{bmatrix} + \frac{1}{5} = -\frac{16}{5} + \frac{10}{5} + \frac{1}{5} = -\frac{5}{5} = -1$$

Příklad – srovnání výsledků pro $C = 1$ a $C = 10$

$C = 1$:



$C = 10$:



Další metody klasifikace

Typy klasifikátorů

1. Podle reprezentace vstupních dat:

- příznakové klasifikátory: paralelní 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 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

- **příznakové** – vstupní data vyjádřena vektorem hodnot jednotlivých proměnných (příznaků):
 - **paralelní** – zpracování vektoru jako celku (např. Bayesův klasifikátor)
 - **sekvenční** – zpracování (občas i měření) proměnných postupně (např. klasifikační stromy)


	A	B	C	D	E
1	id	vek	pohlaví	vyska	vaha
2	1	38	Z	164	45
3	2	36	M	167	90
4	3	26	Z	178	70

- **strukturální (syntaktické)** – vstupní data popsána relačními strukturami



PRIMITIVA:
 (K) – KOLEČKO
 (B) – BRAMBORA

RELACE:
 (1) – DOTÝKÁ SE SHORA
 (2) – DOTÝKÁ SE ZLEVA
 (3) – LEŽÍ UVNITŘ
 (4) – LEŽÍ VLEVO OD
 (5) – LEŽÍ POD



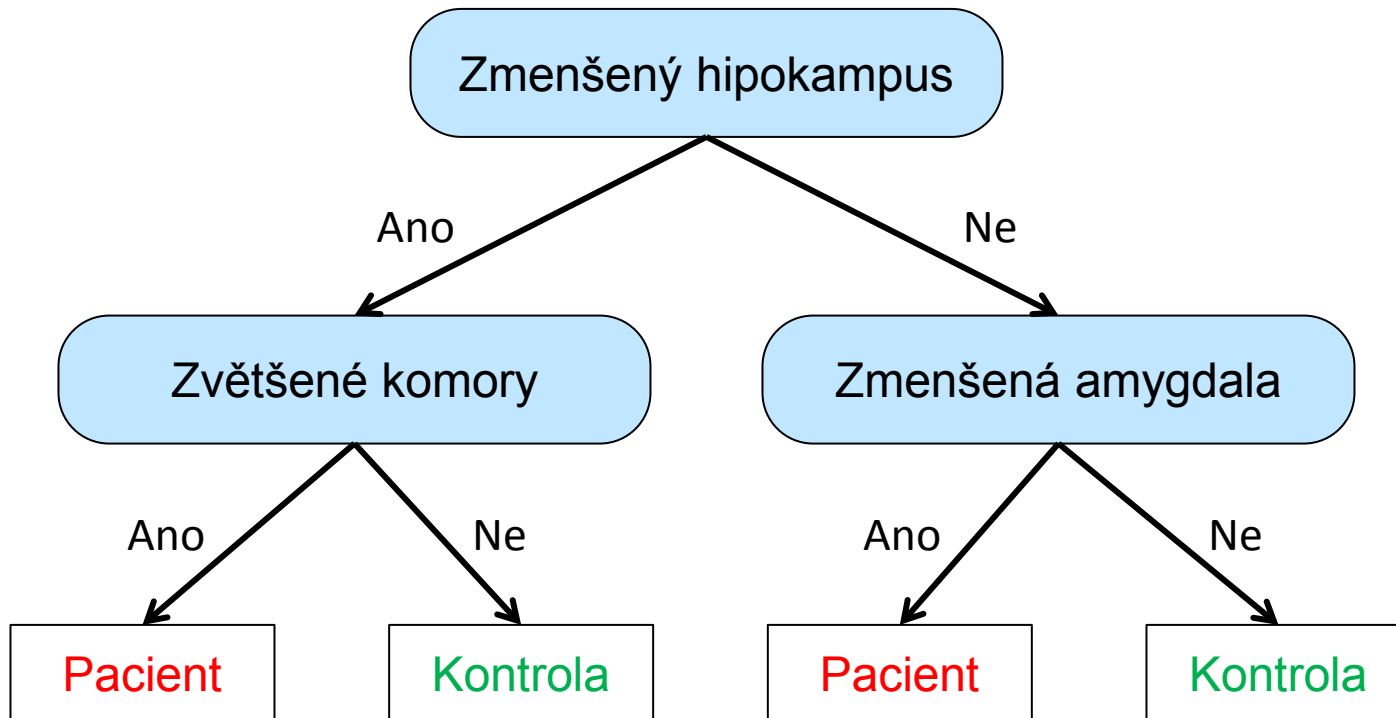
- **kombinované** – jednotlivá primitiva doplněna příznakovým popisem

Sekvenční klasifikace - motivace

- až dosud (bayesovské klasifikátory, klasifikátory s diskriminační hranicí, s minimální vzdáleností, ...) – pevný konstantní počet příznaků
- kolik a jaké proměnných?
 - málo proměnných – možná chyba klasifikace;
 - moc proměnných – možná nepřiměřená pracnost, vysoké náklady;
 - použít proměnné, které nesou co nejvíce informace o klasifikační úloze;
- **sekvenční klasifikace** - kompromis mezi velikostí klasifikační chyby a cenou určení příznaků
 - klasifikace na základě klasifikačního stromu
 - klasifikace s rostoucím počtem proměnných, přičemž okamžik ukončení klasifikační procedury stanoví klasifikátor sám podle předem daného kritéria pro kvalitu rozhodnutí (tj. na základě vlastností klasifikačních tříd, resp. objektů v nich)

Klasifikační (rozhodovací) stromy a lesy

Princip: Postupné rozdělování datasetu do skupin podle hodnot jednotlivých proměnných.



Klasifikační lesy – použití více klasifikačních stromů ke klasifikaci.

Klasifikace s rostoucím počtem proměnných

- **Waldovo kritérium:**


- $p(x_1, x_2, \dots, x_i | \omega_1)$ a $p(x_1, x_2, \dots, x_i | \omega_2)$ jsou i -rozměrné hustoty pravděpodobnosti (tzn. dané prvními i proměnnými) výskytu objektu $\mathbf{x} = (x_1, x_2, \dots, x_i)$ v i -tém klasifikačním kroku v třídách ω_1 a ω_2
- A a B jsou konstanty ($0 < B < 1 < A < \infty$)
- pokud pro věrohodnostní poměr:
$$\Lambda_i = \frac{p(x_1, x_2, \dots, x_i | \omega_1)}{p(x_1, x_2, \dots, x_i | \omega_2)}$$
 1. je $\Lambda_i \leq B$, pak se objekt \mathbf{x} zařadí do třídy ω_2 a proces se ukončí
 2. je $\Lambda_i \geq A$, pak se objekt \mathbf{x} zařadí do třídy ω_1 a proces se ukončí
 3. je $\Lambda_i \in (B, A)$, přidáme další proměnnou (příznak) x_{i+1} a proces se opakuje

- **Modifikované Waldovo kritérium** - 2 možnosti:

- po určitém počtu kroků se sekvenční výpočet přeruší a dokončí se na základě nějakého rozhodnutí vycházejícího z nějakého kritéria založeného na pevném počtu příznaků
- zavedení proměnných hranic $A(i)$ a $B(i)$

- **Reedovo kritérium**

Srovnání původního a modifikovaného Waldova kritéria



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