

# Analýza a klasifikace dat – přednáška 5



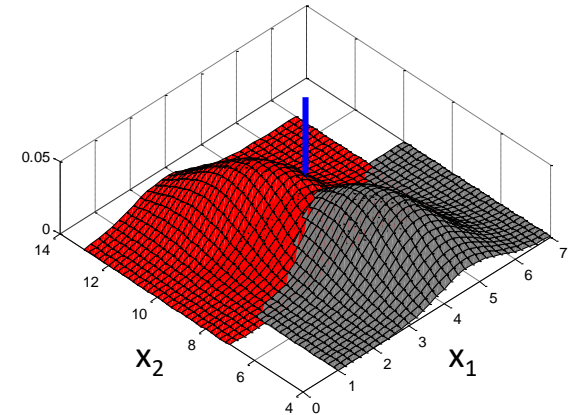
RNDr. Eva Koriťáková, Ph.D.

Podzim 2018

# Typy klasifikátorů – podle principu klasifikace

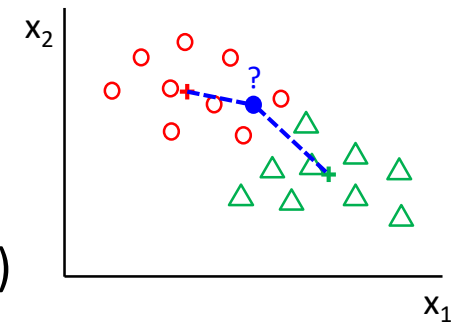
- **klasifikace pomocí diskriminačních funkcí:**

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



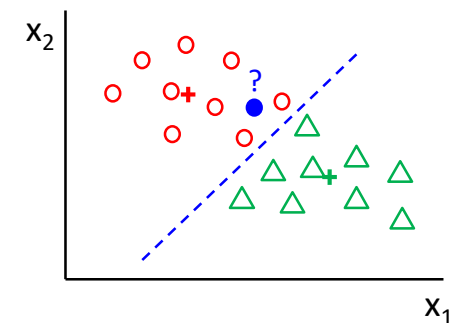
- **klasifikace pomocí vzdálenosti od etalonů klasif. tříd:**

- 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)



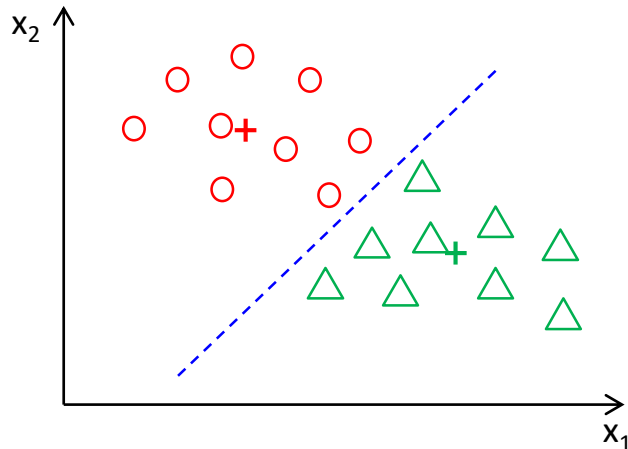
- **klasifikace pomocí hranic v obrazovém prostoru:**

- stanovení hranic (hraničních ploch) oddělujících klasifikační třídy

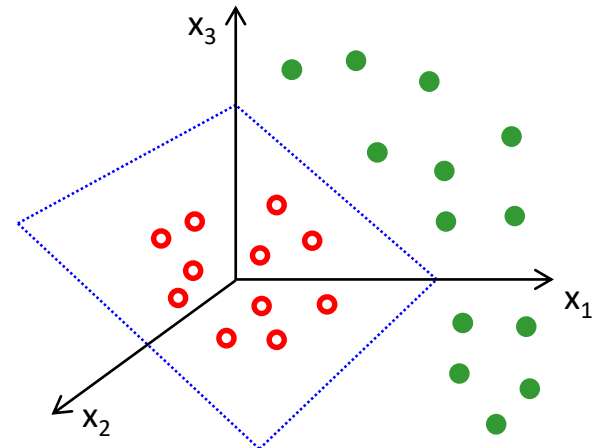


# Motivace

2-rozměrný prostor



3-rozměrný prostor



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

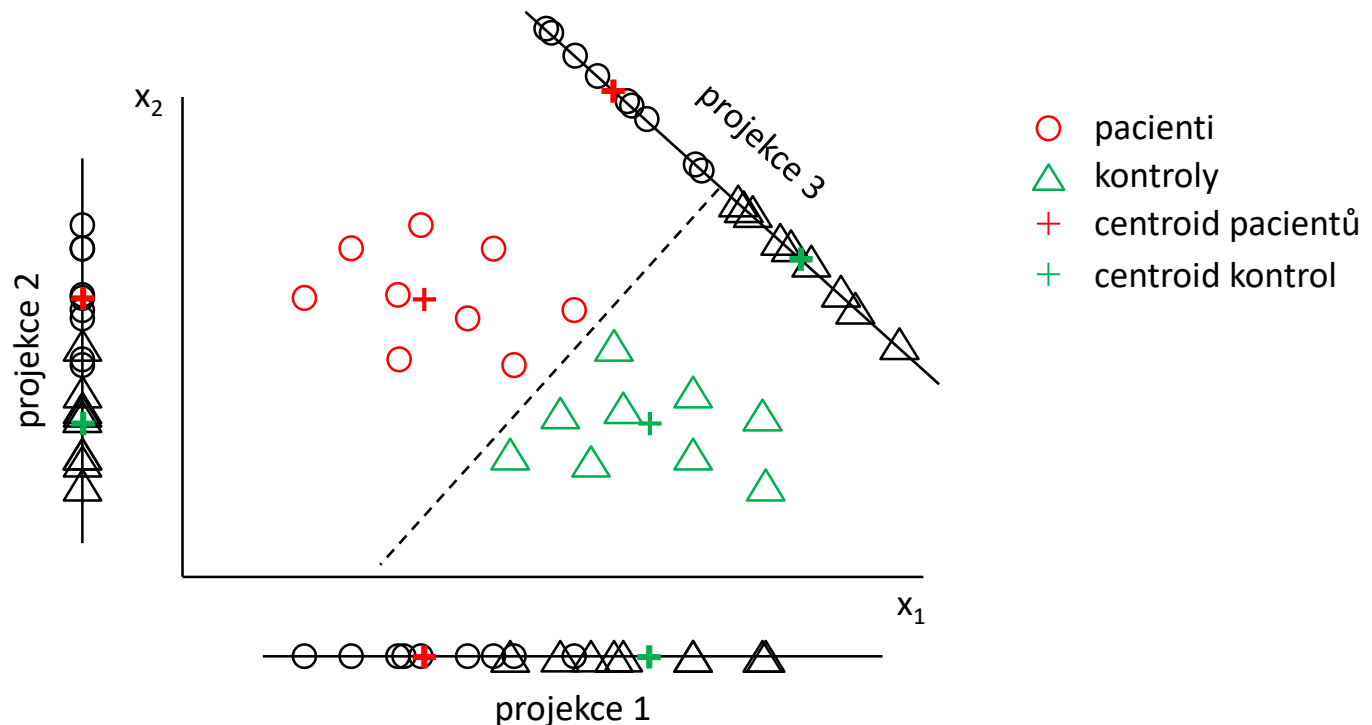
- ve 2-rozměrném prostoru je hranicí křivka (v lineárním případě přímka)
- v 3-rozměrném prostoru plocha (v lineárním případě rovina)

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)

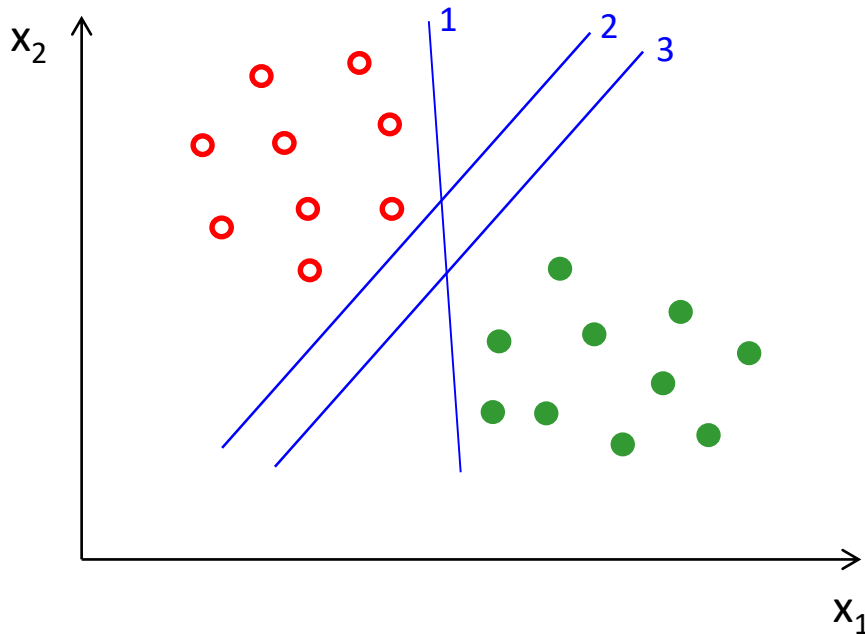
- použití pro lineární klasifikaci
- **princip:** transformace do jednorozměrného prostoru tak, aby se třídy od sebe maximálně oddělily (maximalizace vzdálenosti skupin a minimalizace variability uvnitř skupin)



- **předpoklad:** vícerozměrné normální rozdělení u jednotlivých skupin

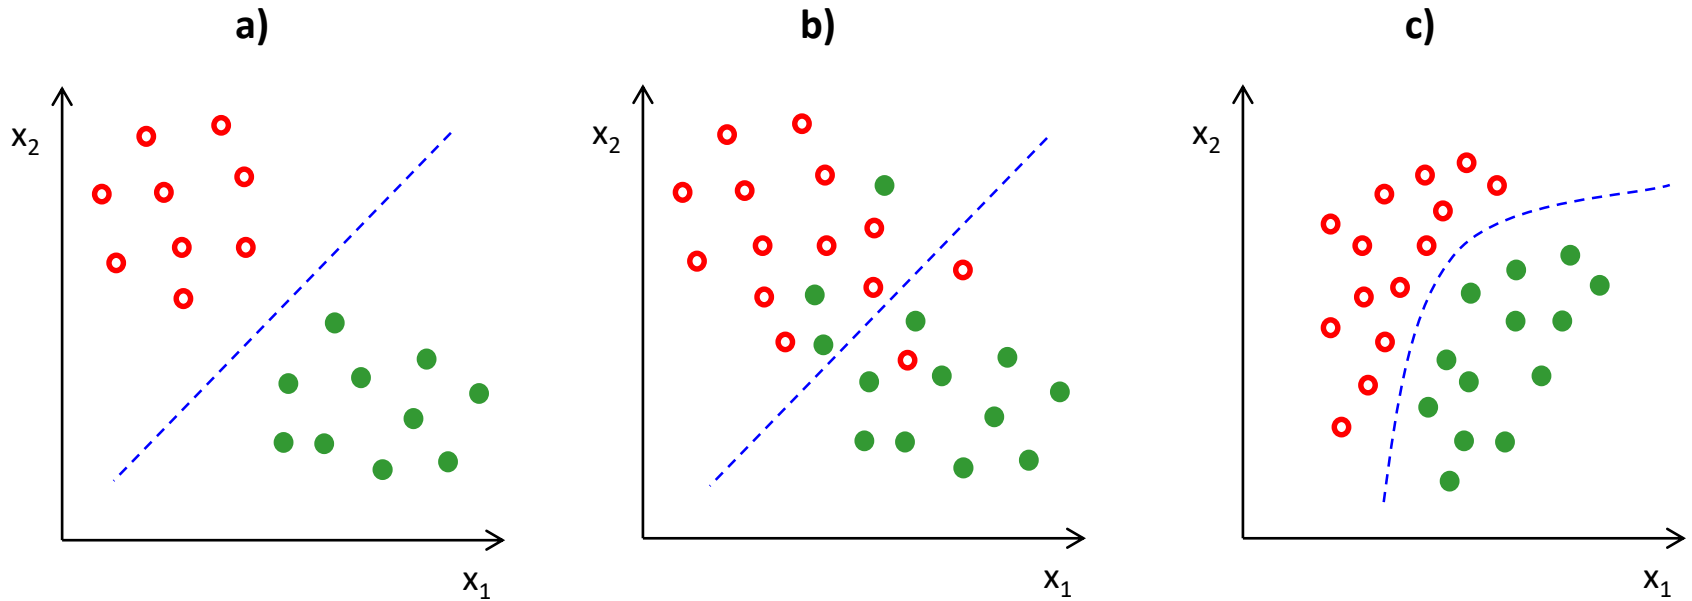
# Metoda podpůrných vektorů (SVM)

- použití pro lineární i nelineární klasifikaci
- **princip:** proložení klasifikační hranice (nadroviny) tak, aby byla v co největší vzdálenosti od subjektů z obou tříd



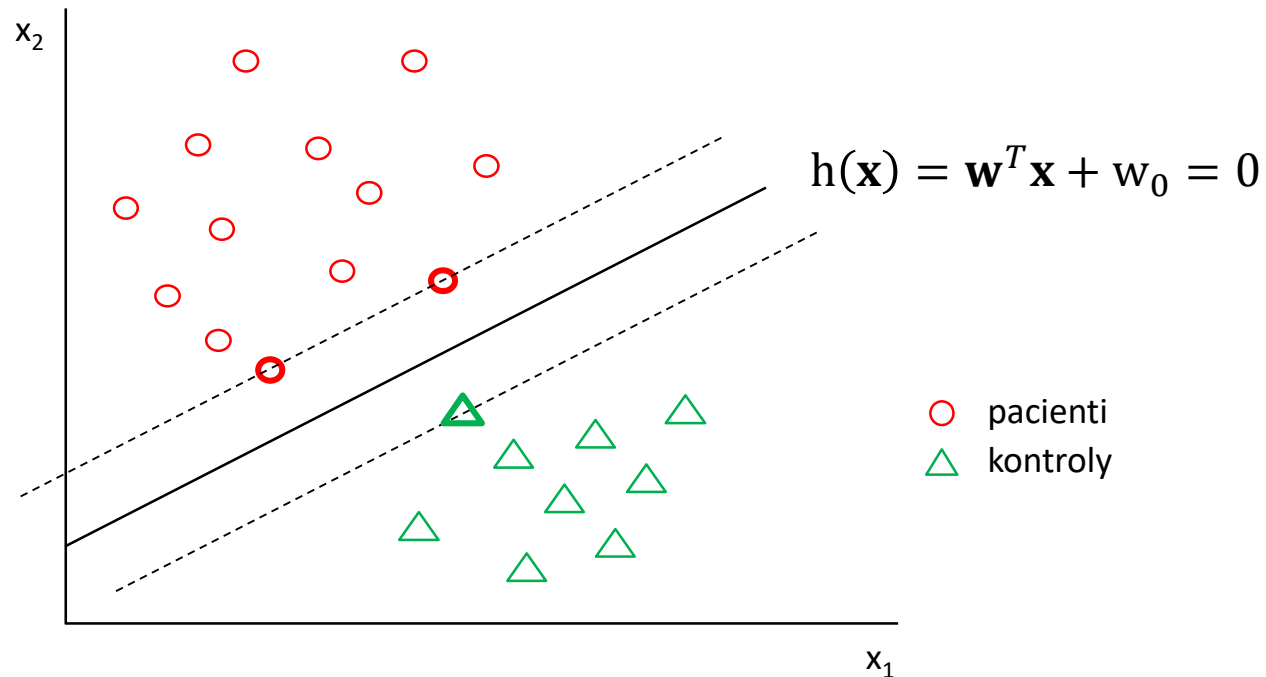
- **výhoda oproti FLDA:** nemá předpoklady o rozdělení dat
- **nevýhoda:** vyžaduje stanovení parametrů (např. C) a případně i typu jádra

# Metoda podpůrných vektorů (SVM) - varianty



- varianty SVM dle typu vstupních dat:
  - a) lineární verze metody podpůrných vektorů pro lineárně separabilní třídy (anglicky *maximal margin classifier*)
  - b) lineární verze metody podpůrných vektorů pro lineárně neseparabilní třídy (anglicky *support vector classifier*)
  - c) nelineární verze metody podpůrných vektorů (anglicky *support vector machine*)

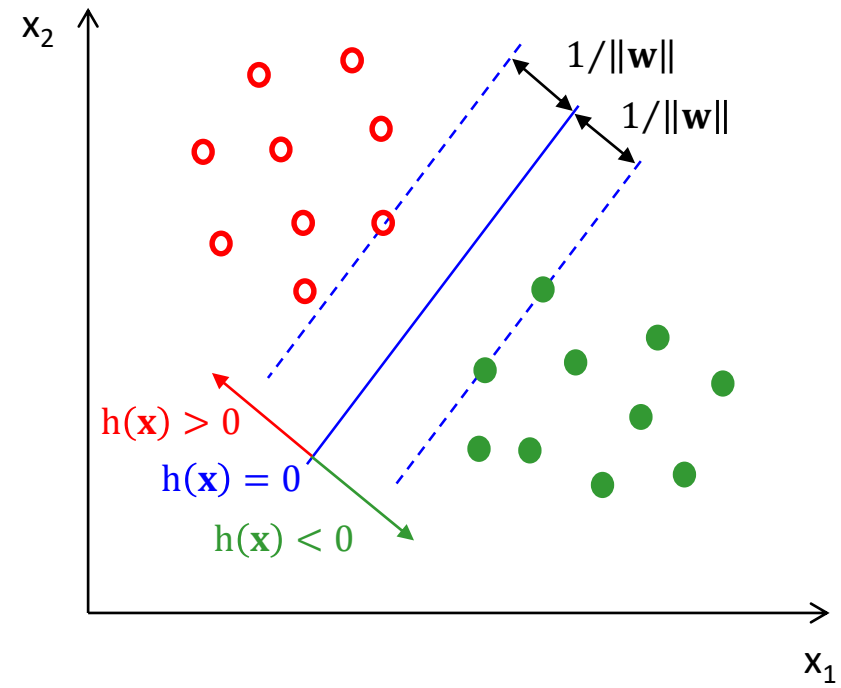
# Lineární SVM – lineárně separabilní třídy



- 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  $\omega_D$ , resp.  $\omega_H$ , 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  $\omega_D$  zvolíme hodnotu výrazu  $\mathbf{w}^T \mathbf{x}_i + w_0$  rovnu +1
- pro nejbližší bod  $\mathbf{x}_j$  ze třídy  $\omega_H$  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  $\omega_D$  a  $\delta_{x_k} = -1$  pro  $\mathbf{x}_k$  ze třídy  $\omega_H$
- hledáme takové hodnoty  $\mathbf{w}$  a  $w_0$ , aby byla celková šířka tolerančního pásma  $\frac{1}{\|\mathbf{w}\|} + \frac{1}{\|\mathbf{w}\|} = \frac{2}{\|\mathbf{w}\|}$  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 Lagrangeových součinitelů

# Lineární SVM – metoda Lagrangeova součinitele

- Chceme minimalizovat výraz  $J(\mathbf{w}, w_0) = \frac{\|\mathbf{w}\|^2}{2}$  za podmínek  $\delta_{x_k}(\mathbf{w}^T \mathbf{x}_k + w_0) \geq 1$
- 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:

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

za podmínek  $\lambda_k [\delta_{x_k}(\mathbf{w}^T \mathbf{x}_k + w_0) - 1] = 0, k = 1, 2, \dots, N$

- tuto Lagrangeovu funkci zderivujeme podle proměnných  $\mathbf{w}$  a  $w_0$  a derivace položíme rovny nule  $\rightarrow$  po dalších úpravách dostaneme soustavu nelin. rovnic:

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

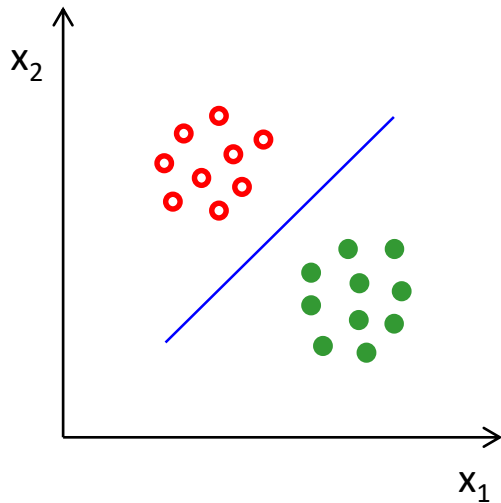
$$\sum_{k=1}^N \lambda_k \delta_{x_k} = 0$$

$\rightarrow$  patrné, že pro výpočet orientace hranice důležité jen ty body, pro které platí  $\lambda_k > 0$

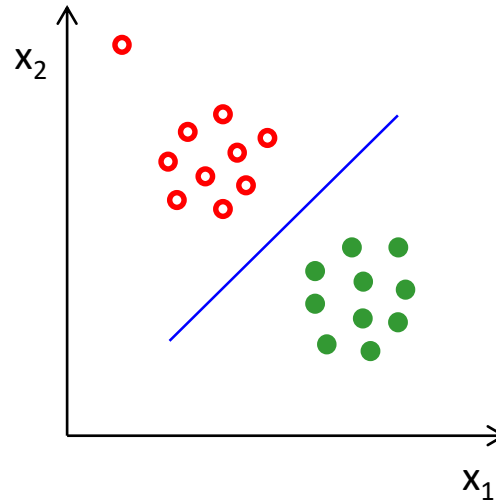
$\rightarrow$  každý takový bod musí splňovat podmínku výše, tedy  $\delta_{x_k}(\mathbf{w}^T \mathbf{x}_k + w_0) - 1 = 0 \rightarrow$  tedy musí ležet přesně na hranici tolerančního pásma

$\rightarrow$  takovým bodům říkáme podpůrné vektory a jen na nich závisí umístění a orientace dělící přímky

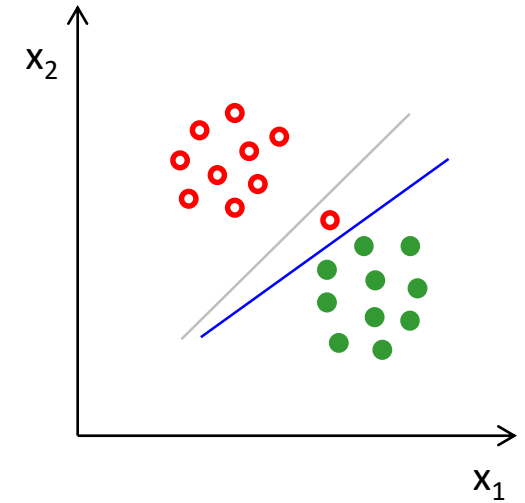
# Lineární SVM – vliv odlehlých hodnot



klasifikace v případě dat  
neobsahujících odlehlé  
hodnoty



klasifikace v případě  
odlehlé hodnoty, která  
není podpurným  
vektorem (poloha  
klasifikační hranice se  
nezmění)



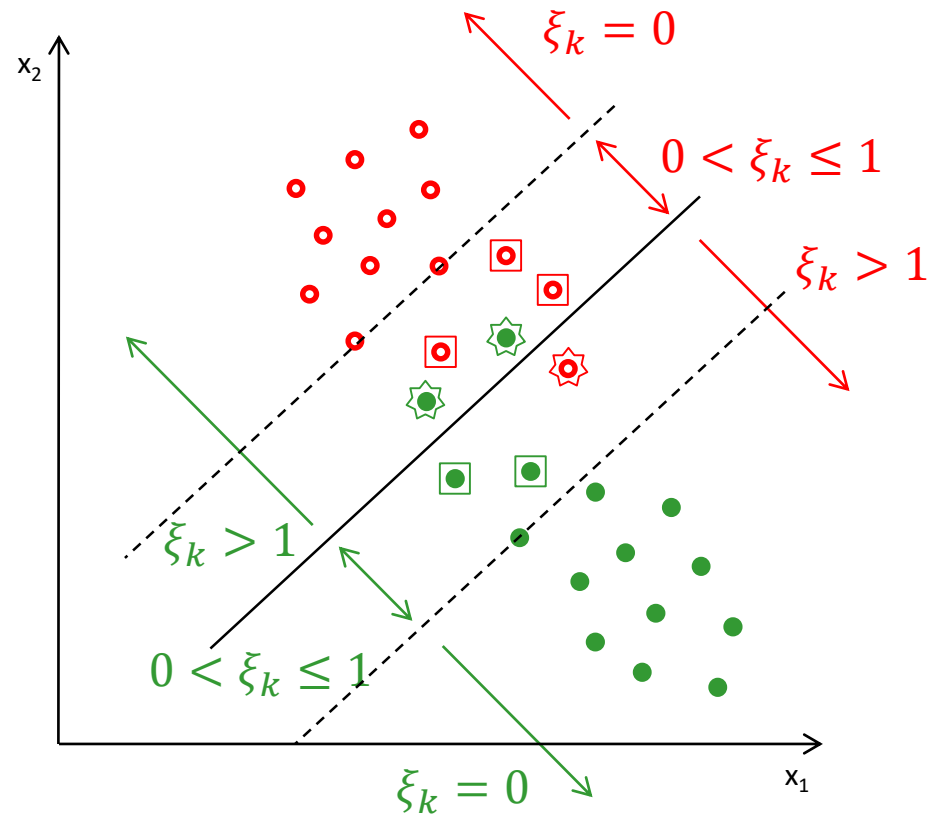
klasifikace v případě  
odlehlé hodnoty, která je  
podpurným vektorem  
(poloha hranice se změní)

→ lepší použít lineární SVM  
pro lineárně neseparabilní  
třídy, kterou tato odlehlá  
hodnota téměř neovlivní

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

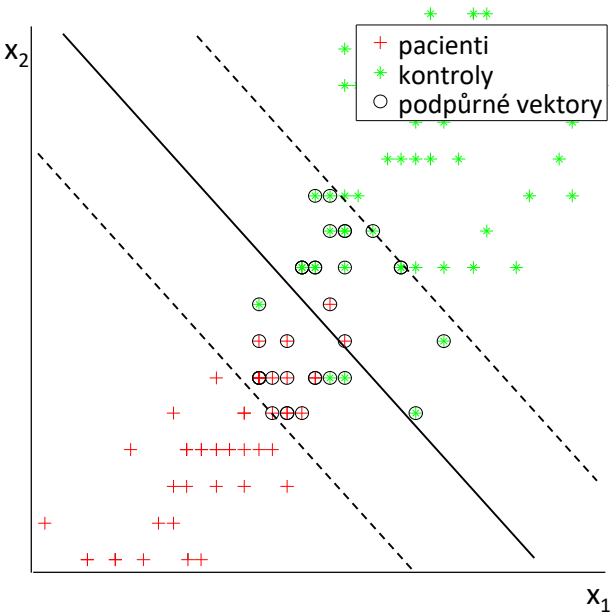
- když chceme najít hranici poskytující co nejrobustnější klasifikaci, musíme se snažit:
  - maximalizovat šířku tolerančního pásma
  - minimalizovat počet subjektů z trénovací množiny, které leží v tolerančním pásmu nebo jsou dokonce špatně klasifikovány (tj. těch, pro které  $\xi_k > 0$ )
- to můžeme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

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

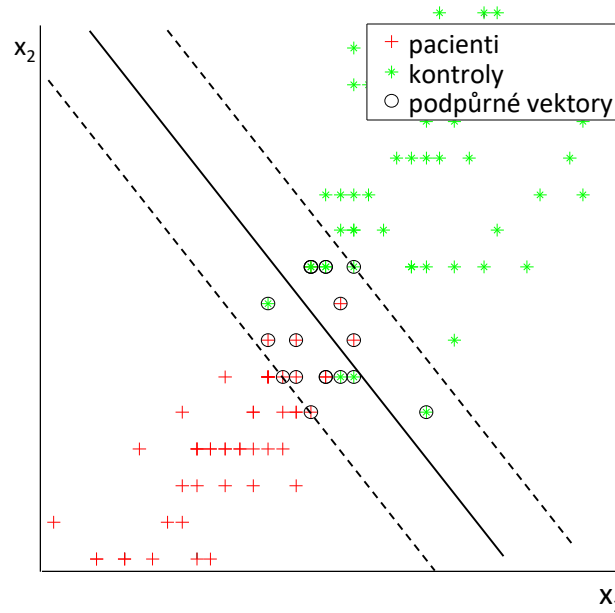
- kde  $C$  vyjadřuje poměr vlivu obou členů kriteriální funkce:
  - **pro nízké hodnoty  $C$**  bude toleranční pásmo širší a počet trénovaných subjektů v tolerančním pásmu a počet chybně klasifikovaných trénovacích subjektů bude vyšší
  - **pro vysoké hodnoty  $C$**  bude toleranční pásmo užší, ale počet trénovaných subjektů v tolerančním pásmu a počet chybně klasifikovaných trénovacích subjektů bude nižší
- řešíme opět pomocí metody Lagrangeova součinitele

# SVM – vliv parametru C

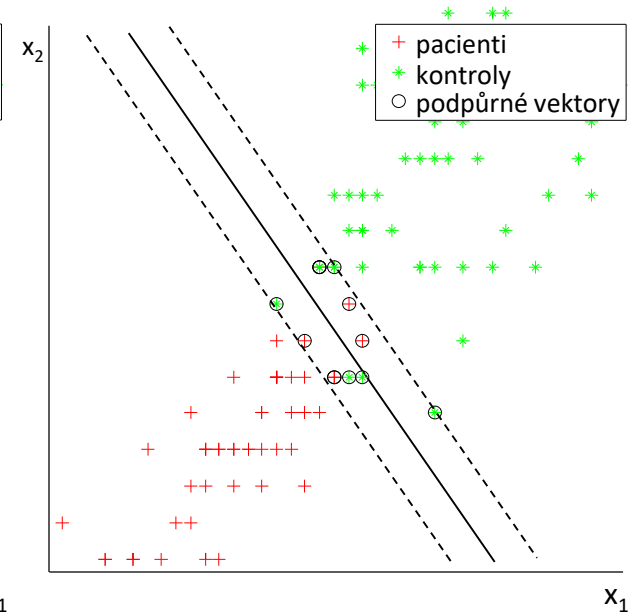
**C = 0.1**



**C = 1**



**C = 10**



- **pro nízké hodnoty C** – toleranční pásmo širší, ale počet trénovaných subjektů v tolerančním pásmu a počet chybně klasifikovaných trénovacích subjektů vyšší
- **pro vysoké hodnoty C** – toleranční pásmo užší, ale počet trénovaných subjektů v tolerančním pásmu a počet chybně klasifikovaných trénovacích subjektů nižší
- zpravidla nevíme, jaká hodnota parametru C pro data nejvhodnější → volba C podle křížové validace

# Lineární SVM – metoda Lagrangeova součinitele

- Chceme minimalizovat  $J(\mathbf{w}, w_0) = \frac{\|\mathbf{w}\|^2}{2} + C \sum_{k=1}^N \xi_k$  za podmínek  $\delta_{x_k}(\mathbf{w}^T \mathbf{x}_k + w_0) \geq 1 - \xi_k$
- 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:

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

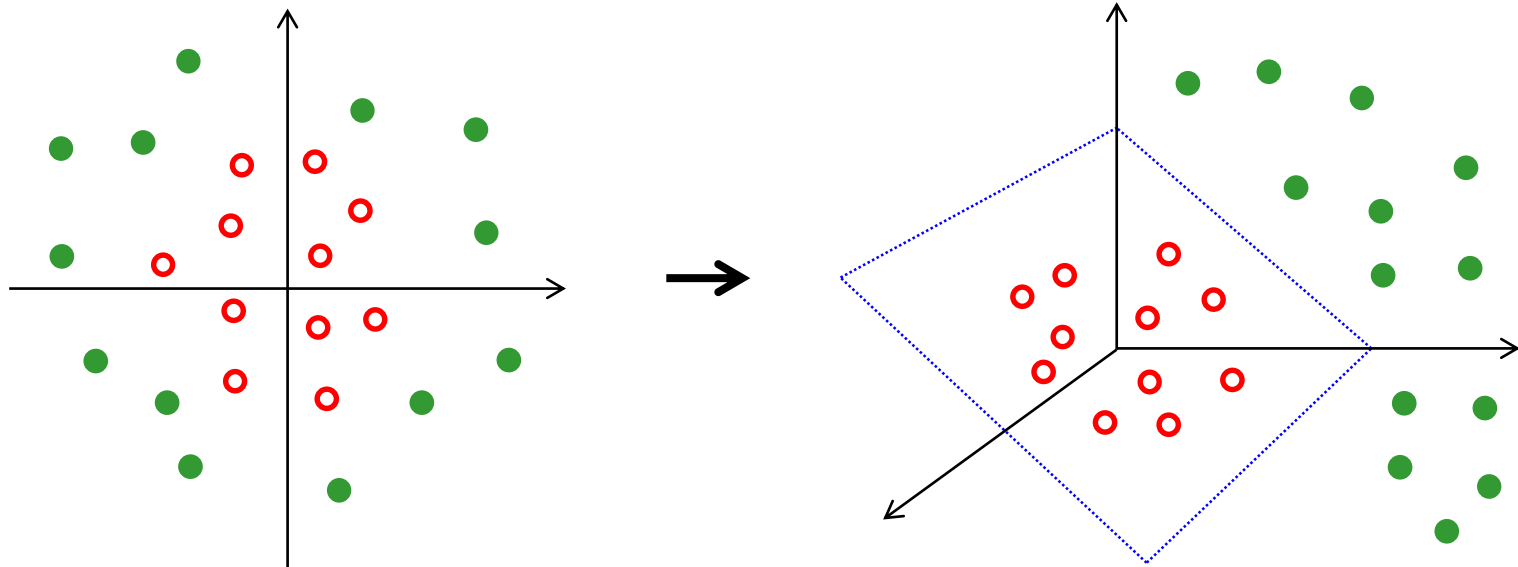
- za podmínek  $\lambda_k [\delta_{x_k}(\mathbf{w}^T \mathbf{x}_k + w_0) - 1 + \xi_k] = 0$  a  $\mu_k \xi_k \geq 0$ , pro  $k = 1, \dots, N$ .
- tuto Lagrangeovu funkci zderivujeme podle proměnných  $\mathbf{w}$ ,  $w_0$  a  $\boldsymbol{\xi}$  a derivace položíme rovny nule  $\rightarrow$  po dalších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

$$\left. \begin{aligned} \mathbf{w} &= \sum_{k=1}^N \lambda_k \delta_{x_k} \mathbf{x}_k & \lambda_k + \mu_k &= C, \\ & & \lambda_k [\delta_{x_k}(\mathbf{w}^T \mathbf{x}_k + w_0) - 1 + \xi_k] &= 0, \\ & & \mu_k \xi_k &= 0. \end{aligned} \right\} \text{ pro } k = 1, \dots, N$$

$$\sum_{k=1}^N \lambda_k \delta_{x_k} = 0$$

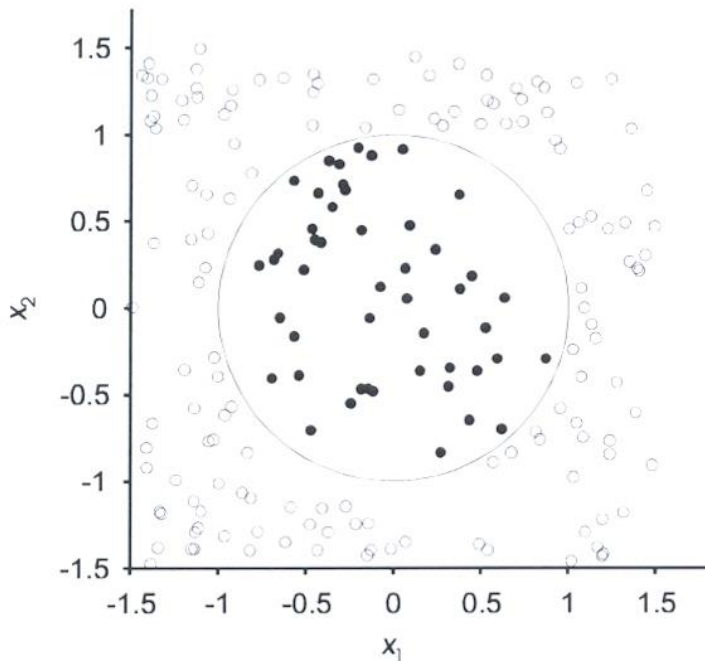
# Nelineární SVM

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

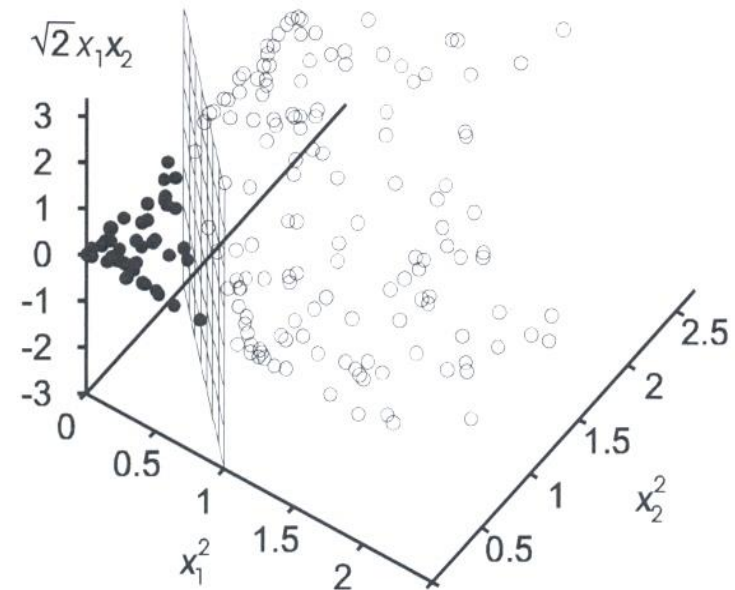




# Nelineární SVM – ukázka 2

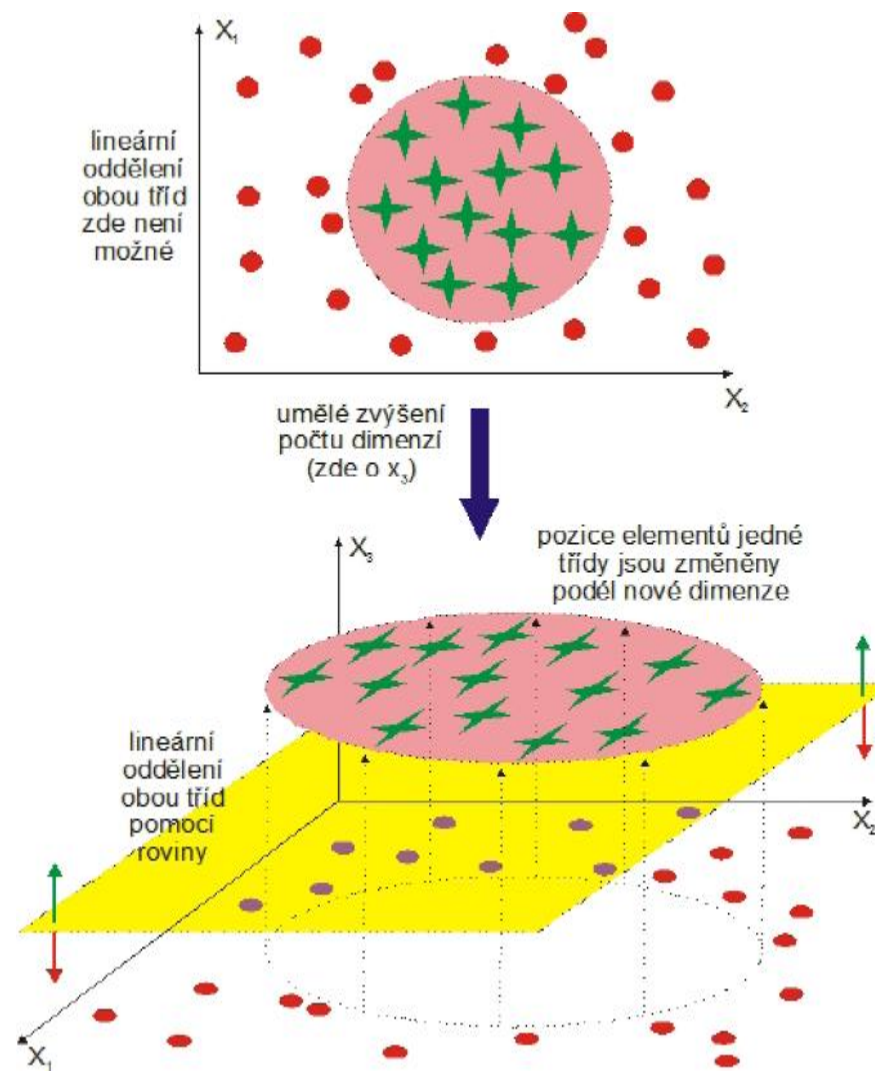


dvourozměrný prostor s  
oddělovací hranicí ve tvaru  
 $x_1^2 + x_2^2 \leq 1$



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

# Nelineární SVM – ukázka 3



# Nelineární SVM

- transformace do nového prostoru může proběhnout navýšením počtu proměnných (např. přidáním kvadratických forem původních proměnných, tedy soubor pak bude obsahovat proměnné  $\mathbf{x}_1, \mathbf{x}_1^2, \mathbf{x}_2, \mathbf{x}_2^2, \dots, \mathbf{x}_p, \mathbf{x}_p^2$ )
- tento přístup však výpočetně náročný  $\rightarrow$  použití jader (*kernels*)
- u lineárního SVM pro lineárně separabilní i neseperabilní třídy lze Lagrangeovu funkci přepsat do podoby

$$L(\mathbf{w}, w_0, \boldsymbol{\lambda}) = \sum_{k=1}^N \lambda_k - \frac{1}{2} \sum_{i,j} \lambda_i \lambda_j \delta_{x_i} \delta_{x_j} \mathbf{x}_i^T \mathbf{x}_j$$

- kde si skalární součin  $\mathbf{x}_i^T \mathbf{x}_j$  můžeme zapsat obecně jako  $K(\mathbf{x}_i, \mathbf{x}_j)$ , kde  $K$  je nějaká funkce, kterou nazveme jádro

- typy jader:

– lineární jádro:  $K(\mathbf{x}_i, \mathbf{x}_j) = \mathbf{x}_i^T \mathbf{x}_j \rightarrow$  lineární SVM

– polynomiální jádro stupně  $d$ :  $K(\mathbf{x}_i, \mathbf{x}_j) = (1 + \mathbf{x}_i^T \mathbf{x}_j)^d = (1 + \sum_{l=1}^p x_{il} x_{jl})^d$

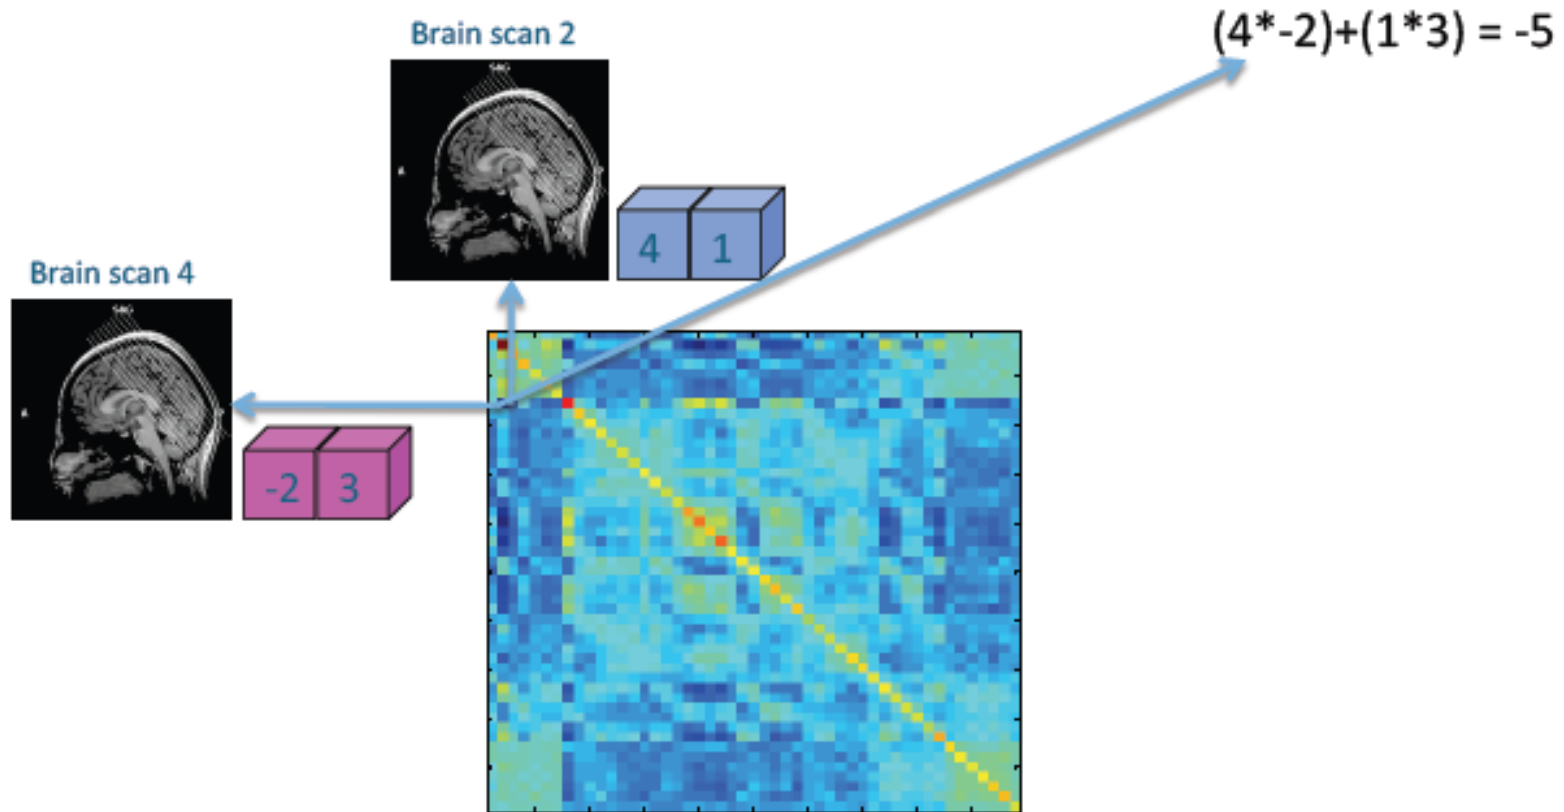
– radiální bázové jádro:  $K(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(-\gamma \sum_{l=1}^p (x_{il} - x_{jl})^2\right)$

– atd.

nelineární  
SVM

# Nelineární SVM – jádro

Anglicky: kernel

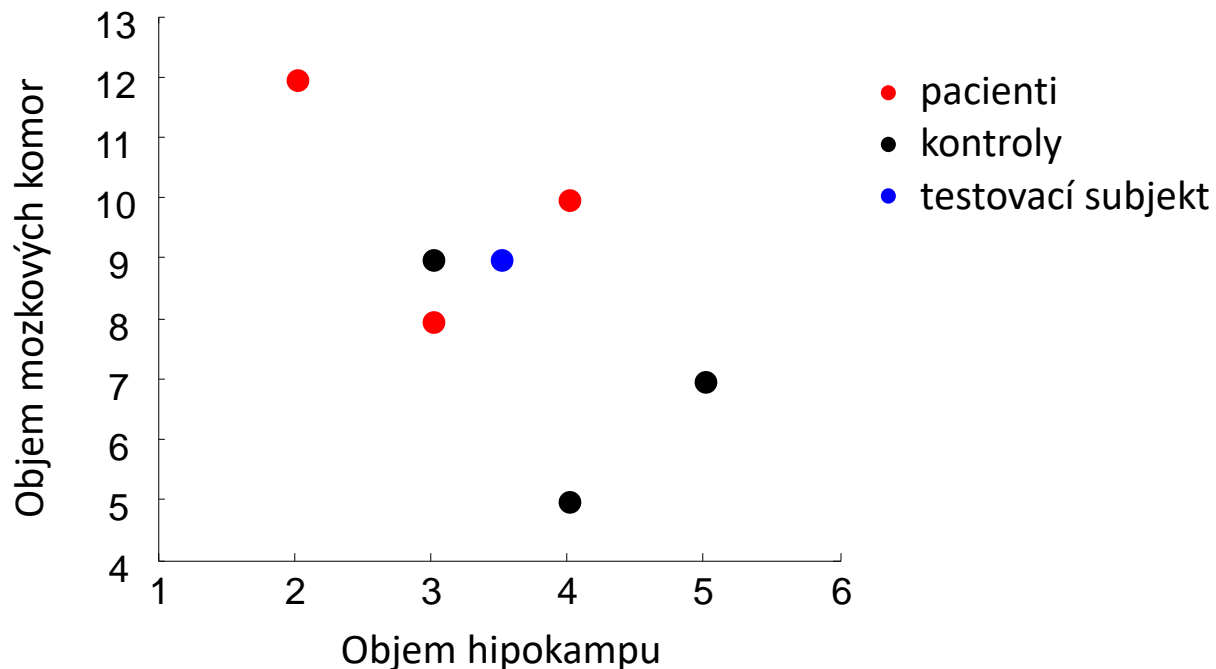


# Příklad

**Příklad:** Bylo provedeno měření objemu hipokampu a mozkových komor

(v  $\text{cm}^3$ ) 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  $\lambda_5$  jsou nenulové. Vypočítáme orientaci hranice:

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

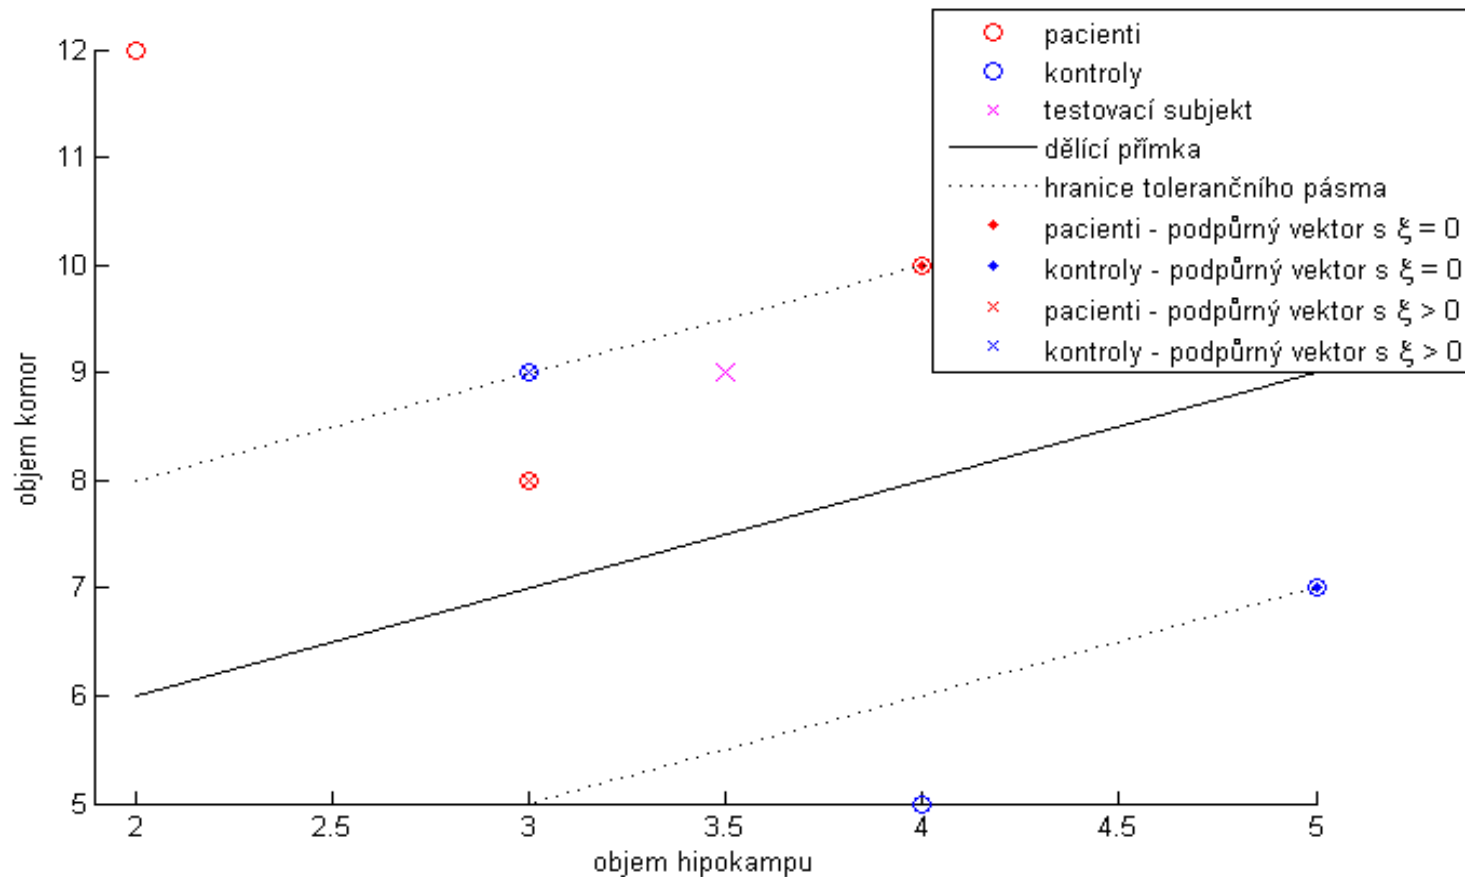
- Pokud zvolíme takové  $\mathbf{x}_k$ , pro které platí  $0 < \lambda_k < C$ , tak podle vztahu  $\lambda_k + \mu_k = C$  musí být  $\mu_k > 0$  a odtud podle vztahu  $\mu_k \xi_k = 0$  plyne, že  $\xi_k = 0$ . Vzorec se tak zjednoduší na  $\delta_{x_k} (\mathbf{w}^T \mathbf{x}_k + w_0) = 1$ . Tedy 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  $\lambda = [0, 3,6371, 8,7629, 2,0371, 10,$
- 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  $\lambda_6$  jsou nenulové. Vypočítáme orientaci hranice:

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

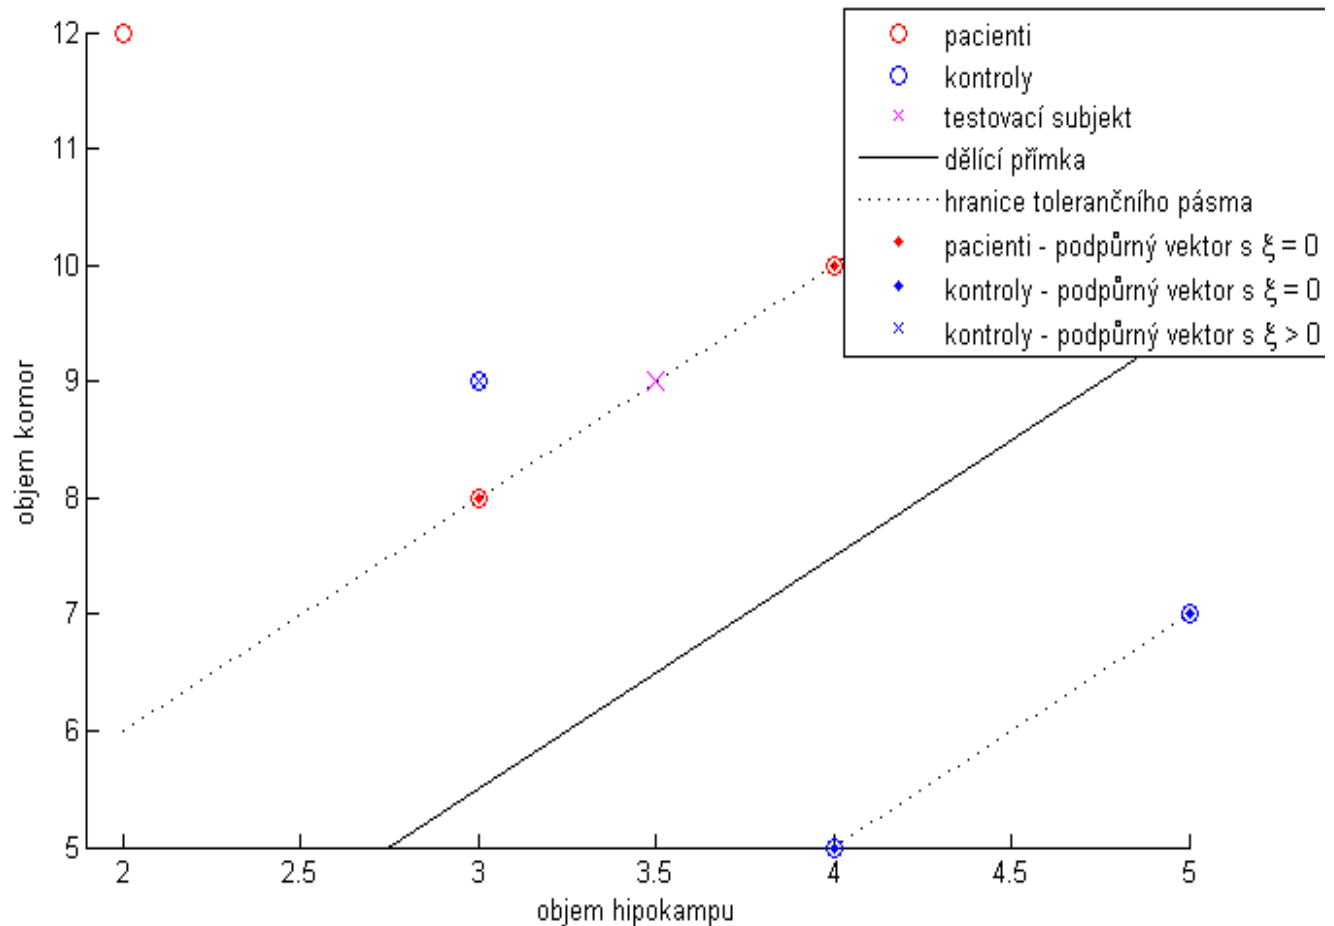
- Polohu dělicí přímky určíme opět ze  $\delta_{x_k} (\mathbf{w}^T \mathbf{x}_k + w_0) = 1$ . Tedy například pro  $\mathbf{x}_2$  ( $0 < \lambda_2 = 3,6371 < C = 10$ ):

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

- 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 chybně subjekt  $\mathbf{x}_5$ :

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

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

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

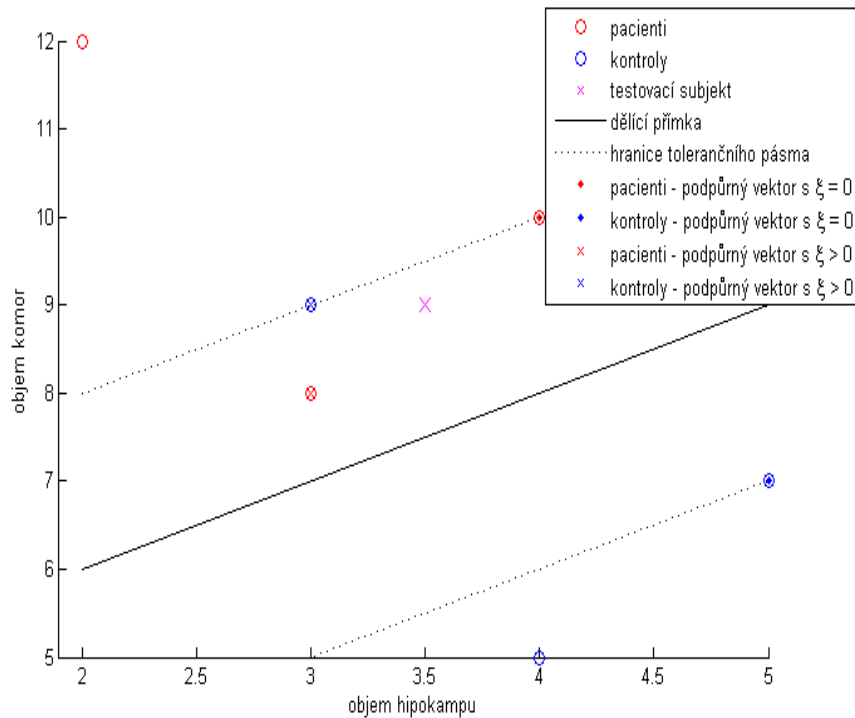
$$\mathbf{w}^T \mathbf{x}_4 + w_0 = \begin{bmatrix} -\frac{4}{5} & \frac{2}{5} \end{bmatrix} \begin{bmatrix} 5 \\ 7 \end{bmatrix} + \frac{1}{5} = -\frac{20}{5} + \frac{14}{5} + \frac{1}{5} = -\frac{5}{5} = -1$$

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

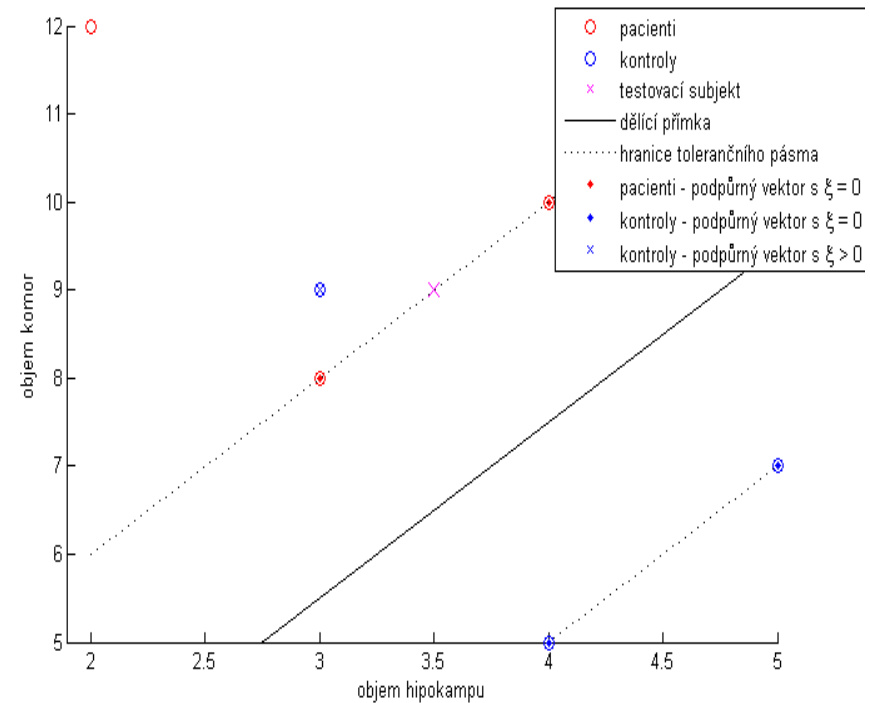
$$\mathbf{w}^T \mathbf{x}_6 + w_0 = \begin{bmatrix} -\frac{4}{5} & \frac{2}{5} \end{bmatrix} \begin{bmatrix} 4 \\ 5 \end{bmatrix} + \frac{1}{5} = -\frac{16}{5} + \frac{10}{5} + \frac{1}{5} = -\frac{5}{5} = -1$$

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

$C = 1$ :



$C = 10$ :



Detailní řešení příkladu zde:

[http://portal.matematickabiologie.cz/res/file/Vicerozmerky%20-%20kap11\\_4%20-%20SVM%20-%20reseni%20prikladu\(1\).pdf](http://portal.matematickabiologie.cz/res/file/Vicerozmerky%20-%20kap11_4%20-%20SVM%20-%20reseni%20prikladu(1).pdf)

# Sekvenční 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	pohlavi	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

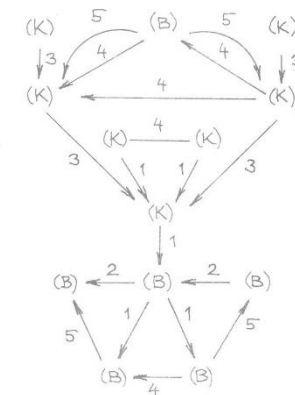


PRIMITIVA :

(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

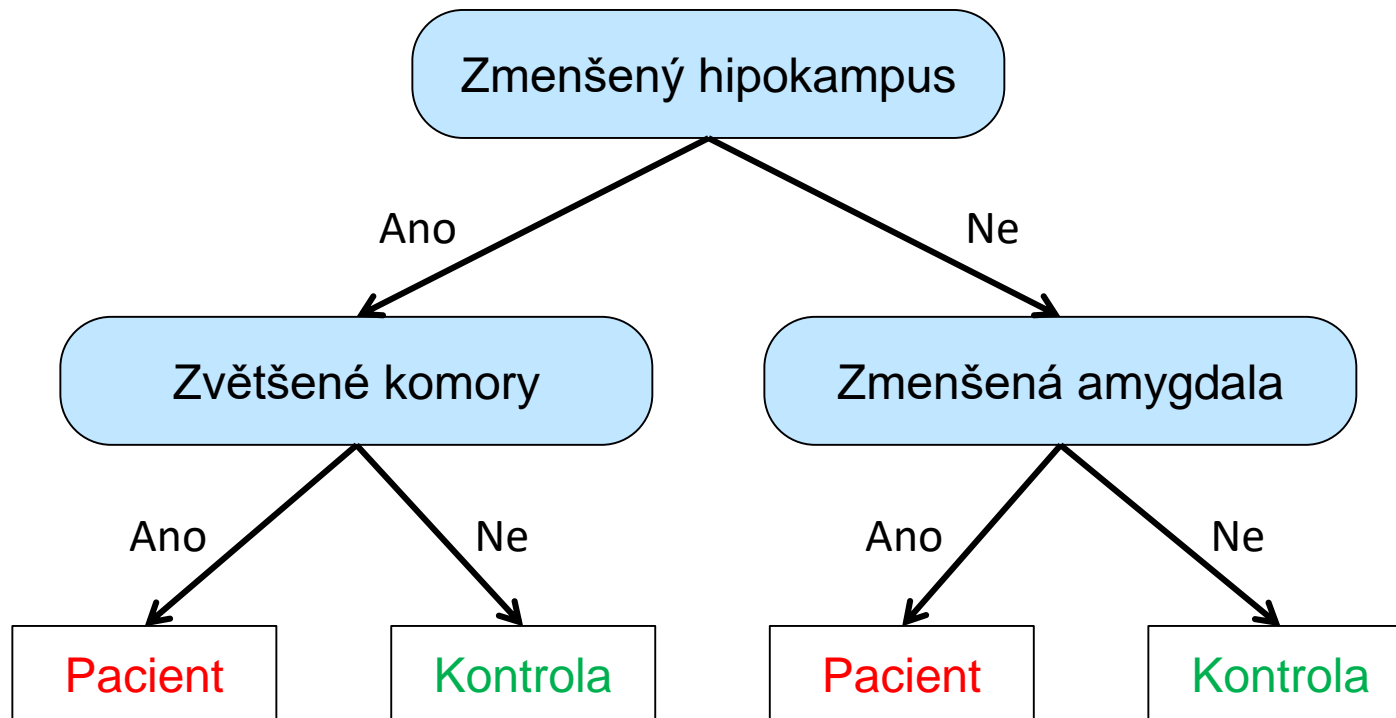
# Sekvenční klasifikace - motivace

- až dosud (bayesovské klasifikátory, klasifikátory s diskriminační hranicí, s minimální vzdáleností, ...) – pevný konstantní počet příznaků
- kolik a jaké proměnné?
  - 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 klasifikačních stromů a lesů
  - 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

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

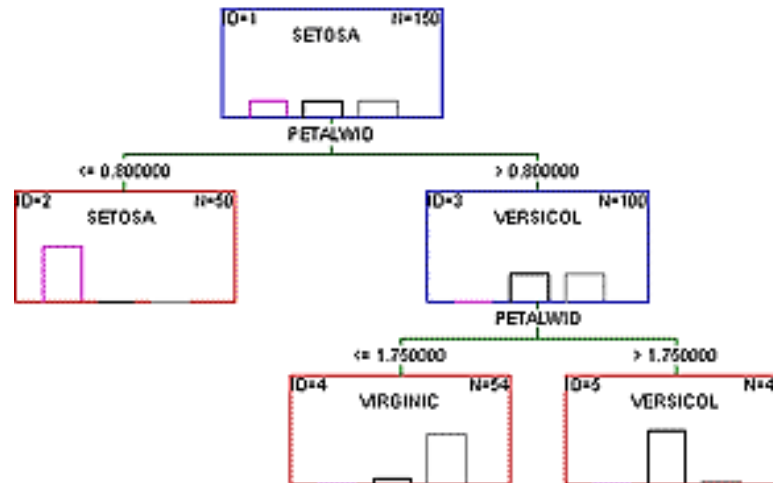


Patří mezi metody sekvenční klasifikace.

Podrobnější informace: <https://www.iba.muni.cz/res/file/ucebnice/komprdova-rozhodovaci-stromy-lesy.pdf>

# Klasifikační (rozhodovací) stromy - doplnění

- kategoriální proměnné – rozdělení se provede podle kategorií (viz obrázek na předchozím slidu)
- spojité proměnné – najde se nejlepší dělicí hodnota a pak dojde k rozdělení; proměnná se může použít i vícekrát s různými dělicími hodnotami



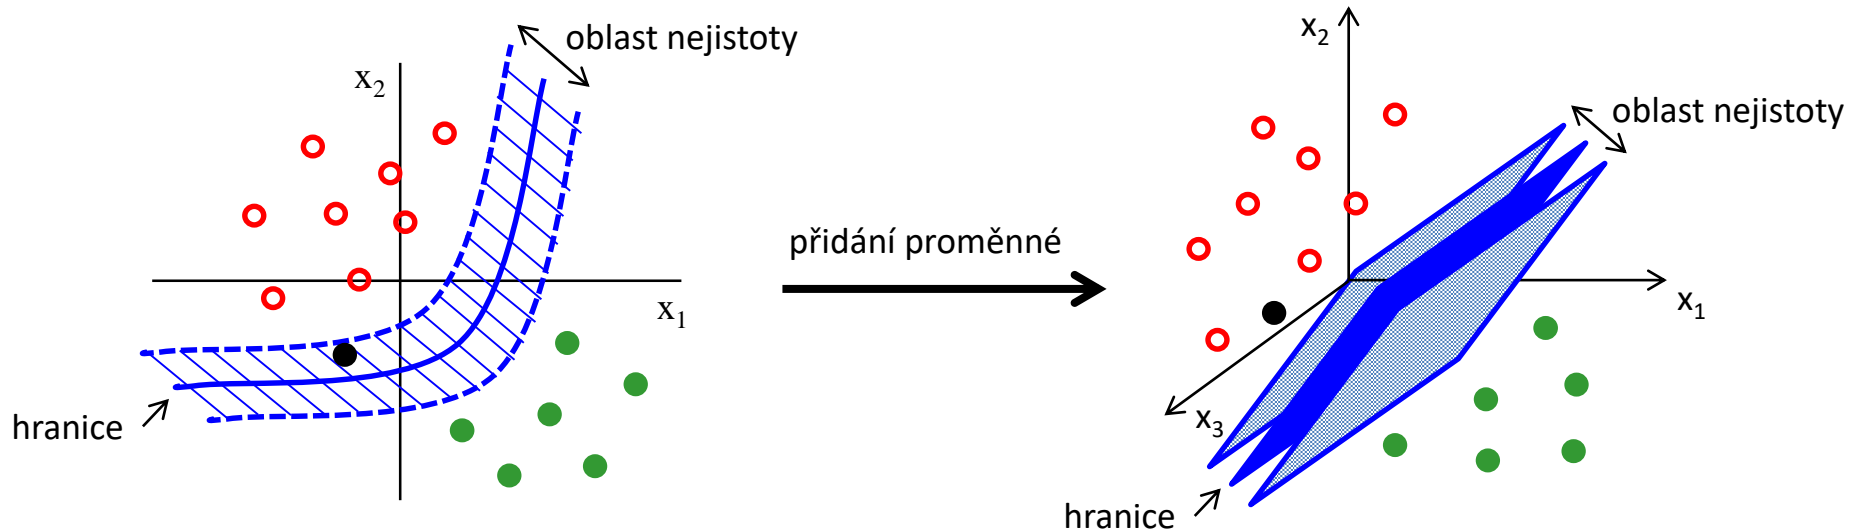
- postup vytvoření stromu:
  - nejprve se vytvoří strom, kde v „listech“ (terminálních uzlech) jsou vždy jen subjekty z jedné skupiny
  - následuje tzv. „prořezávání stromu“ – odstraní se ty uzly, které jsou nejvíce zbytečné (příliš velký strom je totiž zpravidla přeučeny a funguje špatně na testovacích datech)

# Klasifikační (rozhodovací) lesy

- klasifikační lesy – použití více klasifikačních stromů ke klasifikaci
- použije se zpravidla jen část dat na vytvoření (tzn. naučení) jednotlivých stromů:
  - náhodně vybrané subjekty
  - náhodně vybrané proměnné
- finální klasifikace testovacích dat se provede „hlasováním“ výsledků z klasifikace pomocí jednotlivých stromů

# Klasifikace s rostoucím počtem proměnných

**Princip:** Seřadíme proměnné podle množství informace, které nesou, a pak opakovaně provádíme klasifikaci objektu (subjektu) s postupně se zvyšujícím počtem proměnných, dokud objekt nejsme schopni jednoznačně zařadit

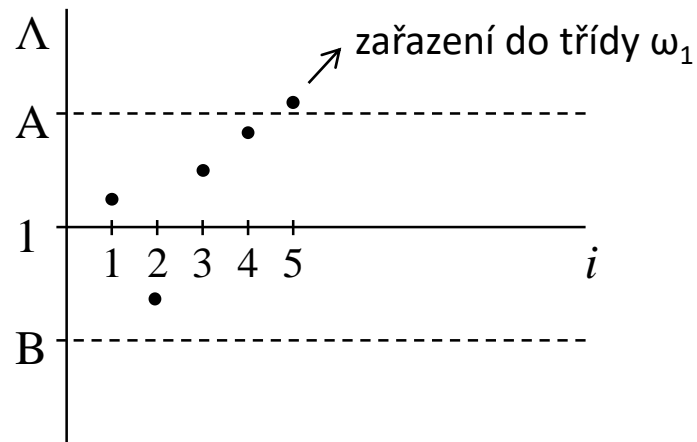


Kritéria pro řízení sekvenčního klasifikátoru:

- Waldovo kritérium
- Reedovo kritérium
- Modifikované Waldovo kritérium
- Modifikované Reedovo kritérium

# Waldovo kritérium

- objekt  $\mathbf{x}$  popsán množinou hodnot proměnných  $\{x_1, x_2, \dots\}$
  - mějme  $p(x_1, x_2, \dots, x_i | \omega_1)$  a  $p(x_1, x_2, \dots, x_i | \omega_2)$ , což 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  $\omega_1$  a  $\omega_2$
  - A a B jsou konstanty ( $0 < B < 1 < A < \infty$ )
  - spočítáme 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. pokud je  $\Lambda_i \leq B$ , pak se objekt  $\mathbf{x}$  zařadí do třídy  $\omega_2$  a proces se ukončí
  2. pokud je  $\Lambda_i \geq A$ , pak se objekt  $\mathbf{x}$  zařadí do třídy  $\omega_1$  a proces se ukončí
  3. pokud je  $\Lambda_i \in (B, A)$ , přidáme další proměnnou (příznak)  $x_{i+1}$  a proces se opakuje

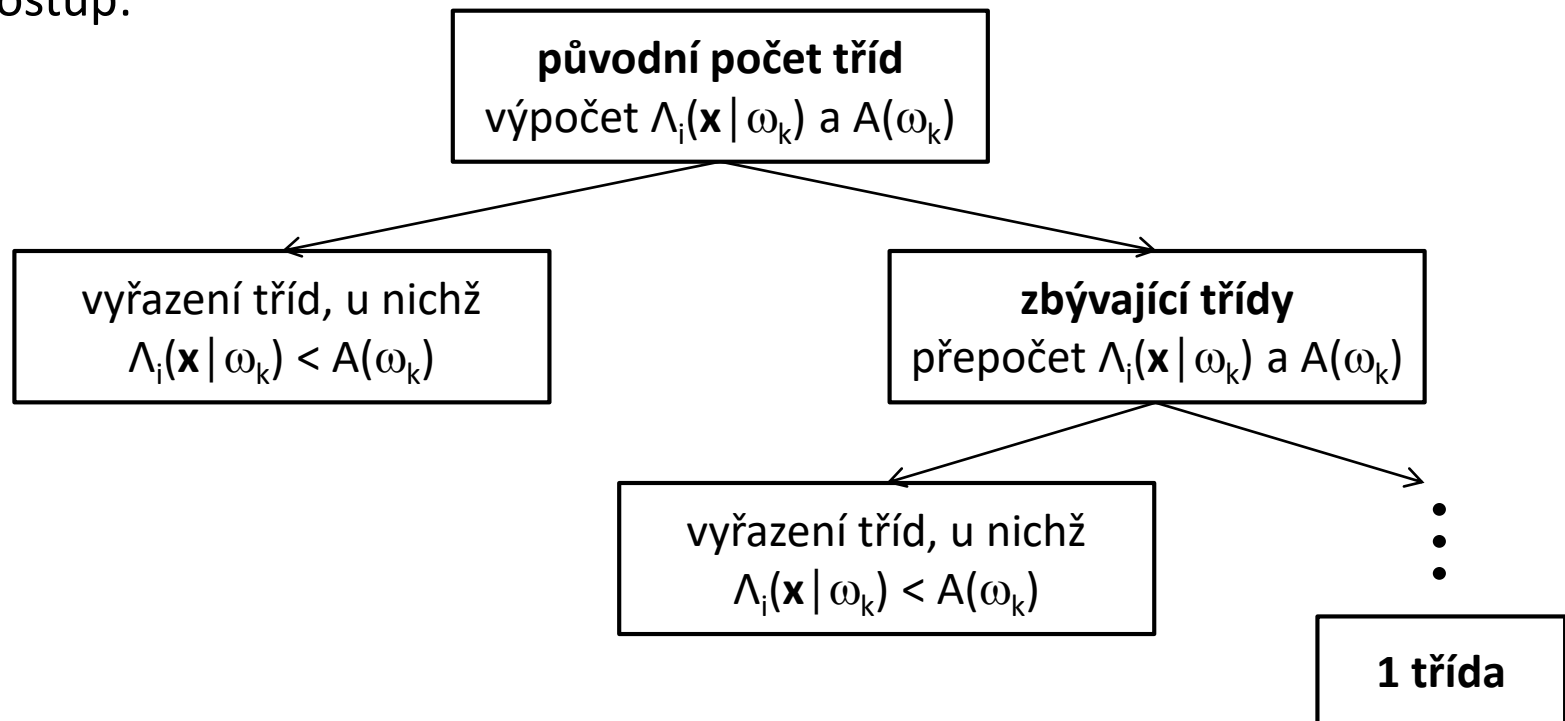


Optimální vlastnosti Waldova kritéria, protože:

- průměrný počet proměnných je menší nebo stejný jako u kritérií s pevným počtem proměnných
- průměrný počet kroků je menší než u jiných sekvenčních kritérií

# Reedovo kritérium

- u více než 2 klasifikačních tříd
- založeno na výpočtu zobecněného věrohodnostního poměru pro  $k$ -tou třídu  $\Lambda_i(\mathbf{x} | \omega_k)$  a mezní hodnoty  $k$ -té třídy  $A(\omega_k)$
- postup:



- pokud není v některém kroku možné vyloučit žádnou třídu, zvýší se počet proměnných o 1 a proces pokračuje od začátku

# Modifikované Waldovo kritérium

- přes optimální vlastnosti Waldova kritéria může nastat:
  - počet kroků pro některé objekty velký, i když střední hodnota nízká
  - střední hodnota počtu kroků velká, pokud chceme malé pravděpodobnosti chybných rozhodnutí
- 2 možnosti řešení:
  - a) po určitém počtu kroků se sekvenční výpočet přeruší a dokončí se na základě nějakého rozhodnutí vycházejícího z nějakého kritéria založeného na pevném počtu příznaků
  - b) zavedení proměnných hranic  $A(i)$  a  $B(i)$   
$$\text{např. } A(i) = a \left(1 - \frac{i}{i_{\max}}\right)^{q_1} \quad a \quad B(i) = -b \left(1 - \frac{i}{i_{\max}}\right)^{q_2}$$

# Modifikované Reedovo kritérium

- zobecněný věrohodnostní poměr se srovnává s prahem  $G_r(i) = g_r \left(1 - \frac{i}{i_{\max}}\right)^{q_r}$
- přičemž pokud  $\Lambda_i(\mathbf{x} | \omega_r) < G_r(i)$ , třída  $\omega_r$  vyloučena z dalšího rozhodování
- jinak je postup stejný jako u klasického Reedova kritéria



# Poznámka

---

- nelze dopředu říci, která klasifikační metoda bude pro daná data fungovat nejlépe → potřebné vyzkoušet více klasifikačních metod a zvolit nejvhodnější pro daná data
- u velkých datových souborů je obtížné dopředu určit, zda je možné data oddělit lineárně nebo ne → potřebné vyzkoušet lineární i nelineární klasifikační metody

# 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“



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ