

Lineární klasifikátory

Lineární klasifikátory

- obsah:
 - perceptronový algoritmus
 - základní verze
 - varianta perceptronového algoritmu
 - přihrádkový algoritmus
 - podpůrné vektorové stroje

Lineární klasifikátor

- navrhnout lineární klasifikátor bez ohledu na rozdělení dat
 - výhoda
 - jednoduché
 - typicky výpočetně nenáročné
 - předpoklad
 - trénovací data jsou lineárně klasifikovatelná
 - omezení
 - klasifikace do dvou tříd ω_1 a ω_2 v d -dimenzionálním prostoru

- lineární klasifikátor ... nadrovina

$$g(\mathbf{x}) = \mathbf{w}^T \cdot \mathbf{x} + w_0 = 0$$

kde

d ... dimenze vstupního prostoru

$\mathbf{w} = (w_1, \dots, w_d)$... váhový vektor

w_0 ... práh

Lineární klasifikátor

- navrhnout lineární klasifikátor bez ohledu na rozdělení dat
 - výhoda
 - jednoduché
 - typicky výpočetně nenáročné
 - předpoklad
 - trénovací data jsou lineárně klasifikovatelná
 - omezení
 - klasifikace do dvou tříd ω_1 a ω_2 v d -dimenzionálním prostoru

- lineární klasifikátor ... **nadrovina**

$$g(\mathbf{x}) = \mathbf{w}^T \cdot \mathbf{x} + w_0 = 0$$

kde

d ... dimenze vstupního prostoru

$\mathbf{w} = (w_1, \dots, w_d)$... **váhový vektor**

w_0 **práh**

Lineární klasifikátor


- nadrovina

$$g(\mathbf{x}) = \mathbf{w}^T \cdot \mathbf{x} + w_0 = 0$$

- vzdálenost z bodu \mathbf{x} od nadroviny

$$z = \frac{|g(\mathbf{x})|}{\|\mathbf{w}\|}$$

- rozdělení prostoru na dvě části
 - jedna strana ... $g(\mathbf{x}) > 0$
 - druhá strana ... $g(\mathbf{x}) < 0$



Perceptronový algoritmus

- cíl
 - nalezení parametrů \mathbf{w} a w_0 dělící nadroviny
- lineárně separabilní množiny
 - existuje nadrovina $\mathbf{w}^{*T} \cdot \mathbf{x} = 0$
 - $\mathbf{w}^{*T} \cdot \mathbf{x} > 0$ pro každý \mathbf{x} z ω_1
 - $\mathbf{w}^{*T} \cdot \mathbf{x} < 0$ pro každý \mathbf{x} z ω_2
- vztah platí i pro nadroviny neprocházející počátkem
 - $\mathbf{w}^{*T} \cdot \mathbf{x} + w_0^* = 0$
 - zavede se rozšířený $(d+1)$ -dimenzionální prostor
 - $\mathbf{w}' \equiv (\mathbf{w}^*, w_0^*)$
 - $\mathbf{x}' \equiv (\mathbf{x}, 1)$
 - a pak
 - $\mathbf{w}^{*T} \cdot \mathbf{x} + w_0^* = \mathbf{w}'^T \cdot \mathbf{x}'$

Perceptronový algoritmus

- cíl
 - nalezení parametrů \mathbf{w} a w_0 dělící nadroviny
- lineárně separabilní množiny
 - existuje nadrovina $\mathbf{w}^{*T} \cdot \mathbf{x} = 0$
 - $\mathbf{w}^{*T} \cdot \mathbf{x} > 0$ pro každý \mathbf{x} z ω_1
 - $\mathbf{w}^{*T} \cdot \mathbf{x} < 0$ pro každý \mathbf{x} z ω_2
- vztah platí i pro nadroviny neprocházející počátkem
 - $\mathbf{w}^{*T} \cdot \mathbf{x} + w_0^* = 0$
 - zavede se rozšířený $(d+1)$ -dimenzionální prostor
 - $\mathbf{w}' \equiv (\mathbf{w}^*, w_0^*)$
 - $\mathbf{x}' \equiv (\mathbf{x}, 1)$
 - a pak
 - $\mathbf{w}^{*T} \cdot \mathbf{x} + w_0^* = \mathbf{w}'^T \cdot \mathbf{x}'$

Perceptronový algoritmus – ztrátová funkce

- perceptronový algoritmus
 - příklad optimalizačního problému
 - ztrátová funkce

- ztrátová funkce

$$J(\mathbf{w}) = \sum_{\mathbf{x} \in Y} (\delta_{\mathbf{x}} \cdot \mathbf{w}^T \cdot \mathbf{x})$$

chybně klasifikované
trénovací vzory

- parametr $\delta_{\mathbf{x}}$
 - -1 pro bod \mathbf{x} z ω_1
 - +1 pro bod \mathbf{x} z ω_2

- $J(\mathbf{w})$ nezáporná

- $J(\mathbf{w}) = 0$... $Y = \emptyset$
- $J(\mathbf{w}) > 0$... (\mathbf{x} je z ω_1 & \mathbf{x} klasifikován chybně) OR (\mathbf{x} je z ω_2 & \mathbf{x} klasifikován chybně)

- $J(\mathbf{w})$ spojitá po částech lineární funkce

- body, kde se mění počet chybně klasif. vzorů → gradient není definován

Perceptronový algoritmus – odvození 1

- iterativní algoritmus pro minimalizaci ztrátové funkce
 - metoda snižování gradientu

$$\mathbf{w}(t+1) = \mathbf{w}(t) - \rho_t \frac{\partial J(\mathbf{w})}{\partial \mathbf{w}} \Big|_{\mathbf{w}=\mathbf{w}(t)}$$

$\mathbf{w}(t)$... odhad váhového vektoru v t -té iteraci

ρ_t ... posloupnost reálných čísel ... parametr učení

- derivace ztrátové funkce (tam, kde je definována)

$$\frac{\partial J(\mathbf{w})}{\partial \mathbf{w}} = \sum_{\mathbf{x} \in Y} \delta_{\mathbf{x}} \cdot \mathbf{x}$$

- po dosazení

$$\mathbf{w}(t+1) = \mathbf{w}(t) - \rho_t \cdot \sum_{\mathbf{x} \in Y} \delta_{\mathbf{x}} \cdot \mathbf{x}$$

Perceptronový algoritmus – odvození 2

- perceptronový algoritmus

$$\mathbf{w}(t+1) = \mathbf{w}(t) - \rho_t \cdot \sum_{x \in Y} \delta_x \cdot \mathbf{x}$$


$\mathbf{w}(0)$ libovolně inicializován

$\sum_{x \in Y} \delta_x \cdot \mathbf{x}$... vektor „opravy“ z nesprávně klasifikovaných vzorů

→ proces učení opakován, dokud nejsou všechny trénovací vzory klasifikovány správně

Perceptronový algoritmus – geometrická interpretace

- geometrická interpretace



Perceptronový algoritmus – konvergence

- podmínky konvergence ... ρ_t

$$\lim_{t \rightarrow \infty} \sum_{k=0}^t \rho_k = \infty$$

$$\lim_{t \rightarrow \infty} \sum_{k=0}^t \rho_k^2 < \infty$$

- např. $\rho_t = c / t$, kde c je konstanta
- volba ρ_t ... rychlost konvergence \rightarrow rychlost algoritmu
- perceptronový algoritmus zkonverguje k řešení v konečném počtu kroků
 - důkaz v literatuře
- nalezená řešení
 - nejednoznačná \rightarrow existuje více než jedna dělicí nadrovina

Perceptronový algoritmus – konvergence

- podmínky konvergence ... ρ_t

$$\lim_{t \rightarrow \infty} \sum_{k=0}^t \rho_k = \infty$$

$$\lim_{t \rightarrow \infty} \sum_{k=0}^t \rho_k^2 < \infty$$

- např. $\rho_t = c / t$, kde c je konstanta
- volba ρ_t ... rychlost konvergence \rightarrow rychlost algoritmu
- perceptronový algoritmus **zkonverguje k řešení v konečném počtu kroků**
 - důkaz v literatuře
- nalezená řešení
 - nejednoznačná \rightarrow existuje více než jedna dělicí nadrovina

Perceptronový algoritmus – příklad

- aktuální dělicí přímka (čárkovaná)

$$x_1 + x_2 - 0.5 = 0$$


$$\rightarrow \mathbf{w}(t) = (1, 1, -0.5)$$

- chybně klasifikované vzory

$$(-0.2, 0.75)$$

$$(0.4, 0.05)$$

- aktualizace váhového vektoru ($\rho_t = \rho = 0.7$)



- nová dělicí přímka

$$1.42x_1 + 0.51x_2 - 0.5 = 0$$

→ správná klasifikace všech trénovacích vzorů

→ algoritmus končí

Perceptronový algoritmus – příklad

- aktuální dělicí přímka (čárkovaná)

$$x_1 + x_2 - 0.5 = 0$$

$$\rightarrow \mathbf{w}(t) = (1, 1, -0.5)$$

- chybně klasifikované vzory

$$(-0.2, 0.75)$$

$$(0.4, 0.05)$$

- aktualizace váhového vektoru ($\rho_t = \rho = 0.7$)


$$\mathbf{w}(t+1) = \begin{pmatrix} 1 \\ 1 \\ -0.5 \end{pmatrix} - 0.7(-1) \begin{pmatrix} 0.4 \\ 0.05 \\ 1 \end{pmatrix} - 0.7(+1) \begin{pmatrix} -0.2 \\ 0.75 \\ 1 \end{pmatrix} = \begin{pmatrix} 1.42 \\ 0.51 \\ -0.5 \end{pmatrix}$$

- nová dělicí přímka

$$1.42x_1 + 0.51x_2 - 0.5 = 0$$

→ správná klasifikace všech trénovacích vzorů

→ **algoritmus končí**



Varianta perceptronového algoritmu

- modifikace

- trénovací vzory ... cyklicky předkládány
- váhový vektor ... změna po **každém** vzoru
- opakované předkládání trénovací množiny

- algoritmus

- aktualizace váhového vektoru

$$\mathbf{w}(t+1) = \mathbf{w}(t) + \rho \cdot \mathbf{x}^t \quad \dots \quad \text{když } \mathbf{x}^t \in \omega_1 \text{ a } \mathbf{w}(t) \cdot \mathbf{x}^t \leq 0$$

$$\mathbf{w}(t+1) = \mathbf{w}(t) - \rho \cdot \mathbf{x}^t \quad \dots \quad \text{když } \mathbf{x}^t \in \omega_2 \text{ a } \mathbf{w}(t) \cdot \mathbf{x}^t \geq 0$$

$$\mathbf{w}(t+1) = \mathbf{w}(t) \quad \dots \quad \text{jinak}$$

- konvergence v konečném počtu iterací

vzor \mathbf{x}^t klasifikován správně

Perceptron – klasifikace


- klasifikace neznámých vzorů
 - předpoklad: konvergence k váhovému vektoru \mathbf{w} a prahu w_0
 - klasifikace
$$\mathbf{w}^T \mathbf{x} + w_0 > 0 \rightarrow \mathbf{x} \text{ do } \omega_1$$
$$\mathbf{w}^T \mathbf{x} + w_0 < 0 \rightarrow \mathbf{x} \text{ do } \omega_2$$

→ perceptron

- f ... nelineární skoková funkce

$$f(\xi) = +1 \dots \xi \geq 0$$

$$f(\xi) = -1 \dots \xi < 0$$



Přihrádkový algoritmus

- perceptronový algoritmus učení
 - lineární separabilita tříd
 - předpoklad není splněn → není zaručena konvergence
- přihrádkový algoritmus učení
 - konvergence k optimálnímu řešení i když množiny nejsou lineárně separabilní

Přihrádkový algoritmus

- Krok 1
 - náhodná inicializace $\mathbf{w}(0)$
 - přihrádkový vektor \mathbf{w}_S
 - čítač historie $h_S = 0$
- Krok 2
 - aktualizace $\mathbf{w}(t+1)$ podle perceptronového algoritmu
 - h počet správně klasifikovaných trénovacích vzorů pomocí $\mathbf{w}(t+1)$
 - $h > h_S$:
 - $\mathbf{w}_S \leftarrow \mathbf{w}(t+1)$
 - $h_S \leftarrow h$
- konvergence
 - algoritmus s pravděpodobností 1 konverguje k optimálnímu řešení
 - řešení s nejmenším počtem chybně klasifikovaných trénovacích vzorů

Přihrádkový algoritmus


- Krok 1
 - náhodná inicializace $\mathbf{w}(0)$
 - přihrádkový vektor \mathbf{w}_S
 - čítač historie $h_S = 0$
- Krok 2
 - aktualizace $\mathbf{w}(t+1)$ podle perceptronového algoritmu
 - h počet správně klasifikovaných trénovacích vzorů pomocí $\mathbf{w}(t+1)$
 - $h > h_S$
 - $\mathbf{w}_S \leftarrow \mathbf{w}(t+1)$
 - $h_S \leftarrow h$
- konvergence
 - algoritmus s pravděpodobností 1 konverguje k optimálnímu řešení
 - řešení s nejmenším počtem chybně klasifikovaných trénovacích vzorů

Podpůrné vektorové stroje (SVM)

- support vector machine (SVM)
- vstup
 - lineárně separabilní třídy ω_1 a ω_2
 - trénovací vzory $\mathbf{x}_1, \dots, \mathbf{x}_n$
- výstup
 - klasifikační nadrovina $g(\mathbf{x})$
$$g(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + w_0 = 0$$
 - správně klasifikuje trénovací vzory

SVM – idea

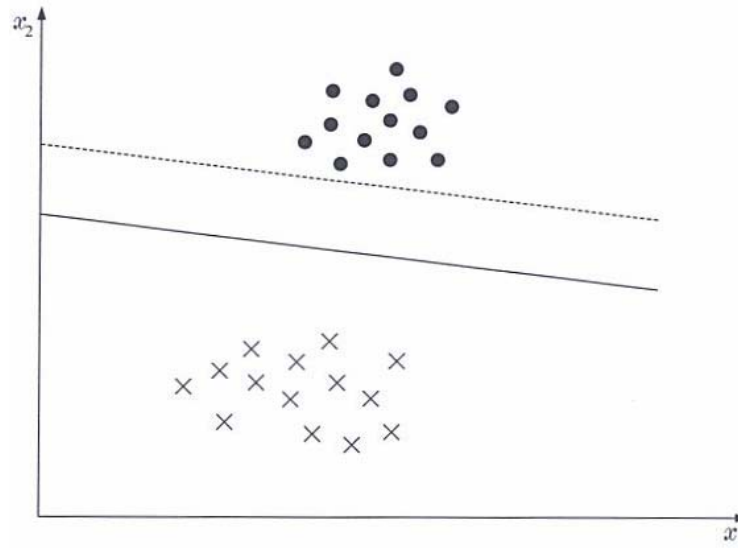
- klasifikační nadrovina $g(\mathbf{x})$ není určena jednoznačně



- kterou klasifikační nadrovinu zvolit?
 - „spolehlivá“ práce i s neznámými vzory generalizace
 - klasifikace trénovacích dat & „největší okolí“ na obou stranách nadroviny

SVM – idea

- klasifikační nadrovina $g(\mathbf{x})$ není určena jednoznačně



- kterou klasifikační nadrovinu zvolit?
 - „spolehlivá“ práce i s neznámými vzory **generalizace**
 - klasifikace trénovacích dat & „největší okolí“ na obou stranách nadroviny


SVM – okolí

- umístění klasifikační nadroviny $g(\mathbf{x})$
 - žádná třída nemá být zvýhodněná
 - stejná vzdálenost (okolí) od nejbližších vzorů v třídách ω_1 a ω_2

→ umístit nadrovinu, aby „okolí“ bylo maximální možné

SVM – okolí


- umístění klasifikační nadroviny $g(\mathbf{x})$
 - žádná třída nemá být zvýhodněná
 - stejná vzdálenost (okolí) od nejbližších vzorů v třídách ω_1 a ω_2



→ umístit nadrovinu, aby „okolí“ bylo maximální možné

SVM – okolí

- nadrovina → škálovací koeficient
 - stejný škálovací koeficient → jediná rovnice roviny
 - volba \mathbf{w} a w_0
 - \mathbf{x} nejbližší bod tříd $\omega_1 \rightarrow g(\mathbf{x}) = 1$
 - \mathbf{x} nejbližší bod tříd $\omega_2 \rightarrow g(\mathbf{x}) = -1$



SVM – zápis podmínek

- hledaná klasifikační nadrovina $g(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + w_0 = 0$

1. velikost „okolí“

$$\frac{|g(\mathbf{x}_{\omega_1})|}{\|\mathbf{w}\|} + \frac{|g(\mathbf{x}_{\omega_2})|}{\|\mathbf{w}\|} = \frac{2}{\|\mathbf{w}\|}$$

2. správná klasifikace trénovacích vzorů

$$\mathbf{w}^T \mathbf{x} + w_0 \geq 1 \quad \dots \text{ pro trénovací vzor z } \omega_1$$

$$\mathbf{w}^T \mathbf{x} + w_0 \leq -1 \quad \dots \text{ pro trénovací vzor z } \omega_2$$

nejbližší bod: $|g(\mathbf{x})|=1$

SVM – zápis podmínek

- indikátor třídy vzoru

$$y_i \begin{cases} \rightarrow +1 \dots \mathbf{x}_i \in \omega_1 \\ \searrow -1 \dots \mathbf{x}_i \in \omega_2 \end{cases}$$

- problém

- parametry \mathbf{w} a w_0 nadroviny

$$J(\mathbf{w}) \equiv 1/2 \|\mathbf{w}\|^2 \quad \text{minimální} \quad (*)$$

- za podmínky

$$y_i(\mathbf{w}^T \mathbf{x}_i + w_0) \geq 1 \quad \text{pro } i=1, \dots, n \quad (**)$$

- poznámky

- minimalizace normálového vektoru \rightarrow maximální „okolí“
- problém kvadratické optimalizace za podmínek lineárních nerovností

SVM – řešení

- problém splňuje Karush-Kuhn-Trackerovy podmínky
 $L(\mathbf{w}, w_0, \boldsymbol{\lambda})$... Lagrangeova funkce

$$L(\mathbf{w}, w_0, \boldsymbol{\lambda}) = \frac{1}{2} \mathbf{w}^T \mathbf{w} - \sum_{i=1}^n \lambda_i (y_i (\mathbf{w}^T \mathbf{x} + w_0) - 1)$$

→ existuje vektor $\boldsymbol{\lambda}$ Lagrangeových multiplikátorů

$$(1) \quad \frac{\partial}{\partial \mathbf{w}} L(\mathbf{w}, w_0, \boldsymbol{\lambda}) = 0$$

$$(2) \quad \frac{\partial}{\partial w_0} L(\mathbf{w}, w_0, \boldsymbol{\lambda}) = 0$$

$$(3) \quad \lambda_i \geq 0 \quad \text{pro } i = 1, \dots, n$$

$$(4) \quad \lambda_i (y_i (\mathbf{w}^T \mathbf{x} + w_0) - 1) = 0 \quad \text{pro } i = 1, \dots, n$$

- po vyřešení

SVM – řešení

- problém splňuje Karush-Kuhn-Truckerovy podmínky
 $L(\mathbf{w}, w_0, \boldsymbol{\lambda})$... Lagrangeova funkce

$$L(\mathbf{w}, w_0, \boldsymbol{\lambda}) = \frac{1}{2} \mathbf{w}^T \mathbf{w} - \sum_{i=1}^n \lambda_i (y_i (\mathbf{w}^T \mathbf{x}_i + w_0) - 1)$$

→ existuje vektor $\boldsymbol{\lambda}$ Lagrangeových multiplikátorů

$$(1) \quad \frac{\partial}{\partial \mathbf{w}} L(\mathbf{w}, w_0, \boldsymbol{\lambda}) = 0$$

$$(2) \quad \frac{\partial}{\partial w_0} L(\mathbf{w}, w_0, \boldsymbol{\lambda}) = 0$$

$$(3) \quad \lambda_i \geq 0 \quad \text{pro } i = 1, \dots, n$$


$$(4) \quad \lambda_i (y_i (\mathbf{w}^T \mathbf{x}_i + w_0) - 1) = 0 \quad \text{pro } i = 1, \dots, n$$

- po vyřešení

$$\mathbf{w} = \sum_{i=1}^n \lambda_i y_i \mathbf{x}_i \quad \text{a} \quad \sum_{i=1}^n \lambda_i y_i = 0$$

SVM – vlastnosti (1a)

- optimální řešení \mathbf{w}
 - lineární kombinace n_s ($n_s < n$) trénovacích vzorů, které odpovídají $\lambda_i \neq 0$

$$\mathbf{w} = \sum_{i=1}^{n_s} \lambda_i y_i \mathbf{x}_i$$


→ podpůrné vektory

- optimální klasifikační nadrovina podpůrný vektorový stroj
- podpůrné vektory
 - (4) + $\lambda_i \neq 0$ → podpůrné vektory leží na jedné z nadrovin $\mathbf{w}^T \mathbf{x} + w_0 = \pm 1$
 - podpůrné vektory = trénovací vzory nejbližší klasifikátoru
 - kritické prvky trénovací množiny

SVM – vlastnosti (1b)

- trénovací vzory s $\lambda_i = 0$
 - typicky
 - vně oblasti definované $\mathbf{w}^T \mathbf{x} + w_0 = \pm 1$
 - degenerované případy
 - na nadrovinách $\mathbf{w}^T \mathbf{x} + w_0 = \pm 1$
- výsledná klasifikační nadrovina není citlivá na počet a umístění trénovacích vzorů, které nejsou podpůrnými vektory

SVM – vlastnosti (2)

- vlastnosti problému
 - funkce $J(\mathbf{w})$ striktně konvexní funkce
 - omezující podmínky (**) jsou lineární
- optimální klasifikační nadrovina jednoznačně určena

SVM – vlastnosti (3)

- dopočetní parametrů z rovnic

$$\mathbf{w} = \sum_{i=1}^n \lambda_i y_i \mathbf{x}_i \quad \text{a} \quad \sum_{i=1}^n \lambda_i y_i = 0$$

- není snadné → různé algoritmy
 - malé soustavy ... lze dopočítat přímo
 - složitější soustavy ... např. konvexní programování a Lagrangeova dualita
- typicky více řešení pro λ_i → stejná optimální klasifikační nadrovina

SVM – příklad

- podpůrný vektorový stroj pro body

$$\omega_1: \begin{bmatrix} 1 \\ 1 \end{bmatrix} \quad \text{a} \quad \begin{bmatrix} 1 \\ -1 \end{bmatrix}$$

$$\omega_2: \begin{bmatrix} -1 \\ 1 \end{bmatrix} \quad \text{a} \quad \begin{bmatrix} -1 \\ -1 \end{bmatrix}$$

– optimální klasifikátor \rightarrow přímka $g(\mathbf{x}) = x_1 = 0$

- obecně rovnice klasifikační nadroviny

$$g(\mathbf{x}) = w_1x_1 + w_2x_2 + w_0 = 0$$

- výsledná optimální nadrovina $g(\mathbf{x}) = x_1 = 0$

$$\rightarrow w_0=0, w_1=1, w_2=0$$

\rightarrow všechny body podpůrné vektory

\rightarrow velikost „okolí“ 1

SVM – příklad

- podpůrný vektorový stroj pro body

$$\omega_1: \begin{bmatrix} 1 \\ 1 \end{bmatrix} \quad \text{a} \quad \begin{bmatrix} 1 \\ -1 \end{bmatrix}$$

$$\omega_2: \begin{bmatrix} -1 \\ 1 \end{bmatrix} \quad \text{a} \quad \begin{bmatrix} -1 \\ -1 \end{bmatrix}$$

- optimální klasifikátor \rightarrow přímka $g(\mathbf{x}) = x_1 = 0$

- obecně rovnice klasifikační nadroviny


$$g(\mathbf{x}) = w_1 x_1 + w_2 x_2 + w_0 = 0$$

- výsledná optimální nadrovina $g(\mathbf{x}) = x_1 = 0$

$$\rightarrow w_0 = 0, w_1 = 1, w_2 = 0$$

\rightarrow všechny body podpůrné vektory

\rightarrow velikost „okolí“ 1



SVM – příklad

- analytické řešení w_1, w_2, w_0
 - $J(w) \equiv 1/2 \|w\|^2$ minimální
 - za podmínek $y_i(\mathbf{w}^T \mathbf{x} + w_0) \geq 1$ pro $i=1, \dots, 4$
- dosazení do podmínek

$$\mathbf{x}_1 = \begin{bmatrix} 1 \\ 1 \end{bmatrix} \quad \dots \quad w_1 + w_2 + w_0 \geq 1$$

$$\mathbf{x}_2 = \begin{bmatrix} 1 \\ -1 \end{bmatrix} \quad \dots \quad w_1 - w_2 + w_0 \geq 1$$

$$\mathbf{x}_3 = \begin{bmatrix} -1 \\ 1 \end{bmatrix} \quad \dots \quad w_1 - w_2 - w_0 \geq 1$$

$$\mathbf{x}_4 = \begin{bmatrix} -1 \\ -1 \end{bmatrix} \quad \dots \quad w_1 + w_2 - w_0 \geq 1$$

SVM – příklad

- Lagrangeova funkce

$$\begin{aligned}L(\mathbf{w}, w_0, \lambda) &= \frac{1}{2} \mathbf{w}^\top \mathbf{w} - \sum_{i=1}^n \lambda_i (y_i (\mathbf{w}^\top \mathbf{x} + w_0) - 1) = \\ &= \frac{1}{2} (w_1^2 + w_2^2) - \lambda_1 (w_1 + w_2 + w_0 - 1) - \lambda_2 (w_1 - w_2 + w_0 - 1) \\ &\quad - \lambda_3 (w_1 - w_2 - w_0 - 1) - \lambda_4 (w_1 + w_2 - w_0 - 1)\end{aligned}$$

SVM – příklad

- Karush-Kuhn-Truckerovy podmínky

$$(1) \quad \frac{\partial L}{\partial \mathbf{w}} = \mathbf{0} \quad \text{je} \quad \frac{\partial L}{\partial \mathbf{w}_1} = 0 \quad \dots \quad \boxed{w_1 = \lambda_1 + \lambda_2 + \lambda_3 + \lambda_4}$$
$$\frac{\partial L}{\partial \mathbf{w}_2} = 0 \quad \dots \quad \boxed{w_2 = \lambda_1 - \lambda_2 - \lambda_3 + \lambda_4}$$

$$(2) \quad \frac{\partial L}{\partial w_0} = 0 \quad \dots \quad \boxed{\lambda_1 + \lambda_2 - \lambda_3 - \lambda_4 = 0}$$

$$(3) \quad \lambda_i \geq 0 \quad \text{pro } i = 1, \dots, 4$$

$$(4) \quad \boxed{\begin{aligned} \lambda_1(w_1 + w_2 + w_0 - 1) &= 0 \\ \lambda_2(w_1 - w_2 + w_0 - 1) &= 0 \\ \lambda_3(w_1 - w_2 - w_0 - 1) &= 0 \\ \lambda_4(w_1 + w_2 - w_0 - 1) &= 0 \end{aligned}}$$

→ 7 rovnic pro 7 neznámých

SVM – příklad

- řešení 7 rovnic o 7 neznámých není snadné

→ dá více řešení

→ všechny vedou ke stejné optimální klasifikační nadrovině:

$$w_1 = 1$$

$$w_2 = 0$$

$$w_0 = 0$$