


# Support Vector Machines (úvod)

- formulace úlohy
- *Support Vector Classifier (SVC)*
  - matematické odvození 💡
- “jaderný trik” (*kernel trick*)
- *Support Vector Machine*
  - $SVM = SVC + kernel$
- hledání parametrů
- rošíření
  - klasifikace s “měkkou hranicí” (*soft-margin classification*)
  - klasifikace do více tříd

# Formulace úlohy


- dáno:
  - $\{\mathbf{x}_i, y_i\}_{i=1}^n$
  - $\mathbf{x}_i \in \mathbb{R}^p$  příznaky
  - $y_i \in \{-1, 1\}$  třídy
- úloha: klasifikovat nové  $\mathbf{x} \in \mathbb{R}^p$  do třídy  $-1$  nebo  $1$

# Motivace



kteřá pŕímka nejlépe odděluje instance daných dvou tříd?

## Přístup SVC (2)



myšlenka:

- maximalizace hranice o šířce  $d = \frac{2}{\|w\|}$
- za podmínky správné klasifikace:
  - $w'x_i + b \geq +1$ , když  $y_i = +1$
  - $w'x_i + b \leq -1$ , když  $y_i = -1$

# Formulace optimalizační úlohy

- $\operatorname{argmax}_{\mathbf{w}, b} \left\{ \frac{2}{\|\mathbf{w}\|} \right\}$
- za podmínky správné klasifikace:
  - $\mathbf{w}'\mathbf{x}_i + b \geq +1$  , když  $y_i = +1$
  - $\mathbf{w}'\mathbf{x}_i + b \leq -1$  , když  $y_i = -1$
  - nebo ekvivalentně:  $y_i(\mathbf{w}'\mathbf{x}_i + b) \geq 1$

ekvivalentně (formulace 1):

- $\operatorname{argmin}_{\mathbf{w}, b} \left\{ \frac{1}{2} \|\mathbf{w}\|^2 \right\}$
- za podmínky správné klasifikace:  $y_i(\mathbf{w}'\mathbf{x}_i + b) \geq 1$

ekvivalentně (chceme se zbavit omezení) (formulace 2):

- $L_p = \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{i=1}^n \alpha_i [(\mathbf{w}'\mathbf{x}_i + b)y_i - 1]$
- $L_p = \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{i=1}^n \alpha_i [(\mathbf{w}'\mathbf{x}_i + b)y_i] + \sum_{i=1}^n \alpha_i$
- $\operatorname{argmin}_{\mathbf{w}, b} L_p$
- za podmínky:  $\alpha_i \geq 0$
- $\alpha_i$  - Lagrangeovy multiplikátory

# Formulace optimalizační úlohy

## Primární a duální úloha

$$L_p = \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{i=1}^n \alpha_i [(\mathbf{w}' \mathbf{x}_i + b) y_i] + \sum_{i=1}^n \alpha_i$$

*argmin* <sub>$\mathbf{w}, b$</sub>   $L_p$  (za podmínky  $\alpha_j \geq 0$ )

Požadujeme  $\nabla L_p = 0$ :

- $\frac{\partial L_p}{\partial \mathbf{w}} = \mathbf{w} - \sum_{i=1}^n \alpha_i \mathbf{x}_i y_i = 0 \rightarrow \mathbf{w} = \sum_{i=1}^n \alpha_i \mathbf{x}_i y_i$
- $\frac{\partial L_p}{\partial b} = \sum_{i=1}^n \alpha_i y_i = 0$

Substitucí do  $L_p$  získáme duální úlohu:

$$L_d = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j \mathbf{x}_i \mathbf{x}_j y_i y_j$$

*argmax* <sub>$\alpha_j$</sub>   $L_d$  (za podmínky  $\alpha_j \geq 0$ )

# Optimalizační úlohy

## Rekapitulace

- formulace 1:
  - $\operatorname{argmin}_{\mathbf{w}, b} \left\{ \frac{1}{2} \|\mathbf{w}\|^2 \right\}$  (za podm.:  $y_i(\mathbf{w}'\mathbf{x}_i + b) \geq 1$ )
  - $p + 1$  parametrů,  $n$  lin. omezení
- formulace 2:
  - $L_p = -\frac{1}{2} \|\mathbf{w}\|^2 - \sum_{i=1}^n \alpha_i [(\mathbf{w}'\mathbf{x}_i + b)y_i] + \sum_{i=1}^n \alpha_i$
  - $\operatorname{argmin}_{\mathbf{w}, b} L_p$  (za podmínky  $\alpha_i \geq 0$ )
  - $p + 1$  parametrů,  $n$  omezení
- formulace 3:
  - $L_d = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j \mathbf{x}_i \mathbf{x}_j y_i y_j$
  - $\operatorname{argmax}_{\alpha_i} L_d$  (za podmínky  $\alpha_i \geq 0$ )
  - $n$  parametrů,  $n$  omezení
  - **proč to všechno snažení?**
  - **data  $\mathbf{x}_i$  vystupují pouze ve formě součinů  $\mathbf{x}_i \mathbf{x}_j$**
  - většina  $\alpha_i$  nulových,  $\alpha_i > 0$  právě pro *support vectors*



# Řešení optimalizační úlohy

Rozhodovací funkce  $f(\mathbf{x}) = \text{sign}(\mathbf{w}'\mathbf{x} + b)$

$$\mathbf{w} = \sum_{i=1}^n \alpha_i \mathbf{x}_i y_i$$

jak získat  $b$ ?

- pro lib. *support vector*:  $y_i(\mathbf{w}'\mathbf{x}_i + b) = 1$

- $\rightarrow b = \frac{1}{y_i} - \mathbf{w}'\mathbf{x}_i$

- prakticky:  $b = \frac{\sum_{i, \alpha_i > 0} (\frac{1}{y_i} - \mathbf{w}'\mathbf{x}_i)}{\sum_{i, \alpha_i > 0} 1}$

tedy konečně dostáváme:

- $f(\mathbf{x}) = \text{sign}(\sum_{i=1}^n \alpha_i y_i \mathbf{x}_i' \mathbf{x} + b)$

## Trik s jádrem (*Kernel trick*)

Rozhodovací funkce:

- $f(\mathbf{x}) = \text{sign}(\sum_{i=1}^n \alpha_i y_i \mathbf{x}_i' \mathbf{x} + b)$

Pozorování:

- příznaky  $\mathbf{x}$  pouze ve formě skalárním součinu  $\mathbf{x}_i' \mathbf{x}$
- skalární součin  $\mathbf{r}' \mathbf{s}$  lze nahradit jádrem  $K(\mathbf{r}, \mathbf{s})$
- $K(\mathbf{r}, \mathbf{s}) = \phi(\mathbf{r})' \phi(\mathbf{s})$
- jádro může realizovat operaci odpovídající skalárnímu součinu ve vysokorozměrném prostoru
- použitím jádra se z SVC stávají SVM

Používaná jádra:

- polynomiální:  $K(\mathbf{r}, \mathbf{s}) = (\mathbf{r}' \mathbf{s} + 1)^q$
- *Gaussian radial-basis function (RBF)*:  
$$K(\mathbf{r}, \mathbf{s}) = \exp\left\{-\frac{\|\mathbf{r}-\mathbf{s}\|^2}{2\sigma^2}\right\}$$
- hyperbolický tangens:  $K(\mathbf{r}, \mathbf{s}) = \tanh\{\beta_1 \mathbf{r}' \mathbf{s} + \beta_2\}$

## Trik s jádrem (*Kernel trick*)

### Příklad

Polynomiální jádro stupně  $q = 2$ :  $K(\mathbf{r}, \mathbf{s}) = (\mathbf{r}'\mathbf{s} + 1)^2$ ,  
 $\mathbf{r}, \mathbf{s} \in \mathbb{R}^2$ , operuje v prostoru  $\mathbb{R}^6$ :

$$\mathbf{r} \rightarrow \phi(\mathbf{r}) = \{r_1^2, r_2^2, \sqrt{2}r_1r_2, \sqrt{2}r_1, \sqrt{2}r_2, 1\}$$


$$\mathbf{s} \rightarrow \phi(\mathbf{s}) = \{s_1^2, s_2^2, \sqrt{2}s_1s_2, \sqrt{2}s_1, \sqrt{2}s_2, 1\}$$

$$\phi(\mathbf{r})'\phi(\mathbf{s}) = r_1^2s_1^2 + r_2^2s_2^2 + 2r_1r_2s_1s_2 + 2r_1s_1 + 2r_2s_2 + 1$$

$$(\mathbf{r}'\mathbf{s} + 1)^2 = (r_1s_1 + r_2s_2 + 1)^2 =$$

$$r_1^2s_1^2 + r_2^2s_2^2 + 1 + 2r_1r_2s_1s_2 + 2r_1s_1 + 2r_2s_2$$

# Ukázka jader




**FIGURE 2.5.** The optimal Bayes decision boundary for the simulation example of Figures 2.1, 2.2 and 2.3. Since the generating density is known for each class, this boundary can be calculated exactly (Exercise 2.2).


(převzato z <http://statweb.stanford.edu/~tibs/ElemStatLearn/>)

# Ukázka jader

SVM - Degree-4 Polynomial in Feature Space



SVM - Radial Kernel in Feature Space



(převzato z <http://statweb.stanford.edu/~tibs/ElemStatLearn/>)

# Klasifikace s “měkkou hranicí”

## Soft-margin classification

Motivace:

- třídy nemusejí být oddělitelné
- přesto chceme SVM použít

Řešení:

- dovolit SVM udělat “malou” chybu

Jak:

- $\operatorname{argmin}_{\mathbf{w}, b} \left\{ \frac{1}{2} \|\mathbf{w}\|^2 \right\} + C \sum_{i=1}^n \xi_i$
- za podm. téměř správné klasifikace:  $y_i(\mathbf{w}'\mathbf{x}_i + b) \geq 1 - \xi_i$
- $C$  představuje regularizační konstantu
- $C = \infty$  odpovídá původní formulaci separabilní úlohy
- $C$  se hledá nejčastěji pomocí křížové validace

- fungují velmi dobře
- časová složitost trénování:  $O(n^2)$
- uživatel volí typ jádra a parametry
- parametry se hledají typicky křížovou validací
- po natrénování si stačí pamatovat *support vectors*

# Porovnání metod

**TABLE 10.1.** Some characteristics of different learning methods. Key: ▲ = good, ◆ = fair, and ▼ = poor.

Characteristic	Neural Nets	SVM	Trees	MARS	k-NN, Kernels
Natural handling of data of “mixed” type	▼	▼	▲	▲	▼
Handling of missing values	▼	▼	▲	▲	▲
Robustness to outliers in input space	▼	▼	▲	▼	▲
Insensitive to monotone transformations of inputs	▼	▼	▲	▼	▼
Computational scalability (large $N$ )	▼	▼	▲	▲	▼
Ability to deal with irrelevant inputs	▼	▼	▲	▲	▼
Ability to extract linear combinations of features	▲	▲	▼	▼	◆
Interpretability	▼	▼	◆	▲	▼
Predictive power	▲	▲	▼	◆	▲

(převzato z <http://statweb.stanford.edu/~tibs/ElemStatLearn/>)



## Klasifikace do více tříd

SVM umí rozlišovat jen do dvou tříd


možná řešení klasifikace do  $K$  tříd:

- “jeden proti všem”:  $K$  úloh: klasifikace třídy  $k$  proti zbytku, “vítěz bere vše”
- “jeden na jednoho”:  $\frac{K(K-1)}{2}$  úloh: klasifikace třídy  $k_1$  proti  $k_2$ , hlasování

# Rozšíření SVM

- *SVM regression*
- shlukování založené na SVM
- detekce nečekaných pozorování (*novelty detection*)

Christopher J.C. Burges: A Tutorial on Support Vector Machines for Pattern Recognition, Data Mining and Knowledge Discovery (1998), volume 2, p.121-167.



Hastie T., Tibshirani R., Friedman J.: **The Elements of Statistical Learning** (2009). Springer-Verlag, <http://statweb.stanford.edu/~tibs/ElemStatLearn/>