


# Support Vector Machines

## Accelerated Network Technologies Research Group

Václav Bartoš

Brno University of Technology, Faculty of Information Technology  
Bozეთეხოვა 2, 612 00 Brno, CZ  
<http://merlin.fit.vutbr.cz/ant/>



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

# Support Vector Machines

- SVM - Binární lineární klasifikátor
  - Rozděluje data (reprezentovaná jako body v  $n$ -rozměrném prostoru) do dvou tříd.
  - Rozděluje nadrovinou
  - V základní variantě tedy musí být data lineárně separovatelná
  - Úkolem je najít takovou nadrovinu, aby vzdálenost k nejbližším bodům v obou skupinách byla maximální.

# SVM - Výpočet dělicí nadroviny

- Definujme trénovací množinu dat jako:

$$\{\mathbf{x}_i, c_i\} \quad \mathbf{x}_i \in \mathbb{R}^D, c_i \in \{-1, 1\}$$

- Nadrovina je dána svým normálovým vektorem  $\mathbf{w}$  a posunutím  $b$ .

# SVM - Výpočet dělicí nadroviny

- Vzdálenost bodu od nadroviny je  $1/\|\mathbf{w}\|$
- Snažíme se najít  $\mathbf{w}$  a  $b$  tak, aby platilo:

$$\mathbf{x}_i \cdot \mathbf{w} + b \geq +1 \quad \text{když} \quad c_i = +1$$

$$\mathbf{x}_i \cdot \mathbf{w} + b \leq -1 \quad \text{když} \quad c_i = -1$$

- Což lze spojit do:

$$c_i(\mathbf{x}_i \cdot \mathbf{w} + b) - 1 \geq 0$$

- Snažíme se maximalizovat  $1/\|\mathbf{w}\|$ , tedy minimalizovat  $\|\mathbf{w}\|$ .

# SVM - Výpočet dělicí nadroviny

- Minimalizaci  $\|\mathbf{w}\|$  převedeme na minimalizaci  $\frac{1}{2}\|\mathbf{w}\|^2$ .
- Dostaneme optimalizační problém kvadratického programování

- Minimalizuj (ve  $\mathbf{w}$ ,  $b$ )

$$\frac{1}{2}\|\mathbf{w}\|^2$$

tak, aby platilo

$$c_i(\mathbf{w} \cdot \mathbf{x}_i - b) - 1 \geq 0 \quad \forall i$$

- Řeší se pomocí Lagrangeových multiplikátorů:

$$L_P \equiv \frac{1}{2}\|\mathbf{w}\|^2 - \sum_{i=1}^n \alpha_i [c_i(\mathbf{w} \cdot \mathbf{x}_i - b) - 1]$$

minimalizujeme  $\mathbf{w}, b$ ; maximalizujeme  $\alpha$

# SVM - Výpočet dělicí nadroviny

$$L_P \equiv \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{i=1}^n \alpha_i [c_i (\mathbf{w} \cdot \mathbf{x}_i - b) - 1]$$

- Lze převést na duální formu:

$$L_D \equiv \sum_{i=1}^L \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j c_i c_j \mathbf{x}_i \cdot \mathbf{x}_j \quad \text{tak aby } \alpha_i \geq 0, \quad \sum_{i=1}^L \alpha_i c_i = \cdot$$

- Z toho pomocí QP solveru vypočítáme  $\alpha$  a dopočítáme  $\mathbf{w}$  a  $b$ .
- Podstatné je, že duální forma potřebuje jen skalární součiny vstupních vektorů  $\mathbf{x}_i$ .

# SVM - Použití

- Jakmile známe  $w$  a  $b$  definující dělicí nadrovinu, třída nové instance dat se vypočítá jednoduše:

$$c' = \text{sgn}(w \cdot x' + b)$$

# Transductive SVM

- K trénovacím datům navíc množina neoznačených dat.
- SVM se snaží najít nadrovinu tak, aby byla optimální i vzhledem k těmto datům.
- Původní optimalizační problém se změní na:
  - Minimalizuj (ve  $\mathbf{w}$ ,  $b$ ,  $c^*$ )

$$\frac{1}{2} \|\mathbf{w}\|^2$$

tak, aby platilo

$$c_i (\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1,$$


$$c_j^* (\mathbf{w} \cdot \mathbf{x}_j^* + b) \geq 1,$$

$$c_j^* \in \{-1, 1\}$$



# Soft margin SVM

- Pokud data nejsou úplně lineárně separabilní z důvodu několika špatně označených instancí dat.
- Zavedeme proměnnou  $\xi$  vyjadřující "rezervu":



$$\mathbf{x}_i \cdot \mathbf{w} + b \geq +1 - \xi_i \quad \text{když} \quad c_i = +1$$

$$\mathbf{x}_i \cdot \mathbf{w} + b \leq -1 + \xi_i \quad \text{když} \quad c_i = -1$$

$$\xi_i \geq 0$$

# Soft margin SVM


- Optimalizační problém se změnil na:

- Minimalizuj (ve  $\mathbf{w}$ ,  $b$ )

$$\frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^L \xi_i$$

tak, aby platilo

$$c_i(\mathbf{w} \cdot \mathbf{x}_i - b) - 1 + \xi_i \geq 0 \quad \forall i$$



- Pomocí parametru  $C$  můžeme měnit trade-off mezi šířkou "prázdného prostoru" a množstvím špatně klasifikovaných dat.

# Nonlinear classification

- Do teď musela být data lineárně separovatelná.
- Pomocí tzv. *kernel trick* lze s SVM udělat nelineární klasifikátor.
  - Problém v původních  $N$  dimenzích se pomocí nelineární transformace převede do vícedimenzionálního prostoru, ve kterém již data jsou lineárně separovatelná.
    - Dimenzí může být i nekonečno
  - Algoritmus tedy zůstává stejný, transformují se vstupní data.

# Nonlinear classification



- Vztah kernelu  $k$  a transformace  $\varphi$  je:

$$k(\mathbf{x}_i, \mathbf{x}_j) = \varphi(\mathbf{x}_i) \cdot \varphi(\mathbf{x}_j)$$

- Výpočty s vektory v SVM obsahují pouze skalární součiny (nebo je na ně lze převést).
- Proto ve skutečnosti nemusíme data transformovat, stačí ve výpočtech každý skalární součin nahradit nějakou kernel funkcí.
- Často používaným kernelem je *Gaussian radial basis function*

$$k(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\gamma \|\mathbf{x}_i - \mathbf{x}_j\|^\gamma) \quad \text{pro } \gamma > 0$$

# Nonlinear classification



# Nonlinear classification

- Používané kernely:

- *Radial basis function*

$$k(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\gamma \|\mathbf{x}_i - \mathbf{x}_j\|^\gamma) \text{ pro } \gamma > 0$$

- *Polynomial kernel*

$$k(\mathbf{x}_i, \mathbf{x}_j) = (\mathbf{x}_i \cdot \mathbf{x}_j + a)^b$$

- *Sigmoidal kernel*

$$k(\mathbf{x}_i, \mathbf{x}_j) = \tanh(a \mathbf{x}_i \cdot \mathbf{x}_j - b)$$

- Efektivita SVM závisí na zvoleném kernelu a jeho parametrech (v případě soft margin ještě na konst. C).

# Konec

---

Děkuji za pozornost.

Hlavní zdroje:

[http://en.wikipedia.org/wiki/Support\\_vector\\_machine](http://en.wikipedia.org/wiki/Support_vector_machine)

<http://www.tristanfletcher.co.uk/SVM%20Explained.pdf>