

## 2. Optimální rozdělující nadplocha. Support vector machine. Adaboost.

Petr Pošík

Katedra kybernetiky  
ČVUT FEL

## Opakování

Lineární diskriminační funkce

Optimální rozdělující nadplocha

---

Když lineární hranice nestačí...

---

Boosting

---

# Opakování

# Lineární diskriminační funkce

Opakování

Lineární diskriminační funkce

Optimální rozdělující nadplocha

Když lineární hranice nestačí...

Boosting

Binární klasifikace objektů  $\mathbf{x}$  (klasifikace do 2 tříd, dichotomie):

- ✓ Stačí 1 diskriminační funkce
- ✓ Pravidlo:

$$f(\mathbf{x}_i) > 0 \iff y_i = +1$$


$$f(\mathbf{x}_i) < 0 \iff y_i = -1$$

neboli

$$y_i = \text{sign}(f(\mathbf{x}))$$

Učení lin. disk. funkce: např. perceptronový algoritmus:

- ✓ váhový vektor je váženým součtem trénovacích bodů  $\mathbf{x}_i$
- ✓ najde jakoukoli separující nadplochu, pokud taková existuje



Která z nekonečného množství rozdělujících nadploch je optimální?

Opakování

Optimální rozdělující nadplocha

Optimální rozdělující nadplocha

Velikost marginu

Učení optimální rozdělující nadplochy

Optimální rozdělující nadplocha: závěrečné poznámky

Demo: optimální rozdělující nadplocha

Když lineární hranice nestačí...

Boosting


## Optimální rozdělující nadplocha

# Optimální rozdělující nadplocha

## Margin (odstup):

- ✓ šířka pásma, v němž se hranice mezi třídami může pohybovat (kolmo ke své směrnici), aniž by se dotkla některého bodu

## Lineární klasifikátor s maximálním marginem



Plus-rovina:  $\{x : \mathbf{w}^T \mathbf{x} + w_0 = 1\}$

Minus-rovina:  $\{x : \mathbf{w}^T \mathbf{x} + w_0 = -1\}$

Hranice mezi třídami:  $\{x : \mathbf{w}^T \mathbf{x} + w_0 = 0\}$

## Support vectors:

- ✓ datové vektory ležící v plus-rovině nebo minus-rovině
- ✓ pouze ty mají vliv na hranici mezi třídami

## Proč maximalizovat margin?

- ✓ Intuitivně se to zdá být nejbezpečnější
- ✓ Pokud bychom udělali malou chybu při stanovování hranice, máme nejmenší šanci, že způsobíme špatnou klasifikaci
- ✓ Model je stabilní vůči změně trénovací množiny, pokud nedojde ke změně některého ze support vectors
- ✓ Existují teoretické výsledky (založené na VC dimenzi), že hledat klasifikátor s maximálním marginem je dobré
- ✓ Maximální margin v praxi dobře funguje

# Velikost marginu

Opakování

Optimální rozdělující nadplocha

Optimální rozdělující nadplocha

Velikost marginu

Učení optimální rozdělující nadplochy


Optimální rozdělující nadplocha: závěrečné poznámky

Demo: optimální rozdělující nadplocha

Když lineární hranice nestačí...

Boosting

Jak vypočítat velikost marginu  $M$  ze známých  $\mathbf{w}$  a  $w_0$ ?



Víme, že:

$$\mathbf{w}^T \mathbf{x}^+ + w_0 = 1$$

$$\mathbf{w}^T \mathbf{x}^- + w_0 = -1$$

$$\mathbf{x}^- + \lambda \mathbf{w} = \mathbf{x}^+$$

Můžeme odvodit:

$$\mathbf{w}^T (\mathbf{x}^+ - \mathbf{x}^-) = 2$$

$$\mathbf{w}^T (\mathbf{x}^- + \lambda \mathbf{w} - \mathbf{x}^-) = 2$$

$$\lambda \mathbf{w}^T \mathbf{w} = 2$$

$$\lambda = \frac{2}{\mathbf{w}^T \mathbf{w}} = \frac{2}{\|\mathbf{w}\|^2}$$

Velikost marginu:

$$M = \|\mathbf{x}^+ - \mathbf{x}^-\| = \|\lambda \mathbf{w}\| = \lambda \|\mathbf{w}\| = \frac{2}{\|\mathbf{w}\|^2} \|\mathbf{w}\| = \frac{2}{\|\mathbf{w}\|}$$

# Učení optimální rozdělující nadplochy

Opakování

Optimální rozdělující nadplocha

Optimální rozdělující nadplocha

Velikost marginu

**Učení optimální rozdělující nadplochy**

Optimální rozdělující nadplocha: závěrečné poznámky

Demo: optimální rozdělující nadplocha

Když lineární hranice nestačí...

Boosting

Chceme maximalizovat margin  $M = \frac{2}{\|w\|}$  při splnění omezení na správnou klasifikaci. To lze formulovat jako úlohu *kvadratického programování* (QP).

# Učení optimální rozdělovací nadplochy

Opakování

Optimální rozdělovací nadplocha

Optimální rozdělovací nadplocha

Velikost marginu

Učení optimální rozdělovací nadplochy

Optimální rozdělovací nadplocha: závěrečné poznámky

Demo: optimální rozdělovací nadplocha

Když lineární hranice nestačí...

Boosting

Chceme maximalizovat margin  $M = \frac{2}{\|\mathbf{w}\|}$  při splnění omezení na správnou klasifikaci. To lze formulovat jako úlohu *kvadratického programování* (QP).

✓ Primární úloha QP:

minimalizuj  $\mathbf{w}^T \mathbf{w}$  vzhledem k  $w_1, \dots, w_D$

tak, aby  $y_i(\mathbf{w}^T \mathbf{x}_i + w_0) \geq 1$



# Učení optimální rozdělovací nadplochy

Opakování

Optimální rozdělovací nadplocha

Optimální rozdělovací nadplocha

Velikost marginu

Učení optimální rozdělovací nadplochy

Optimální rozdělovací nadplocha: závěrečné poznámky

Demo: optimální rozdělovací nadplocha

Když lineární hranice nestačí...

Boosting

Chceme maximalizovat margin  $M = \frac{2}{\|\mathbf{w}\|}$  při splnění omezení na správnou klasifikaci. To lze formulovat jako úlohu *kvadratického programování* (QP).

- ✓ Primární úloha QP:

minimalizuj  $\mathbf{w}^T \mathbf{w}$  vzhledem k  $w_1, \dots, w_D$

tak, aby  $y_i(\mathbf{w}^T \mathbf{x}_i + w_0) \geq 1$

- ✓ Duální úloha QP:

maximalizuj  $\sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j$  vzhledem k  $\alpha_1, \dots, \alpha_m$

tak, aby  $\alpha_i \geq 0$

a  $\sum_{i=1}^N \alpha_i y_i = 0$ .

# Učení optimální rozdělující nadplochy

Opakování

Optimální rozdělující nadplocha

Optimální rozdělující nadplocha

Velikost marginu

Učení optimální rozdělující nadplochy

Optimální rozdělující nadplocha: závěrečné poznámky

Demo: optimální rozdělující nadplocha

Když lineární hranice nestačí...

Boosting

Chceme maximalizovat margin  $M = \frac{2}{\|\mathbf{w}\|}$  při splnění omezení na správnou klasifikaci. To lze formulovat jako úlohu *kvadratického programování* (QP).

- ✓ Primární úloha QP:

minimalizuj  $\mathbf{w}^T \mathbf{w}$  vzhledem k  $w_1, \dots, w_D$

tak, aby  $y_i(\mathbf{w}^T \mathbf{x}_i + w_0) \geq 1$

- ✓ Duální úloha QP:

maximalizuj  $\sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j$  vzhledem k  $\alpha_1, \dots, \alpha_m$

tak, aby  $\alpha_i \geq 0$

a  $\sum_{i=1}^N \alpha_i y_i = 0$ .

- ✓ Výpočet řešení primární úlohy z řešení duální úlohy:

$$\mathbf{w} = \sum_{i=1}^m \alpha_i y_i \mathbf{x}_i, \quad w_0 = y_k - \mathbf{w}^T \mathbf{x}_k,$$

kde  $(\mathbf{x}_k, y_k)$  je libovolný *support vector*.

Opakování

Optimální rozdělující nadplocha

Optimální rozdělující nadplocha

Velikost marginu

Učení optimální rozdělující nadplochy

Optimální rozdělující nadplocha: závěrečné poznámky

Demo: optimální rozdělující nadplocha

Když lineární hranice nestačí...

Boosting

## Význam duální formulace:

- ✓ Úloha QP v duální formě je pro QP solvery snáze řešitelná než QP v primární formě.
- ✓ Klasifikovat nové body pak lze pomocí funkce

$$f(\mathbf{x}, \mathbf{w}, w_0) = \text{sign}(\mathbf{w}^T \mathbf{x} + w_0) = \text{sign}\left(\sum_{i=1}^N \alpha_i y_i \mathbf{x}_i^T \mathbf{x} + w_0\right),$$

t.j. data se v diskriminační funkci vyskytují jen ve formě skalárních součinů.

- ✓ Data s  $\alpha_i > 0$  jsou support vectors, takže součty mohou být jen přes *support vectors*.
- ✓ Duální formulace umožňuje využít dalších triků, o kterých se teprve dozvíte.

## Když data nejsou lineárně separabilní:

- ✓ I v tomto případě existuje formulace úlohy QP (*soft margin*).
- ✓ Primární úloha má dvojnásobný počet omezení, úloha tedy je složitější.
- ✓ Výsledky úlohy QP se *soft marginem* jsou stejného typu jako bez něj.

# Demo: optimální rozdělující nadplocha

Opakování

Optimální rozdělující nadplocha

Optimální rozdělující nadplocha

Velikost marginu


Učení optimální rozdělující nadplochy

Optimální rozdělující nadplocha: závěrečné poznámky

Demo: optimální rozdělující nadplocha

Když lineární hranice nestačí...

Boosting



Opakování

Optimální rozdělující  
nadplocha

**Když lineární hranice  
nestačí...**

Rozšíření báze

Dvě soustavy souřadnic

Rozšíření báze:  
poznámky

Optimální rozdělující  
nadplocha s rozšířením  
báze

Kernel trik

Support vector machine

Demo: SVM s lineárním  
jádre

Demo: SVM s  
Gaussovským (RBF)  
jádre

Boosting

## Když lineární hranice nestačí...

Opakování

Optimální rozdělující  
nadplocha

Když lineární hranice  
nestačí...

**Rozšíření báze**

Dvě soustavy souřadnic

Rozšíření báze:  
poznámky

Optimální rozdělující  
nadplocha s rozšířením  
báze

Kernel trik

Support vector machine

Demo: SVM s lineárním  
jádre

Demo: SVM s  
Gaussovským (RBF)  
jádre

Boosting

a.k.a. *vyrovnání příznakového porstoru.*

Opakování

Optimální rozdělující nadplocha

Když lineární hranice nestačí...

**Rozšíření báze**

Dvě soustavy souřadnic

Rozšíření báze:  
poznámky

Optimální rozdělující nadplocha s rozšířením báze

Kernel trik

Support vector machine

Demo: SVM s lineárním jádrem

Demo: SVM s Gaussovským (RBF) jádrem

Boosting

a.k.a. *vyrovnání příznakového porstoru*.

**Proč?**

- ✓ Lineární hranice nemusí být dostatečně flexibilní
- ✓ Využijeme algoritmy pro učení lineární diskriminační funkce i pro učení nelineárních modelů

Opakování

Optimální rozdělující  
nadplocha

Když lineární hranice  
nestačí...

Rozšíření báze

Dvě soustavy souřadnic

Rozšíření báze:  
poznámky

Optimální rozdělující  
nadplocha s rozšířením  
báze

Kernel trik

Support vector machine

Demo: SVM s lineárním  
jádro

Demo: SVM s  
Gaussovským (RBF)  
jádro

Boosting

a.k.a. *vyrovnání příznakového prostoru*.

**Proč?**

- ✓ Lineární hranice nemusí být dostatečně flexibilní
- ✓ Využijeme algoritmy pro učení lineární diskriminační funkce i pro učení nelineárních modelů

**Jak?**

- ✓ Zavedeme nový vícerozměrný obrazový prostor  $F$
- ✓ Do tohoto prostoru přetransformujeme data (odvodíme nové příznaky):

$$\mathbf{x} \rightarrow \mathbf{z} = \Phi(\mathbf{x}),$$
$$\mathbf{x} = (x_1, x_2, \dots, x_D) \rightarrow \mathbf{z} = (\Phi_1(\mathbf{x}), \Phi_2(\mathbf{x}), \dots, \Phi_G(\mathbf{x})),$$

příčemž obvykle  $D \ll G$ .

- ✓ Naučíme lineární model, který v původním prostoru nebude lineární

$$f(\mathbf{z}) = w_1 z_1 + w_2 z_2 + \dots + w_G z_G + w_0$$

$$f(\mathbf{x}) = w_1 \Phi_1(\mathbf{x}) + w_2 \Phi_2(\mathbf{x}) + \dots + w_G \Phi_G(\mathbf{x}) + w_0$$



# Dvě soustavy souřadnic

Opakování

Optimální rozdělující nadplocha

Když lineární hranice nestačí...

Rozšíření báze

**Dvě soustavy souřadnic**

Rozšíření báze: poznámky

Optimální rozdělující nadplocha s rozšířením báze

Kernel trik

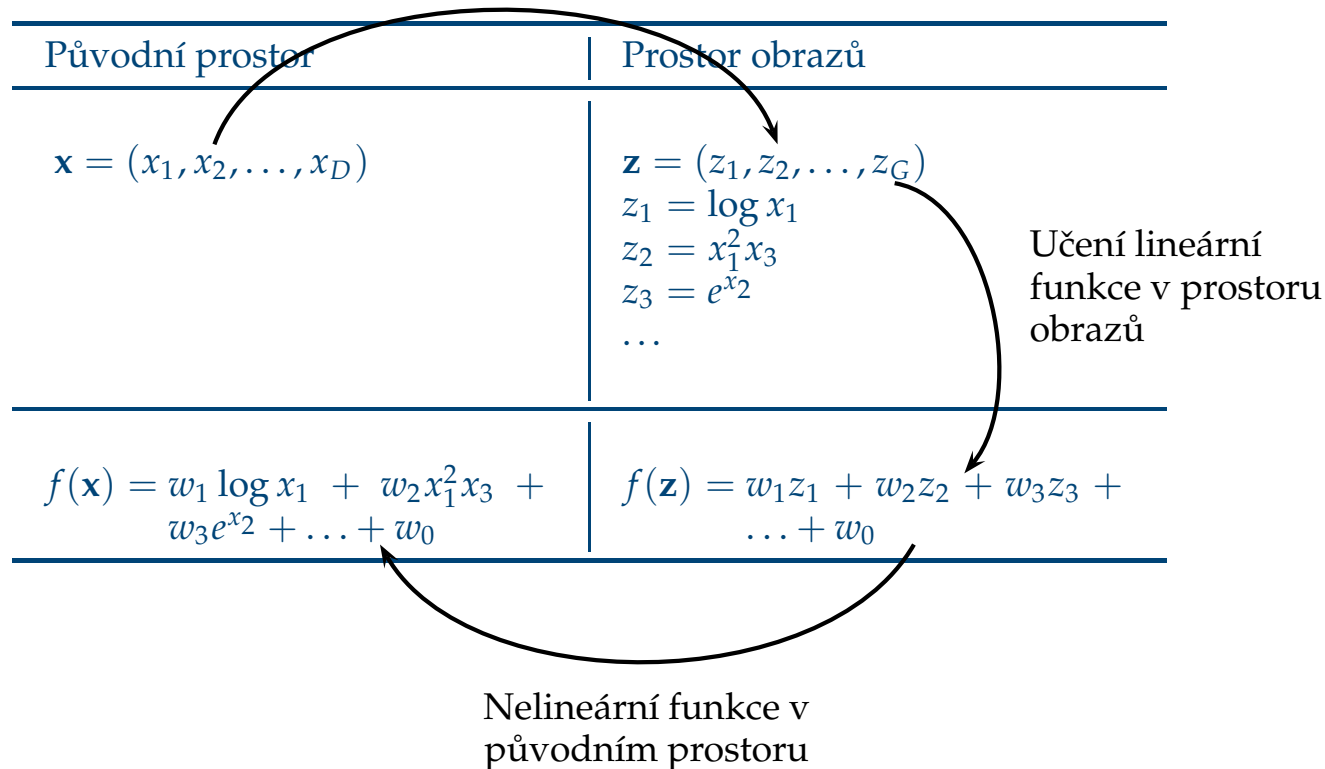
Support vector machine

Demo: SVM s lineárním jádrem

Demo: SVM s Gaussovským (RBF) jádrem

Boosting

## Transformace do vícerozměrného prostoru obrazů



# Dvě soustavy souřadnic: graficky

Opakování

Optimální rozdělující  
nadplocha

Když lineární hranice  
nestačí...

Rozšíření báze

**Dvě soustavy souřadnic**

Rozšíření báze:  
poznámky

Optimální rozdělující  
nadplocha s rozšířením  
báze

Kernel trik

Support vector machine


Demo: SVM s lineárním  
jádre

Demo: SVM s  
Gaussovským (RBF)  
jádre

Boosting

Původní prostor

Prostor obrazů



# Dvě soustavy souřadnic: graficky

Opakování

Optimální rozdělující nadplocha

Když lineární hranice nestačí...

Rozšíření báze

**Dvě soustavy souřadnic**

Rozšíření báze:  
poznámky

Optimální rozdělující nadplocha s rozšířením báze

Kernel trik

Support vector machine

Demo: SVM s lineárním jádrem



Demo: SVM s Gaussovským (RBF) jádrem

Boosting

Transformace do  
vícerozměrného  
prostoru obrazů

Původní prostor

Prostor obrazů



# Dvě soustavy souřadnic: graficky

Opakování

Optimální rozdělující nadplocha

Když lineární hranice nestačí...

Rozšíření báze

Dvě soustavy souřadnic

Rozšíření báze: poznámky

Optimální rozdělující nadplocha s rozšířením báze

Kernel trik

Support vector machine

Demo: SVM s lineárním jádrem



Demo: SVM s Gaussovským (RBF) jádrem

Boosting


Transformace do vícerozměrného prostoru obrazů

Původní prostor

Prostor obrazů



Učení lineární funkce v prostoru obrazů



# Dvě soustavy souřadnic: graficky

Opakování

Optimální rozdělující nadplocha

Když lineární hranice nestačí...

Rozšíření báze

Dvě soustavy souřadnic

Rozšíření báze: poznámky

Optimální rozdělující nadplocha s rozšířením báze

Kernel trik

Support vector machine

Demo: SVM s lineárním jádrem



Demo: SVM s Gaussovským (RBF) jádrem

Boosting



Transformace do vícerozměrného prostoru obrazů

Původní prostor

Prostor obrazů



Učení lineární funkce v prostoru obrazů



Nelineární funkce v původním prostoru

Opakování

Optimální rozdělující  
nadplocha

Když lineární hranice  
nestačí...

Rozšíření báze  
Dvě soustavy souřadnic

**Rozšíření báze:  
poznámky**

Optimální rozdělující  
nadplocha s rozšířením  
báze

Kernel trik

Support vector machine

Demo: SVM s lineárním  
jádre

Demo: SVM s  
Gaussovským (RBF)  
jádre

Boosting

Výhody:

- ✓ univerzální, obecně použitelná metoda

Nevýhody:

- ✓ zůstává na člověku zvolit, které nové příznaky dá učicímu algoritmu k dispozici
- ✓ data je třeba skutečně namapovat do obrazového prostoru

Existuje metoda, jak využít rozšíření báze, aniž bychom mapování skutečně museli provést!!!

# Optimální rozdělující nadplocha s rozšířením báze

Opakování

Optimální rozdělující nadplocha

Když lineární hranice nestačí...

Rozšíření báze

Dvě soustavy souřadnic

Rozšíření báze: poznámky

Optimální rozdělující nadplocha s rozšířením báze

Kernel trik

Support vector machine

Demo: SVM s lineárním jádrem

Demo: SVM s Gaussovským (RBF) jádrem

Boosting

Připomeňme: při učení optimální rozdělující nadplochy se vektory  $\mathbf{x}$  vyskytují pouze

v optimalizačním kritériu  $\sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j$

a v diskriminační funkci  $f(\mathbf{x}) = \text{sign}\left(\sum_{i=1}^N \alpha_i y_i \mathbf{x}_i^T \mathbf{x} + w_0\right)$ .

# Optimální rozdělující nadplocha s rozšířením báze

Opakování

Optimální rozdělující nadplocha

Když lineární hranice nestačí...

Rozšíření báze

Dvě soustavy souřadnic

Rozšíření báze: poznámky

Optimální rozdělující nadplocha s rozšířením báze

Kernel trik

Support vector machine

Demo: SVM s lineárním jádrem

Demo: SVM s Gaussovským (RBF) jádrem

Boosting

Připomeňme: při učení optimální rozdělující nadplochy se vektory  $\mathbf{x}$  vyskytují pouze

v optimalizačním kritériu 
$$\sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j$$

a v diskriminační funkci 
$$f(\mathbf{x}) = \text{sign}\left(\sum_{i=1}^N \alpha_i y_i \mathbf{x}_i^T \mathbf{x} + w_0\right).$$

Použijeme-li rozšíření báze, změní se

optimalizační kritérium na 
$$\sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j \Phi(\mathbf{x}_i)^T \Phi(\mathbf{x}_j)$$

a diskriminační funkce na 
$$f(\mathbf{x}) = \text{sign}\left(\sum_{i=1}^N \alpha_i y_i \Phi(\mathbf{x}_i)^T \Phi(\mathbf{x}) + w_0\right).$$



# Optimální rozdělující nadplocha s rozšířením báze

Opakování

Optimální rozdělující nadplocha

Když lineární hranice nestačí...

Rozšíření báze

Dvě soustavy souřadnic

Rozšíření báze: poznámky

Optimální rozdělující nadplocha s rozšířením báze

Kernel trik

Support vector machine

Demo: SVM s lineárním jádrem

Demo: SVM s Gaussovským (RBF) jádrem

Boosting

Připomeňme: při učení optimální rozdělující nadplochy se vektory  $\mathbf{x}$  vyskytují pouze

$$\text{v optimalizačním kritériu } \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j$$

$$\text{a v diskriminační funkci } f(\mathbf{x}) = \text{sign}\left(\sum_{i=1}^N \alpha_i y_i \mathbf{x}_i^T \mathbf{x} + w_0\right).$$

Použijeme-li rozšíření báze, změní se

$$\text{optimalizační kritérium na } \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j \Phi(\mathbf{x}_i)^T \Phi(\mathbf{x}_j)$$

$$\text{a diskriminační funkce na } f(\mathbf{x}) = \text{sign}\left(\sum_{i=1}^N \alpha_i y_i \Phi(\mathbf{x}_i)^T \Phi(\mathbf{x}) + w_0\right).$$

Místo skalárního součinu v obrazovém prostoru lze použít funkci  $K(\mathbf{x}_i, \mathbf{x}_j)$

$$\text{v optimalizačním kritériu } \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j K(\mathbf{x}_i, \mathbf{x}_j)$$

$$\text{a v diskriminační funkci } f(\mathbf{x}) = \text{sign}\left(\sum_{i=1}^N \alpha_i y_i K(\mathbf{x}_i, \mathbf{x}) + w_0\right).$$

Opakování

Optimální rozdělující  
nadplocha

Když lineární hranice  
nestačí...

Rozšíření báze

Dvě soustavy souřadnic

Rozšíření báze:  
poznámky

Optimální rozdělující  
nadplocha s rozšířením  
báze

Kernel trik

Support vector machine

Demo: SVM s lineárním  
jádre

Demo: SVM s  
Gaussovským (RBF)  
jádre

Boosting

Existují funkce dvou vektorových argumentů ( $K(\mathbf{a}, \mathbf{b})$ ), jejichž hodnoty jsou rovny skalárnímu součinu ( $\phi(\mathbf{a})^T \phi(\mathbf{b})$ ) vektorů vzniklých namapováním obou původních vektorů do mnohazměrného prostoru obrazů. Takovým funkcím se říká **jádrové funkce** nebo **kernely**.

**Kernel trik:** Mějme lineární algoritmus, v němž se trénovací příklady vyskytují pouze ve skalárních součinech.

- ✓ Takový algoritmus lze znelinearizovat, když nahradíme skalární součiny dvou trénovacích vektorů jádrovou funkcí těchto vektorů.
- ✓ Výsledek je stejný, jako by se tentýž algoritmus učil v mnohazměrném prostoru nelineárních bázových funkcí.
- ✓ Díky kernelům ovšem není nutné vlastní mapování provádět, algoritmus je mnohem efektivnější.

Často používané kernely:

Polynomiální:  $K(\mathbf{a}, \mathbf{b}) = (\mathbf{a}^T \mathbf{b} + 1)^d$ , kde  $d$  je stupeň polynomu.

Gaussovský (RBF):  $K(\mathbf{a}, \mathbf{b}) = \exp\left(-\frac{|\mathbf{a} - \mathbf{b}|^2}{\sigma^2}\right)$ , kde  $\sigma^2$  je „šířka“ Gausiánu.

Opakování

Optimální rozdělující  
nadplocha

Když lineární hranice  
nestačí...

Rozšíření báze

Dvě soustavy souřadnic

Rozšíření báze:  
poznámky

Optimální rozdělující  
nadplocha s rozšířením  
báze

Kernel trik

**Support vector machine**

Demo: SVM s lineárním  
jádre

Demo: SVM s  
Gaussovským (RBF)  
jádre

Boosting

Opakování

Optimální rozdělující nadplocha

Když lineární hranice nestačí...

Rozšíření báze

Dvě soustavy souřadnic

Rozšíření báze:  
poznámky

Optimální rozdělující nadplocha s rozšířením báze

Kernel trik

**Support vector machine**

Demo: SVM s lineárním jádrem

Demo: SVM s Gaussovským (RBF) jádrem

Boosting

Support vector machine (SVM)

=

optimální rozdělující nadplocha

+

kernel trik

# Demo: SVM s lineárním jádrem

Opakování

Optimální rozdělující nadplocha

Když lineární hranice nestačí...

Rozšíření báze

Dvě soustavy souřadnic

Rozšíření báze:  
poznámky

Optimální rozdělující nadplocha s rozšířením báze





Kernel trik

Support vector machine

**Demo: SVM s lineárním jádrem**

Demo: SVM s Gaussovským (RBF) jádrem

Boosting



# Demo: SVM s Gaussovským (RBF) jádrem

Opakování

Optimální rozdělující nadplocha

Když lineární hranice nestačí...

Rozšíření báze

Dvě soustavy souřadnic

Rozšíření báze: poznámky

Optimální rozdělující nadplocha s rozšířením báze





Kernel trik

Support vector machine

Demo: SVM s lineárním jádrem

Demo: SVM s Gaussovským (RBF) jádrem

Boosting



Opakování

Optimální rozdělující  
nadplocha

Když lineární hranice  
nestačí...

**Boosting**

Ensembles, committees

Boosting

AdaBoost

AdaBoost graficky

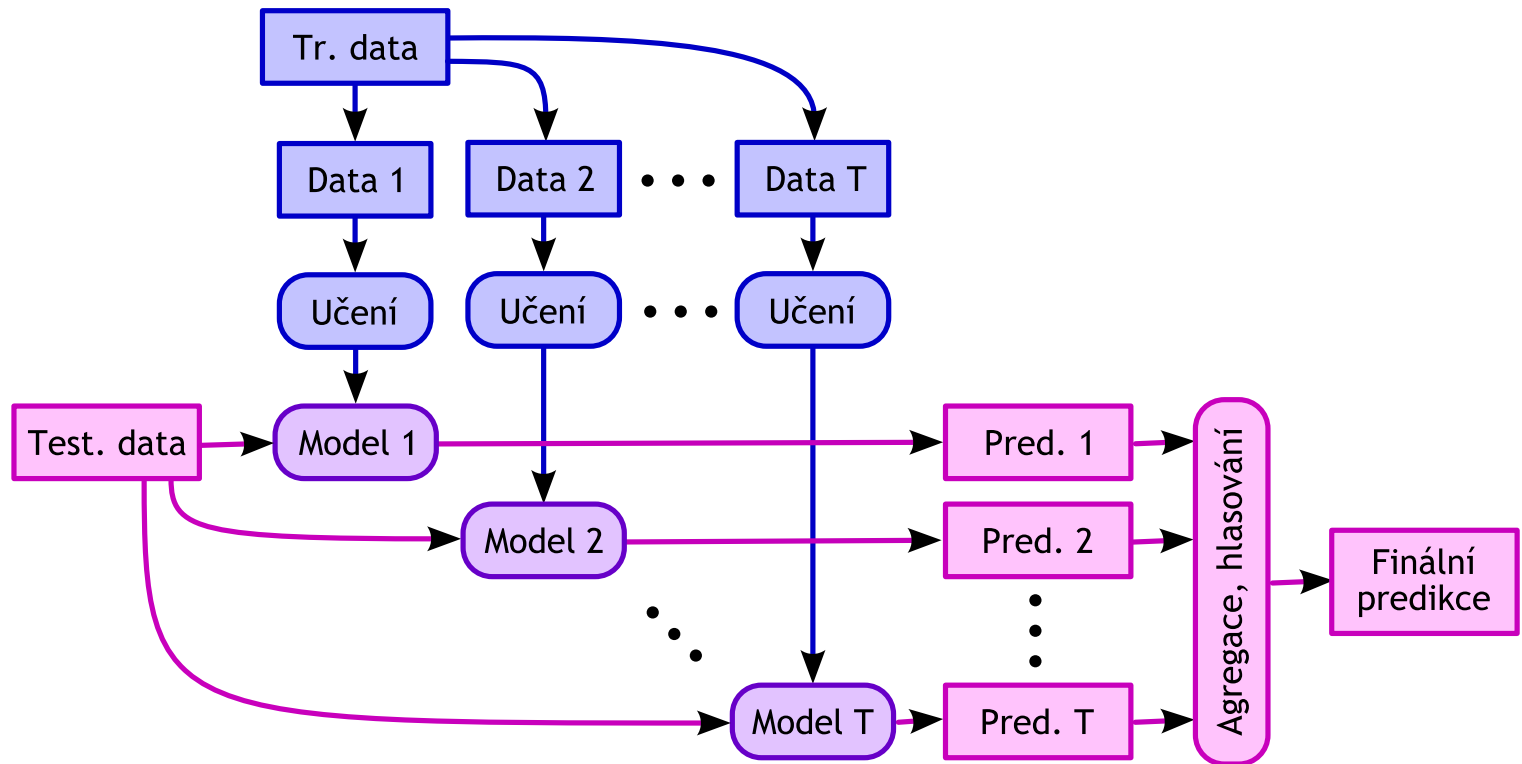
AdaBoost: poznámky

Závěr

# Boosting

# Ensembles, committees

**Ensemble** je komise různých modelů, jejichž predikce jsou sloučeny dohromady např. hlasováním nebo vážením.



Jednotlivé metody si liší tím, jakým způsobem vytvářejí jednotlivé modely tak, aby byly *různé*.



Opakování

Optimální rozdělující  
nadplocha

Když lineární hranice  
nestačí...

Boosting

Ensembles, committees

Boosting

AdaBoost

AdaBoost graficky

AdaBoost: poznámky

Závěr

## Boosting

- ✓ obecná metoda, jak ze *slabých klasifikátorů* vytvořit *silný klasifikátor*
- ✓ všechny modely jsou stejného typu, všechny jsou učeny stejným algoritmem
- ✓ různorodost modelů: každý z  $T$  modelů se učí na jinou podmnožinu trénovacích dat
- ✓ máme-li algoritmus pro učení slabého klasifikátoru, který umí konzistentně nacházet modely, jejichž přesnost je alespoň o málo větší než náhodné tipování, lze dokázat, že boosting umí vytvořit klasifikátor s vysokou úspěšností, např. 99 %.

## AdaBoost

- ✓ trénovací data
  - ✗ všechny modely se učí na všech trénovacích datech (nikoli jen na podmnožinách)
  - ✗ v každé iteraci  $t = 1, \dots, T$  se liší váhy  $D_t(i)$  trénovacích bodů  $\mathbf{x}_i$
  - ✗ špatně zaklasifikované body mají v další iteraci větší váhu
- ✓ výsledný klasifikátor
  - ✗ vážené hlasování

Opakování

Optimální rozdělující nadplocha

Když lineární hranice nestačí...

Boosting

Ensembles, committees

Boosting

AdaBoost

AdaBoost graficky

AdaBoost: poznámky

Závěr

## Algoritmus 1: AdaBoost

**Vstup:** Trénovací množina správně ohodnocených bodů:  $\{\mathbf{x}_i, y_i\}, \mathbf{x}_i \in \mathcal{R}^D, y_i \in \{+1, -1\},$   
 $i = 1, \dots, m$

**Výstup:** Finální klasifikátor  $H_{\text{final}}(\mathbf{x}) = \text{sign} \left( \sum_{t=1}^T \alpha_t h_t(\mathbf{x}) \right)$

1 **begin**

2     Inicializuj váhy trénovacích případů:  $D_1(i) = \frac{1}{m}.$

3     **for**  $t = 1, \dots, T$  **do**

4         Najdi slabý klasifikátor  $h_t$

5         Spočti váženou chybu:  $\epsilon_t = \sum_{i=1}^m D_t(i) I(y_i \neq h_t(\mathbf{x}_i))$

6         Spočti váhu modelu  $h_t$ :


$$\alpha_t = \frac{1}{2} \ln \left( \frac{1 - \epsilon_t}{\epsilon_t} \right) > 0$$

7         Uprav váhy trénovacích bodů:

$$D_{t+1}(i) = \frac{D_t(i)}{Z_t} \times \begin{cases} e^{-\alpha_t}, & \text{pokud } y_i = h_t(\mathbf{x}_i), \\ e^{\alpha_t}, & \text{pokud } y_i \neq h_t(\mathbf{x}_i), \end{cases}$$
$$= \frac{D_t(i)}{Z_t} \times \exp(-\alpha_t y_i h_t(\mathbf{x}_i)),$$

   kde  $Z_t$  je normalizační konstanta.

## Iterace 1:




$$\epsilon_1 = 0.3$$

$$\alpha_1 = 0.42$$

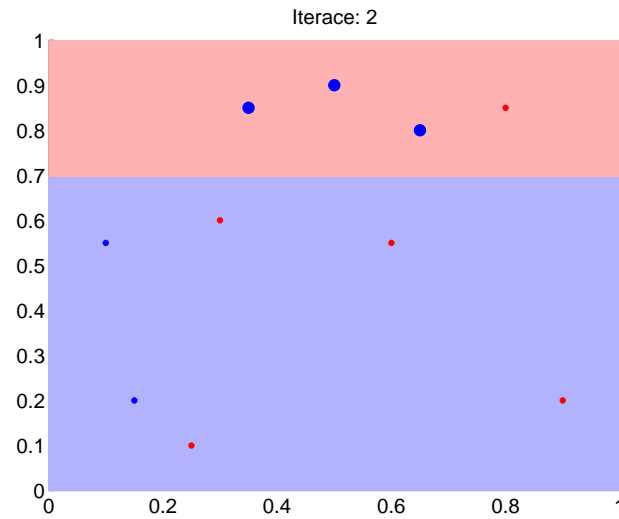
# AdaBoost graficky

## Iterace 1:



$$\epsilon_1 = 0.3$$
$$\alpha_1 = 0.42$$

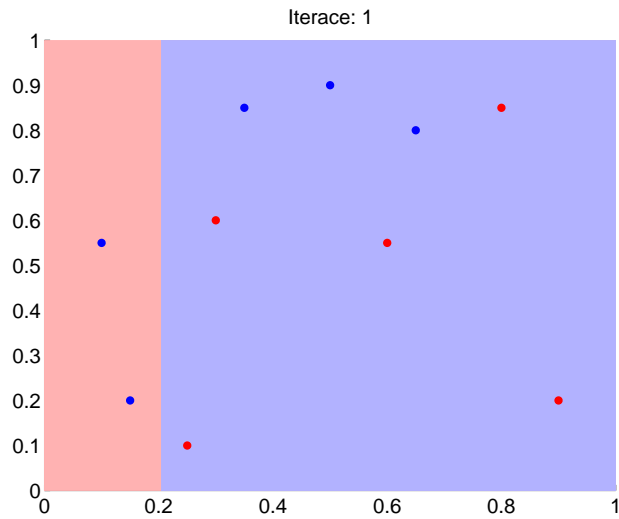
## Iterace 2:



$$\epsilon_2 = 0.21$$
$$\alpha_2 = 0.65$$


# AdaBoost graficky

## Iterace 1:




$$\epsilon_1 = 0.3$$
$$\alpha_1 = 0.42$$

## Iterace 2:



$$\epsilon_2 = 0.21$$
$$\alpha_2 = 0.65$$


## Iterace 3:



$$\epsilon_3 = 0.13$$
$$\alpha_3 = 0.92$$

# AdaBoost graficky


Iterace 1:



$$\epsilon_1 = 0.3$$

$$\alpha_1 = 0.42$$


Iterace 2:



$$\epsilon_2 = 0.21$$


$$\alpha_2 = 0.65$$

Iterace 3:



$$\epsilon_3 = 0.13$$

$$\alpha_3 = 0.92$$



Opakování

Optimální rozdělující  
nadplocha

Když lineární hranice  
nestačí...

Boosting

Ensembles, committees

Boosting

AdaBoost

AdaBoost graficky

AdaBoost: poznámky

Závěr

Trénovací chyba:

- ✓ označme  $\gamma_t = 0.5 - \epsilon_t$ , o co je  $t$ . model lepší než náhodné hádání
- ✓ označme  $\gamma = \min_t \gamma_t$ , neboli všechny modely  $h(t)$  jsou na trénovací sadě úspěšnější než náhodné hádání alespoň o  $\gamma$  (platí také  $\forall \gamma_t : \gamma_t \geq \gamma > 0$ )
- ✓ lze ukázat, že trénovací chyba  $\text{Err}_{\text{Tr}}(H_{\text{final}}) \leq e^{-2\gamma^2 T}$

Opakování

Optimální rozdělovací  
nadplocha

Když lineární hranice  
nestačí...

Boosting

Ensembles, committees

Boosting

AdaBoost

AdaBoost graficky

AdaBoost: poznámky

Závěr

Metody pro binární klasifikaci objektů popsaných *reálnými příznaky*:

- ✓ učení lineární diskriminační funkce
  - ✗ perceptron (pomalu konverguje)
  - ✗ optimální rozdělovací nadplocha (úloha QP)
  
- ✓ využití lineárních metod pro konstrukci nelineárních modelů
  - ✗ rozšíření báze
  - ✗ kernel trik (SVM)
  - ✗ ensembles (AdaBoost)

Poznámky:

- ✓ SVM: existují jádra umožňující využít SVM i pro nenumerické příznaky (např. pro klasifikaci textů)
- ✓ AdaBoost: algoritmus je možné využít i pro kategoriální příznaky