

# Vytěžování Dat

## Přednáška 9 – Lineární klasifikátor, rozšíření báze, LDA, logistická regrese

Miroslav Čepek

Fakulta Elektrotechnická, ČVUT



Evropský sociální fond Praha & EU:  
Investujeme do vaší budoucnosti

25.11.2014


- Jaké znáte klasifikační algoritmy?

- Jaké znáte klasifikační algoritmy?
  - ▶ naivní Bayesův klasifikátor (NB),
  - ▶ rozhodovací strom,
  - ▶ k nejbližších sousedů (kNN).

- Jaké znáte klasifikační algoritmy?
  - ▶ naivní Bayesův klasifikátor (NB),
  - ▶ rozhodovací strom,
  - ▶ k nejbližších sousedů (kNN).
- Jak fungují?

- Jaké znáte klasifikační algoritmy?
  - ▶ naivní Bayesův klasifikátor (NB),
  - ▶ rozhodovací strom,
  - ▶ k nejbližších sousedů (kNN).
- Jak fungují?
  - ▶ NB počítá pravděpodobnost přiřazení do třídy za podmínky dané pozorováním,
  - ▶ rozhodovací strom generuje posloupnost rozhodnutí,
  - ▶ kNN hledá nejbližší instance z trénovací množiny.


- Další možný pohled je z hlediska **rozhodovací hranice**.
- Rozhodovací hranice je místo, kde instance přestávají patřit do třídy A a začínají patřit do třídy B.



Andrew Ng: Machine Learning. Open Classroom course.


## Rozhodovací hranice (2)

- Jak bude vypadat nejjednodušší rozhodovací hranice, která data oklasifikuje bez chyby?



## Rozhodovací hranice (2)

- Jak bude vypadat nejjednodušší rozhodovací hranice, která data oklasifikuje bez chyby?



- Stačí přece přímka!
- Nejjednodušší = s nejmenším počtem parametrů.




# Lineární klasifikátor

- Takovou přímku umíme celkem jednoduše najít a vyrobit :).
- Jak vypadá rovnice přímky, resp. **nadroviny** pro větší dimenze?
- Uvažujme  $d$  dimenzionální reálný vstupní prostor  $\mathbf{x} \in \mathbb{R}^d$ .
- Výstup nechť je binární  $y \in \{+1, -1\}$ .

# Lineární klasifikátor

- Takovou přímkou umíme celkem jednoduše najít a vyrobit :).
- Jak vypadá rovnice přímky, resp. **nadroviny** pro větší dimenze?
- Uvažujme  $d$  dimenzionální reálný vstupní prostor  $\mathbf{x} \in \mathbb{R}^d$ .
- Výstup nechť je binární  $y \in \{+1, -1\}$ .

$$\sum_{j=1}^d w_j x_j = \mathbf{w} \cdot \mathbf{x} = 0$$



## Lineární klasifikátor (2)

- Jak odhadneme, do které třídy patří vzor  $\mathbf{x}$ ?

## Lineární klasifikátor (2)

- Jak odhadneme, do které třídy patří vzor  $\mathbf{x}$ ?
  - ▶ Prostým dosazením!
  - ▶ Pokud  $\mathbf{w} \cdot \mathbf{x} > 0$  vzor patří do třídy  $+1$ ,
  - ▶ pokud  $\mathbf{w} \cdot \mathbf{x} < 0$  vzor patří do třídy  $-1$ .
  - ▶  $0$  je rozhodovací hranice, kde se nelze rozhodnout.
  - ▶ Naštěstí se toto nestává často.
  - ▶ Formálně lze zapsat

$$y' = \textit{signum}(\mathbf{w} \cdot \mathbf{x})$$

- ▶ kde *signum* je znaménkovou funkcí
  - ★ vrací  $+1$  pro kladná čísla,  $-1$  pro záporná a  $0$  pro nulový vstup.

## Lineární klasifikátor (3)

- Vidíte v rovnici  $w \cdot x = 0$  nějaký problém?

# Lineární klasifikátor (3)

- Vidíte v rovnici  $\mathbf{w} \cdot \mathbf{x} = 0$  nějaký problém?
  - ▶ Zkusme pro  $d = 2$  dosadit do rovnice  $x_1 = x_2 = 0$ . Co vyjde?
  - ▶ 0 bez ohledu na nastavení vah  $w_1$  a  $w_2$ .
  - ▶ Rozhodovací hranice vždy prochází 0, resp. vektorem  $(0, 0, \dots, 0)$ .
  - ▶ Nepříjemné omezení – hranicí pouze otáčíme kolem středu. Co s tím?
- Můžeme rozšířit rovnice rozhodovací hranice a klasifikátoru na

$$\sum_{j=1}^d w_j x_j + \Theta = 0, \text{ resp. } y' = \textit{signum}(\mathbf{w} \cdot \mathbf{x} + \Theta)$$

- ▶  $\Theta$  je aditivní konstanta a označuje se jako **práh**.

- Zbývá najít vektor koeficientů (vah)  $(w_1, w_2, \dots, w_n)$  a práh  $\Theta$ .
- Představuje práh  $\Theta$  anomálii, která potřebuje speciální zacházení?

- Zbývá najít vektor koeficientů (vah)  $(w_1, w_2, \dots, w_n)$  a práh  $\Theta$ .
- Představuje práh  $\Theta$  anomálii, která potřebuje speciální zacházení?
- Tak napůl :). Nepotřebuje, pokud trochu upravíme vstupní data.
- Co kdyby všechny vzory měly jeden atribut (vstupní proměnnou, řekněme  $x_0$ ) se stejnou hodnotou?
- Když pak budu počítat  $w_0x_0$ , vyjde mi vždy stejná hodnota ... to je přece náš práh!



- Zbývá najít vektor koeficientů (vah)  $(w_1, w_2, \dots, w_n)$  a práh  $\Theta$ .
- Představuje práh  $\Theta$  anomálii, která potřebuje speciální zacházení?
- Tak napůl :). Nepotřebuje, pokud trochu upravíme vstupní data.
- Co kdyby všechny vzory měly jeden atribut (vstupní proměnnou, řekněme  $x_0$ ) se stejnou hodnotou?
- Když pak budu počítat  $w_0x_0$ , vyjde mi vždy stejná hodnota ... to je přece náš práh!
- Ke každému vzoru přidám ještě jednu dimenzi s konstantní hodnotou – pro jednoduchost 1.
- Pak už se o práh nemusím speciálně starat.

- Gradientní sestup je iterativní optimalizační metoda.
  - ▶ Hledáme minimum funkce  $f(\mathbf{x})$ .
  - ▶ Tj. hledáme takové  $\mathbf{x}$ , kde má funkce  $f(\mathbf{x})$  nejnižší hodnotu.
  - ▶ Mám nějaké  $\mathbf{x}_0$  a znám hodnotu  $f(\mathbf{x}_0)$ . Hledám v okolí  $\mathbf{x}_0$ , nějaké  $\mathbf{x}_1$ , kde bude hodnota  $f(\mathbf{x}_1)$  nižší. A to budu opakovat stále dokola, až to dál nepůjde.

- Gradientní sestup je iterativní optimalizační metoda.
  - ▶ Hledáme minimum funkce  $f(\mathbf{x})$ .
  - ▶ Tj. hledáme takové  $\mathbf{x}$ , kde má funkce  $f(\mathbf{x})$  nejnižší hodnotu.
  - ▶ Mám nějaké  $\mathbf{x}_0$  a znám hodnotu  $f(\mathbf{x}_0)$ . Hledám v okolí  $\mathbf{x}_0$ , nějaké  $\mathbf{x}_1$ , kde bude hodnota  $f(\mathbf{x}_1)$  nižší. A to budu opakovat stále dokola, až to dál nepůjde.
- "Na horách se chci dostat do údolí. Podívám se, kterým směrem se kopec nejvíc snižuje a udělám krok tím směrem. A zase se podívám, kam je to nejvíc z kopce a udělám krok. A tak dále, až jednou zjistím, že to dál nejde, čili jsem v údolí."

## Gradientní sestup – krok stranou (2)

- V matematice existuje možnost, jak zjistit směr největšího vzestupu hodnoty funkce – gradient. Tou je první parciální derivace podle všech dimenzí. Když půjdu přesně opačně, půjdu ve směru největšího poklesu.
- Gradient je vektor parciálních derivací podle jednotlivých proměnných:

$$\text{grad}(f(x_1, x_2, \dots, x_n)) = \left( \frac{\partial f}{\partial x_1}, \frac{\partial f}{\partial x_2}, \dots, \frac{\partial f}{\partial x_n} \right)$$

# Chybová funkce a gradientní sestup

- Jako u jiných klasifikačních metod hledáme nastavení klasifikátoru (zde vah) takové, abychom správně označili co nejvíc vzorů.
- Uvažujme nejprve chybovou funkci  $J(\mathbf{w}, \chi)$ , která vrací počet špatně klasifikovaných vzorů  $\mathbf{x}$  z množiny vzorů  $\chi$  (například z trénovací množiny) při daných vahách  $\mathbf{w}$ .

# Chybová funkce a gradientní sestup

- Jako u jiných klasifikačních metod hledáme nastavení klasifikátoru (zde vah) takové, abychom správně označili co nejvíc vzorů.
- Uvažujme nejprve chybovou funkci  $J(\mathbf{w}, \chi)$ , která vrátí počet špatně klasifikovaných vzorů  $\mathbf{x}$  z množiny vzorů  $\chi$  (například z trénovací množiny) při daných vahách  $\mathbf{w}$ .
  - ▶ Nehodí se – neumím spočítat parciální derivace (a ani gradient).

# Chybová funkce a gradientní sestup

- Jako u jiných klasifikačních metod hledáme nastavení klasifikátoru (zde vah) takové, abychom správně označili co nejvíc vzorů.
- Uvažujme nejprve chybovou funkci  $J(\mathbf{w}, \chi)$ , která vrátí počet špatně klasifikovaných vzorů  $\mathbf{x}$  z množiny vzorů  $\chi$  (například z trénovací množiny) při daných vahách  $\mathbf{w}$ .
  - ▶ Nehodí se – neumím spočítat parciální derivace (a ani gradient).

- Zkusme jinou

$$E(\mathbf{w}) = \sum_{\mathbf{x}_e \in \chi^{err}} (-y_e \mathbf{w}(\mathbf{t}) \cdot \mathbf{x}_e)$$

- kde  $\chi^{err}$  jsou špatně klasifikované vzory z  $\chi$ ,
- a  $y_e$  je korektní klasifikace instance  $\mathbf{x}_e$ .

# Chybová funkce a gradientní sestup

- Jako u jiných klasifikačních metod hledáme nastavení klasifikátoru (zde vah) takové, abychom správně označili co nejvíc vzorů.
- Uvažujme nejprve chybovou funkci  $J(\mathbf{w}, \chi)$ , která vrátí počet špatně klasifikovaných vzorů  $\mathbf{x}$  z množiny vzorů  $\chi$  (například z trénovací množiny) při daných vahách  $\mathbf{w}$ .
  - ▶ Nehodí se – neumím spočítat parciální derivace (a ani gradient).

- Zkusme jinou

$$E(\mathbf{w}) = \sum_{\mathbf{x}_e \in \chi^{err}} (-y_e \mathbf{w}(\mathbf{t}) \cdot \mathbf{x}_e)$$

- kde  $\chi^{err}$  jsou špatně klasifikované vzory z  $\chi$ ,
- a  $y_e$  je korektní klasifikace instance  $\mathbf{x}_e$ .
  - ▶ To už je spojitá funkce.
  - ▶  $E$  mohu minimalizovat změnou vah – pomocí gradientního sestupu.



# Chybová funkce a gradientní sestup

- Parciální derivace chybové funkce  $E$  podle jedné proměnné:

$$\frac{\partial E}{\partial w_1} = \frac{\partial \sum_{\mathbf{x}_e \in \mathcal{X}^{err}} (-y_e w_1(t) x_{1e})}{\partial w_1}$$

- Kde  $x_{1e}$  je první souřadnice z  $\mathbf{x}_e$  a  $w_1$  je první souřadnice z  $\mathbf{w}$ .

$$\frac{\partial \sum_{\mathbf{x}_e \in \mathcal{X}^{err}} (-y_e w_1(t) x_{1e})}{\partial w_1} = - \sum_{\mathbf{x}_e \in \mathcal{X}^{err}} y_e x_{1e}$$

- Chybu nejméně snížím změnou váhy  $w_1$  o součet hodnot prvních vstupních proměnných  $x_1$  pozitivních vzorů, na kterých jsem udělal chybu (u negativních vzorů budu odečítat).
- Analogicky i ostatní vstupní proměnné (včetně prahu).

## • Perceptronový algoritmus

- ▶ Založen přesně na této myšlence ...

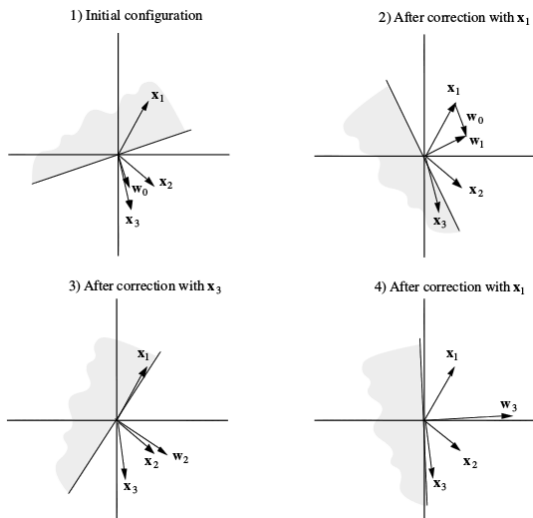
- 1 Inicializuj váhy na náhodné hodnoty.
- 2 Vezmi náhodný vstupní vzor  $\mathbf{x}$ . A spočítej hodnotu

$$y'(\mathbf{x}) = \text{sgn}\left(\sum_j w_j x_j = \mathbf{w} \cdot \mathbf{x}\right)$$

- 3 Liší-li se požadovaný výstup  $y$  od odhadu  $y'$ , oprav váhy  $\mathbf{w}$  takto:
  - ▶  $e(\mathbf{x}_e) = \text{signum}(y_e - y'_e)$
  - ▶  $\mathbf{w}(t+1) = \mathbf{w}(t) + \eta e(\mathbf{x}_e) \mathbf{x}_e$
  - ▶  $\eta$  je koeficient učení, který s postupem času může klesat k nule.
- 4 Pokud chceš, pokračuj bodem 2).

# Ilustrace učení perceptronu

- 4 pozitivní příklady, dělící přímka středem . . . ukázka konvergence.



Rojas: Neural Networks.

# Jednoznačnost výsledné přímky


- Jak poznám, že se perceptronový algoritmus zastavil?

# Jednoznačnost výsledné přímky

- Jak poznám, že se perceptronový algoritmus zastavil?
- Je výsledná přímka jediná možná?


# Jednoznačnost výsledné přímky

- Jak poznám, že se perceptronový algoritmus zastavil?
- Je výsledná přímka jediná možná?
- Ne, takových přímek je dokonce nekonečně mnoho.
- Přesto jsou některé lepší než jiné.




- Kterou mám vybrat? A kterou nám vybere Perceptronový algoritmus?

- Lze pomocí perceptronu bezchybně klasifikovat následující data?



# Lineárně separovatelné problémy

- Lze pomocí perceptronu bezchybně klasifikovat následující data?



- Ne!
- Třídám (datům), které lze oddělit přímkou, říkáme lineárně separovatelná.



- Lze pomocí lineárního klasifikátoru vyřešit lineárně ne-separovatelné problémy?



# Lineárně ne-separovatelné problémy

- Lze pomocí lineárního klasifikátoru vyřešit lineárně ne-separovatelné problémy?
- Ne. K tomu potřebuji přidat další kvalitu.

- Lze pomocí lineárního klasifikátoru vyřešit lineárně ne-separovatelné problémy?
- Ne. K tomu potřebuji přidat další kvalitu.
  - 1 Jednou z možností je zkombinovat lineární klasifikátory.  
O tom bude příští přednáška.

- Lze pomocí lineárního klasifikátoru vyřešit lineárně ne-separovatelné problémy?
- Ne. K tomu potřebuji přidat další kvalitu.
  - 1 Jednou z možností je zkombinovat lineární klasifikátory. O tom bude příští přednáška.
  - 2 Rozšíření báze.

- Když data nejsou oddělitelná v původním prostoru, zkusme jestli by nebyla lineárně separovatelná ve více-dimenzionálním prostoru.



- Zase existuje mnoho transformací.
- Přidej ke stávajícím dimenzím **součiny originálních dimenzí**.
  - ▶ Jedna z těch jednodušších metod.
  - ▶ Pracuje s parametrem  $s$  – maximálním stupněm součinu.

- Zase existuje mnoho transformací.
- Přidej ke stávajícím dimenzím **součiny originálních dimenzí**.
  - ▶ Jedna z těch jednodušších metod.
  - ▶ Pracuje s parametrem  $s$  – maximálním stupněm součinu.
- Příklad pro  $s = 2$  a původní dimenze  $(x_1, x_2)$ 
  - ▶ získám 5D prostor dimenzí  $(x_1, x_2, \chi_1, \chi_2, \chi_3)$
  - ▶  $\chi_1 = x_1^2$
  - ▶  $\chi_2 = x_1 * x_2$
  - ▶  $\chi_3 = x_2^2$

- Jak naučím klasifikátor v novém prostoru?




# Učení nelineárního klasifikátoru

- Jak naučíme klasifikátor v novém prostoru?
- Díky rozšíření báze nakládám s více-dimenzionálním prostorem a (třeba) dokážu třídy lineárně separovat.
- Postupuji úplně stejně jako v předchozím případě. Tj. použiji např. perceptronový algoritmus.

- Jak naučíme klasifikátor v novém prostoru?
- Díky rozšíření báze nakládám s více-dimenzionálním prostorem a (třeba) dokážu třídy lineárně separovat.
- Postupuji úplně stejně jako v předchozím případě. Tj. použiji např. perceptronový algoritmus.
- Pokud se mi nepodaří získat lineární separaci, mohu zkusit zvýšit maximální stupeň součiny a zkusit separaci znovu.
- Obecně platí, že k oddělení  $N$  bodů stačí prostor o  $N - 1$  dimenzích.

# Rozhodovací hranice

- Jak pak bude vypadat projekce rozhodovací hranice zpět do originálních dimenzí?



- Podařilo se dosáhnout "ohnutí" rozhodovací hranice.
- Hranice bude "poddajnější" s rostoucím  $s$ .

## Rozhodovací hranice (2)

- Můžu zvyšovat maximální stupeň součiny (parametr  $s$ ) do nekonečna? Nebo někde narazím?

## Rozhodovací hranice (2)

- Můžu zvyšovat maximální stupeň součinu (parametr  $s$ ) do nekonečna? Nebo někde narazím?
- S vyšším maximálním stupněm  $s$  vyvstávají dva problémy:
  - 1 Musím nastavovat více vah, perceptronový (nebo jakýkoliv jiný) algoritmus to nemusí zvládnout, váhy se nastaví špatně.
  - 2 Zvyšuji pravděpodobnost, že se klasifikátor přeučí, tj. naučí se šum a chyby v trénovacích datech, nedokáže vlastnosti trénovacích dat zobecnit, podobně jako například 1-NN klasifikátor.

# Klasifikace do několika tříd

- Co když mám více než dvě třídy?
- Mohu použít (ne-)lineární separaci? Případně jak?

# Klasifikace do několika tříd

- Co když mám více než dvě třídy?
- Mohu použít (ne-)lineární separaci? Případně jak?
- Budu rozhodovat o každé třídě samostatně.
  - ▶ Pro problém s  $N$  třídami budu mít  $N$  klasifikátorů.
  - ▶ Každý bude říkat – "Instance patří resp. **nepatří** do mé třídy".

# Klasifikace do několika tříd

- Co když mám více než dvě třídy?
- Mohu použít (ne-)lineární separaci? Případně jak?
- Budu rozhodovat o každé třídě samostatně.
  - ▶ Pro problém s  $N$  třídami budu mít  $N$  klasifikátorů.
  - ▶ Každý bude říkat – "Instance patří resp. **nepatří** do mé třídy".
- Při rozhodování o neznámé instanci  $x$  se zeptám všech  $N$  klasifikátorů na jejich rozhodnutí:
  - 1  $x$  patří právě do jedné třídy  $\rightarrow$  OK.
  - 2  $x$  patří do více tříd  $\rightarrow$  rozhodnu např. podle hodnoty  $w \cdot x$  (čím je větší, tím je  $x$  dále od rozhodovací hranice).
  - 3 analogicky, pokud  $x$  nepatří do žádné třídy  $\rightarrow$  hledám třídu, kam  $x$  nepatří nejméně :).



- Linearita
- Pokud se dostatečně pohnu i jen v jedné proměnné, můžu získat obrácený výsledek.
- Hodnota  $w \cdot x$  roste se vzdáleností od rozhodovací hranice a nemá žádnou interpretaci.
- Lineární klasifikátory špatně snášejí chybějící hodnoty.
- Pokud provádím rozšíření báze, může trvat učení velmi dlouho.



# Linear Discriminant Analysis

- LDA je statistický přístup k problému lineární separace.
- Pamatujete si PCA?
  - ▶ Principal Component Analysis – mluvili jsme o ní u SOM.

# Linear Discriminant Analysis

- LDA je statistický přístup k problému lineární separace.
- Pamatujete si PCA?
  - ▶ Principal Component Analysis – mluvili jsme o ní u SOM.
- LDA redukuje původní prostor na přímku (1 dimenzi)
  - ▶ Dělá to tak, aby co nejvíce oddělila vzory různých tříd.
  - ▶ V jistém smyslu je to opak rozšíření báze.

## Linear Discriminant Analysis (2)



- Obraz vzoru v nové souřadnici získám jako  $w \cdot x$ , kde  $w$  jsou váhy.
- V principu počítám to samé jako u lineárního klasifikátoru
  - ▶ interpretace a postup jsou úplně jiné.

# Linear Discriminant Analysis (3)

- Při počítání LDA se snažím maximalizovat “separaci” mezi třídami.
- Nejprve pro každou třídu musím spočítat rozptyl v obraze (scatter).
  - ▶ Projekce objektu do nové souřadnice:

$$y_i = \mathbf{x}_i \cdot \mathbf{w}$$

- ▶ Odhad střední hodnoty (pro pozitivní třídu  $\chi^+$ ):

$$\tilde{\mu}_{\chi^+} = \frac{1}{\|\chi^+\|} \sum_{\forall x_i \in \chi^+} y_i = \frac{1}{\|\chi^+\|} \sum_{\forall x_i \in \chi^+} \mathbf{x}_i \cdot \mathbf{w}$$

- ▶ Odhad rozptylu v obraze (pro pozitivní třídu  $\chi^+$ )


$$\tilde{s}_{\chi^+}^2 = \sum_{\forall x_1 \in \chi^+} y_i - \tilde{\mu}_{\chi^+}$$

# Linear Discriminant Analysis (4)

- Nyní můžu spočítat míru “separace” pro projekci danou vahami  $\mathbf{w}$ :

$$J(\mathbf{w}) = \frac{\|\tilde{\mu}_{\chi^+} - \tilde{\mu}_{\chi^-}\|^2}{\tilde{s}_{\chi^+}^2 + \tilde{s}_{\chi^-}^2}$$



- Hledáme tedy projekci, která co nejvíc seskupí vzory stejné třídy a zároveň co nejvíc oddělí vzory různých tříd.



- LDA lze zobecnit tak, aby dokázala klasifikovat do více tříd.
- Pak se nevytváří pouze jedna nová dimenze, ale "počet tříd"-1 nových dimenzí a mírně se upraví vzorečky :).

# Problémy LDA


- Stejně jako všechno, má i LDA nějaké mouchy:
  - ▶ LDA dimenze nemusí stačit ke správném zařazení do třídy.
  - ▶ LDA předpokládá normální rozložení dat ve třídách. A selhává, pokud tomu tak není (např. pokud třídy mají komplexní tvary).
  - ▶ Rozdíly mezi třídami jsou spíše v rozptylu hodnot než v rozdílu středních hodnot.





- Mohu interpretovat vzdálenosti objektů od rozhodovací hranice?
  - ▶ Ideálně jako pravděpodobnost příslušnosti k dané třídě.

- Mohu interpretovat vzdálenosti objektů od rozhodovací hranice?
  - ▶ Ideálně jako pravděpodobnost příslušnosti k dané třídě.
- Existuje **logistická funkce**
  - ▶ Definovaná jako  $f(z) = \frac{1}{1+e^{-z}}$ .
  - ▶ Její hodnoty jsou omezené na interval  $0 \dots 1$ .
  - ▶ Navíc kolem  $z = 0$  (rozhodovací hranice) je její změna největší.



## Logistická regrese (2)

- Zkusíme zavést pojem  $sance = \frac{p}{1-p}$

## Logistická regrese (2)

- Zkusíme zavést pojem  $sance = \frac{p}{1-p}$
- Zlogaritmuje ji a položíme rovnou vzdálenosti k dělicí hranici
  - ▶ Tím nejprve získáme funkci  $logit(p) = \log(sance(p)) = \log\left(\frac{p}{1-p}\right)$
  - ▶ Následně  $logit(p) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k$
  - ▶ Kde  $\beta_1, \dots, \beta_k$  jsou regresní koeficienty a  $\beta_0$  je posun.
  - ▶ Přičtení vzdálenosti teď odpovídá násobení šance.

## Logistická regrese (2)

- Zkusíme zavést pojem  $sance = \frac{p}{1-p}$
- Zlogaritmujeme ji a položíme rovnou vzdálenosti k dělicí hranici
  - ▶ Tím nejprve získáme funkci  $logit(p) = \log(sance(p)) = \log\left(\frac{p}{1-p}\right)$
  - ▶ Následně  $logit(p) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k$
  - ▶ Kde  $\beta_1, \dots, \beta_k$  jsou regresní koeficienty a  $\beta_0$  je posun.
  - ▶ Přičtení vzdálenosti teď odpovídá násobení šance.
- Zkusme zpětně dopočítat pravděpodobnost vzoru  $\mathbf{x}$ :

$$p(\mathbf{x}) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k)}}$$

- Pro dvě třídy stačí rozhodnutí dle testu  $p(\mathbf{x}) > 0.5$ .

- Tři lineární metody klasifikace
  - ▶ Perceptron – diskriminativní model, optimalizuje dělící hranici.
  - ▶ LDA – vhodná při splnění silných předpokladů, generativní model.
  - ▶ Logistická regrese – pravděpodobnostní přístup.
- Na začátku jsme nezmínili použití metody nejmenších čtverců
  - ▶ Klasický přístup v lineární regresi.
  - ▶ Při klasifikaci pro každou třídu zavedeme jako závislou veličinou indikátorový vektor třídy.
  - ▶ Objekt zařazen do třídy, k jejíž nadrovině má největší kladnou vzdálenost.
  - ▶ Je citlivá na odlehlé hodnoty.
  - ▶ Při větším počtu tříd některé z nich “odmaskovává”.
  - ▶ Přednost má logistická regrese.

- Perceptron, čtěte např. Hagan et al.: Neural Network Design, [hagan.okstate.edu/4\\_Perceptron.pdf](http://hagan.okstate.edu/4_Perceptron.pdf)
- LDA převzata z [research.cs.tamu.edu/prism/lectures/pr/pr\\_l10.pdf](http://research.cs.tamu.edu/prism/lectures/pr/pr_l10.pdf)
- Logistic Regression tutorial <http://www.omidrouhani.com/research/logisticregression/html/logisticregression.htm>