


# Strojové učenie


- **Strojové učenie s učiteľom**
  - regresia, klasifikácia
- **Strojové učenie bez učiteľa**
  - zhukovanie, analýza hlavných komponentov (PCA)
- **Pravdepodobnostné modelovanie**
  - skryté Markovove modely, Bayesovské siete
- **Teória strojového učenia**
  - výchylka a rozptyl, PAC učenie, VC dimenzia
- **Učenie posilňovaním (reinforcement learning)**

# Regresia




- Lineárna regresia
- Normálne rovnice  $O(n^3)$
- Bákové funkcie => generalizovaná lineárna regresia

# Neurónové siete



- V každom uzle lineárna kombinácia + nelineárna transformácia
- Gradientová metóda => algoritmus spätnej propagácie


# Klasifikácia



Lineárna klasifikácia


Expanzia pomocou básových funkcií

# Support Vector Machines




- Lineárny klasifikátor s najväčším odstupom
- Kvadratický program
- Kernelový trik: rozvoj do nekonečne veľkého priestoru  $K(x,y)$  – intuitívne miera podobnosti

# Support Vector Machines




# Diskrétné klasifikátory



+BAGGING AND BOOSTING

# Výchylka vs. rozptyl



# PAC učenie

## (pravdepodobne približne správne)

- $t$ : Koľko tréningových dát potrebujeme na natréningovanie klasifikátora?
- Pre dostatočne veľké  $t$ , **trénovacia a testovacia chyba sa s veľkou pravdepodobnosťou ( $>1-\delta$ ) odlišujú len málo ( $<\epsilon$ )**
- Teória PAC učenia dáva odhady, aké veľké  $t$  stačí pre dané  $H$ ,  $\epsilon$  a  $\delta$


# PAC učenie - odhady

- **Konečná množina hypotéz:**  
 $t = O(\log |H|)$
- **Nekonečná množina hypotéz:**
  - Vapnik-Červonenkis (VC) dimenzia  $d$   
( $t$  rastie lineárne s  $d$ )  
Neurónové siete:  $d = \Theta(W \log n)$   
( $W$  – počet váh,  $n$  – počet sigmoidov)
  - SVM:  $t = O(1/r^2 \log^2 1/r)$   
( $r$  – veľkosť odstupu)

# Pravdepodobnostné modelovanie


- Definujeme **generatívny pravdepodobnostný model**, ktorý (na základe parametrov  $\theta$ ) priradí pravdepodobnosť pozorovania dátam  $X$
- **Vierohodnosť parametrov**:  $\Pr(X \mid \theta)$
- Pri tréňovaní hľadáme **najvieryhodnejšie parametre**

# Skryté Markovovské modely



- Viterbiho algoritmus
- Forward algoritmus
- Trénovanie: pozorované frekvencie

# Bayesovské siete



- Eliminačný algoritmus
- Trénovanie pomocou pozorovaných frekvencií
- Trénovanie pomocou EM algoritmu

# Matematické metódy

- Maticová algebra, riešenie sústav rovníc
- Vlastné vektory, vlastné čísla
- Parciálne derivácie, Lagrangeove multiplikátory
- Numerika: Gradientová metóda
- Optimalizácia: lineárne, kvadratické programovanie, teória duality
- Analytická geometria, vektorový počet
- Pravdepodobnosť, Bayesov vzorec, vierohodnosť
- Štatistika: očakávané hodnoty, štandardná odchýlka
- Teória informácie: entropia