


Strojové učenie


- **Strojové učenie s učiteľom**
 - regresia, klasifikácia
- **Strojové učenie bez učiteľa**
 - zhlukovanie, 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



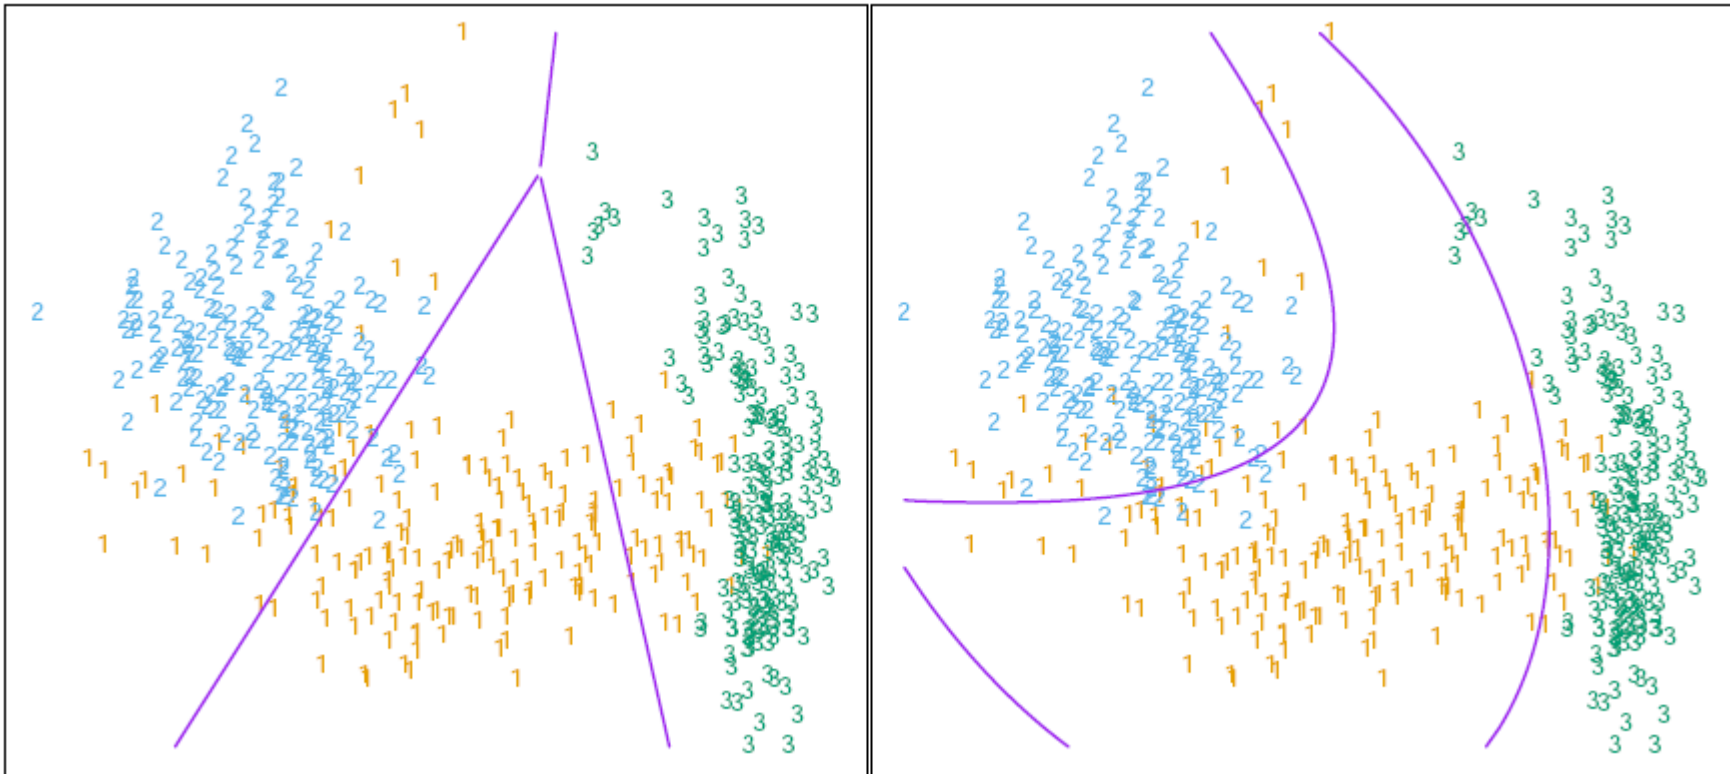
- Lineárna regresia
- Normálne rovnice $O(n^3)$
- Bázové funkcie => generalizovaná lineárna regresia

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




Diskrétne klasifikátory



+BAGGING AND BOOSTING

Výchylka vs. rozptyl



PAC učenie

(pravdepodobne približne správne)

- t : Koľko tréningových dát potrebujeme na natréningovanie klasifikátora?
- Pre dostatočne veľké t , **tréningová 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 , ϵ a δ


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: $d = \Theta(W \cdot \log n)$
(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 θ) priradí pravdepodobnosť pozorovania dátam X
- **Vierohodnosť parametrov**: $\Pr(X | \theta)$
- 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 (DNES!)

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: stredné hodnoty, štandardná odchýlka

(Ne)súvisiace predmety

Leto 2015:

- 1-AIN-480: Neurónové siete
- 1-AIN-551: Algoritmy pre AI robotiku
- 2-IKV-265: Rozpoznávanie reči
- (2016) 2-INF-238: Grafové modely v strojovom učení

Zima 2015:

- 2-AIN-501: Metódy v bioinformatike
- 2-PMS-129: Stochastické optimalizačné metódy