

GÉPI TANULÁS – RÖVID BEVEZETÉS


Szepesvári Csaba

MTA SZTAKI

2005 márc. 22

- 1 MI A GÉPI TANULÁS?
- 2 MIÉRT NEHÉZ?
- 3 OCKHAM BOROTVÁJA
- 4 TANULÁS MINT KERESÉSI PROBLÉMA
- 5 FŐBB PROBLÉMA TÍPUSOK
 - Klasszifikációs problémák
 - Tanuló algoritmusok
 - Regressziós problémák
 - Sűrűségfüggvény becslés
 - Altér keresés
 - Klaszterezés
- 6 EGY KIS ELMÉLET
- 7 ÖSSZEFOGLALÁS

MI A GÉPI TANULÁS?

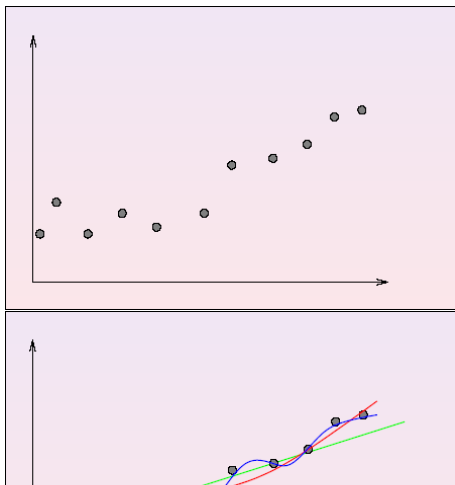


MI A GÉPI TANULÁS?

- Tanulás: Fontos emberi tulajdonság
- 'Jelentése': Változás úgy, hogy a következő hasonló szituációbeli teljesítmény javuljon (valamiféle kritérium szerint).
- **NEM magolás**
- Magolás könnyű a számítógépnek; a nehézséget az új szituációkra való *általánosítás* jelenti

MIÉRT NEHÉZ?

- **Véges** sok tanítási minta segítségével meg kell adni egy függvényt ami kapcsolatot teremt az adatok között
- **Végtelen** sok lehetőségből kell választani



- William **Ockham**: 14. sz.-i szerzetes
- **Egyszerűség Elve**:

„Pluralitas non est ponenda sine neccesitate”

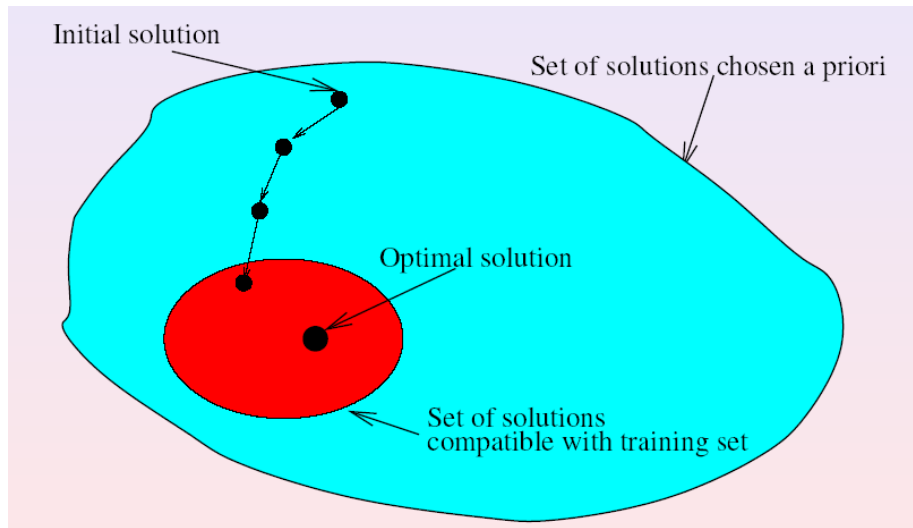
avagy

„A többletet nem kell bevezetni szükségtelenül”

- Interpretáció: a **sok** lehetséges megoldásból válaszd a **legegyszerűbbet**
- Mi az hogy **egyszerű**?
- Egyszerűség: „**prior**” **ismereteink** határozzák meg, hogy mit tartunk egyszerűnek

*Példa: **simaság***

TANULÁS MINT KERESÉSI PROBLÉMA




FŐBB PROBLÉMA TÍPUSOK

- Főbb típusok:

- Regresszió , klasszifikáció , sűrűségfüggvény becslés

- .. és még sokan mások:

preferenciák tanulása, multi-osztályozás, klaszterezés, újdonság detektálás, tulajdonságkiemelés, ..



- Felügyelt tanítás („tanár” jel):
 - regresszió
 - klasszifikáció
 - preferenciák tanulása
- Felügyelet nélküli:
 - sűrűségfüggvény becslés
 - klaszterezés
 - újdonság detektálás
 - tulajdonságkiemelés
 - altér keresés, faktor analízis, független komponens analízis
 - ...
- Megerősítéses tanulás

- On-line tanulás vs. off-line tanulás
- Rekurzív (inkrementális) vs. one-shot
- ..

- Adatok: $(X_1, Y_1), \dots, (X_n, Y_n)$, független, azonos eloszlásúak
- $X_i \in \mathbb{R}^d$
- $Y_i \in \{0, 1\}$ (esetleg $Y_i \in \{1, 2, \dots, m\}$)

CÉL

Adott új X példára legvalószínűbb $Y = ?$ (ill. $P(Y|X) = ?$).

ARCFELISMERÉS



3 9 8 6 1 1 3 6
0 0 4 7 1 4 4 2
6 0 4 3 3 7 4 1
3 5 0 0 2 1 0 0
1 7 9 2 0 6 0 0

- Klasszifikációs szabály: $g : \mathbb{R}^d \rightarrow \{0, 1\}$
- Hiba: $L(g) = P(g(X) \neq Y)$
- Bayes szabály
 - Posterior: $\eta(x) = P(Y = 1|X = x) = \mathbb{E}[Y|X = x]$
 - Bayes szabály: $g^*(x) = \mathbf{1}(\eta(x) > 1/2)$

BAYES SZABÁLY, BAYES HIBA

ÁLLÍTÁS:

Nincs más szabály, amelyik a Bayes szabálynál kisebb hibát érne el:

$$P(g^*(X) \neq Y) \leq P(g(X) \neq Y)$$

BIZONYÍTÁS.

$$L(g) = 1 - \mathbb{E}[\mathbf{1}(g(X) = 1)\eta(X) + \mathbf{1}(g(X) = 0)(1 - \eta(X))]$$



DEFINÍCIÓ: BAYES HIBA

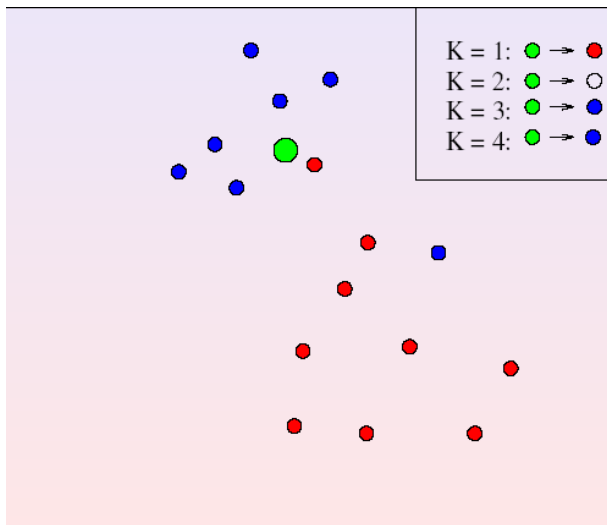
A Bayes szabály által elért hiba (a legkisebb elérhető hiba):

$$L^* = L(g^*).$$

- $D_n = \{(X_1, Y_1), \dots, (X_n, Y_n)\}$.
- g_n ; függ a múltbeli adatoktól: $g_n(x; D_n)$

$$L(g_n) = P(g_n(X) \neq Y | D_n) \text{ val.változó!}$$

- Legközelebbi szomszéd (k-NN) algoritmusok:
 - $g_n(x) = \mathbf{1}(\sum_i w_{ni}(x)\mathbf{1}(Y_i = 1) > \sum_j w_{nj}(x)\mathbf{1}(Y_j = 0))$
 - $w_{ni}(x) = 1/k$, ha i -edik pont x legközelebbi k szomszédja között van.



- Jel: $L_n = L(g_n)$.
- Konzisztencia:
 - Gyenge: $\mathbb{E}[L_n] \rightarrow L^*$
 - Erős: $L_n \rightarrow L^*$ w.p.1
- k-NN-re:
 - $k = k_n \rightarrow \infty, k_n/n \rightarrow 0$: $L_n \rightarrow L^*$ w.p.1. – feltéve, hogy X eloszlásának van sűrűségfüggvénye
 - $L_{NN} = 2\mathbb{E}[\eta(X)(1 - \eta(X))]$; k rögz., $\mathbb{E}[L_n] \rightarrow L_{NN}$.
 - $L^* \leq L_{NN} \leq 2L^*(1 - L^*) \leq 2L^*$


- $\eta \rightarrow \tilde{\eta}, g^* \rightarrow g_{\tilde{\eta}}$
- $L(g_{\tilde{\eta}}) \leq L^* + 2\mathbb{E}[|\eta(X) - \tilde{\eta}(X)|]$
- $\eta_n \rightarrow \eta$, regressziós probléma!
 - $L(g_n) \leq L^* + 2\mathbb{E}[|\eta_n(X) - \eta(X)| | D_n]$
 - $L(g_n) \leq L^* + 2\mathbb{E}[|\eta_n(X) - \eta(X)|^2 | D_n]$
- Dimenzió redukció: hagyja invariánsan L^* -ot..

REGRESSZIÓS PROBLÉMÁK

- Adatok: $(X_1, Y_1), \dots, (X_n, Y_n)$, független, azonos eloszlásúak
- $X_i \in \mathbb{R}^d$
- $Y_i \in \mathbb{R}^m$

CÉL

Adott új X példára $Y = ?$.



Változat: Z_1, \dots, Z_n, \dots idősor;

$$X_n = (Z_n, Z_{n-1}, \dots, Z_{n-k}),$$

$$Y_n = Z_{n+1}$$

- Példák:
 - Holnapi árfolyamok a tőzsdén
 - Mozgó objektum dinamikája

- Regressziós függvény: $f : \mathbb{R}^d \rightarrow \mathbb{R}^m$
- Költség (veszteség) függvény:

$$\ell(y, y') = \|y - y'\|^2$$


- Hiba: $L(f) = \mathbb{E}(\ell(f(X), Y))$
- „A” regressziós függvény:
 - Feltételes várható érték: $\eta(x) = \mathbb{E}[Y|X = x]$
 - Hasonlóan a Bayes szabályhoz, ez is optimális.

SŰRŰSÉGFÜGGVÉNY BECSLÉS





- Adatok: (X_1, \dots, X_n) , független, azonos eloszlásúak
- $X_i \in \mathbb{R}^d$

CÉL

Adott új X példára $P(X) = ?$ (ill. $P(X) > p_0?$)



ÚJDONSÁG DETEKTÁLÁS




ALTÉR KERESÉS

Az adatok valamely alacsonyabb dimenziós sokaságon „élnek” – eltekintve a zajtól. Találjuk meg ezeket!

CÉL

Lehető legkisebb torzítás: $\mathbb{E}[\ell(P^T X, X)] \rightarrow \min$




Találjuk meg a csoportokat az adatokban!

- Mitől csoport a csoport? („Távolság” / „Közelség”)
- Mitől jó a csoportosítás?
- Hány csoport?

CÉL

Lehető legkisebb torzítás: $\mathbb{E}[\ell(c(X), X)] \rightarrow \min$



TANÍTÁSKOR RENDELKEZÉSRE ÁLLÓ ADATOK:

- $D_n = (Z_1, \dots, Z_n) \in \mathcal{Z}^n$
 - független, azonos eloszlású (iid)
- egy ismeretlen $p(Z)$ eloszlásból dobtuk

ALESETEK

- **Klasszifikáció:**

$$Z = (X, Y) \in \mathbb{R}^d \times \{0, 1\}$$

- **Regresszió:**

$$Z = (X, Y) \in \mathbb{R}^d \times \mathbb{R}$$

- **Sűrűségfüggvény becslés:**

$$Z \in \mathbb{R}^d$$

Tanulás: találjunk meg egy jó függvényt az \mathcal{F} függvénytérben.

Példák; $f(\cdot; \theta) \in \mathcal{F}$

- **Klasszifikáció:**

$$y = \text{sgn}(ax^2 + bx + c); \quad \theta = (a, b, c)$$

- **Regresszió:**

$$y = ax^2 + bx + c; \quad \theta = (a, b, c)$$

- **Sűrűségfüggvény becslés:**

$$p(z) = p(z; \mu, \Sigma) = \frac{1}{(2\pi)^{d/2} \sqrt{|\Sigma|}} \exp\left(-\frac{1}{2}(z - \mu)^T \Sigma^{-1}(z - \mu)\right)$$

Tanulás: találjunk meg egy jó függvényt az \mathcal{F} függvénytérben.

Hiba költsége: $L : \mathcal{Z} \times \mathcal{F} \rightarrow \mathbb{R}$;

- **Klasszifikáció:**

$$L((x, y), f) = \ell(y, f(x)) = \begin{cases} 0, & \text{ha } f(x) = y \\ 1, & \text{ha } f(x) \neq y. \end{cases}$$

- **Regresszió:**

$$L((x, y), f) = \ell(y, f(x)) = \frac{1}{2}(y - f(x))^2$$

- **Sűrűségfüggvény becslés:**

$$L(z, f) = -\log(f(z))$$

Tanulás: találjunk meg egy jó függvényt az \mathcal{F} függvénytérben.

- Kritérium: f használatából eredő **várható hiba** minimalizálása:

$$R(f) = \mathbb{E}[L(Z, f(Z))]$$

- Indukciós elv:

- $f^* = \operatorname{argmin}_{f \in \mathcal{F}} R(f)$
- Probléma: Z eloszlása nem ismert és különben is egy integrált minimalizálni nem könnyű!

- **Empirikus hiba:**

$$\hat{R}(f; D_n) = \frac{1}{n} \sum_{i=1}^n L(z_i, f).$$

- Az empirikus hiba a várható hiba *torzítatlan* becslése:

$$\mathbb{E}[\hat{R}(f; D)] = R(f)$$

- **Empirikus hiba-minimalizációs elv:**

$$f^*(D) = \operatorname{argmin}_{f \in \mathcal{F}} \hat{R}(f; D)$$

- Hiba a tanító mintákon:

$$\hat{R}(f^*(D), D) \quad (= \min_{f \in \mathcal{F}} \hat{R}(f; D))$$

A tanítási hiba torzítatlan, vagy torzított becslése az empirikus hibának?

A tanítási hiba torzítatlan, vagy torzított becslése az empirikus hibának?

Torzított.

$$\begin{aligned}\mathbb{E}[R(f^*(D)) - \hat{R}(f^*(D), D)] &= \mathbb{E}[R(f^*(D)) - \min_{f \in \mathcal{F}} \hat{R}(f, D)] \\ &\geq \max_{f \in \mathcal{F}} \mathbb{E}[R(f^*(D)) - \hat{R}(f, D)] \geq 0\end{aligned}$$

- A D segítségével talált megoldás jobb teljesítményt ad D -n, mint egy másik véletlenül sorsolt D' adathalmazon.
- Tudjuk-e felülről korlátozni a **tanítási** és a **várható hiba** különbségét?

$$|R(f^*(D)) - \hat{R}(f^*(D), D)| \leq ?$$

- Válasz: ha \mathcal{F} kellően megszorított, akkor **igen**
- A korlát az \mathcal{F} **kapacitásától** (méretétől) függ.

- Tanulás az adatokból
- Milyen feladatok?
 - Felügyelt: klasszifikáció, regresszió, ..
 - Felügyelet nélküli: sűrűségfüggvény becslés, altér becslés, klaszterezés, ..
- Empirikus hiba, várható hiba, empirikus hiba-minimalizáció
- Legközelebb:
 - Kapacitás, bias-variance dilemma, regularizáció, modell szelekció
 - Egy kis módszertan: Tanuló algoritmusok összehasonlítása
 - Paraméterbecslés: MLE, MAP, Bayes
 - Klasszifikációs módszerek (k-NN, naive Bayes, döntési fák, SVM)