

# Valószínűségszámítás és statisztika

## 9. gyakorlat

2014. 11. 20.

### Elmélet

[ Sűrűségfüggvény becslése magfüggvény segítségével  $n$  elemű mintából: ]

$$\text{Parzen-Rosenblatt becslés: } f(x) \approx f_n(x) = \frac{1}{nh_n} \sum_{i=1}^n k\left(\frac{x-X_i}{h_n}\right)$$

[ Tapasztalati eloszlásfüggvény konvergenciája: ] Az  $F_n(x) = \sum_{i=1}^n \frac{I(X_i < x)}{n}$  tapasztalati eloszlásfüggvény 1 valószínűséggel tart a (valódi)  $F(x)$  eloszlásfüggvényhez.

[ Likelihood függvény: ] Legyen  $\mathbf{X} = (X_1, \dots, X_n)$  i.i.d. minta

- $L(\theta, \mathbf{x}) = f_\theta(\mathbf{x}) = \prod_{i=1}^n f_\theta(x_i)$ , ha az eloszlás folytonos
- $L(\theta, \mathbf{x}) = P_\theta(\mathbf{X} = \mathbf{x}) = \prod_{i=1}^n P_\theta(X_i = x_i)$ , ha az eloszlás diszkrét.

[ Log-likelihood függvény: ]  $l(\theta, \mathbf{x}) = \log(L(\theta, \mathbf{x}))$ .

#### Paraméterbecslési módszerek

- **Maximum likelihood módszer (ML-módszer):** Azt a paraméterértéket keressük, ahol a likelihood függvény a legnagyobb értéket veszi fel:  $\max_{\theta} L(\theta, \mathbf{x})$

Amennyiben a függvény deriválható  $\theta$  szerint, akkor a maximumot kereshetjük a szokásos módon, az első és második deriváltak segítségével, azonban a feladatunkat jelentősen megnehezíti, hogy olyan  $n$ -szeres szorzatot kellene deriválni, amelyiknek minden tagjában ott van az a változó, ami szerint deriválnunk kellene. Ezért a likelihood függvény helyett a log-likelihood függvény maximumhelyét keressük.

Ha  $\theta$  1 dimenziós, akkor az

- elsőrendű feltétel:  $\partial_{\theta} l(\theta, \mathbf{x}) = 0 \rightsquigarrow \hat{\theta}$
- másodrendű feltétel:  $\partial_{\theta}^2 l(\theta, \mathbf{x}) < 0$

Ha  $\theta$   $p$  dimenziós, akkor  $\theta = (\theta_1, \dots, \theta_p)$ , az

- elsőrendű feltétel:  
 $\partial_{\theta_i} l(\theta, \mathbf{x}) = 0 \rightsquigarrow \hat{\theta}_i \ (i = 1, \dots, p) \rightsquigarrow \hat{\theta} = (\hat{\theta}_1, \dots, \hat{\theta}_p)$
- másodrendű feltétel:  $H(\theta_1, \dots, \theta_p) = (\partial_{\theta_i} \partial_{\theta_j} l(\theta, \mathbf{x}))_{i,j=1,\dots,p}$  Hesse-mátrix negatív definit a  $\theta = \hat{\theta}$  helyen

- **Momentum módszer:** A mintából számítható tapasztalati momentumokat ( $m_i := \frac{\sum_j x_j^i}{n}$ ) egyenlővé tesszük az elméleti momentumokkal ( $M_i := E_{\theta} X^i$ ), az elsőtől kezdve, mégpedig annyit, amennyi paraméter van. Tehát  $p$  darab ismeretlen paraméter esetén a következő  $p$  ismeretlenes egyenletrendszert oldjuk meg:

$$\begin{aligned} M_1 &= m_1 \\ &\vdots \\ M_p &= m_p \end{aligned}$$

Megjegyzés:  $m_1 = \bar{x}$

**Fisher-tétel:** Ha  $\theta$  ML-becslése  $\hat{\theta}$ , akkor tetszőleges  $g$  függvény esetén  $g(\theta)$  ML-becslése  $g(\hat{\theta})$ .

---

Személyes adatok:

Név: Bondici László

E-mail: bondici@cs.elte.hu

Honlap: www.cs.elte.hu/~bondici

## Feladatok

- (8-as feladatsor 6-os feladata) Legyen  $X$  exponenciális eloszlású  $\lambda = 1$  paraméterrel. Adjuk meg  $1 - e^{-X}$  sűrűségfüggvényét és várható értékét.
- (8-as feladatsor 8-as feladata) Tegyük fel, hogy egy tábla csokoládé tömege normális eloszlású 100g várható értékkel és 3g szórással, valamint, hogy az egyes táblák tömege egymástól független. Legalább hány csokoládét csomagoljunk egy dobozba, hogy a dobozban levő táblák átlagos tömege legalább 0.9 valószínűséggel nagyobb legyen 99.5 g-nál?
- Legyen  $X$  egyenletes eloszlású az  $(a, 5)$  intervallumon, és  $P(X < E(X + 1)) = \frac{5}{6}$ . Határozzuk meg  $a$  értékét és írjuk fel  $X$  sűrűségfüggvényét.
- Adjunk becslést az alábbi, éves maximum vízállások alapján az eloszlás 99%-os kvantilisére
  - a tapasztalati eloszlásból;
  - normális közelítésből;
  - $500 + Y$ -ből, ahol  $Y$  exponenciális.

Év	Szint	Év	Szint	Év	Szint	Év	Szint	Év	Szint
2000	690	2001	709	2002	876	2003	544	2004	843
2005	586	2006	546	2007	923	2008	830	2009	873

- Határozzuk meg az ismeretlen paraméter maximum likelihood (ML) becslését, ha a minta
  - Pascal ( $p$  az ismeretlen paraméter);
  - $E(a, 1)$  ( $a$  az ismeretlen paraméter)eloszlású.
- Legyen a  $Z_1, Z_2, \dots, Z_n$  minta a következő diszkrét eloszlásból:  $P(Z_i = 1) = c, P(Z_i = 2) = 3c, P(Z_i = 3) = 1 - 4c$  ( $c$  az ismeretlen paraméter). Határozzuk meg  $c$  momentum módszerrel adódó becslését.
- Tegyük fel, hogy december 7-e középhőmérséklete Budapesten az elmúlt 10 évben az alábbiak szerint alakult: 2.0, 8.5, 1.6, -4.5, 3.3, 7.9, 0.2, -1.6, -2.2, 5.6. Számítsuk ki és ábrázoljuk a középhőmérséklet sűrűségfüggvényének Parzen-Rosenblatt becslését, ha  $h = 0.25$  és a magfüggvényünk  $\frac{1}{2}$ , ha  $|x| < 1$ , és 0 különben.

## Házi feladatok

- A 4-es feladat adatai alapján adjunk becslést az eloszlás 99%-os kvantilisére a tapasztalati eloszlásból.
  - Határozzuk meg az ismeretlen paraméter maximum likelihood (ML) becslését, ha a minta Binomiális ( $p$  az ismeretlen paraméter,  $n$  ismert) eloszlású.