

Matematikai statisztika

4. előadás
2022. október 3.

Becslésemélet

- A minta eloszlásának ismeretlen paraméterét közelítjük a minta függvényével
- Def.: becslőfüggvény: $\hat{\vartheta}: \mathcal{X} \rightarrow \Theta$
- Def.: becslés: $\hat{\vartheta}(\xi)$

- A becslések maguk is statisztikák. Szubjektíven: olyan statisztikák, amik jól közelítik az ismeretlen paramétert.

Likelihood függvény

Def.: A ξ_1, \dots, ξ_n független, azonos eloszlású minta likelihood függvénye

$$L(\mathbf{x}, \theta) = \begin{cases} P_\theta(\boldsymbol{\xi} = \mathbf{x}) = \prod_{i=1}^n P_\theta(\xi_i = x_i) & \text{diszkrét minta esetén} \\ f_\theta(\mathbf{x}) = \prod_{i=1}^n f_\theta(x_i) & \text{abszolút folytonos} \\ & \text{minta esetén} \end{cases}$$

ahol f_θ ξ_i sűrűségfüggvénye.

$l(\mathbf{x}, \theta) = \ln L(\mathbf{x}, \theta)$ a loglikelihood függvény.

Maximum likelihood becslés

- Definíció heurisztikusan: azt a paraméterértéket keressük, amelyre az adott minta bekövetkezési valószínűsége maximális.

Def.: θ maximum likelihood becslése $\hat{\theta} = T(\xi) \in \Theta$, ha

$$L(\xi, \hat{\theta}) = \max_{\theta \in \Theta} L(\xi, \theta)$$

Likelihood egyenlet

Gyakran a loglikelihood függvény maximumhelyét keresik a $\frac{\partial l(\mathbf{x}, \theta)}{\partial \theta} = 0$ egyenletet (vagy egyenletrendszer) megoldva.

Ez diszkrét minta esetén a

$$\sum_{i=1}^n \frac{\partial \ln P_{\theta}(\xi_i = x_i)}{\partial \theta} = 0$$

egyenletet (vagy egyenletrendszer) jelenti.

Abszolút folytonos minta esetén

$$\sum_{i=1}^n \frac{\partial \ln f_{\theta}(x_i)}{\partial \theta} = 0$$

egyenletet (vagy egyenletrendszer) oldjuk meg.

Példa (indikátor)

$$L(\mathbf{x}, p) = p^{\sum_{i=1}^n x_i} (1-p)^{n-\sum_{i=1}^n x_i},$$

$$l(\mathbf{x}, p) = \ln L(\mathbf{x}, p) = \left(\sum_{i=1}^n x_i \right) \ln p + \left(n - \sum_{i=1}^n x_i \right) \ln(1-p).$$

Likelihood egyenlet

$$\frac{\partial l(\mathbf{x}, p)}{\partial p} = \left(\sum_{i=1}^n x_i \right) \frac{1}{p} - \left(n - \sum_{i=1}^n x_i \right) \frac{1}{1-p} = 0$$

Ennek megoldása

$$p = \frac{\sum_{i=1}^n x_i}{n}.$$

És ez valóban maximumhely!

Így a ML becslés

$$\hat{p} = \frac{\sum_{i=1}^n \xi_i}{n}.$$

Példa. (Poisson)

Tegyük fel, hogy $\eta_1, \eta_2, \dots, \eta_n \sim \text{Poisson}(\lambda)$. Ekkor

$$L(\underline{k}, \lambda) = P_\lambda(\eta_1 = k_1, \dots, \eta_n = k_n) = \prod_{i=1}^n \frac{\lambda^{k_i} e^{-\lambda}}{k_i!} = \left(\prod_{i=1}^n \frac{1}{k_i!} \right) \lambda^{\sum k_i} e^{-n\lambda}$$

$$\ell(\underline{k}, \lambda) = \ln L(\underline{k}, \lambda) = \left(\sum_{i=1}^n \ln \left(\frac{1}{k_i!} \right) \right) + \left(\sum_{i=1}^n k_i \right) \ln \lambda - n\lambda$$

$$\frac{\partial \ell}{\partial \lambda} = \frac{\sum k_i}{\lambda} - n = 0 \iff \lambda = \frac{\sum k_i}{n}$$

így az ML becslés

$$\hat{\lambda} = \frac{\sum \eta_i}{n}$$

Becslések tulajdonságai

- Def.: *Torzítatlanság*: A paraméter $\vartheta(\xi)$ becslése torzítatlan, ha

$$E_{\vartheta}(\hat{\vartheta}(\xi)) = \vartheta, \forall \vartheta \in \Theta.$$

- *Konzisztencia*: $\hat{\vartheta}(\xi) \rightarrow \vartheta$ sztochasztikusan ($n \rightarrow \infty$) minden paraméterértékre.
- Példák:
 - Valószínűség becslése relatív gyakorisággal.
 - Glivenko tétele: a tapasztalati eloszlásfüggvény egyenletesen is konvergál az elméleti eloszlásfüggvényhez.
 - Várható érték becslése mintaátlaggal

Konzisztencia

- Elégséges feltétel $E_{\vartheta}(\hat{\vartheta}_n(\xi)) \rightarrow \vartheta$
(aszimptotikus torzítatlanság)
és $D_{\vartheta}^2(\hat{\vartheta}_n(\xi)) \rightarrow 0$.

Példák

- Poisson eloszlás paraméterére:
mintaátlag
- Exponenciális eloszlás paraméterére:
 - mintaátlag reciproka: aszimptotikusan torzítatlan, konzisztens
 - $n \cdot \min(X_1, \dots, X_n)$ torzítatlan, de nem konzisztens
- Szórásnégyzetre

Becslések összehasonlítása

- Melyik a jobb becslés?

$$X_i = \begin{cases} 1, & i. \text{ fiú} \\ 0, & i. \text{ lány} \end{cases}, P_p(X_i = 1) = p,$$

$$\hat{p}_1 = \frac{\sum_{i=1}^n X_i}{n},$$

$$\hat{p}_2 = X_1, \text{ vagy}$$

$$\hat{p}_3 = \frac{\sum_{i=1}^{\lfloor n/2 \rfloor} X_i}{\lfloor n/2 \rfloor}?$$

Becslések összehasonlítása (hatásos becslések)

- Torzítatlan becslésekre: T_1 hatásosabb becslése $h(\theta)$ -nak a T_2 -nél, ha

$$D_{\theta}^2(T_1(\underline{X})) \leq D_{\theta}^2(T_2(\underline{X}))$$

- teljesül minden θ paraméterértékre.

Példa: a mintaátlag hatásosabb becslés a várható értékre minden

$$\sum_{i=1}^n c_i X_i$$

alakú becslésnél.

Hatásos becslés

- Def.: A T torzítatlan becslés hatásos, ha minden más torzítatlan becslésnél hatásosabb.
- Miért a torzítatlanokra? Furcsa példa: azonosan 0-val becsüljük az ismeretlen paramétert.
- Ezért érdemes a hatásos becsléseket csak a torzítatlan becslések között keresni.
- Átlagos négyzetes eltérés:

$$E_{\theta}(T(\underline{X}) - \theta)^2$$

Hatásos becslés egyértelműsége

Áll.: Amennyiben T_1 és T_2 hatásos becslései $h(\theta)$ -nak, akkor 1 valószínűséggel megegyeznek minden lehetséges paraméter esetén.

$E_\theta T_1 = E_\theta T_2 = h(\theta)$, továbbá $D_\theta T_1 = D_\theta T_2$. Ebből

$$D_\theta^2(T_1) \leq D_\theta^2\left(\frac{T_1 + T_2}{2}\right) = \frac{D_\theta^2(T_1) + 2\text{cov}(T_1, T_2) + D_\theta^2(T_2)}{4} = \frac{D_\theta^2(T_1) + \text{cov}(T_1, T_2)}{2} \Rightarrow$$

$$D_\theta^2(T_1) \leq \text{cov}(T_1, T_2) = D_\theta T_1 \square D_\theta T_2 \square R(T_1, T_2) = D_\theta^2(T_1) \square R(T_1, T_2) \leq D_\theta^2(T_1) \Rightarrow$$

$$D_\theta^2(T_1) = D_\theta^2(T_2) = \text{cov}(T_1, T_2) \Rightarrow D_\theta^2(T_1 - T_2) = D_\theta^2(T_1) - 2\text{cov}(T_1, T_2) + D_\theta^2(T_2) = 0.$$

Így $E_\theta(T_1 = T_2) = 1 \quad \forall \theta \in \Theta$.

Mit kell tudni a mintáról?

- Benzinkutas példa. Megfigyelések: 78, 89, 167, 90, 85.
- Svájcban 1871 és 1900 között a 2.644.757 megszületett gyermekből 1.359.671 fiú és 1.285.086 lány volt.

Kár- szám	0	1	2	3	4	5	6	7	> 7	Össze- sen
Veze- tők száma	129524	16267	1966	211	31	5	1	1	0	148006

Mennyi információt hordoz a statisztika?

Példa: ξ_1, \dots, ξ_n független $N(m, 1)$ minta. Ekkor

$$\bar{\xi} = \frac{\sum_{i=1}^n \xi_i}{n} \sim N\left(m, \frac{1}{n}\right) \text{ eloszlású (függ } m\text{-től!),}$$

miközben

$$s^2 = \frac{\sum_{i=1}^n (\xi_i - \bar{\xi})^2}{n} \text{ eloszlása nem függ } m\text{-től!}$$

Elégséges statisztika

- Minden információt (ugyanannyit mint az eredeti minta) tartalmaz az ismeretlen paraméterre vonatkozóan.
- "Elég" az ő értékét ismerni.
- Ismeretében már "nincs bizonytalanság" a mintában (úgy értve, hogy egyértelmű a minta eloszlása, már nem függ az ismeretlen paramétértől).

Elégséges statisztika diszkrét minta esetén

Def.: A diszkrét ξ mintából képzett $T(\xi)$ statisztika elégséges θ -ra, ha a $P_{\theta}(\xi = \mathbf{x} | T(\xi) = t)$ feltételes valószínűség nem függ θ -tól

Feltételes várható érték

Legyenek X és Y diszkrét val. változók.

$E(X|Y)$ az a val. változó, ami az $Y = y_k$ eseményen az $E(X|Y = y_k)$ értéket veszi fel.

Tulajdonságok:

- Ha $X \geq 0$, akkor $E(X|Y) \geq 0$
- $E(E(X|Y)) = EX$ (a teljes várható érték tételének általánosítása)
- Ha X_1, X_2 várható értéke véges, akkor $E(c_1X_1 + c_2X_2|Y) = c_1E(X_1|Y) + c_2E(X_2|Y)$
- Ha X független Y -től, akkor $E(X|Y) = E(X)$
- Ha X és $h(Y)$ várható értéke véges, akkor $E(h(Y)X|Y) = h(Y)E(X|Y)$
- Teljes szórásnégyzet tétele:
$$D^2(X) = D^2(E(X|Y)) + E(D^2(X|Y))$$

Példa (indikátor minta)

$$X_i = \begin{cases} 1, & p \text{ valószínűséggel} \\ 0, & 1-p \text{ valószínűséggel} \end{cases} \Rightarrow P_p(X_i = x) = p^x(1-p)^{1-x}, x = 0 \text{ és } 1.$$

$$P_p\left(\mathbf{X} = \mathbf{x} \mid \sum_{i=1}^n X_i = t\right) = P_p\left(X_1 = x_1, \dots, X_n = x_n \mid \sum_{i=1}^n X_i = t\right) =$$

$$\frac{P_p\left(X_1 = x_1, \dots, X_n = x_n, \sum_{i=1}^n X_i = t\right)}{P_p\left(\sum_{i=1}^n X_i = t\right)} = \begin{cases} 0 & \sum_{i=1}^n x_i \neq t \\ \frac{P_p(X_1 = x_1, \dots, X_n = x_n)}{P_p\left(\sum_{i=1}^n X_i = t\right)} & \sum_{i=1}^n x_i = t \end{cases} =$$

$$\begin{cases} 0 & \sum_{i=1}^n x_i \neq t \\ \frac{p^{\sum_{i=1}^n x_i} (1-p)^{n-\sum_{i=1}^n x_i}}{\binom{n}{t} p^t (1-p)^{n-t}} & \sum_{i=1}^n x_i = t \end{cases} = \begin{cases} 0 & \sum_{i=1}^n x_i \neq t \\ \frac{1}{\binom{n}{t}} & \sum_{i=1}^n x_i = t \end{cases}$$

Tétel (Neyman-féle faktorizációs):

A diszkrét ξ mintából képzett $T(\xi)$ statisztika pontosan akkor elégséges

Θ -ra, ha $\exists g_\theta(t)$ és $h(\mathbf{x})$ úgy, hogy $\forall \theta \in \Theta$ és $\mathbf{x} \in \mathcal{X}$ -ra

$$P_\theta(\xi = \mathbf{x}) = h(\mathbf{x})g_\theta(T(\mathbf{x})).$$

Biz.:

$$\Rightarrow T(\xi) \text{ elégséges, ekkor } P_\theta(\xi = \mathbf{x}) = P_\theta(T(\xi) = T(\mathbf{x})) \frac{P_\theta(\xi = \mathbf{x}, T(\xi) = T(\mathbf{x}))}{P_\theta(T(\xi) = T(\mathbf{x}))}$$

$$= P_\theta(T(\xi) = T(\mathbf{x}))P_\theta(\xi = \mathbf{x} | T(\xi) = T(\mathbf{x})) = g_\theta(T(\mathbf{x}))h(\mathbf{x}).$$

$\Leftarrow P_\theta(\xi = \mathbf{x} | T(\xi) = t) = 0$, ha $t \neq T(\mathbf{x})$. Amennyiben ez teljesül:

$$P_\theta(\xi = \mathbf{x} | T(\xi) = t) = \frac{P_\theta(\xi = \mathbf{x}, T(\xi) = t)}{P_\theta(T(\xi) = t)} = \frac{P_\theta(\xi = \mathbf{x}, T(\xi) = t)}{P_\theta(T(\xi) = t)} = \frac{P_\theta(\xi = \mathbf{x})}{\sum_{\mathbf{y}: T(\mathbf{y})=t} P_\theta(\xi = \mathbf{y})}$$

$$= \frac{h(\mathbf{x})g_\theta(T(\mathbf{x}))}{\sum_{\mathbf{y}: T(\mathbf{y})=t} h(\mathbf{y})g_\theta(T(\mathbf{y}))} = \frac{h(\mathbf{x})g_\theta(t)}{\sum_{\mathbf{y}: T(\mathbf{y})=t} h(\mathbf{y})g_\theta(t)} = \frac{h(\mathbf{x})}{\sum_{\mathbf{y}: T(\mathbf{y})=t} h(\mathbf{y})}.$$

Ez nem függ θ -tól!

Példa (Poisson minta)

η_i – k független λ Poissonok. Ekkor

$$P_\lambda(\eta_1 = k_1, \dots, \eta_n = k_n) = \prod_{i=1}^n \frac{\lambda^{k_i} e^{-\lambda}}{k_i!} = \left(\prod_{i=1}^n \frac{1}{k_i!} \right) \lambda^{\sum_{i=1}^n k_i} e^{-n\lambda} =$$
$$= h(\mathbf{k}) g_\lambda \left(\sum_{i=1}^n k_i \right),$$

ahol

$$h(\mathbf{k}) = \prod_{i=1}^n \frac{1}{k_i!}, \quad g_\lambda(t) = \lambda^t e^{-n\lambda}.$$

Elégséges statisztika általában

Def.: A ξ mintából képzett $T(\xi)$ statisztika elégséges

Θ -ra, ha minden $\mathbf{x} \in \mathbf{R}^n$ -re a $P_\theta(\xi < \mathbf{x} | T(\xi) = t) = P_\theta(\xi_1 < x_1, \dots, \xi_n < x_n | T(\xi) = t)$ feltételes eloszlásfüggvény nem függ θ -tól.

Probléma: A feltételes valószínűség és várható érték fogalmát nem tanultuk általánosan!

Abszolút folytonos eset

- Definíció a faktorizációval

Def.:

Az abszolút folytonos ξ mintából képzett $T(\xi)$ statisztika elégséges Θ -ra, ha $\exists g_\theta(t)$ és $h(\mathbf{x})$ úgy, hogy $\forall \theta \in \Theta$ és $\mathbf{x} \in \mathcal{X}$ -ra a likelihood függvény felírható a következő alakban:

$$L(\mathbf{x}, \theta) = h(\mathbf{x})g_\theta(T(\mathbf{x})).$$

Példa (normális $N(m, \sigma^2)$ minta)

ξ_i – k független, $N(m, \sigma^2)$ eloszlásúak. Ekkor $\theta = (m, \sigma^2)$

$$\begin{aligned} L(\mathbf{x}, (m, \sigma^2)) &= \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(x_i - m)^2}{2\sigma^2}\right) = \\ &= (2\pi\sigma^2)^{-n/2} \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i^2 - 2x_i m + m^2)\right) = \\ &= (2\pi\sigma^2)^{-n/2} \exp\left(-\frac{1}{2\sigma^2} \left(\sum_{i=1}^n x_i^2 - 2nm\bar{x} + nm^2\right)\right) = \\ &= (2\pi\sigma^2)^{-n/2} \exp\left(-\frac{1}{2\sigma^2} \left(\sum_{i=1}^n (x_i - \bar{x})^2 + n\bar{x}^2 - 2nm\bar{x} + nm^2\right)\right). \end{aligned}$$

Ebből következik, hogy $\left(\sum_{i=1}^n x_i^2, \bar{x}\right)$ elégséges statisztika.

Hasonlóan $\left(\sum_{i=1}^n (x_i - \bar{x})^2 / n, \bar{x}\right)$ is.

Példa (egyenletes $E(0, a)$ minta)

ξ_i – k független, $E(0, a)$ eloszlásúak. Sűrűségfüggvényük

$$f_a(x) = \begin{cases} 1/a & 0 \leq x \leq a \\ 0 & \text{különben} \end{cases}$$

$$L(\mathbf{x}, a) = \prod_{i=1}^n \frac{1}{a} \chi\{x_i \leq a\} = \frac{1}{a^n} \chi\left\{\max_{1 \leq i \leq n} x_i \leq a\right\} \Rightarrow$$

$\max_{1 \leq i \leq n} x_i$ elégséges!

Maximum likelihood becslés

- A maximum likelihood becslés mindig az elégséges statisztika függvénye
- $E(0, a)$ minta esetén a ML becslése

$$\max_{1 \leq i \leq n} \xi_i$$

Momentum módszer

- Ha az eloszlást k db paraméter határozza meg, akkor k db egyenletből kaphatunk rájuk becslést. Az egyenletek a tapasztalati és az elméleti momentumok egybevetéséből adódnak:

$$m_i(\underline{\theta}) = E_{\underline{\theta}}(X^i)$$

$$m_i(\underline{\theta}) = \frac{\sum_{j=1}^n (\xi_j)^i}{n}$$