

Maximumlikelihood-módszer

Definíció (Likelihood-függvény)


Ha az (Y_1, \dots, Y_n) független minta diszkrét (a lehetséges értékeinek száma véges vagy megszámlálható sok), akkor a likelihood-függvénye:

$$L_{n,\vartheta}(k_1, \dots, k_n) = \prod_{j=1}^n \mathbb{P}_{j,\vartheta}(Y_j = k_j) \quad ((k_1, \dots, k_n) \in H).$$

Ha az (Y_1, \dots, Y_n) független minta abszolút folytonos, és Y_j sűrűségfüggvénye (a \mathbb{P}_ϑ valószínűség mellett) $f_{j,\vartheta}$, akkor a minta likelihood-függvénye:


$$L_{n,\vartheta}(t_1, \dots, t_n) = \prod_{j=1}^n f_{j,\vartheta}(t_j) \quad (t_1, \dots, t_n \in \mathbb{R}).$$

Likelihoodfüggvény



$n = 94$ elemű minta testmagasság-adatok alapján, normális eloszlást feltételezve.
Az átlag: $\bar{X} = 174,8$, a tapasztalati szórás $s_n = 10,5$.

Log-likelihoodfüggvény



$n = 94$ elemű minta testmagasság-adatok alapján, normális eloszlást feltételezve.
Az átlag: $\bar{X} = 174,8$, a tapasztalati szórás $s_n = 10,5$.

ML-becslés: normális eloszlás

X_1, \dots, X_n függetlenek, eloszlásuk normális eloszlás $m, \sigma > 0$ paraméterekkel. Ekkor

$$L_{n,m,\sigma}(X_1, \dots, X_n) = \prod_{j=1}^n f_{j,\vartheta}(X_j) = \prod_{j=1}^n \left[\frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(X_j - m)^2}{2\sigma^2}\right) \right].$$

ML-becslés: normális eloszlás

X_1, \dots, X_n függetlenek, eloszlásuk normális eloszlás $m, \sigma > 0$ paraméterekkel. Ekkor

$$L_{n,m,\sigma}(X_1, \dots, X_n) = \prod_{j=1}^n f_{j,\vartheta}(X_j) = \prod_{j=1}^n \left[\frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(X_j - m)^2}{2\sigma^2}\right) \right].$$

$$L_{n,m,\sigma}(X_1, \dots, X_n) = \left(\frac{1}{\sqrt{2\pi}\sigma}\right)^n \exp\left(-\sum_{j=1}^n \frac{(X_j - m)^2}{2\sigma^2}\right).$$

ML-becslés: normális eloszlás

X_1, \dots, X_n függetlenek, eloszlásuk normális eloszlás $m, \sigma > 0$ paraméterekkel. Ekkor

$$L_{n,m,\sigma}(X_1, \dots, X_n) = \prod_{j=1}^n f_{j,\vartheta}(X_j) = \prod_{j=1}^n \left[\frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(X_j - m)^2}{2\sigma^2}\right) \right].$$

$$L_{n,m,\sigma}(X_1, \dots, X_n) = \left(\frac{1}{\sqrt{2\pi}\sigma}\right)^n \exp\left(-\sum_{j=1}^n \frac{(X_j - m)^2}{2\sigma^2}\right).$$

$$\log L_{n,m,\sigma}(X_1, \dots, X_n) = -n \log(\sqrt{2\pi}) - n \log \sigma - \sum_{j=1}^n \frac{(X_j - m)^2}{2\sigma^2}.$$

Rögzített σ mellett ez akkor maximális, ha $\sum_{j=1}^n (X_j - m)^2 = \sum_{j=1}^n X_j^2 - 2 \sum_{j=1}^n X_j m + nm^2$ minimális $\Rightarrow \hat{m} = \bar{X}$.

ML-becslés: normális eloszlás

$$\log L_{n,\sigma}(X_1, \dots, X_n) = -n \log(\sqrt{2\pi}) - n \log \sigma - \sum_{j=1}^n \frac{(X_j - \bar{X})^2}{2\sigma^2}.$$

A σ szerinti parciális derivált:

$$\frac{\partial}{\partial \sigma} \log L_{n,\sigma}(X_1, \dots, X_n) = -\frac{n}{\sigma} + \sum_{j=1}^n \frac{(X_j - \bar{X})^2}{\sigma^3}.$$

Ez pontosan akkor pozitív, ha $\sigma^2 < \frac{1}{n} \sum_{j=1}^n (X_j - \bar{X})^2 = s_n^2$.

Tehát az ML-becslés:

$$\hat{m} = \bar{X}; \quad \hat{\sigma} = s_n = \sqrt{\frac{1}{n} \sum_{j=1}^n X_j^2 - \bar{X}^2}.$$

Tehát normális eloszlásnál az m paraméter becslése a mintaátlag, a szórásé a tapasztalati szórás. Ebben a speciális esetben a momentum módszer és az ML-módszer ugyanazt adja eredményül.

ML-becslés: egyenletes eloszlás

Ebben az esetben az ML-becslés nem számítható ki az ML-egyenlet gyökeként, vagyis nem kapható meg deriválással.

X_1, \dots, X_n függetlenek, eloszlásuk egyenletes eloszlás az $[a, b]$ intervallumon. Ekkor

$$L_{n,a,b}(X_1, \dots, X_n) = \prod_{j=1}^n f_{j,\vartheta}(X_j) = \prod_{j=1}^n \mathbb{I}(a \leq X_j \leq b) \cdot \frac{1}{b-a}.$$

$$L_{n,a,b}(X_1, \dots, X_n) = \left(\frac{1}{b-a}\right)^n \mathbb{I}(a \leq \min_j X_j \text{ és } \max_j X_j \leq b).$$

ML-becslés: egyenletes eloszlás

Ebben az esetben az ML-becslés nem számítható ki az ML-egyenlet gyökeként, vagyis nem kapható meg deriválással.

X_1, \dots, X_n függetlenek, eloszlásuk egyenletes eloszlás az $[a, b]$ intervallumon. Ekkor

$$L_{n,a,b}(X_1, \dots, X_n) = \prod_{j=1}^n f_{j,\vartheta}(X_j) = \prod_{j=1}^n \mathbb{I}(a \leq X_j \leq b) \cdot \frac{1}{b-a}.$$

$$L_{n,a,b}(X_1, \dots, X_n) = \left(\frac{1}{b-a}\right)^n \mathbb{I}(a \leq \min_j X_j \text{ és } \max_j X_j \leq b).$$

Az első tényező legyen minél nagyobb (vagyis $b - a$ minél kisebb) úgy, hogy a második tényező nem nulla. Ebből:

$$\hat{a} = \min_j X_j; \quad \hat{b} = \max_j X_j.$$

Maximum-likelihood becslések

- binomiális eloszlás ismert k renddel: $\hat{p} = \bar{X}/k$
- Poisson-eloszlás: $\hat{\lambda} = \bar{X}$
- geometriai eloszlás: $\hat{p} = 1/\bar{X}$
- normális eloszlás: $\hat{m} = \bar{X}, \hat{\sigma} = s_n$
- exponenciális eloszlás: $\hat{\lambda} = 1/\bar{X}$
- egyenletes eloszlás: $\hat{a} = \min_j X_j; \quad \hat{b} = \max_j X_j$

Az ML-becslés tulajdonságai

- Nem minden statisztikai mezőn létezik ML-becslés.
- Az ML-becslés nem feltétlenül egyértelmű.
- Az ML-becslés nem feltétlenül torzítatlan.
- A $\psi(\vartheta)$ függvény ML-becslése $\psi(\hat{\vartheta})$, ahol $\hat{\vartheta}$ ML-becslés ϑ -ra.
- Az alábbi egyenlet a maximumlikelihood-egyenlet:

$$\frac{\partial}{\partial \vartheta} \log L_{n,\vartheta}(X_1, \dots, X_n) = 0.$$

Megfelelő feltételek mellett az ML-becslés a maximumlikelihood-egyenlet megoldása (ha az ML-becslés nem számítható ki, de az egyenlet megoldható, gyakran az egyenlet megoldásával helyettesítik az ML-becslést).

A maximum-likelihood becslés tulajdonságai

Ha likelihoodfüggvény teljesít bizonyos regularitási feltételeket, akkor a ϑ paraméternek az X_1, X_2, \dots, X_n mintából számolt $\hat{\vartheta}_n$ maximumlikelihood-becslése

- létezik;
- aszimptotikusan torzítatlan: $\lim_{n \rightarrow \infty} \mathbb{E}_{\vartheta}(\hat{\vartheta}_n) = \vartheta$ minden $\vartheta \in \Theta$ -ra;
- aszimptotikusan hatásos: $\lim_{n \rightarrow \infty} \sqrt{nl_1(\vartheta)} D_{\vartheta}(\hat{\vartheta}_n) = 1$ minden $\vartheta \in \Theta$ -ra;
- aszimptotikusan normális eloszlású: $\sqrt{nl_1(\vartheta)}(\hat{\vartheta}_n - \vartheta)$ eloszlásban tart a standard normális eloszláshoz minden $\vartheta \in \Theta$ -ra $n \rightarrow \infty$ esetén.

Momentumok

Definíció

Az X valószínűségi változó k . momentuma:

$$\mathbb{E}(X^k) \quad (k \geq 1),$$

ha ez a várható érték létezik.

Ha az X valószínűségi változó diszkrét, és lehetséges értékei: x_1, x_2, \dots , akkor

$$\mathbb{E}(X^k) = \sum_{j=1}^{\infty} x_j^k \mathbb{P}(X = x_j).$$

Ha az X valószínűségi változó abszolút folytonos és sűrűségfüggvénye f , akkor

$$\mathbb{E}(X^k) = \int_{-\infty}^{\infty} x^k f(x) dx.$$

Momentum módszer

Legyen X_1, \dots, X_n független azonos eloszlású minta.

- 1 Az eloszlás k . momentuma, ha ϑ az ismeretlen paraméter: $\mu_{k,\vartheta} = \mathbb{E}_{\vartheta}(X_1^k)$.
- 2 Legyen $\hat{\mu}_k = \frac{1}{n} \sum_{j=1}^n X_j^k$ az eloszlás k . tapasztalati momentuma.
- 3 Írjuk fel az alábbi egyenleteket a legkisebb olyan k -ig, amire az egyenletrendszer egyértelműen meghatározza ϑ -t (**bár nincs mindig ilyen k**):

$$\mathbb{E}_{\vartheta}(X_1) = \frac{1}{n} \sum_{j=1}^n X_j;$$

$$\mathbb{E}_{\vartheta}(X_1^2) = \frac{1}{n} \sum_{j=1}^n X_j^2;$$

...

$$\mathbb{E}_{\vartheta}(X_1^k) = \frac{1}{n} \sum_{j=1}^n X_j^k.$$

- 4 A ϑ momentum módszerrel kapott becslése az a $\hat{\vartheta}$, ami megoldása a fenti egyenletrendszernek. **Nem mindig létezik, nem mindig egyértelmű, nem feltétlenül hatásos.**

Momentum módszer: Poisson- és exponenciális eloszlás

X_1, \dots, X_n független **Poisson-eloszlásúak** ismeretlen $\lambda > 0$ paraméterrel. A $k = 1$ -hez tartozó egyenlet:

$$\mathbb{E}_\lambda(X_1) = \bar{X}.$$

Mivel a λ paraméterű Poisson-eloszlás várható értéke λ :

$$\hat{\lambda} = \bar{X}.$$

Momentum módszer: Poisson- és exponenciális eloszlás

X_1, \dots, X_n független **Poisson-eloszlásúak** ismeretlen $\lambda > 0$ paraméterrel. A $k = 1$ -hez tartozó egyenlet:

$$\mathbb{E}_\lambda(X_1) = \bar{X}.$$

Mivel a λ paraméterű Poisson-eloszlás várható értéke λ :

$$\hat{\lambda} = \bar{X}.$$

X_1, \dots, X_n független **exponenciális** eloszlásúak ismeretlen $\lambda > 0$ paraméterrel. A $k = 1$ -hez tartozó egyenlet:

$$\mathbb{E}_\lambda(X_1) = \frac{1}{\lambda} = \frac{1}{n} \sum_{j=1}^n X_j = \bar{X}.$$

Ez egyértelműen oldható meg λ -ra:

$$\hat{\lambda} = \frac{1}{\bar{X}}.$$

Momentum módszer: normális eloszlás

X_1, \dots, X_n független $N(m, \sigma^2)$ eloszlású minta (azaz normális eloszlású m várható értékkel és σ szórással).

A $k = 1$ -hez és $k = 2$ -höz tartozó egyenletek:

$$\mathbb{E}_{m,\sigma}(X_1) = m = \bar{X};$$

$$\mathbb{E}_{m,\sigma}(X_1^2) = \sigma^2 + m^2 = \frac{1}{n} \sum_{j=1}^n X_j^2.$$

A másodikba beírva az elsőt: $\sigma^2 = \frac{1}{n} \sum_{j=1}^n X_j^2 - \bar{X}^2 = s_n^2$ (a tapasztalati szórásnégyzet). Tehát az első két egyenlet együtt egyértelműen oldható meg, a momentum módszerrel kapott becslés:

$$\hat{m} = \bar{X}; \quad \hat{\sigma} = s_n.$$