

Matematikai statisztika

Témakör 4: Becslési módszerek

Elek Péter

1. Momentumok módszere

Eloszlások momentumai

- $m_k = E(X^k)$ az eloszlás k -dik *momentuma*
 - Várható érték: $E(X)$
 - * első momentum
- $E[(X - E(X))^k]$ az eloszlás k -dik *centrális momentuma*
 - Variancia: $\sigma^2 = E[(X - E(X))^2]$
 - * második centrális momentum
 - Ferdeség (skewness) = $E[(X - E(X))^3] / \sigma^3$
 - * standardizált harmadik centrális momentum
 - Csúcsosság (kurtosis) = $E[(X - E(X))^4] / \sigma^4$
 - * standardizált negyedik centrális momentum

Tapasztalati momentumok

- $\hat{m}_k = \frac{\sum_{i=1}^n X_i^k}{n}$ a k -dik *tapasztalati momentum*
- Ez torzítatlanul és konzisztensen becsüli m_k -t.

Momentumok módszere (Method of moments, MM)

- Legyenek a becsülendő paraméterek $(\theta_1, \dots, \theta_k)$.
- Tegyük fel, hogy ezek az eloszlási momentumok függvényei:

$$\theta_j = g_j(m_1, m_2, \dots, m_k) \quad (j = 1, \dots, k).$$

- *Momentumok módszere*: a becslőfüggvényt a tapasztalati momentumok ugyan-ezen függvényeiként definiáljuk:

$$\hat{\theta}_j = g_j(\hat{m}_1, \hat{m}_2, \dots, \hat{m}_k) \quad (j = 1, \dots, k)$$

- Általánosabban az *analógia elve*: az eloszlás elméleti jellemzőit a tapasztalati jellemzőknek megfelelően konstruáljuk meg a becslőfüggvényt
 - Pl.: a sokasági medián becslése a tapasztalati mediánnal

MM-becslőfüggvények konstruálása a gyakorlatban

- 1. lépés: néhány eloszlási momentumot előállítunk a paraméterek függvényeként:

$$\begin{aligned} m_1 &= h_1(\theta_1, \dots, \theta_k) \\ m_2 &= h_2(\theta_1, \dots, \theta_k) \\ m_k &= h_k(\theta_1, \dots, \theta_k). \end{aligned}$$

- 2. lépés: a tapasztalati momentumokat egyenlővé tesszük ezekkel a függvényekkel, és a kapott egyenletrendszert megoldjuk:

$$\begin{aligned} \hat{m}_1 &= h_1(\hat{\theta}_1, \dots, \hat{\theta}_k) \\ \hat{m}_2 &= h_2(\hat{\theta}_1, \dots, \hat{\theta}_k) \\ \hat{m}_k &= h_k(\hat{\theta}_1, \dots, \hat{\theta}_k). \end{aligned}$$

Várható érték és variancia MM-becslőfüggvénye

- \bar{X} a μ MM-becslőfüggvénye.
 - Definíció szerint igaz.
- s^2 a sokasági variancia MM-becslőfüggvénye.
 - "Majdnem" definíció szerint igaz.
 - Formálisan: tudjuk, hogy $m_1 = \mu$ and $m_2 = \mu^2 + \sigma^2$. Ezért

$$\hat{\sigma}_{MM}^2 = \hat{m}_2 - (\bar{X})^2 = \frac{\sum_{i=1}^n X_i^2}{n} - \left(\frac{\sum_{i=1}^n X_i}{n} \right)^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n}.$$

- Példák:
 - Ha $X \sim N(\mu, \sigma^2)$, akkor $\hat{\mu}_{MM} = \bar{X}$ és $\hat{\sigma}_{MM}^2 = s^2$.
 - Ha $X \sim Bernoulli(p)$, akkor $\hat{p}_{MM} = \bar{X}$.

Kovariancia MM-becslőfüggvénye

- (Elméleti) kovariancia:

$$\sigma_{XY} = E [(X - E(X))(Y - E(Y))]$$

- Ennek MM-becslőfüggvénye:

$$\hat{\sigma}_{XY} = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{n}$$

– Torzított és konzisztens.

- Korrigált tapasztalati kovariancia:

$$\hat{\sigma}_{XY} = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{n - 1}$$

– Torzítatlan és konzisztens.

Korrelációs együttható MM-becslőfüggvénye

- (Elméleti) korrelációs együttható:

$$\rho_{XY} = \frac{\sigma_{XY}}{\sigma_X \sigma_Y} = \frac{E [(X - E(X))(Y - E(Y))]}{\sqrt{E [(X - E(X))^2]} \sqrt{E [(Y - E(Y))^2]}}$$

- MM-becslőfüggvény:

$$\hat{\rho}_{XY} = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}}$$

- ami torzított és konzisztens.
- Nem létezik általános torzítatlan becslőfüggvény ρ_{XY} -ra.

Példa: θ MM-becslőfüggvénye exponenciális mintában

- Legyen $X \sim Exp(\theta)$, és X_1, X_2, \dots, X_n f.a.e. minta ebből az eloszlásból. Adjuk meg θ MM-becslőfüggvényét!
- Megoldás 1: ekkor $E(X) = \theta$ (integrálással belátható), ezért $\hat{\theta}_{MM} = \bar{X}$.
- Megoldás 2: azt is tudjuk, hogy $\sqrt{Var(X)} = \theta$, tehát $\hat{\theta}_{MM} = s$ is megfelelő (a második momentum alapján).
- Általában az alacsonyabb momentumok alapján számított MM-becslőfüggvényeket preferáljuk.

MM-becslőfüggvények általános tulajdonságai

- Az MM-becslőfüggvények konzisztensek.
 - Ha $g(\cdot)$ folytonos függvény, akkor $\hat{\theta} = g(\hat{m}_1, \dots, \hat{m}_k)$ konzisztensen becsüli a $\theta = g(m_1, \dots, m_k)$ paramétert.
- Az MM-becslőfüggvények nem feltétlenül torzítatlanok.
 - Speciális esetekben igen: ha $g(\cdot)$ lineáris függvény, akkor például $g(\bar{X})$ torzítatlanul becsüli a $g(\mu)$ paramétert.
- Az MM-becslőfüggvények csak az eloszlás néhány momentumában rejlő információt hasznosítják, ezért nem mindig hatásosak (aszimptotikusan).
- Ugyanakkor sokszor könnyű őket kiszámítani és robusztusak a modell félre-specifikálására.

2. Maximum Likelihood (ML) becslés

Likelihood függvény

- Legyen a tényleges sokasági sűrűségfüggvény (vagy diszkrét esetben az eloszlás) $f(x; \theta)$, ahol θ az ismeretlen paraméter.
- Egy konkrét x_1, x_2, \dots, x_n minta bekövetkezésének együttes "valószínűsége": $f(x_1; \theta) \cdot f(x_2; \theta) \cdot \dots \cdot f(x_n; \theta)$.
- Ez a *likelihood függvény*:

$$\mathcal{L}(x_1, x_2, \dots, x_n; \theta) = \prod_{i=1}^n f(x_i; \theta).$$

- Ezt most θ függvényeként vizsgáljuk (nem pedig az x_i mintaelemek függvényeként).

Maximum likelihood (ML) becslőfüggvény

- A θ paraméter *ML-becslőfüggvénye* a likelihood-függvény maximumhelye:

$$\hat{\theta}_{ML} = \arg \max_{\theta} \mathcal{L}(X_1, X_2, \dots, X_n; \theta).$$

- Intuíció: azt a θ -t választjuk, amelyre a konkrét minta bekövetkezési "valószínűsége" maximális.

A ML-beclsés meghatározása

- F.a.e. minta *log-likelihood* függvénye:

$$\log \mathcal{L}(x_1, x_2, \dots, x_n; \theta) = \sum_{i=1}^n \log f(x_i; \theta).$$

- Sok esetben ez *analitikusan* maximalizálható a deriváltja zérushelyének megkeresésével és annak bizonyításával, hogy tényleg maximumhelyhez jutottunk:

$$\partial \log \mathcal{L}(x_1, x_2, \dots, x_n; \theta) / \partial \theta = \sum_{i=1}^n \partial \log f(x_i; \theta) / \partial \theta = 0.$$

- Más esetekben *numerikus* maximalizálás szükséges (pl. Newton-Raphson módszer).

Példa: a p sokasági arány ML-beclsése

- Legyen $X \sim \text{Bernoulli}(p)$ és X_1, X_2, \dots, X_n f.a.e. minta ebből az eloszlásból.
- Bizonyítsuk be, hogy p ML-beclsőfüggvénye $\hat{p}_{ML} = \bar{X}$.

Példa: normális eloszlás paramétereinek ML-beclsése

- Legyen $X \sim N(\mu, \sigma^2)$ és X_1, X_2, \dots, X_n f.a.e. minta ebből az eloszlásból. Határozzuk meg μ and σ^2 ML-beclsését!

Megoldás

- $f(x_i; \mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x_i-\mu)^2}{2\sigma^2}}$, tehát

$$\begin{aligned} \mathcal{L}(x_1, x_2, \dots, x_n, \mu, \sigma^2) &= f(x_1) \cdot f(x_2) \cdot \dots \cdot f(x_n) \\ &= \frac{1}{(\sqrt{2\pi\sigma^2})^n} e^{-\sum_{i=1}^n \frac{(x_i-\mu)^2}{2\sigma^2}}, \end{aligned}$$

- és ezt kell maximalizálni μ és σ^2 szerint.
- Ez ekvivalens a log-likelihood maximalizálásával:

$$\begin{aligned} \log \mathcal{L}(x_1, x_2, \dots, x_n, \mu, \sigma^2) &= \sum_{i=1}^n \log f(x_i) \\ &= -\frac{n}{2} \log(2\pi) - \frac{n}{2} \log \sigma^2 - \sum_{i=1}^n \frac{(x_i - \mu)^2}{2\sigma^2}. \end{aligned}$$

Megoldás (folyt.)

- Maximalizálva μ and σ^2 szerint:

$$\frac{\partial \log \mathcal{L}}{\partial \mu} = \frac{1}{\sigma^2} \sum_{i=1}^n (x_i - \mu) = 0$$
$$\frac{\partial \log \mathcal{L}}{\partial (\sigma^2)} = -\frac{n}{2\sigma^2} + \frac{1}{2\sigma^4} \sum_{i=1}^n (x_i - \mu)^2 = 0,$$

- amiből kapjuk, hogy $\hat{\mu}_{ML} = \bar{X}$ és $\hat{\sigma}_{ML}^2 = s^2$.
- Belátható, hogy ez tényleg maximumhely.

ML-becslőfüggvények konzisztenciája

- A ML-becslőfüggvények *nem feltétlenül torzítatlanok*.
 - Példa: $\hat{\sigma}_{ML}^2 = s^2$ a normális eloszlás esetén
- A ML-becslőfüggvények általános "regularitási" feltételek mellett *konzisztensek*.
 - Vannak ellenpéldák (pl. bonyolultabb adatstruktúrában: dummy változós regresszió nemlineáris panelmodellekben)
 - (A fentiek akkor érvényesek, ha az eloszlás jól specifikált. Ha nem, akkor is konzisztens lehet a ML-becslőfüggvény, ld. QML (quasi maximum likelihood) elmélet.)

ML-becslőfüggvények aszimptotikus normalitása

- A ML-becslőfüggvények általános "regularitási" feltételek mellett *aszimptotikusan normális eloszlásúak* a következő variációval:

$$\hat{\theta}_{ML} \overset{A}{\approx} N \left(\theta, - \left[E \frac{\partial^2 \log \mathcal{L}}{\partial \theta^2} \right]^{-1} \right)$$
$$= N \left(\theta, - \left[n E \frac{\partial^2 \log f(X; \theta)}{\partial \theta^2} \right]^{-1} \right).$$

- Tehát a becslőfüggvény ilyenkor \sqrt{n} -konzisztens.
- (Ellenpélda a feltételek nem teljesülése esetén: amikor az eloszlás tartója függ θ -tól, pl. egyenletes eloszlás $[0, \theta]$ -n)

Cramer-Rao-egyenlőtlenség

- *Cramer-Rao tétel:* Ha $\hat{\theta}$ egy torzítatlan becslőfüggvény, akkor általános "regularitási" feltételek esetén

$$\text{Var}(\hat{\theta}) \geq - \left[E \frac{\partial^2 \log \mathcal{L}}{\partial \theta^2} \right]^{-1}.$$

- (A jobb oldalon levő mennyiség a Cramer-Rao határ.)
- Tehát az alsó határt elérő torzítatlan becslőfüggvény szükségképpen hatásos.

ML-becslőfüggvények aszimptotikus hatásossága

- Egy becslőfüggvény *aszimptotikusan hatásos*, ha aszimptotikus eloszlása a következő:

$$\hat{\theta} \stackrel{A}{\approx} N \left(\theta, - \left[E \frac{\partial^2 \log \mathcal{L}}{\partial \theta^2} \right]^{-1} \right).$$

- azaz ha konzisztens, aszimptotikusan normális és aszimptotikusan eléri a Cramer-Rao határt.
- (Más tankönyvek kissé különböző definíciót használnak.)
- Az előző tétel alapján a ML-becslőfüggvény általános regularitási feltételek mellett aszimptotikusan hatásos.
- Gyakran több is igaz: gyakran a ML-becslőfüggvény hatásos, mert torzítatlan és véges mintában is eléri a Cramer-Rao határt.

Példa: \bar{X} hatásos becslése μ -nek normális minta esetén

- Ha $X \sim N(\mu, \sigma^2)$, akkor \bar{X} hatásosan becsüli μ -t.
- Megjegyzés: azt már eddig is tudtuk általánosan, hogy \bar{X} a μ legjobb *lineáris* torzítatlan becslőfüggvénye.
- (A hatásosság több más eloszlás esetén is igaz, például ha $X \sim \text{Bernoulli}(p)$, akkor \bar{X} szintén hatásosan becsüli p -t.)

Megoldás

- Az egyszerűség kedvéért tegyük fel, hogy σ^2 ismert (bár az állítás e nélkül is igaz).

- A log-likelihood második deriváltja:

$$\frac{\partial^2 \log \mathcal{L}}{\partial \mu^2} = -\frac{n}{\sigma^2},$$

- tehát a Cramer-Rao határ:

$$- \left[E \frac{\partial^2 \log \mathcal{L}}{\partial \mu^2} \right]^{-1} = \frac{\sigma^2}{n}.$$

- Mivel \bar{X} torzítatlan és eléri a Cramer-Rao határt, a Cramer-Rao-tétel miatt hatásos is.

3. Legkisebb négyzetek

Legkisebb négyzetek módszere (Least squares, LS)

- *Legkisebb négyzetek módszere:* $\hat{\theta}$ -t úgy választjuk, hogy a mintaelemek és azok várható értékei különbségének négyzetösszege minimális legyen.
- Példa: legyen X_1, X_2, \dots, X_n egy n elemű f.a.e. minta. Az $E(X) = \mu$ legkisebb négyzetek módszerén alapuló becslése a $\sum_{i=1}^n (X_i - \hat{\mu})^2$ kifejezést minimalizálja, a minimumhely $\hat{\mu}_{LS} = \bar{X}$. (Korábban szerepelt.)
 - Normális eloszlás esetén $\hat{\mu}_{LS} = \bar{X}$.
 - Bernoulli-eloszlás esetén $\hat{p}_{LS} = \bar{X}$.
 - Exponenciális eloszlás esetén $\hat{\theta}_{LS} = \bar{X}$.

Tananyag

Tananyag

- slide-ok, feladatok és házi feladatok
- Wooldridge Appendix C.4
- Amemiya 7.1.1, 7.3, 7.4 (bizonyítások nélkül)