

Matematikai statisztika

Témakör 3: Becslések nagymintás tulajdonságai

Elek Péter

Jelölések

- θ a becslendő sokasági paraméter
- $\hat{\theta}$ ennek becslőfüggvénye
- $\hat{\theta}_n$ a jelölés, ha a mintaelemszámot hangsúlyozni kívánjuk

1. Aszimptotikus torzítatlanság

Aszimptotikus torzítatlanság

- $\hat{\theta}_n$ a θ paraméter *aszimptotikusan torzítatlan* becslőfüggvénye, ha minden θ esetén $\lim_{n \rightarrow \infty} E(\hat{\theta}_n) = \theta$.
- (Ellenkező esetben $\hat{\theta}_n$ aszimptotikusan torzított.)
- Példa: s^2 korrigálatlan tapasztalati variancia (mint a σ^2 sokasági variancia becslőfüggvénye)
 - $E(s^2) = \frac{n-1}{n}\sigma^2$, ezért s^2 torzított.
 - Azonban $\lim_{n \rightarrow \infty} E(s^2) = \lim_{n \rightarrow \infty} \frac{n-1}{n}\sigma^2 = \sigma^2$, ezért s^2 aszimptotikusan torzítatlan.

2. Konzisztencia

2.1. Sztochasztikus konvergencia és konzisztencia

Konzisztencia

- $\hat{\theta}_n$ a θ paraméter *konzisztens* becslőfüggvénye, ha minden $\varepsilon > 0$ esetén $\lim_{n \rightarrow \infty} \Pr(|\hat{\theta}_n - \theta| < \varepsilon) = 1$.
 - Azaz $\hat{\theta}_n$ mintavételi eloszlása egyre inkább "ráhúzódik" θ -ra.

- Ha ez legalább egy θ esetén nem teljesül, akkor $\hat{\theta}_n$ inkonzisztens.
- Máshogyan, azt mondjuk, hogy $\hat{\theta}_n$ *sztochasztikusan konvergens* és *sztochasztikus határértéke* θ .
- Jelölés: $\text{plim}_{n \rightarrow \infty} \hat{\theta}_n = \theta$ vagy $\hat{\theta}_n \xrightarrow{p} \theta$

Sztochasztikus konvergencia (convergence in probability) (plim)

- A sztochasztikus konvergencia mindenféle v.v. esetén értelmezhető (és a határérték lehet nem konstans v.v. is).
- Legyen Z_n v.v.-k egy sorozata.
- Definíció: $\text{plim}_{n \rightarrow \infty} Z_n = Z$ ha $\lim_{n \rightarrow \infty} \Pr(|Z_n - Z| < \varepsilon) = 1$ minden $\varepsilon > 0$ esetén.
- Megjegyzés:
 - lim definíciója az analízisben: $\lim_{n \rightarrow \infty} x_n = A$ ha minden $\varepsilon > 0$ esetén létezik olyan N_ε küszöb, hogy $n > N_\varepsilon$ esetén $|x_n - A| < \varepsilon$.
 - Valószínűségi változókra többféle konvergenciafogalom értelmezhető.

Konzisztencia elégséges feltétele

- Állítás: ha $\lim_{n \rightarrow \infty} E(\hat{\theta}_n) = \theta$ és $\lim_{n \rightarrow \infty} \text{Var}(\hat{\theta}_n) = 0$, akkor $\text{plim}_{n \rightarrow \infty} \hat{\theta}_n = \theta$.
 - Azaz ha egy aszimptotikusan torzítatlan becslőfüggvény varianciája zérushoz tart, akkor az konzisztens.
 - Bizonyítás: Csebisev-egyenlőtlenség alapján

Példa: μ becslőfüggvényei

- A *mintaátlag* a μ várható érték konzisztens becslőfüggvénye.
 - Tudjuk, hogy $E(\bar{X}) = \mu$ and $\text{Var}(\bar{X}) = \frac{\sigma^2}{n}$.
 - Ezért $\lim_{n \rightarrow \infty} E(\bar{X}) = \mu$ and $\lim_{n \rightarrow \infty} \text{Var}(\bar{X}) = 0$,
 - tehát \bar{X} konzisztensen becsüli μ -t.
- X_1 első mintaelem a μ nem konzisztens becslőfüggvénye.
 - Mivel $E(X_1) = \mu$, a becslőfüggvény (aszimptotikusan) torzítatlan.
 - Azonban $n \rightarrow \infty$ esetén eloszlása változatlan, nem húzódik rá az ismeretlen paraméterre, tehát nem konzisztens.

2.2. Tulajdonságok és tételek

Nagy számok (gyenge) törvénye (NSZT)

- Nagy számok (gyenge) törvénye (NSZT): Ha X_1, X_2, \dots, X_n f.a.e. minta egy μ várható értékű eloszlásból, akkor $\text{plim}_{n \rightarrow \infty} \bar{X} = E(X) = \mu$.
 - (Korábban ezt láttuk akkor, ha σ^2 véges.)
 - Azonban akkor is igaz, ha σ^2 nem véges.

plim tulajdonságai

- Ha c konstans, akkor $\text{plim}_{n \rightarrow \infty} c = c$.
- Ha x_1, x_2, x_3, \dots nem véletlen sorozat, akkor $\text{plim}_{n \rightarrow \infty} x_n = \lim_{n \rightarrow \infty} x_n$.
- Ha $\text{plim}_{n \rightarrow \infty} \hat{\theta}_{1n} = \alpha$ és $\text{plim}_{n \rightarrow \infty} \hat{\theta}_{2n} = \beta$, akkor
 - $\text{plim}_{n \rightarrow \infty} (\hat{\theta}_{1n} + \hat{\theta}_{2n}) = \alpha + \beta$,
 - $\text{plim}_{n \rightarrow \infty} (\hat{\theta}_{1n} \hat{\theta}_{2n}) = \alpha\beta$
 - továbbá $\beta \neq 0$ esetén $\text{plim}_{n \rightarrow \infty} (\hat{\theta}_{1n} / \hat{\theta}_{2n}) = \alpha / \beta$.

Folytonos transzformáció és konzisztencia

- Tétel ("Continuous mapping theorem" stb.): ha $\text{plim}_{n \rightarrow \infty} \hat{\theta}_n = \theta$ és $g(\cdot)$ folytonos függvény a θ helyen, akkor $\text{plim}_{n \rightarrow \infty} g(\hat{\theta}_n) = g(\theta)$.
 - Bizonyítás: lim tulajdonságai alapján
- Tehát ha $\hat{\theta}_n$ konzisztensen becüli θ -t és g folytonos, akkor $g(\hat{\theta}_n)$ konzisztensen becüli $g(\theta)$ -t.
- Hasonló állítás nem igaz a torzítatlanságra!

2.3. Alkalmazások

Konzisztencia bizonyításának szokásos módszerei

- Bizonyíthatjuk, hogy $\lim_{n \rightarrow \infty} E(\hat{\theta}_n) = \theta$ és $\lim_{n \rightarrow \infty} \text{Var}(\hat{\theta}_n) = 0$.
- Vagy valamilyen átlagra alkalmazhatjuk a NSZT-t, majd kihasználhatjuk a plim operátor egyéb tulajdonságait (pl. viselkedését folytonos leképezések esetén).

σ^2 becslőfüggvényei

- s^2 (korrigálatlan tapasztalati variancia) konzisztensen becsüli σ^2 -et.
 - Tudjuk, hogy $s^2 = \left(\frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2\right) - (\bar{X} - \mu)^2$.
 - Első tagra: $\text{plim}_{n \rightarrow \infty} \left(\frac{1}{n} \sum_{i=1}^n (X_i - \mu)^2\right) = E[(X_i - \mu)^2] = \sigma^2$.
 - A második tagra $\text{plim}_{n \rightarrow \infty} [(\bar{X} - \mu)^2] = 0$, mert $\text{plim}_{n \rightarrow \infty} \bar{X} = \mu$ és így $\text{plim}_{n \rightarrow \infty} (\bar{X} - \mu) = 0$, majd alkalmazhatjuk a folytonos leképezésekre vonatkozó tulajdonságot.
- s^{*2} (korrigált tapasztalati variancia) is konzisztens.
 - $s^{*2} = \frac{n}{n-1} s^2$ és $\text{plim}_{n \rightarrow \infty} \frac{n}{n-1} = 1$

σ becslőfüggvényei

- s és s^* (korrigálatlan és korrigált tapasztalati szórás) konzisztensen becsüli σ -t (a sokasági szórást).
 - $\text{plim}_{n \rightarrow \infty} \sqrt{s_n^2} = \sqrt{\sigma^2}$, azaz $\text{plim}_{n \rightarrow \infty} s_n = \sigma$.
- Hasonló állítás nem igaz a torzítatlanságra: s^* torzított, bár s^{*2} torzítatlan.

További példák

- Példa 1: $\hat{\mu}_1 = \frac{\sum_{i=1}^n X_i}{n-1}$. Konzisztens?
- Példa 2: $\hat{\mu}_2 = wX_1 + (1-w) \frac{\sum_{i=2}^n X_i}{n-1}$. Konzisztens?
- Példa 3: Legyen X_1, \dots, X_n f.a.e. Bernoulli(p) eloszlású minta. Becsüljük $\frac{p}{1-p}$ értéket $\frac{\bar{X}}{1-\bar{X}}$ becslőfüggvénnyel. Torzítatlan? Konzisztens?

Megjegyzések a konzisztenciáról

- A fenti példák mutatják, hogy
 - konzisztens becslőfüggvények NEM feltétlenül torzítatlanok;
 - torzítatlan (illetve aszimptotikusan torzítatlan) becslőfüggvények NEM feltétlenül konzisztensek.

3. Aszimptotikus normalitás

3.1. Eloszlásbeli konvergencia és asimptotikus normalitás

Eloszlásbeli konvergencia (convergence in distribution)

- A Z_n v. v.-k sorozata *eloszlásban konvergál* egy Z folytonos valószínűségi változóhoz, ha *minden* z valós szám esetén

$$\lim_{n \rightarrow \infty} \Pr(Z_n \leq z) = \Pr(Z \leq z).$$

- Intuíció: Z_n eloszlásának alakja egyre közelebb kerül Z eloszlásához
- Jelölés: \xrightarrow{d}
- A definíciót alkalmazhatjuk $\hat{\theta}_n$ becslőfüggvényekre is.

Aszimptotikus normalitás

- Ha a határeloszlás normális, azaz $Z \sim N(\mu, \sigma^2)$, akkor Z_n -t *aszimptotikusan normális eloszlásúnak* mondjuk.
 - Jelölés: $Z_n \overset{A}{\sim} N(\mu, \sigma^2)$.
- Ha $Z \sim N(0, 1)$, akkor Z_n *aszimptotikusan standard normális eloszlású*. Ekkor nagy n esetén $\Pr(Z_n \leq z) \approx \Phi(z)$, ahol $\Phi(z)$ a standard normális eloszlásfüggvény.

3.2. Tulajdonságok és tételek

Eloszlásbeli konvergencia tulajdonságai

- *Folytonos leképezésekre vonatkozó tulajdonság* (continuous mapping theorem): Ha $Z_n \xrightarrow{d} Z$ és $g(\cdot)$ folytonos függvény, akkor $g(Z_n) \xrightarrow{d} g(Z)$.
- *Szluckij-lemma*: Ha $X_n \xrightarrow{d} X$ és $Y_n \xrightarrow{p} \alpha$ (ahol X egy eloszlás és α egy konstans), akkor
 - $X_n + Y_n \xrightarrow{d} X + \alpha$,
 - $X_n Y_n \xrightarrow{d} \alpha X$,
 - és ha $\alpha \neq 0$, akkor $X_n / Y_n \xrightarrow{d} X / \alpha$.
 - Fontos, hogy α *konstans* legyen.

Centrális határeloszlás-tétel (central limit theorem) (CHT, CLT)

- *Centrális határeloszlás-tétel:* Ha X_1, \dots, X_n f.a.e. minta egy olyan eloszlásból, amelyre $E(X_i) = \mu$ és $Var(X_i) = \sigma^2$, akkor

$$Z_n = \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \xrightarrow{d} N(0, 1).$$

- Korábbi eredmény: ha X_i normális eloszlású, akkor $\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0, 1)$ pontosan teljesül minden n esetén. A CHT szerint minden véges szórású eloszlásra $\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \xrightarrow{d} N(0, 1)$.
- Tehát a normális eloszlás természetes határeloszlásként adódik.
- Megjegyzés: \sqrt{n} a szükséges skálázó sorozat (mint általában az egyszerű statisztikai eljárások esetén).

Delta-módszer

- *Tétel:* Legyen $\sqrt{n}(Z_n - \theta) \xrightarrow{d} N(0, \sigma^2)$ és legyen $h(\cdot)$ folytonosan differenciálható θ -ban úgy, hogy $h'(\theta) \neq 0$. Ekkor

$$\sqrt{n}(h(Z_n) - h(\theta)) \xrightarrow{d} N\left(0, [h'(\theta)]^2 \sigma^2\right).$$

- A becslőfüggvények aszimptotikus normalitásának belátása sokszor a delta-módszer és a CHT együttes alkalmazásával történhet.

3.3. Alkalmazások

A binomiális eloszlás normális közelítése

- Legyen $\Pr(X = 1) = p$, $\Pr(X = 0) = 1 - p$, és ebből X_1, X_2, \dots, X_n f.a.e. minta.
- Ekkor a CHT szerint $\frac{\bar{X} - p}{\sqrt{p(1-p)/n}} \xrightarrow{d} N(0, 1)$, azaz (kissé pongyola jelöléssel) $\bar{X} \overset{A}{\sim} N\left(p, \frac{p(1-p)}{n}\right)$.
- Ezért az $Y = \sum_{i=1}^n X_i = n\bar{X}$ valószínűségi változóra, amely Binom(n, p) eloszlású, igaz, hogy

$$\frac{Y - np}{\sqrt{np(1-p)}} \xrightarrow{d} N(0, 1)$$

azaz $Y \overset{A}{\sim} N(np, np(1-p))$.

A mintabeli t -érték aszimptotikus normalitása

- A CHT alapján $\frac{\bar{X}-\mu}{\sigma/\sqrt{n}} \xrightarrow{d} N(0, 1)$, valamint a NSZT és a folytonos leképezésekre vonatkozó tulajdonság miatt $\frac{\sigma}{s^*} \xrightarrow{p} 1$.
- Ezért az eloszlásbeli konvergencia tulajdonságai miatt $\frac{\bar{X}-\mu}{\sigma/\sqrt{n}} \frac{\sigma}{s^*} = \frac{\bar{X}-\mu}{s^*/\sqrt{n}} \xrightarrow{d} N(0, 1)$.
 - Tehát a mintabeli t -érték nagy n esetén közelítően standard normális (még ha az alapeloszlás nem is normális).
- Megjegyzés:
 - Tudjuk, hogy normális minta esetén bármilyen n -re $\frac{\bar{X}-\mu}{s^*/\sqrt{n}} \sim t_{n-1}$. Ebből is következik, hogy $n \rightarrow \infty$ esetén $t_n \xrightarrow{d} N(0, 1)$. Ez utóbbi egyébként a NSZT alapján is következik a t -eloszlás definíciójából.

s^2 aszimptotikus normalitása

- Használjuk a következő jelölést: $H = \sqrt{\text{Var}[(X_i - \mu)^2]}$.

- Ekkor

$$s^2 = \frac{\sum_{i=1}^n (X_i - \mu)^2}{n} - (\bar{X} - \mu)^2$$

$$s^2 - \sigma^2 = \frac{\sum_{i=1}^n (X_i - \mu)^2}{n} - \sigma^2 - (\bar{X} - \mu)^2$$

$$\sqrt{n} \frac{s^2 - \sigma^2}{H} = \sqrt{n} \frac{\sum_{i=1}^n (X_i - \mu)^2 / n - \sigma^2}{H} - \frac{1}{\sqrt{n}} \frac{\sigma^2}{H} \left(\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \right)^2.$$

- Itt az első tag $\xrightarrow{d} N(0, 1)$, a második tag pedig $\xrightarrow{p} 0$.
- Így a Szluckij-lemma miatt $\sqrt{n} \frac{s^2 - \sigma^2}{H} \xrightarrow{d} N(0, 1)$, azaz $s^2 \overset{A}{\sim} N\left(\sigma^2, \frac{H^2}{n}\right)$.

s^{*2} aszimptotikus normalitása

- $s^{*2} = \frac{n}{n-1} s^2$. Tehát:

$$\sqrt{n} \frac{s^{*2} - \sigma^2}{H} = \frac{n}{n-1} \sqrt{n} \frac{s^2 - \sigma^2}{H} + \sqrt{\frac{n}{(n-1)^2}} \frac{\sigma^2}{H}.$$

- Itt $\frac{n}{n-1} \xrightarrow{p} 1$, $\sqrt{n} \frac{s^2 - \sigma^2}{H} \xrightarrow{d} N(0, 1)$, $\sqrt{\frac{n}{(n-1)^2}} \frac{\sigma^2}{H} \xrightarrow{p} 0$.
- Tehát $\sqrt{n} \frac{s^{*2} - \sigma^2}{H} \xrightarrow{d} N(0, 1)$ és így s^{*2} és s^2 aszimptotikus eloszlása megegyezik.

Aszimptotikus eloszlások normális minta esetén

- Ha X_i normális eloszlású, akkor

$$H^2 = E[(X_i - \mu)^4] - E^2[(X_i - \mu)^2] = 2\sigma^4,$$

- ezért

$$\frac{s^2 - \sigma^2}{\sqrt{\frac{2\sigma^4}{n}}} = \sqrt{\frac{n}{2}} \frac{s^2 - \sigma^2}{\sigma^2} \xrightarrow{d} N(0, 1),$$

- azaz

$$s^2 \overset{A}{\sim} N\left(\sigma^2, \frac{2\sigma^4}{n}\right).$$

- Ugyanez igaz s^{*2} -re is.

Példa: mintaátlag asimptotikus eloszlása

- Egy elemgyártó azt állítja, hogy az általa gyártott elemek várható élettartama $\mu = 54$ hónap, $\sigma = 30$ hónap szórással. Ezen állítás ellenőrzésére $n = 400$ elemű véletlen mintát veszünk: X_1, X_2, \dots, X_{400} .
- Ha a gyártó igazat állít, akkor mi \bar{X} mintavételi eloszlása? Mennyi annak a valószínűsége, hogy $\bar{X} \leq 50$ hónap?
- Megjegyzés: mit jelent a "nagy mintaelemszám"?
 - Ez függ a becslőfüggvénytől és a sokasági eloszlástól is.
 - Általában a sokasági várható érték becslésekor $n > 120$ (vagy akár $n > 60$) elég nagynek számít ahhoz, hogy a közelítések működjenek.

Példa: mintabeli arány asimptotikus eloszlása

- Legyen X Bernoulli-eloszlású $p = 0.2$ paraméterrel.
- Ebből az eloszlásból $n = 400$ elemű f.a.e. mintánk van: X_1, X_2, \dots, X_{400} .
- Mennyi a valószínűsége, hogy az \bar{X} mintabeli arány 0.17 és 0.23 közé esik?
- Megjegyzés: szokásos gyakorlati feltétel a binomiális eloszlás nagymintás közelítésére: $np > 10$ és $n(1-p) > 10$.

4. Fontosabb becslőfüggvények összefoglalása

Mintaátlag: $\bar{X} = \frac{\sum_{i=1}^n X_i}{n}$

Jellemző	Normális minta	Általános minta
$E(\bar{X})$	μ	μ
$Var(\bar{X})$	σ^2/n	σ^2/n
plim \bar{X}	μ	μ
\bar{X} kismintás eloszlása	$\sim N\left(\mu, \frac{\sigma^2}{n}\right)$	általános
$\frac{\bar{X}-\mu}{\sigma/\sqrt{n}}$ kismintás eloszlása	$\sim N(0, 1)$	általános
$\frac{\bar{X}-\mu}{\sigma/\sqrt{n}}$ aszimpt. eloszlása	$\sim N(0, 1)$	$\xrightarrow{d} N(0, 1)$
$\frac{\bar{X}-\mu}{s^*/\sqrt{n}}$ kismintás eloszlása	$\sim t_{n-1}$	általános
$\frac{\bar{X}-\mu}{s^*/\sqrt{n}}$ aszimpt. eloszlása	$\xrightarrow{d} N(0, 1)$	$\xrightarrow{d} N(0, 1)$

Sokasági variancia becslőfüggvényei normális eloszlású minta esetén

Jellemző	s^2	s^{*2}
E	$\frac{n-1}{n}\sigma^2$	σ^2
Var	$\frac{2\sigma^4(n-1)}{n^2}$	$\frac{2\sigma^4}{n-1}$
plim	σ^2	σ^2
kismintás eloszlás	$\frac{ns^2}{\sigma^2} \sim \chi_{n-1}^2$	$\frac{(n-1)s^{*2}}{\sigma^2} \sim \chi_{n-1}^2$
aszimpt. eloszlás	$\frac{s^2-\sigma^2}{\sigma^2\sqrt{2/n}} \xrightarrow{d} N(0, 1)$	$\frac{s^{*2}-\sigma^2}{\sigma^2\sqrt{2/n}} \xrightarrow{d} N(0, 1)$

Sokasági variancia becslőfüggvényei általános eloszlású minta esetén

Jellemző	$s^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}$	$s^{*2} = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}$
E	$\frac{n-1}{n}\sigma^2$	σ^2
Var	általános	általános
plim	σ^2	σ^2
kismintás eloszlás	általános	általános
aszimpt. eloszlás	$\frac{s^2-\sigma^2}{H/\sqrt{n}} \xrightarrow{d} N(0, 1)$	$\frac{s^{*2}-\sigma^2}{H/\sqrt{n}} \xrightarrow{d} N(0, 1)$

Tananyag

- Jegyzet, feladatok és házi feladatok
- Wooldridge Appendix C.3
- Amemiya 6 (kivéve definition 6.1.3, Theorem 6.1.1, Theorem 6.2.3, Example 6.4.2) és section 7.2.6