

Matematikai statisztika

Témakör 5: Konfidenciaintervallumok

Elek Péter

1. Alapok

Konfidenciaintervallumok

- Eddig *pontbecslések* szerepeltek a kurzus során (azaz a becslés eredménye egy konkrét numerikus érték vagy vektor volt).
 - Az (aszimptotikusan torzítatlan) pontbecslés mintavételi szórása közvetett információt ad a becslés jószágáról (azaz hogy várhatóan milyen messze van a becslés a tényleges paramétertől).
- *Konfidenciaintervallum* esetén a becslés eredménye egy intervallum.

Példa

- Megmértük 16 doboz gabonapehely tömegét, és a kapott eredmények:

506, 508, 499, 503, 504, 510, 497, 512,
514, 505, 493, 496, 506, 502, 509, 496.

- Tegyük fel, hogy a gyártási folyamat eredményeképpen a tömeg normális eloszlású ismeretlen μ várható értékkel és $\sigma = 5$ szórással. Adjunk 90%-os konfidenciaintervallumot μ -re!

Megoldás

- Tudjuk, hogy $\bar{X} \sim N\left(\mu, \frac{\sigma^2}{n}\right)$, azaz $\frac{\bar{X}-\mu}{\sigma/\sqrt{n}} \sim N(0, 1)$. Ezért

$$\Pr\left(z_{0.05} < \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} < z_{0.95}\right) = 0.9.$$

- Ez a kifejezés \bar{X} -ra (illetve pontosabban $\frac{\bar{X}-\mu}{\sigma/\sqrt{n}}$ -re) vonatkozik.

- Ekvivalens felírás (mivel $z_{0.05} = -z_{0.95}$):

$$\Pr\left(\bar{X} - z_{0.95} \frac{\sigma}{\sqrt{n}} < \mu < \bar{X} + z_{0.95} \frac{\sigma}{\sqrt{n}}\right) = 0.9.$$

- Tehát a $\left[\bar{X} - z_{0.95} \frac{\sigma}{\sqrt{n}}; \bar{X} + z_{0.95} \frac{\sigma}{\sqrt{n}}\right]$ véletlen intervallum 90% valószínűséggel tartalmazza μ -t.

Megoldás (folyt.)

- Példánkban $\bar{x} = 503.8$, $\sigma = 5$, $n = 16$, $z_{0.05} = -1.645$, $z_{0.95} = 1.645$,
- tehát $\bar{x} - z_{0.95} \frac{\sigma}{\sqrt{n}} = 501.7$ és $\bar{x} + z_{0.95} \frac{\sigma}{\sqrt{n}} = 505.8$.
- Ezért a 90%-os konfidenciaintervallum $[501.7; 505.8]$.

Megjegyzések

- A klasszikus statisztikában *nem mondhatjuk*, hogy 90% annak valószínűsége, hogy μ a $[501.7; 505.8]$ intervallumban van, mivel μ nem valószínűségi változó (μ vagy benne van az intervallumban, vagy nem)
- Pontos értelmezés: az $\{X_i\}$ minta vétele *előtt* 90% annak valószínűsége, hogy a véletlen intervallum tartalmazza μ -t.
- Később: Bayes-statisztikában az intervallumbecslések értelmezése természetesebb, hiszen beszélhetünk μ (a posteriori) eloszlásáról.

2. Várható érték becslése

μ konfidenciaintervalluma nagy minta esetén

- Tudjuk, hogy f.a.e. minta esetén $\frac{\bar{X} - \mu}{s^*/\sqrt{n}} \stackrel{A}{\sim} N(0, 1)$.
- Tehát a korábbiakhoz hasonlóan:

$$\Pr\left(z_{\alpha/2} < \frac{\bar{X} - \mu}{s^*/\sqrt{n}} < z_{1-\alpha/2}\right) = 1 - \alpha$$

- azaz (felhasználva, hogy $z_{\alpha/2} = -z_{1-\alpha/2}$),

$$\Pr\left(\bar{X} - z_{1-\alpha/2} * \frac{s^*}{\sqrt{n}} < \mu < \bar{X} + z_{1-\alpha/2} * \frac{s^*}{\sqrt{n}}\right) = 1 - \alpha.$$

- A μ paraméter $1 - \alpha$ szintű konfidenciaintervalluma:

$$\left[\bar{x} - z_{1-\alpha/2} * \frac{s^*}{\sqrt{n}}; \bar{x} + z_{1-\alpha/2} * \frac{s^*}{\sqrt{n}} \right].$$

- Szokásos szabály a nagymintás közelítésre: $n > 120$ (vagy akár $n > 60$)
 - de ez természetesen nem egy precíz állítás

Konfidenciaintervallum normális mintában: ismert σ

- Tegyük fel, hogy $X \sim N(\mu, \sigma^2)$.
- Ekkor $\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0, 1)$.
- Ezért

$$\Pr\left(z_{\alpha/2} < \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} < z_{1-\alpha/2}\right) = 1 - \alpha$$

$$\Pr\left(\bar{X} - z_{1-\alpha/2} \frac{\sigma}{\sqrt{n}} < \mu < \bar{X} + z_{1-\alpha/2} \frac{\sigma}{\sqrt{n}}\right) = 1 - \alpha.$$

- Tehát a μ paraméter $1 - \alpha$ szintű konfidenciaintervalluma:

$$\left[\bar{x} - z_{1-\alpha/2} \frac{\sigma}{\sqrt{n}}; \bar{x} + z_{1-\alpha/2} \frac{\sigma}{\sqrt{n}} \right].$$

Konfidenciaintervallum normális mintában: ismeretlen σ

- Tegyük fel, hogy $X \sim N(\mu, \sigma^2)$.
- Ekkor $\frac{\bar{X} - \mu}{s^*/\sqrt{n}} \sim t_{n-1}$.
- Tehát

$$\Pr\left(t_{\alpha/2; n-1} < \frac{\bar{X} - \mu}{s^*/\sqrt{n}} < t_{1-\alpha/2; n-1}\right) = 1 - \alpha$$

$$\Pr\left(\bar{X} - t_{1-\alpha/2; n-1} \frac{s^*}{\sqrt{n}} < \mu < \bar{X} + t_{1-\alpha/2; n-1} \frac{s^*}{\sqrt{n}}\right) = 1 - \alpha.$$

- Tehát a μ paraméter $1 - \alpha$ szintű konfidenciaintervalluma:

$$\left[\bar{x} - t_{1-\alpha/2; n-1} * \frac{s^*}{\sqrt{n}}; \bar{x} + t_{1-\alpha/2; n-1} * \frac{s^*}{\sqrt{n}} \right].$$

Feladat

- A túlfoglalás elfogadható mértékének meghatározása érdekében egy légitársaság a járatain el nem foglalt helyek számára szeretne konfidenciaintervallumot adni.
- Ezért véletlenszerűen kiválasztanak $n = 225$ hasonló járatot, és azt találják, hogy ezeken az el nem foglalt helyek átlaga $\bar{x} = 11.6$ fő, korrigált tapasztalati szórása pedig $s^* = 4.1$ fő.
- Határozzuk meg az el nem foglalt helyek várható számának 90%-os, 95%-os és 99%-os konfidenciaintervallumát!

3. Sokasági arány nagymintás becslése

p konfidenciaintervalluma nagy minta esetén

- Legyen $X \sim \text{Bernoulli}(p)$.
- Nagy mintában ekkor $\frac{\bar{X} - \mu}{s^*/\sqrt{n}} \stackrel{A}{\sim} N(0, 1)$ és $\frac{\bar{X} - \mu}{s/\sqrt{n}} \stackrel{A}{\sim} N(0, 1)$.
- Mivel $s^2 = \bar{X}(1 - \bar{X})$, ezért $\frac{\bar{X} - p}{\sqrt{\frac{\bar{X}(1 - \bar{X})}{n}}} \stackrel{A}{\sim} N(0, 1)$.

- Ezért

$$\Pr \left(z_{\alpha/2} < \frac{\bar{X} - p}{\sqrt{\frac{\bar{X}(1 - \bar{X})}{n}}} < z_{1-\alpha/2} \right) = 1 - \alpha.$$

- Tehát a (közelítően) $1 - \alpha$ szintű konfidenciaintervallum:

$$\left[\bar{x} - z_{1-\alpha/2} * \sqrt{\frac{\bar{x}(1 - \bar{x})}{n}}; \bar{x} + z_{1-\alpha/2} * \sqrt{\frac{\bar{x}(1 - \bar{x})}{n}} \right].$$

- Szokásos szabály a nagymintás közelítésre: $np > 10$ és $n(1 - p) > 10$
 - bár ennél nagyobb "szerencsétlen" paraméterek is vannak.

Feladat

- A KSH (vagy más országok statisztikai hivatalainak) munkaerő-felmérése (MEF, LFS) a foglalkoztatás becslésére szolgál.
- Magyarországon 2013 első negyedében, 54.000 fő megkérdezése alapján, a munkaképes korú (15-74 éves) korosztály foglalkoztatási rátája 51,5%-nak adódott.

- Adjuk meg a foglalkoztatási ráta 95%-os konfidenciaintervallumát!
 - Feltételezzünk f.a.e. mintát, bár a valóságban rétegzett mintavétel van.
- Magyarország munkaképes korú lakossága körülbelül 7.630.000 fő. Adjunk 95%-os konfidenciaintervallumot a foglalkoztatottak létszámára 2013 első negyedévében!

4. Sokasági variancia becslése

σ^2 konfidenciaintervalluma normális mintában

- Normális eloszlású mintában $\frac{(n-1)s^2}{\sigma^2} = \frac{ns^2}{\sigma^2} \sim \chi_{n-1}^2$.
- Ekkor

$$\Pr\left(k_{\alpha/2;n-1} < \frac{ns^2}{\sigma^2} < k_{1-\alpha/2;n-1}\right) = 1 - \alpha$$

$$\Pr\left(\frac{ns^2}{k_{1-\alpha/2;n-1}} < \sigma^2 < \frac{ns^2}{k_{\alpha/2;n-1}}\right) = 1 - \alpha.$$

- A σ^2 paraméter $1 - \alpha$ szintű konfidenciaintervalluma:

$$\left[\frac{ns^2}{k_{1-\alpha/2;n-1}}; \frac{ns^2}{k_{\alpha/2;n-1}}\right].$$

Feladat

- Tudjuk, hogy a férfiak illetve a nők testmagassága normális eloszlású.
- Egy $n = 100$ elemű f.a.e. mintában a korrigálatlan tapasztalati szórásnégyzet $s^2 = 169$ -nek adódott.
- Határozzuk meg a sokasági variancia 95%-os konfidenciaintervallumát!
- Határozzuk meg a sokasági variancia (közelítő) konfidenciaintervallumát normális közelítést használva is!

Tananyag

Tananyag

- Wooldridge Appendix C.5
- Amemiya 8.1-8.2