

Leíró és matematikai statisztika

Matematika alapszak, matematikai elemző szakirány

Zempléni András

Valószínűségelméleti és Statisztika Tanszék
Matematikai Intézet
Természettudományi Kar
Eötvös Loránd Tudományegyetem

Honlap: zempleni.elte.hu

E-mail: andras.zempleni@ttk.elte.hu

Szoba: D 3-310

8. előadás

Nevezetes paraméteres próbák – áttekintés

Próbák a normális eloszlás várható értékére vonatkozóan:

- Egymintás u -próba, egymintás t -próba
- Kétmintás próbák:

	a két minta független	a két minta párosított
σ_1 és σ_2 ismert	<u>kétmintás u-próba</u>	egymintás u -próba a különbségekre
σ_1 és σ_2 ismeretlen	előzetes F -próba	
	$\sigma_1 = \sigma_2$ <u>kétmintás t-próba</u>	$\sigma_1 \neq \sigma_2$ <u>Welch-próba</u>
		egymintás t -próba a különbségekre

Próbák normális eloszlás szórásnégyzetére vonatkozóan:

- Egymintás próba: χ^2 -próba
- Kétmintás próba: F -próba

Összefüggő (párosított) minták: X_i és Y_i ugyanahhoz, az i -edik személyhez, tárgyhoz, objektumhoz tartozó véletlen mennyiség, $i = 1, 2, \dots$

Egymintás t -próba

$X_1, \dots, X_n \sim N(m, \sigma^2)$, ahol m és σ ismeretlen paraméterek

Kétoldali: $H_0 : m = m_0$

$H_1 : m \neq m_0$

Próbastatisztika: $T(\mathbf{X}) = t := \sqrt{n} \frac{\bar{X} - m_0}{S_n^*} \stackrel{H_0 \text{ esetén}}{\sim} t_{n-1}$

Kritikus tartomány: $\mathcal{X}_k = \{\mathbf{x} : |t| > t_{n-1, 1-\alpha/2}\}$

Egyoldali próbák esetén H_0 és a próbastatisztika ugyanaz marad, csak H_1 , és ezáltal a kritikus tartomány változik.

Egyoldaliak:

$H_1 : m > m_0$

$H_1 : m < m_0$

Kritikus tartomány: $\mathcal{X}_k = \{\mathbf{x} : t > t_{n-1, 1-\alpha}\}$

$\mathcal{X}_k = \{\mathbf{x} : t < -t_{n-1, 1-\alpha}\}$

Áttekintés

E33.) A fogyasztóvédelmi hatóság többszöri lakossági bejelentést kapott, hogy a Portokall nevű, fél literes kiszerezésű narancsitalokban a flakonra írt 500 ml-nél jóval kevesebb üdítő van. Ez alapján vizsgálatot kezdtek, a fogyasztóvédelem munkatársa vásárolt a boltban 10 darabot, majd megnézte a benne lévő ital térfogatát (ml):
483, 502, 498, 496, 502, 483, 494, 491, 505, 486.

Tegyük fel, hogy egy fél literes üdítő üvegbe töltött narancslé mennyisége normális eloszlást követ.

Állíthatjuk-e 95%-os megbízhatóság esetén, hogy a Portokall gyártója át akarja verni a vevőket?

E34.) Használjuk az első előadáson kitöltött kérdőív eredményeit, és próbáljunk meg az alapján a TTK hallgatóira vonatkozólag következtetéseket levonni!

- a.) Állíthatjuk-e, hogy a TTK-n a fiúk várható értékben legalább 10 cm-rel magasabbak a lányoknál;
- b.) Elfogadhatjuk-e, hogy a lányok magasságának szórása k cm, ahol $k = 1, 2, \dots, 15$?

Kétmintás u -próba

$$X_1, \dots, X_n \sim N(m_1, \sigma_1^2)$$

$$Y_1, \dots, Y_m \sim N(m_2, \sigma_2^2) \text{ független minták}$$

ahol m_1, m_2 ismeretlen paraméterek, σ_1, σ_2 ismert

$$\text{Kétoldali: } H_0 : m_1 = m_2$$

$$H_1 : m_1 \neq m_2$$

$$\text{Próbastatisztika: } T(\mathbf{X}, \mathbf{Y}) = u := \frac{\bar{X} - \bar{Y}}{\sqrt{\frac{\sigma_1^2}{n} + \frac{\sigma_2^2}{m}}} \stackrel{H_0 \text{ esetén}}{\sim} N(0, 1)$$

$$\text{Kritikus tartomány: } \mathcal{X}_k = \{(\mathbf{x}, \mathbf{y}) : |u| > u_{1-\alpha/2}\}$$

Egyoldali próbák esetén H_0 és a próbastatisztika ugyanaz marad, csak H_1 , és ezáltal a kritikus tartomány változik.

Egyoldaliak:

$$H_1 : m_1 > m_2$$

$$H_1 : m_1 < m_2$$

$$\text{Kritikus tartomány: } \mathcal{X}_k = \{(\mathbf{x}, \mathbf{y}) : u > u_{1-\alpha}\} \quad \mathcal{X}_k = \{(\mathbf{x}, \mathbf{y}) : u < -u_{1-\alpha}\}$$

Áttekintés

Kétmintás t -próba

$$X_1, \dots, X_n \sim N(m_1, \sigma_1^2)$$

$$Y_1, \dots, Y_m \sim N(m_2, \sigma_2^2) \text{ független minták}$$

ahol $m_1, m_2, \sigma_1 = \sigma_2$ ismeretlen paraméterek

$$\text{Kétoldali: } H_0 : m_1 = m_2$$

$$H_1 : m_1 \neq m_2$$

$$\text{Próbastatisztika: } T(\mathbf{X}, \mathbf{Y}) = t := \sqrt{\frac{nm}{n+m}} \frac{\bar{X} - \bar{Y}}{\sqrt{\frac{(n-1)(S_1^*)^2 + (m-1)(S_2^*)^2}{n+m-2}}} \stackrel{H_0 \text{ esetén}}{\sim} t_{n+m-2}$$

$$\text{Kritikus tartomány: } \mathcal{X}_k = \{(\mathbf{x}, \mathbf{y}) : |t| > t_{n+m-2, 1-\alpha/2}\}$$

Egyoldali próbák esetén H_0 és a próbastatisztika ugyanaz marad, csak H_1 , és ezáltal a kritikus tartomány változik.

$$\text{Egyoldaliak: } H_1 : m_1 > m_2 \qquad H_1 : m_1 < m_2$$

$$\text{Krit. tart. } \mathcal{X}_k = \{(\mathbf{x}, \mathbf{y}) : t > t_{n+m-2, 1-\alpha}\} \mathcal{X}_k = \{(\mathbf{x}, \mathbf{y}) : t < -t_{n+m-2, 1-\alpha}\}$$

Áttekintés

Welch-próba

$X_1, \dots, X_n \sim N(m_1, \sigma_1^2)$ és $Y_1, \dots, Y_m \sim N(m_2, \sigma_2^2)$ független minták ahol $m_1, m_2, \sigma_1 \neq \sigma_2$ ismeretlen paraméterek

Kétoldali: $H_0 : m_1 = m_2$

$$\underline{H_1 : m_1 \neq m_2}$$

Próbastatisztika: $T(\mathbf{X}, \mathbf{Y}) = t' := \frac{\bar{X} - \bar{Y}}{\sqrt{\frac{(s_1^*)^2}{n} + \frac{(s_2^*)^2}{m}}}$ H_0 esetén $\sim t_f$, ahol

$$\frac{1}{f} = \frac{c^2}{n-1} + \frac{(1-c)^2}{m-1}, \quad c = \frac{\frac{(s_1^*)^2}{n}}{\frac{(s_1^*)^2}{n} + \frac{(s_2^*)^2}{m}}, \quad \text{ha } s_1^* > s_2^* \text{ (így csináljuk)}$$

Kritikus tartomány: $\mathcal{X}_k = \{(\mathbf{x}, \mathbf{y}) : |t| > t_{f, \alpha/2}\}$

Egyoldali próbák esetén H_0 és a próbastatisztika ugyanaz marad, csak H_1 , és ezáltal a kritikus tartomány változik.

Egyoldaliak: $H_1 : m_1 > m_2$ $H_1 : m_1 < m_2$

Krit. tartomány: $\mathcal{X}_k = \{(\mathbf{x}, \mathbf{y}) : t > t_{f, \alpha}\}$ $\mathcal{X}_k = \{(\mathbf{x}, \mathbf{y}) : t < -t_{f, \alpha}\}$

Áttekintés

- 2011-ben az USA-ban 11000 új állás jött létre (azaz az év végén ennyivel többen dolgoztak, mint az év elején)
- Wisconsin állam kormányzója büszkén jelentette be, hogy az ő állama egyedül az ország állásainak 50%-át hozta létre, mert náluk 5500-zal dolgoztak többen.
- Mi a véleményünk?
- A szomszédos Minnesota viszont 13000 új állást hozott létre (>100%)
- Azaz nem szabad százalékot használni ott, ahol negatív értékek is vannak!
- Forrás: Ellenberg: How not to be wrong?

- 2011-ben az USA-ban 11000 új állás jött létre (azaz az év végén ennyivel többen dolgoztak, mint az év elején)
- Wisconsin állam kormányzója büszkén jelentette be, hogy az ő állama egyedül az ország állásainak 50%-át hozta létre, mert náluk 5500-zal dolgoztak többen.
- Mi a véleményünk?
- A szomszédos Minnesota viszont 13000 új állást hozott létre (>100%)
- Azaz nem szabad százalékot használni ott, ahol negatív értékek is vannak!
- Forrás: Ellenberg: How not to be wrong?

Nevezetes paraméteres próbák VI

χ^2 -próba (normális eloszlás szórására)

$X_1, \dots, X_n \sim N(m, \sigma^2)$, ahol m és σ ismeretlen paraméterek

Kétoldali: $H_0 : \sigma = \sigma_0$

$H_1 : \sigma \neq \sigma_0$

Próbastatisztika: $T(\mathbf{X}) = h := \frac{(n-1)(S_n^*)^2}{\sigma_0^2} \stackrel{H_0 \text{ esetén}}{\sim} \chi_{n-1}^2$

Kritikus tartomány: $\mathcal{X}_k = \left\{ \mathbf{x} : h < \chi_{n-1, \alpha/2}^2 \text{ vagy } h > \chi_{n-1, 1-\alpha/2}^2 \right\}$

Egyoldali próbák esetén H_0 és a próbastatisztika ugyanaz marad, csak H_1 , és ezáltal a kritikus tartomány változik.

Egyoldaliak:

$H_1 : \sigma > \sigma_0$

$H_1 : \sigma < \sigma_0$

Kritikus tartomány: $\mathcal{X}_k = \left\{ \mathbf{x} : h > \chi_{n-1, 1-\alpha}^2 \right\}$ $\mathcal{X}_k = \left\{ \mathbf{x} : h < \chi_{n-1, \alpha}^2 \right\}$

[Áttekintés](#)

F-próba

$$X_1, \dots, X_n \sim N(m_1, \sigma_1^2)$$

$$Y_1, \dots, Y_m \sim N(m_2, \sigma_2^2) \text{ független minták}$$

ahol $m_1, m_2, \sigma_1, \sigma_2$ ismeretlen paraméterek

$$\text{Kétoldali: } H_0 : \sigma_1 = \sigma_2$$

$$\underline{H_1 : \sigma_1 \neq \sigma_2}$$

$$\text{Próbastatisztika: } T(\mathbf{X}, \mathbf{Y}) = F = \frac{(S_1^*)^2}{(S_2^*)^2} \stackrel{H_0 \text{ esetén}}{\sim} F_{n-1, m-1}$$

Kritikus tartomány:

$$\mathcal{X}_k = \{(\mathbf{x}, \mathbf{y}) : F < F_{n-1, m-1, \alpha/2} \text{ vagy } F > F_{n-1, m-1, 1-\alpha/2}\}$$

Egyoldali próbák esetén H_0 és a próbastatisztika ugyanaz marad, csak H_1 , és ezáltal a kritikus tartomány változik.

$$\text{Egyoldaliak: } H_1 : \sigma_1 > \sigma_2$$

$$H_1 : \sigma_1 < \sigma_2$$

$$\text{Krit. tart.: } \{(\mathbf{x}, \mathbf{y}) : F > F_{n-1, m-1, 1-\alpha}\}$$

$$\{(\mathbf{x}, \mathbf{y}) : F < F_{n-1, m-1, \alpha}\}$$

Áttekintés

E35.) Használjuk az első előadáson kitöltött kérdőív eredményeit, és próbáljunk meg az alapján a TTK hallgatóira vonatkozólag következtetéseket levonni! Állíthatjuk-e, hogy a TTK-n

- a.) a fiúk legalább 10 cm-rel magasabbak a lányoknál;
- b.) a lányok magasságának szórása k cm, ahol $k = 1, 2, \dots, 15$?

E36.) Bálint gazda este összefut a helyi kocsmában a szomszéd gazdálkodóval, Máté gazdával, aki elmeséli, a tehenei tejének tejsírszázaléka jelentősen megnőtt, mióta szilázssal is eteti őket minden nap. Ezen felbuzdulva, Bálint gazda úgy dönt, hogy 6 kedvenc tehenén kipróbálja ezt a "diétát" – egy hónapon keresztül szilázssal is etette őket, majd megnézte a tejük tejsírszázalékát:

Mit ettek	Julcsa	Bogár	Riska	Csendes	Bimbó	Mula
Csak fűvet	3,84	3,79	3,78	4,00	3,83	3,84
Szilázst is	3,90	4,05	3,8	4,01	3,81	3,9

Vizsgáljuk meg alkalmas statisztikai próbával, hogy a szilázs növeli-e a tej tejsírszázalékát!

Az előző feladat végeredménye (számítógéppel megoldva):

p -érték = 0,0867 (egymintás t -próba a különbségekre)

Helyes, a szövegkörnyezetbe ágyazott szöveges értelmezések:

- 95%-os megbízhatóság mellett nem tudjuk bizonyítani, hogy a szilázssal való etetés növeli a tehenek tejének tejsírszázalékát. ($\rightsquigarrow H_1$ -et elvetjük)
- 5%-os elsőfajú hiba valószínűsége mellett nem tudjuk elutasítani, hogy a szilázssal való etetés nem változtat a tehenek tejének tejsírszázalékán. ($\rightsquigarrow H_0$ -t nem tudjuk elvetni)
- 90%-os megbízhatóság esetén azt mondhatjuk, hogy a szilázssal való etetés növeli a tehenek tejének tejsírszázalékát.

Nem teljesen korrekt értelmezés:

- 5%-os elsőfajú hiba valószínűsége mellett azt mondhatjuk, hogy a szilázssal való etetés nem változtat a tehenek tejének tejsírszázalékán. ($\rightsquigarrow H_0$ -t elfogadjuk)

Eredmény, magyarázatok/2, még egy feladat

- 8,67% az esélye, hogy ilyen (vagy még nagyobb) eltérést kapunk akkor, ha a szilázssal való etetés valójában nem változtat a tehenek tejének tejsírszázalékán. ($\rightsquigarrow H_0$ -t elfogadjuk)

Helytelen, hibás szöveges értelmezések:

- 95%-os **valószínűséggel** elvethetjük, hogy a szilázssal való etetés növeli a tehenek tejének tejsírszázalékát.
- 5%-os **valószínűséggel** nem tudjuk elutasítani, hogy a szilázssal való etetés nem változtat a tehenek tejének tejsírszázalékán.
- **8,67% az esélye, hogy a szilázssal való etetés nem növeli a tehenek tejének tejsírszázalékát.**

Mi történik, ha az u -próbák, illetve t -próbák feltételei közül nem teljesül az, hogy a minta normális eloszlású, mi mégis hagyományos módon végrehajtjuk a próbát?

E37.) Vizsgáljuk meg szimulációval a kétoldali, egymintás t -próba terjedelmét, amennyiben a minta $n = 10, 20, 50, 100, 200$ elemű, független normális, illetve exponenciális eloszlású!