

11. STATISZTIKA GYAKORLAT: Nemparaméteres próbák

1 Kolmogorov–Szmirnov próba

1.1 Egymintás eset (illeszkedésvizsgálat):

H_0 : n -elemű fae. mintánk az F folytonos eloszlásfüggvényű eloszlásból származik.

Kétoldali alternatíva:

$$H_1 : \mathbb{P}(X < x) \neq F(x).$$

Legyen

$$D_n = \sup_{x \in \mathbb{R}} |F_n^*(x) - F(x)|.$$

Amennyiben $x_1^* \leq \dots \leq x_n^*$ az $\mathbf{x} = (x_1, \dots, x_n)$ mintarealizáció rendezett alakja; $y_i = F(x_i)$, $y_i^* = F(x_i^*)$ ($i = 1, \dots, n$) a $(0,1)$ -en egyenletesbe transzformált minta, akkor

$$\begin{aligned} D_n(\mathbf{x}) &= \max_i \max\{|F_n^*(x_i^*) - F(x_i^*)|, |F_n^*(x_i^* + 0) - F(x_i^*)|\} = \\ &= \max_i \max\{|\frac{i-1}{n} - F(x_i^*)|, |\frac{i}{n} - F(x_i^*)|\} \\ &= \max_i \max\{|\frac{i-1}{n} - y_i^*|, |\frac{i}{n} - y_i^*|\} = \\ &= \max_i \max\{|G_n^*(y_i^*) - G(y_i^*)|, |G_n^*(y_i^* + 0) - G(y_i^*)|\} = D_n(\mathbf{y}), \end{aligned}$$

Ahol G_n^* az y -minta empirikus eof.-e és $G(y) = y$, $0 < y < 1$.

A Kolmogorov-tétel alapján tudjuk, hogy H_0 fennállása esetén

$$\lim_{n \rightarrow \infty} \mathbb{P}(\sqrt{n}D_n < z) = K(z), \quad \forall z \in \mathbb{R},$$

ahol

$$K(z) = \sum_{i=-\infty}^{\infty} (-1)^i e^{-2i^2 z^2} = 1 - 2 \sum_{i=1}^{\infty} (-1)^{i-1} e^{-2i^2 z^2}, \quad z > 0.$$

A Kolmogorov-eof. számunkra fontos értékei az alábbi táblázatban található:

z	1.14	1.22	1.36	1.52	1.63	k_α
$K(z)$	0.85	0.90	0.95	0.98	0.99	$1 - \alpha$

Így “elég nagy” n esetén az α szignifikanciához (I fajú hibához) tartozó kritikus tartomány:

$$\mathcal{X}_k = \{\mathbf{x} : \sqrt{n}D_n(\mathbf{x}) \geq k_\alpha\},$$

ahol k_α a Kolmogorov-eloszlás $1 - \alpha$ kvantilise.

Egyoldali alternatíva:

$$H_0 : \mathbb{P}(X < x) \leq F(x) \quad H_1 : \mathbb{P}(X < x) > F(x).$$

Legyen

$$D_n^+ = \sup_{x \in \mathbb{R}} (F_n^*(x) - F(x)) = \max_i \max\{(F_n^*(x_i^*) - F(x_i^*)), (F_n^*(x_i^* + 0) - F(x_i^*))\}.$$

A Szmirnov-tétel alapján tudjuk, hogy

$$\lim_{n \rightarrow \infty} \mathbb{P}(\sqrt{n}D_n^+ < z) = S(z), \quad \forall z \in \mathbb{R},$$

ahol

$$S(z) = 1 - e^{-2z^2}, \quad z > 0.$$

A Szmirnov-eloszlásfüggvény értékei (és inverze is) számolható expliciten.

$$\mathcal{X}_k = \{\mathbf{x} : \sqrt{n}D_n^+(\mathbf{x}) \geq k_\alpha\},$$

ahol k_α a Szmirnov-eloszlás $1 - \alpha$ kvantilise.

1.2 Kétmintás eset (homogenitásvizsgálat):

H_0 : n -elemű és m -elemű, egymástól is független fae. mintáink ugyanaból a folytonos eloszlásfüggvényű eloszlásból származnak, azaz

$$H_0 : F = G.$$

Kétoldali alternatíva:

$$H_1 : F \neq G.$$

Legyen

$$D_{n,m} = \sup_{x \in \mathbb{R}} |F_n^*(x) - G_m^*(x)|,$$

ami megint véges maximum.

A Kolmogorov-tétel alapján tudjuk, hogy H_0 fennállása esetén

$$\lim_{n,m \rightarrow \infty} \mathbb{P}\left(\sqrt{\frac{nm}{n+m}} D_{n,m} < z\right) = K(z), \quad \forall z \in \mathbb{R}.$$

Ezért

$$\mathcal{X}_k = \{\mathbf{x}, \mathbf{y} : \sqrt{\frac{nm}{n+m}} D_{n,m}(\mathbf{x}, \mathbf{y}) \geq k_\alpha\},$$

ahol k_α a Kolmogorov-eloszlás $1 - \alpha$ kvantilise.

Egyoldali alternatíva:

$$H_0 : F \leq G \quad H_1 : F > G.$$

Legyen

$$D_{n,m}^+ = \sup_{x \in \mathbb{R}} (F_n^*(x) - G_m^*(x)),$$

ami megint véges maximum.

A Szmirnov-tétel alapján tudjuk, hogy H_0 fennállása esetén

$$\lim_{n,m \rightarrow \infty} \mathbb{P}(\sqrt{\frac{nm}{n+m}} D_{n,m}^+ < z) = S(z), \quad \forall z \in \mathbb{R}.$$

Ezért

$$\mathcal{X}_k = \{\mathbf{x}, \mathbf{y} : \sqrt{\frac{nm}{n+m}} D_{n,m}^+(\mathbf{x}, \mathbf{y}) \geq k_\alpha\},$$

ahol k_α a Szmirnov-eloszlás $1 - \alpha$ kvantilise.

2 χ^2 -próba

Ld. könyv és képletgyűjtemény. Előnye a Kolmogorov–Szmirnov próbával szemben, hogy diszkrét eloszlásokra is alkalmazható; viszont folytonos eloszlásokat is diszkretizálni kell, így információt veszünk.

3 Feladatok példatár 3.2 részből

- Szabályosnak tekinthető-e az alábbi 100-szor feldobott dobókocka $\alpha = 0.05$ szignifikanciával?

kategória	1	2	3	4	5	6
gyakoriság	24	21	19	12	13	11

$\chi^2 = 8.72 < \chi^2(5)$, az 5 szab. fokú χ^2 eo. $1 - 0.05 = 0.95$ kvantilise, ezért nem tudjuk elutasítani H_0 -t, a kocka szabályos.

- Származhat-e mintánk $[0.5, 6.5]$ -ön folytonos egyenletes eloszlásból, ha az ekvidisztans felosztásban a gyakoriságok a fentiek? ($\alpha = 0.05$)
Megint

$$H_0 : p_i = 1/6, \quad i = 1, \dots, 6$$

így ugyanaz a χ^2 adódik.

Ha 100-elemű mintánk konkrét $[0.5, 6.5]$ -beli értékeit is ismernénk, akkor egymintás, kétoldali Kolmogorov–Szmirnov próbát hajthatnánk végre.

- Jó-e a RANDOM generátor? Származhat-e az alábbi 20 szám (az egyszerűség kedvéért nagyság szerint rendezve) $[0, 1]$ -en egyenletes eloszlásból?
0.03, 0.05, 0.08, 0.08, 0.11, 0.12, 0.14, 0.19, 0.23, **0.24**,
0.31, 0.43, 0.45, 0.56, 0.61, 0.67, 0.69, 0.78, 0.85, 0.88

- Most egymintás, kétoldali Kolmogorov–Szmirnov próbát hajthatunk végre (bár 20 nem kimondottan ‘nagy’):

$$D_{20}(\mathbf{y}) = \max_{i=1}^{20} \max\{|G_{20}^*(y_i^*) - y_i^*|, |G_{20}^*(y_i^* + 0) - y_i^*|\} =$$

$$= |G_{20}^*(y_{10}^* + 0) - y_{10}^*| = \left| \frac{10}{20} - 0.24 \right| = 0.26.$$

Mivel $\sqrt{20}D_{20} = 1.16$, a Kolmogorov-táblázat alapján $1 - \alpha$ valamivel kisebb, mint 0.9, α pedig valamivel nagyobb, mint 0.1. Ez a szignifikancia nem elég H_0 elutasításához, ezért úgy döntünk, hogy jó a véletlen szám generátor (nagyobb minta azért bizonyítóbb erejű lett volna).

- χ^2 -próbával 4 ekvidisztans intervallumra osztjuk $[0,1]$ -et és a

$$H_0 : p_i = 1/4, \quad i = 1, 2, 3, 4$$

null-hipotézist teszteljük:

intervallum	0–0.25	0.25–0.5	0.5–0.75	0.75–1
ν_i	10	3	4	3
$20p_i$	5	5	5	5

$$\chi^2 = \frac{25 + 4 + 1 + 4}{5} = 6.8,$$

ami valamivel nagyobb, mint a $\chi^2(3)$ -eloszlás 0.9 kvantilise, α pedig valamivel (de csak kevéssel) kisebb, mint 0.1. Tehát χ^2 -próbával valamivel kisebb szignifikanciával (I. fajú hibával) tudnánk elutasítani H_0 -t, mint a Kolmogorov–Szmirnov próbával. Azonban ez a szignifikancia sem elég H_0 elutasításához, ezért inkább úgy döntünk, hogy jó a véletlen szám generátor (nagyobb minta itt is bizonyítóbb erejű lett volna).

Pl. $\alpha = 0.05$ mellett, mindkét próbával el kell fogadnunk H_0 -t.

- Fizetések (példatár 1.1)

- Normális eo.-t követnek-e becsült paraméterekkel? Nem, mert van egy kiugró érték.
- Pareto eo.-t követnek-e becsült paraméterekkel? (ld. Hf.)
Pareto: olasz közgazdász vezette be ezt az eo.-t a javak egyenlőtlen elosztására (XX sz. első fele).