

Kolmogorov–Szmirnov próba

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.

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

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

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.

A χ^2 -próba előnye a Kolmogorov–Szmirnov próbával szemben, hogy diszkrét eloszlásokra is alkalmazható; viszont folytonos eloszlásokat is diszkrétizálni kell, így információt veszünk.