

1.2.6. Definíció. A $\xi_1, \xi_2, \dots, \xi_n$ mintából képezett **rendezett minta**:

$$\xi_{1:n}^* \leq \xi_{2:n}^* \leq \dots \leq \xi_{n:n}^*.$$

A rendezett minta elemei statisztikák, ugyanis például $\xi_{1:n}^* = T_n(\xi_1, \xi_2, \dots, \xi_n)$, ahol

$$T_n(x_1, x_2, \dots, x_n) = \min\{x_1, x_2, \dots, x_n\}$$

folytonos függvény. Megjegyezzük, hogy a $\xi_{1:n}^*, \xi_{2:n}^*, \dots, \xi_{n:n}^*$ valószínűségi változók nem függetlenek és nem azonos eloszlásúak.

1.2.7. Definíció. A $\xi_1, \xi_2, \dots, \xi_n$ mintából képezett **tapasztalati medián**:

$$\begin{cases} \xi_{m+1:n}^*, & \text{ha } n = 2m + 1 \text{ páratlan,} \\ (\xi_{m:n}^* + \xi_{m+1:n}^*)/2, & \text{ha } n = 2m \text{ páros.} \end{cases}$$

A $\xi_1, \xi_2, \dots, \xi_n$ minta **terjedelme**:

$$\xi_{n:n}^* - \xi_{1:n}^*.$$

1.2.8. Definíció. A $\xi_1, \xi_2, \dots, \xi_n$ mintából képezett **tapasztalati (empirikus) eloszlásfüggvény**: $\mathcal{F}_n : \mathbb{R} \times \Omega \rightarrow \mathbb{R}$,

$$\mathcal{F}_n(x) = \mathcal{F}_n(x, \omega) := \sum_{i: \xi_i(\omega) < x} \frac{1}{n} = \begin{cases} 0, & \text{ha } x \leq \xi_{1:n}^*, \\ \frac{k}{n}, & \text{ha } \xi_{k:n}^* < x \leq \xi_{k+1:n}^*, \\ 1, & \text{ha } x > \xi_{n:n}^*. \end{cases}$$

Vagyis minden rögzített $x \in \mathbb{R}$ esetén $\mathcal{F}_n(x, \cdot) : \Omega \rightarrow \mathbb{R}$ valószínűségi változó, ezért statisztika, mégpedig a $\{\omega \in \Omega : \xi_i(\omega) < x\} \in \mathcal{A}$ esemény relatív gyakorisága. Továbbá minden rögzített $\omega \in \Omega$ esetén $\mathcal{F}_n(\cdot, \omega) : \mathbb{R} \rightarrow \mathbb{R}$ eloszlásfüggvény, mégpedig annak a diszkrét eloszlásnak az eloszlásfüggvénye, melynek a lehetséges értékei a mintaelemek $\xi_1(\omega), \xi_2(\omega), \dots, \xi_n(\omega)$ realizációi, és ezen értékeket egyaránt $1/n$ valószínűséggel veheti fel.

2) Glivenko - Cantelli alaptétel: Minden valószínűségi változónak van valószínű értéke

$$E(\bar{X}) = \frac{x_1 + x_2 + \dots + x_n}{n} = \bar{x} \quad E(X) = \mu \quad D^2(X) = \sigma^2$$

↑
minták központosított értéke

variancia

empirikus négyzetes középérték: $D^2(\bar{X}) = \frac{(x_1 - \bar{x})^2 + \dots + (x_n - \bar{x})^2}{n} = s_n^2$

minták központosított valósn. vált.

$$\bar{X} = \frac{X_1 + X_2 + \dots + X_n}{n}$$

$E(\bar{X}) = \mu = E(X)$

↑
középérték

$E(S_n^2) = \frac{n-1}{n} \cdot \sigma^2$

↑
empirikus négyzetes középérték

másképpen kiszámolható

korrigált empirikus négyzetes középérték: $S_n^{*2} = \frac{n}{n-1} \cdot S_n^2$

↑
középérték

Kolmogorov–Szmirnov-tételkör

A Glivenko–Cantelli-tétel arról szól, hogy az empirikus eloszlásfüggvény 1 valószínűséggel (majdnem minden realizációra) az egész számegyenesen egyenletesen tart az elméleti eloszlásfüggvényhez. Tehát kellő számú mintát véve tetszőleges pontossággal közelíteni tudjuk a valódi eloszlásfüggvényt. De adott pontossághoz vajon hány elemű mintát kell vennünk? A konvergencia sebességére vonatkozóan újabb tételeket fogunk kimondani. Ezek azt jelzik, hogy n kísérlet kb. $1/\sqrt{n}$ nagyságrendű közelítéshez elegendő.

Legyen a háttéreloszlás F eloszlásfüggvénye folytonos, F_n^* pedig jelölje az n -elemű mintához tartozó empirikus eloszlásfüggvényt. Akkor

2.1. Tétel (Szmirnov).

$$\lim_{n \rightarrow \infty} \mathbb{P} \left(\sqrt{n} \sup_{x \in \mathbb{R}} (F_n^*(x) - F(x)) < z \right) = S(z), \quad \forall z \in \mathbb{R},$$

ahol

$$S(z) = \begin{cases} 0, & \text{ha } z \leq 0, \\ 1 - e^{-2z^2}, & \text{ha } z > 0, \end{cases} \quad (2.1)$$

az ún. Szmirnov-eloszlásfüggvény.

2.2. Tétel (Kolmogorov).

$$\lim_{n \rightarrow \infty} \mathbb{P} \left(\sqrt{n} \sup_{x \in \mathbb{R}} |F_n^*(x) - F(x)| < z \right) = K(z), \quad \forall z \in \mathbb{R},$$

ahol

$$K(z) = \begin{cases} 0, & \text{ha } z \leq 0, \\ \sum_{i=-\infty}^{\infty} (-1)^i e^{-2i^2 z^2} = 1 - 2 \sum_{i=1}^{\infty} (-1)^{i-1} e^{-2i^2 z^2}, & \text{ha } z > 0, \end{cases} \quad (2.2)$$

az ún. Kolmogorov-eloszlásfüggvény.

Legyen most az X illetve Y háttérváltozó (nem feltétlenül ismert) eloszlásfüggvénye a folytonos F illetve G függvény, F_n^* illetve G_m^* pedig jelölje az n -elemű X_1, \dots, X_n illetve az m -elemű Y_1, \dots, Y_m , egymástól is független mintákhoz tartozó empirikus eloszlásfüggvényeket. Tegyük fel továbbá, hogy $F(x) = G(x)$, $\forall x \in \mathbb{R}$. Akkor

2.3. Tétel (Szmirnov).

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

1.2.6. Definíció. A $\xi_1, \xi_2, \dots, \xi_n$ mintából képezett **rendezett minta**:

$$\xi_{1:n}^* \leq \xi_{2:n}^* \leq \dots \leq \xi_{n:n}^*.$$

A rendezett minta elemei statisztikák, ugyanis például $\xi_{1:n}^* = T_n(\xi_1, \xi_2, \dots, \xi_n)$, ahol

$$T_n(x_1, x_2, \dots, x_n) = \min\{x_1, x_2, \dots, x_n\}$$

folytonos függvény. Megjegyezzük, hogy a $\xi_{1:n}^*, \xi_{2:n}^*, \dots, \xi_{n:n}^*$ valószínűségi változók nem függetlenek és nem azonos eloszlásúak.

1.2.7. Definíció. A $\xi_1, \xi_2, \dots, \xi_n$ mintából képezett **tapasztalati medián**:

$$\begin{cases} \xi_{m+1:n}^*, & \text{ha } n = 2m + 1 \text{ páratlan,} \\ (\xi_{m:n}^* + \xi_{m+1:n}^*)/2, & \text{ha } n = 2m \text{ páros.} \end{cases}$$

A $\xi_1, \xi_2, \dots, \xi_n$ minta **terjedelme**:

$$\xi_{n:n}^* - \xi_{1:n}^*.$$

1.2.8. Definíció. A $\xi_1, \xi_2, \dots, \xi_n$ mintából képezett **tapasztalati (empirikus) eloszlásfüggvény**: $\mathcal{F}_n : \mathbb{R} \times \Omega \rightarrow \mathbb{R}$,

$$\mathcal{F}_n(x) = \mathcal{F}_n(x, \omega) := \sum_{i: \xi_i(\omega) \leq x} \frac{1}{n} = \begin{cases} 0, & \text{ha } x \leq \xi_{1:n}^*, \\ \frac{k}{n}, & \text{ha } \xi_{k:n}^* < x \leq \xi_{k+1:n}^*, \\ 1, & \text{ha } x > \xi_{n:n}^*. \end{cases}$$

Vagyis minden rögzített $x \in \mathbb{R}$ esetén $\mathcal{F}_n(x, \cdot) : \Omega \rightarrow \mathbb{R}$ valószínűségi változó, ezért statisztika, mégpedig a $\{\omega \in \Omega : \xi_i(\omega) < x\} \in \mathcal{A}$ esemény relatív gyakorisága. Továbbá minden rögzített $\omega \in \Omega$ esetén $\mathcal{F}_n(\cdot, \omega) : \mathbb{R} \rightarrow \mathbb{R}$ eloszlásfüggvény, mégpedig annak a diszkrét eloszlásnak az eloszlásfüggvénye, melynek a lehetséges értékei a mintaelemek $\xi_1(\omega), \xi_2(\omega), \dots, \xi_n(\omega)$ realizációi, és ezen értékeket egyaránt $1/n$ valószínűséggel veheti fel.

2) Glivenko - Cantelli alaptétel: Minden valószínűségi változónak van valószínű értéke
 $E(\bar{X}) = \frac{x_1 + x_2 + \dots + x_n}{n} = \bar{x}$ $E(X) = \mu$ $D^2(X) = \sigma^2$
 \uparrow mintaelem (empirikus valószínű érték) \uparrow várható érték \uparrow variancia
empirikus négyzetérték: $D^2(\bar{X}) = \frac{(x_1 - \bar{x})^2 + \dots + (x_n - \bar{x})^2}{n} = s_n^2$
mintaelem valósn. vált: $\bar{X} = \frac{x_1 + x_2 + \dots + x_n}{n}$
 $E(\bar{X}) = \mu = E(X)$ $E(s_n^2) = \frac{n-1}{n} \cdot \sigma^2$
 \uparrow várható érték \uparrow empirikus négyzetérték \uparrow minden torzítással becsül.
korrigált empirikus négyzetérték $s_n^{*2} = \frac{n}{n-1} \cdot s_n^2$

Kolmogorov–Szmirnov-tételkör

A Glivenko–Cantelli-tétel arról szól, hogy az empirikus eloszlásfüggvény 1 valószínűséggel (majdnem minden realizációra) az egész számegyenesen egyenletesen tart az elméleti eloszlásfüggvényhez. Tehát kellő számú mintát véve tetszőleges pontossággal közelíteni tudjuk a valódi eloszlásfüggvényt. De adott pontossághoz vajon hány elemű mintát kell vennünk? A konvergencia sebességére vonatkozóan újabb tételeket fogunk kimondani. Ezek azt jelzik, hogy n kísérlet kb. $1/\sqrt{n}$ nagyságrendű közelítéshez elegendő.

Legyen a háttéreloszlás F eloszlásfüggvénye folytonos, F_n^* pedig jelölje az n -elemű mintához tartozó empirikus eloszlásfüggvényt. Akkor

2.1. Tétel (Szmirnov).

$$\lim_{n \rightarrow \infty} \mathbb{P} \left(\sqrt{n} \sup_{x \in \mathbb{R}} (F_n^*(x) - F(x)) < z \right) = S(z), \quad \forall z \in \mathbb{R},$$

ahol

$$S(z) = \begin{cases} 0, & \text{ha } z \leq 0, \\ 1 - e^{-2z^2}, & \text{ha } z > 0, \end{cases} \quad (2.1)$$

az ún. Szmirnov-eloszlásfüggvény.

2.2. Tétel (Kolmogorov).

$$\lim_{n \rightarrow \infty} \mathbb{P} \left(\sqrt{n} \sup_{x \in \mathbb{R}} |F_n^*(x) - F(x)| < z \right) = K(z), \quad \forall z \in \mathbb{R},$$

ahol

$$K(z) = \begin{cases} 0, & \text{ha } z \leq 0, \\ \sum_{i=-\infty}^{\infty} (-1)^i e^{-2i^2 z^2} = 1 - 2 \sum_{i=1}^{\infty} (-1)^{i-1} e^{-2i^2 z^2}, & \text{ha } z > 0, \end{cases} \quad (2.2)$$

az ún. Kolmogorov-eloszlásfüggvény.

Legyen most az X illetve Y háttérváltozó (nem feltétlenül ismert) eloszlásfüggvénye a folytonos F illetve G függvény, F_n^* illetve G_m^* pedig jelölje az n -elemű X_1, \dots, X_n illetve az m -elemű Y_1, \dots, Y_m , egymástól is független mintákhoz tartozó empirikus eloszlásfüggvényeket. Tegyük fel továbbá, hogy $F(x) = G(x)$, $\forall x \in \mathbb{R}$. Akkor

2.3. Tétel (Szmirnov).

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