

Przypuśćmy, że cecha \mathbb{X} populacji generalnej na podstawie metody (2) ma określony typ rozkładu $F(x, \tau)$, gdzie τ jest nieznaną wartością jednego z parametrów znanego typu rozkładu F . Lub ogólniej, być może nie znamy nawet typu tego rozkładu, ale dysponujemy informacjami na temat istnienia jego momentów.

Jeśli uda się skonstruować dwie statystyki

$$\mathbb{Z}_j = f_j(\mathbb{X}_1 \dots \mathbb{X}_n), \quad j = 1, 2,$$

gdzie $(x_1 \dots x_n) = (\mathbb{X}_1 \dots \mathbb{X}_n)(\omega_o)$ jest próbą prostą i takie, że dla dostatecznej małej liczby α (np. 0,05) wiemy, że

$$P(\{\omega \in \Omega : \tau \in (\mathbb{Z}_1(\omega), \mathbb{Z}_2(\omega))\}) = 1 - \alpha,$$

to będziemy mówili, że otrzymaliśmy *przedział losowy* przybliżający nieznaną wartość parametru τ z prawdopodobieństwem $1 - \alpha$.

Wtedy, wiedząc, że zdarzenie elementarne ω_o , które wyznacza próbę prostą należy do zdarzenia, które opisuje przedział losowy, otrzymalibyśmy oszacowanie na wartość tego parametru

$$\tau \in (\mathbb{Z}_1(\omega_o), \mathbb{Z}_2(\omega_o)).$$

Ponieważ weryfikacja tego faktu może być niemożliwa, lepiej jest powiedzieć, że na *poziomie ufności* $1 - \alpha$ oszacowaliśmy przedział, z którego można wybrać wartość liczbową parametru τ .

Metodę tę omówimy dokładniej w poniższych przykładach. Ograniczymy się tylko do kilku sytuacji, zakładając, że cecha ma drugi moment (patrz też [10]).

Przykład 6.4.2 Załóżmy, że z obserwacji histogramu dla próby prostej

$$(x_1 \dots x_n) = (\mathbb{X}_1 \dots \mathbb{X}_n)(\omega_o)$$

zauważyliśmy, że

$$\mathbb{X} \in \mathcal{N}(m, \sigma^2), \quad \text{gdzie nieznanym jest tylko parametr } m.$$

Pokażemy, jak w tym przypadku można zdefiniować przedział losowy.

Bierzemy statystyki

$$\mathbb{Z}_1 = \bar{\mathbb{X}}_n - n_\alpha \frac{\sigma}{\sqrt{n}} \quad \mathbb{Z}_2 = \bar{\mathbb{X}}_n + n_\alpha \frac{\sigma}{\sqrt{n}},$$

gdzie

$$P(\{\omega \in \Omega : |\mathbb{N}(\omega)| > n_\alpha\}) = \alpha,$$

i n_α jest takie, że

$$\Phi(n_\alpha) = 1 - \frac{\alpha}{2}, \quad \text{co odczytujemy z tablic.}$$

Z twierdzenia 6.3.1 (3) wynika, że uzyskane statystyki poprawnie definiują przedział losowy na zadanym poziomie ufności.

Niech teraz $(2,23, 2,12, 1,97, 2,01) = (\mathbb{X}_1 \dots \mathbb{X}_4)(\omega_o)$ będzie próbą prostą i \mathbb{X} rozkładem typu $\mathcal{N}(m, (0,25)^2)$.

Dla $\alpha = 0,05$ mamy:

$$x_4 = \overline{\mathbb{X}}_4(\omega_o) \simeq 2,083, \quad \Phi(n_\alpha) = 1 - \frac{\alpha}{2} \text{ implikuje, że } n_\alpha = 1,96,$$

więc z prawdopodobieństwem 0,95

$$m \in \left(2,083 - 1,96 \frac{0,25}{2}, 2,083 + 1,96 \frac{0,25}{2} \right) = (1,838, 2,328).$$

Przykład 6.4.3 Załóżmy, że z obserwacji histogramu dla próby prostej $(x_1 \dots x_n) = (\mathbb{X}_1 \dots \mathbb{X}_n)(\omega_o)$ zauważyliśmy, że

$\mathbb{X} \in \mathcal{N}(m, \sigma^2)$, gdzie nieznane są oba parametry oraz estymujemy m .

W tej sytuacji bierzemy:

$$\mathbb{Z}_1 = \overline{\mathbb{X}}_n - t_\alpha \frac{\mathbb{S}}{\sqrt{n-1}}, \quad \mathbb{Z}_2 = \overline{\mathbb{X}}_n + t_\alpha \frac{\mathbb{S}}{\sqrt{n-1}},$$

gdzie dla danej wartości α

$$P(\{\omega \in \Omega : |t_{n-1}(\omega)| > t_\alpha\}) = \alpha, \quad \text{i } \mathbb{S} = \sqrt{\mathbb{S}^2}.$$

Korzystając z Twierdzenia 6.3.1 (2) można pokazać, że uzyskane statystyki poprawnie definiują przedział losowy na zadanym poziomie ufności.

Odpowiednią symulację liczbową przeprowadzimy na danych liczbowych pochodzących z wcześniejszego przykładu. Korzystając z rozkładu t -Studenta o trzech stopniach swobody, dostaniemy

$$P(\{\omega \in \Omega : |t_3(\omega)| > t_\alpha\}) = 0,05 \text{ implikuje, że } t_\alpha = 3,182.$$

Ponieważ z poprzedniego przykładu $\overline{\mathbb{X}}_4(\omega_o) = 2,083$, więc

$$s = \mathbb{S}(\omega_o) =$$

$$\begin{aligned} & \sqrt{1/4((2,23 - 2,083)^2 + (2,12 - 2,083)^2 + (1,97 - 2,083)^2 + (2,01 - 2,083)^2)} \\ & = \sqrt{0,01} = 0,1. \end{aligned}$$

Stąd z postaci przedziału losowego dostaniemy

$$m \in \left(2,083 - 3,182 \frac{0,1}{1,73}, 2,083 + 3,182 \frac{0,1}{1,73} \right) = (1,899, 2,267)$$

z prawdopodobieństwem 0,95.

Przykład 6.4.4 W tym przykładzie obserwacja dystrybuanty empirycznej albo histogramu powstałego na podstawie zaobserwowanej próby prostej nie wiele dałoby nam znać o typie rozkładu cechy \mathbb{X} . Skądinąd wiemy natomiast, że ma on drugi moment. W dalszym ciągu będziemy estymowali parametr m . Weźmy teraz n dostatecznie duże, co najmniej równe 100.

Następujące 3 fakty:

1.

$$\frac{\bar{X}_n - m}{\frac{\sigma}{\sqrt{n}}} \xrightarrow{d} \mathcal{N}(0, 1), \quad (\text{z CTG}),$$

2.

$$E\hat{S}^2 = \text{var}(\mathbb{X}),$$

3.

$$\hat{S}^2 \xrightarrow{p.w.} \sigma^2, \quad (\text{z MPWL})$$

uzasadniają, że w tym przypadku następujące statystyki

$$Z_1 = \bar{X}_n - n_\alpha \frac{\hat{S}}{\sqrt{n}}, \quad Z_2 = \bar{X}_n + n_\alpha \frac{\hat{S}}{\sqrt{n}},$$

gdzie n_α ma takie samo znaczenie jak w przykładzie 6.4.2 wyznaczają przedział losowy dla parametru m z prawdopodobieństwem $1 - \alpha$.

Ze względu na potrzebę korzystania w tej sytuacji z twierdzeń granicznych wielkość próby prostej jest tutaj bardzo istotna. Aby uprościć symulację liczbową załóżmy, że:

$$\bar{x}_{100} = 2,0031, \quad \hat{s} = 0,1967, \quad \alpha = 0,05.$$

Wtedy z prawdopodobieństwem 0,95 wartość średnia cechy \mathbb{X} należy do przedziału

$$\left(2,0031 - 1,96 \frac{0,1967}{10}, 2,0031 + 1,96 \frac{0,1967}{10} \right) = (1,965, 2,042).$$