

Estymacja parametrów populacji

Estymacja parametrów populacji

Estymacja polega na szacowaniu wartości parametrów rozkładu lub postaci samego rozkładu zmiennej losowej, na podstawie próby statystycznej.

Estymacje można podzielić na:

- *estymację punktową* - wyznaczanie na podstawie próby statystycznej konkretnych wartości parametrów dla całej zbiorowości generalnej (mogą to być takie parametry jak wartość oczekiwana, mediana, czy odchylenie standardowe),
- *estymację przedziałową* polegającą na konstruowaniu przedziału liczbowego, który z ustalonym z góry, wysokim prawdopodobieństwem pokrywa nieznaną wartość szacowanego parametru. Przedział taki nazywa się przedziałem ufności, a prawdopodobieństwo, z jakim pokrywa on szacowany parametr - współczynnikiem ufności.

Przedział ufności

Granice przedziału ufności są **losowe**, a więc dla konkretnych prób będziemy uzyskiwać różne wartości. Uzyskany konkretny przedział będziemy interpretować następująco: **w $1-\alpha$ procentach przypadków przedział (a, b) pokrywa nieznaną wartość parametru.**

Oznacza to jednocześnie, że średnio w α procentach przypadków wyznaczony przedział **nie pokrywa** szacowanego parametru.

Przedział ufności (c.d.)

Dokładność estymacji parametru określa rozpiętość przedziału ufności będąca różnicą między jego górną i dolną granicą: $d = b - a$.

Rozpiętość przedziału ufności zależy między innymi od przyjętego poziomu ufności $1-\alpha$: im to prawdopodobieństwo jest bliższe jedności, tym rozpiętość przedziału jest większa (a precyzja oceny mniejsza).

W zastosowaniach praktycznych najczęściej stosujemy poziomy ufności rzędu 0.90, 0.95 czy 0.99 (α odpowiednio 0.10, 0.05 czy 0.01)

Przedział ufności dla wartości oczekiwanej – znane odchylenie standardowe

Jeśli znamy odchylenie standardowe zbiorowości, to wartość szacowanej średniej, z prawdopodobieństwem równym $1-\alpha$, znajduje się w przedziale danym wzorem:

$$P\left(\bar{x} - u_{\alpha} \frac{\sigma}{\sqrt{n}} \leq m \leq \bar{x} + u_{\alpha} \frac{\sigma}{\sqrt{n}}\right) = 1 - \alpha$$

gdzie:

- \bar{x} - średnia arytmetyczna,
- u_{α} - wartość odczytana z tablicy rozkładu t -Studenta dla liczby stopni swobody $r=\infty$,
- σ - odchylenie standardowe,
- n - liczebność próby,
- m - wartość oczekiwana.

Przykład

Zakładając, że ceny jednostkowe lokali mieszkalnych z danego przykładu w miejscowości A w pierwszym kwartale 2019 r. mają rozkład zbliżony do rozkładu normalnego $N(6460,241)$ oraz, że znane jest odchylenie standardowe zbiorowości $\sigma = 241$ oraz liczebność próby $n = 30$ oszacować przedział ufności dla nieznannej wartości średniej zbiorowości. Przyjmijmy współczynnik ufności $1 - \alpha = 0,95$

Rozwiązanie

Podstawiając powyższe dane do danego wzoru oraz odczytując z tablicy zmiennej losowej t -Studenta wartość krytyczną, dla liczby stopni swobody $r = \infty$ (albowiem odchylenie standardowe zbiorowości jest znane) i $\alpha = 0,05$ otrzymujemy:

$$P\left(6460 - 1,96 \frac{241}{\sqrt{30}} \leq m \leq 6460 + 1,96 \frac{241}{\sqrt{30}}\right) = 0,95$$

Oznacza to, że przedział liczbowy $P(6373,8 \leq m \leq 6546,2) = 0,95$ z prawdopodobieństwem $1 - \alpha = 0,95$ pokrywa nieznaną wartość m .

Przedział ufności dla wartości oczekiwanej – odchylenie standardowe nie jest znane

Jeżeli odchylenie standardowe zbiorowości nie jest znane, to przedział ufności dla wartości oczekiwanej m należy skonstruować w oparciu o rozkład t-Studenta:

$$P\left(\bar{x} - t_{\alpha;r} \frac{s}{\sqrt{n-1}} \leq m \leq \bar{x} + t_{\alpha;r} \frac{s}{\sqrt{n-1}}\right) = 1 - \alpha$$

gdzie:

$r = n - 1$ stopni swobody,

s - odchylenie standardowe.

Przykład

Zakładając, że ceny jednostkowe lokali mieszkalnych z danego przykładu w miejscowości A w pierwszym kwartale 2019 r. mają rozkład zbliżony do rozkładu normalnego $N(6460, \sigma)$, $s = 241$ oraz liczebność próby $n = 29$ oszacować przedział ufności dla nieznannej wartości średniej. Przyjmijmy współczynnik ufności $1 - \alpha = 0,95$

Rozwiązanie

Podstawiając powyższe dane do wzoru oraz odczytując z tablicy zmiennej losowej t -Studenta wartość, dla liczby stopni swobody $r = n - 1 = 28$ i $\alpha = 0,05$ otrzymujemy:

$$P\left(6460 - 2,048 \frac{241}{\sqrt{28}} \leq m \leq 6460 + 2,048 \frac{241}{\sqrt{28}}\right) = 0,95$$

$$P(6366,7 \leq m \leq 6553,3) = 0,95$$

Można zatem stwierdzić, że z prawdopodobieństwem 95% średnia cena jednostkowa lokali mieszkalnych w miejscowości A zawiera się w przedziale liczbowym o końcach 6366,7 zł/m² i 6553,3 zł/m².

Jeżeli liczba obserwacji n dąży do nieskończoności, to różnica między wyżej podanymi przedziałami jest bardzo mała. Dzieje się tak dlatego, że rozkład t-Studenta jest zbieżny do rozkładu normalnego. Występuje to wtedy, gdy liczba stopni swobody $(n-1)$ wzrasta nieograniczenie. Począwszy od $n=30$ różnicę między tymi przedziałami można praktycznie zaniedbać.

Przedział ufności dla wariancji σ^2 w populacji normalnej

Niech zmienna losowa $X \sim N(m, \sigma)$ oraz niech x_i ($i = 1, 2, \dots, n$) oznacza n -elementową próbę losową.

Statystyka
$$\chi^2 = \frac{ns^2}{\sigma^2}$$

ma rozkład χ^2 z liczbą stopni swobody $\nu = n - 1$.

Dla ustalonego α można określić takie dwie wartości

$\chi^2_{\frac{\alpha}{2}, n-1}$ i $\chi^2_{1-\frac{\alpha}{2}, n-1}$, dla których spełnione są równości:

$$P(\chi^2 \geq \chi^2_{\frac{\alpha}{2}, n-1}) = \frac{\alpha}{2} \quad P(\chi^2 \geq \chi^2_{1-\frac{\alpha}{2}, n-1}) = 1 - \frac{\alpha}{2}$$

Przedział ufności dla wariancji σ^2 w populacji normalnej (c.d.)

Z obu wzorów wynika, że

$$P(\chi_{1-\frac{\alpha}{2}, n-1}^2 < \chi^2 < \chi_{\frac{\alpha}{2}, n-1}^2) = 1 - \alpha$$

Po odpowiednich przekształceniach otrzymujemy przedział ufności dla wariancji:

$$P\left(\frac{ns^2}{\chi_{\frac{\alpha}{2}, n-1}^2} < \sigma^2 < \frac{ns^2}{\chi_{1-\frac{\alpha}{2}, n-1}^2}\right) = 1 - \alpha$$

Przedział ufności dla odchylenia standardowego σ w populacji normalnej.

Pierwiastkując krańce przedziału ufności dla wariancji otrzymujemy poszukiwany przedział dla odchylenia standardowego:

$$P\left(\sqrt{\frac{ns^2}{\chi_{\frac{\alpha}{2}, n-1}^2}} < \sigma < \sqrt{\frac{ns^2}{\chi_{1-\frac{\alpha}{2}, n-1}^2}}\right) = 1 - \alpha$$

Przedział ufności dla odchylenia standardowego w populacji normalnej – dla dużej próby

$$P\left(S - u_{\alpha} \frac{s}{\sqrt{2n}} < \sigma < S + u_{\alpha} \frac{s}{\sqrt{2n}}\right) = 1 - \alpha$$

Gdzie:

u_{α} - wartość odczytana z tablicy rozkładu t-Studenta dla liczby stopni swobody $r = \infty$,

Przedział ufności dla prawdopodobieństwa w populacji normalnej

$$P\left(\frac{m}{n} - u_{\alpha} \sqrt{\frac{\frac{m}{n}\left(1-\frac{m}{n}\right)}{n}} < p < \frac{m}{n} + u_{\alpha} \sqrt{\frac{\frac{m}{n}\left(1-\frac{m}{n}\right)}{n}}\right) = 1-\alpha$$

Gdzie:

m - liczba jednostek w próbie mających wyróżnioną cechę,

n - liczebność próby,

$W = \frac{m}{n}$ - wskaźnik struktury w próbie, który jest estymatorem

prawdopodobieństwa p w populacji generalnej

u_{α} - wartość odczytana z tablicy rozkładu t-Studenta dla liczby stopni swobody $r = \infty$,

Uzasadnienie wielkości próby

$$n = \frac{u_{\alpha}^2 \sigma^2}{d^2} \quad (\text{wariancja jest znana})$$

$$n = \frac{t_{\alpha}^2 \hat{S}^2}{d^2} \quad (\text{wariancja jest nieznana})$$

gdzie:

$$\hat{S}^2 = \frac{1}{n_0 - 1} \sum_{i=1}^{n_0} (x_i - \bar{x})^2$$

$$n = \frac{u_{\alpha}^2 pq}{d^2}$$

Zbiorowość generalna ma rozkład dwupunktowy z parametrem p (p jest frakcją jedynek lub elementów wyróżnionych w zbiorowości.)

Jeżeli nie znamy rzędu wielkości szacowanego wskaźnika struktury p , to przyjmując za iloczyn pq jego największą wartość $\frac{1}{4}$, otrzymujemy poniższy wzór:

$$n = \frac{u_{\alpha}^2}{4d^2}$$

gdzie:

d - dopuszczalny, ustalony z góry maksymalny błąd szacunku wartości m .