

Poprzedni wykład

- Wzór na przenoszenie błędów $(X_1, X_2, \dots) \rightarrow (Y_1, Y_2, \dots)$

$$\text{cov}(Y_k, Y_q) = \sum_{l,m} \left(\frac{\partial Y_k}{\partial X_l} \right) \bigg|_{\vec{x}=\vec{E}(\vec{x})} \left(\frac{\partial Y_q}{\partial X_m} \right) \bigg|_{\vec{x}=\vec{E}(\vec{x})} \text{cov}(X_l, X_m)$$

$$C(Y) = TC(X)T^T$$

- Transformacja łącznej funkcji gęstości

$$f_{v,w}(v, w) = f_{x,y}(x(v, w), y(v, w)) \left| J_{(x,y)} \right|^{-1}$$

Przykład: transformacja Box-Mullera dająca $N(0,1)$

1

Dystrybuanta warunkowa

- Syt. Szukamy **dystrybuanty warunkowej zmiennej X** czyli dystrybuanty zmiennej X pod warunkiem, że zmienna losowa $Y=y$. Ale dla zmiennej ciągłej $P(Y=y)=0$ dlatego rozpatrujemy $y < Y < y+dy$ i przejdziemy do granicy $dy \rightarrow 0$.

$$\int_{-\infty}^x \int_y^{y+dy} f_{x,y}(u, v) du dv = F_{X|Y}(x | Y \in (y, y+dy)) \cdot \int_y^{y+dy} f_Y(v) dv$$

$$\int_{-\infty}^x f_{x,y}(u, y) du dy = F_{X|Y}(x | Y \in (y, y+dy)) \cdot f_Y(y) dy \quad / : dy \quad / dy \rightarrow 0$$

$$\int_{-\infty}^x f_{x,y}(u, y) du = F_{X|Y}(x | Y = y) \cdot f_Y(y)$$

$$F_{X|Y}(x | y) = \frac{\int_{-\infty}^x f_{x,y}(u, y) du}{f_Y(y)}$$

RPIS 2024/2025 2

2

Warunkowa funkcja gęstości prawdopodobieństwa

$$f_{X|Y}(x | y) = \frac{d}{dx} F_{X|Y}(x | y) = \frac{f_{X,Y}(x, y)}{f_Y(y)}$$

- Definicja ta prowadzi do równoważnej definicji niezależności dwóch zmiennych losowych poprzez warunek:

$$f_{X|Y}(x | y) = \frac{f_{X,Y}(x, y)}{f_Y(y)}$$

$$f_{X|Y}(x | y) \cdot f_Y(y) = f_{X,Y}(x, y)$$

$$f_{X|Y}(x | y) \cdot f_Y(y) = f_X(x) \cdot f_Y(y)$$

$$f_{X|Y}(x | y) = f_X(x) \quad / \int_{-\infty}^v dx$$

$$F_{X|Y}(v | y) = F_X(v)$$

RPIS 2024/2025 3

3

Warunkowa wartość oczekiwana

$$E(X | Y = y) = \int_{-\infty}^{+\infty} x f_{X|Y}(x | y) dx$$

- Jest to funkcja zmiennej losowej Y, zatem $E(X|Y)$ też jest zmienną losową

$$E[E(X | Y)] = \int_{-\infty}^{+\infty} E(X | Y = y) f_Y(y) dy =$$

$$= \int_{-\infty}^{+\infty} \left[\int_{-\infty}^{+\infty} x f_{X|Y}(x | y) dx \right] f_Y(y) dy = \int_{-\infty}^{+\infty} \left[\int_{-\infty}^{+\infty} x \frac{f_{X,Y}(x, y)}{f_Y(y)} dx \right] f_Y(y) dy =$$

$$= \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} x f_{X,Y}(x, y) dx dy = \int_{-\infty}^{+\infty} x f_X(x) dx = E(X)$$

$$\text{ogólnie dla dowolnej funkcji } h(x) \quad E(h(X)) = E[E(h(X) | Y)]$$

RPIS 2024/2025 4

4

Statystyka – podstawowe pojęcia

- Populacja generalna** – zbiór wszystkich możliwych wyników (skończony lub nieskończony).
- Próba** – skończony zbiór doświadczeń.
- Estymacja** – zajmuje się wnioskowaniem o własnościach populacji na podstawie próby.
Najczęściej interesują nas wartość oczekiwana i odchylenie standardowe (lub wariancja).
- Próba prosta to ciąg niezależnych doświadczeń odnoszących się do tej samej populacji generalnej. Wynikiem n-elementowej próby jest n-wymiarowa zmienna losowa.
- Statystyka** – funkcja zmiennych losowych obserwowanych w próbie, sama też jest zmienną losową.

RPIS 2024/2025 6

5

6

Estymatory - podstawowe definicje

- Syt. X_1, \dots, X_n – wyniki pomiarów w próbie, mają one pewien rozkład prawdopodobieństwa (funkcję gęstości prawdopodobieństwa). Zakładamy, że ten rozkład jest taki sam dla każdego X_i , czyli wylosowanie pojedynczego X_i nie zmienia rozkładu (np. przedziałów rozkładu jednorodnego) i próba jest odpowiednio liczna. Rozkład ten zależy od jakiegoś parametru Θ (lub kilku parametrów).
- Estymatorem** parametru Θ nazywamy statystykę o rozkładzie prawdopodobieństwa zależnym od Θ i oznaczamy $T_n(\Theta)$ lub $T_n(x_1, x_2, \dots, x_n; \Theta)$.
Zatem dla danego parametru może istnieć wiele estymatorów o różnych własnościach. Pożądanymi własnościami są:

- 1. Zgodność** – estymator $T_n(\Theta)$ jest zgodny gdy

$$\forall \varepsilon > 0: \lim_{n \rightarrow \infty} P(|T_n(\Theta) - \Theta| < \varepsilon) = 1$$

↑
wartość estymatora (statystyki)

RPIS 2024/2025 7

7

Estymatory - podstawowe definicje

- 2. Obciążenie (jego brak)** – estymator $T_n(\Theta)$ jest zmienna losowa (różne próby dają różne wartości estymatora), zatem ma wartość oczekiwaną i wariancję. Obciążenie estymatora to

$$B_n \equiv E(T_n(\Theta)) - \Theta$$

- Estymator jest nieobciążony**, gdy niezależnie od wielkości próby

$$E(T_n(\Theta)) = \Theta \quad \text{czyli} \quad B_n = 0$$

- Estymator jest obciążony gdy $B_n \neq 0$.
- Estymator jest asymptotycznie nieobciążony** gdy

$$\lim_{n \rightarrow \infty} B_n = 0$$

- 3. Efektywność** – estymator jest **najbardziej efektywny** gdy ma najmniejszą wariancję.

- Optymalnie estymator powinien być: zgodny, nieobciążony i najbardziej efektywny.

RPIS 2024/2025 8

8

Estymatory – własności ogólne

- Estymacja punktowa** – oszacowanie wartości parametru Θ przez podanie wartości estymatora $T_n(\Theta)$ tego parametru.
- Estymacja przedziałowa** – podanie przedziału liczbowego, wewnątrz którego, z założonym prawdopodobieństwem, leży prawdziwa wartość parametru Θ .

Estymacja punktowa:

- Estymatorem wartości oczekiwanej jest średnia z próby:

$$T_n(E(X)) \equiv \bar{X} = \frac{1}{n} \sum_{i=1}^n x_i$$

RPIS 2024/2025 9

9

Estymatory odchylenia standardowego

- Estymator zgodny, asymptotycznie nieobciążony

$$T_n(\sigma(X)) \equiv S(X) = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{X})^2}$$

Uwaga $S^2(X)$ jest estymatorem nieobciążonym wariancji

- Estymator zgodny, asymptotycznie nieobciążony

$$T_n(\sigma(X)) \equiv \hat{S}(X) = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{X})^2}$$

- Estymator zgodny, nieobciążony, najbardziej efektywny

$$T_n(\sigma(X)) \equiv \tilde{S}(X) = \sqrt{\frac{n-1}{2} \frac{\Gamma(0.5(n-1))}{\Gamma(0.5n)}} S^2(X)$$

RPIS 2024/2025 10

10

Estymatory współczynnika korelacji

$$T_n(\rho_{X,Y}) = \frac{\sum_{i=1}^n (x_i - \bar{X}) \cdot (y_i - \bar{Y})}{\sqrt{\left(\sum_{i=1}^n (x_i - \bar{X})^2 \right) \left(\sum_{i=1}^n (y_i - \bar{Y})^2 \right)}}$$

Ten estymator jest zgodny i obciążony.

RPIS 2024/2025 11

11

Estymacja przedziałowa

- Estymacja przedziałowa** – podanie przedziału liczbowego, $[T_n^L(\theta), T_n^P(\theta)]$

wewnątrz którego, z założonym prawdopodobieństwem $\gamma = 1 - \alpha$, leży prawdziwa wartość parametru Θ .

- Przedział ten nazywamy **przedziałem ufności** dla parametru Θ na poziomie ufności $1 - \alpha = \gamma$.

- Własności przedziału ufności:

$$1) \quad P(T_n^L(\theta) \leq \theta \leq T_n^P(\theta)) = 1 - \alpha \equiv \gamma$$

2) Końce przedziału zależą od próby i od γ , a nie zależą funkcyjnie od Θ .

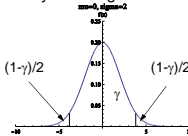
3) Zwykle używa się $1 - \alpha \approx 0.9$ (zwiększając $1 - \alpha$ tracimy na dokładności, bo zwiększa się długość przedziału ufności).

RPIS 2024/2025 12

12

Estymacja przedziałowa wartości oczekiwanej

- Aby znaleźć przedział ufności szukamy statystyki o znanim rozkładzie prawdopodobieństwa zależnej od estymowanego parametru Θ i próby.
- Przypadek 1** – znany $\sigma(X)$
- Twierdzenie: Statystyka**

$$Z \equiv \frac{\bar{X} - E(X) - (\bar{X} - E(X))\sqrt{n}}{\sigma(\bar{X})} = \frac{\bar{X} - E(X)}{\sigma(X)}$$


ma rozkład normalny $N(0, 1)$. (Średnia ma rozkład $N(E(X), \sigma^2(X)/n)$, standaryzacja przekształca rozkład normalny w normalny).

Chcemy znaleźć przedział ufności taki, że

$$P(Z^L \leq Z \leq Z^P) = \gamma$$

Kwantyle rozkładu $N(0,1)$

Jest to spełnione przez $Z^L = Z_{\frac{1-\gamma}{2}}$ i $Z^P = Z_{\frac{1-\gamma}{2} + \frac{1+\gamma}{2}}$

RPIS 2024/2025 13

13

Estymacja przedziałowa wartości oczekiwanej

- Dla rozkładu $N(0,1)$ (z parzystości) $Z_{\frac{1-\gamma}{2}} = -Z_{\frac{1+\gamma}{2}}$, a stąd

$$P\left(-Z_{\frac{1+\gamma}{2}} \leq Z \leq Z_{\frac{1+\gamma}{2}}\right) = \gamma$$

$$P\left(-Z_{\frac{1+\gamma}{2}} \leq \frac{(\bar{X} - E(X))\sqrt{n}}{\sigma(X)} \leq Z_{\frac{1+\gamma}{2}}\right) = \gamma$$

$$P\left(-\frac{1}{\sqrt{n}}\sigma(X)Z_{\frac{1+\gamma}{2}} \leq \bar{X} - E(X) \leq \frac{1}{\sqrt{n}}\sigma(X)Z_{\frac{1+\gamma}{2}}\right) = \gamma$$

$$P\left(-\bar{X} - \frac{1}{\sqrt{n}}\sigma(X)Z_{\frac{1+\gamma}{2}} \leq E(X) \leq -\bar{X} + \frac{1}{\sqrt{n}}\sigma(X)Z_{\frac{1+\gamma}{2}}\right) = \gamma$$

$$P\left(\bar{X} - \frac{1}{\sqrt{n}}\sigma(X)Z_{\frac{1+\gamma}{2}} \leq E(X) \leq \bar{X} + \frac{1}{\sqrt{n}}\sigma(X)Z_{\frac{1+\gamma}{2}}\right) = \gamma$$

- Stąd

$T_n^L(E(X)) = \bar{X} - \frac{1}{\sqrt{n}}\sigma(X)Z_{\frac{1+\gamma}{2}}$	$T_n^P(E(X)) = \bar{X} + \frac{1}{\sqrt{n}}\sigma(X)Z_{\frac{1+\gamma}{2}}$
-----------------------------------------------------------------------------	-----------------------------------------------------------------------------

RPIS 2024/2025 14

14

Estymacja przedziałowa wartości oczekiwanej

- Przypadek 2** – nie znany $\sigma(X)$
- Twierdzenie: Statystyka**

$$t \equiv \frac{\bar{X} - E(X) - (\bar{X} - E(X))\sqrt{n}}{s(\bar{X})} = \frac{\bar{X} - E(X)}{s(X)}$$

$$s(\bar{X}) = \sqrt{\frac{1}{n}}s(X) = \sqrt{\frac{1}{n(n-1)} \sum_{i=1}^n (x_i - \bar{X})^2}$$

ma rozkład t-Studenta o $n-1$ stopniach swobody. Tak jak w poprzednim przypadku jest to rozkład symetryczny względem $x=0$ i analogicznie:

$$P\left(\bar{X} - \frac{1}{\sqrt{n}}s(X)t_{\frac{1+\gamma}{2}} \leq E(X) \leq \bar{X} + \frac{1}{\sqrt{n}}s(X)t_{\frac{1+\gamma}{2}}\right) = \gamma$$

$t_{\frac{1-\gamma}{2}}$ i $t_{\frac{1+\gamma}{2}}$ to kwantyle rozkładu t-Studenta o $n-1$ stopniach swobody

RPIS 2024/2025 15

15