

Poprzednim razem

- Statystyka (w dwóch znaczeniach)
- Estymatory punktowe

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

$$T_n(\sigma(X)) \equiv S(X) = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{X})^2}$$
- Estymatory przedziałowe
- Przedział ufności, poziom ufności
- Dla E(X) przy znanym $\sigma(X)$

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

Estymacja przedziałowa wartości oczekiwanej

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

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

$$S(\bar{X}) = \sqrt{\frac{1}{n}S(X)} = \sqrt{\frac{1}{n(n-1)} \sum_{i=1}^n (x_i - \bar{X})^2}$$
- 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 $t_{\frac{\gamma}{2}}$ to kwantyle rozkładu t-Studenta o n-1 stopniach swobody

RPIS 2023/2024 2

Estymacja przedziałowa wariancji

- Twierdzenie: Statystyka**

$$Y \equiv \frac{(n-1)S^2(X)}{\sigma^2(X)} \quad S(X) = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{X})^2}$$
- ma rozkład χ^2 (Chi-kwadrat) o n-1 stopniach swobody. Ten rozkład nie jest symetryczny względem x=0.

RPIS 2023/2024 3

Estymacja przedziałowa wariancji

- $$P\left(\chi_{\frac{1-\gamma}{2}}^{2, n-1} \leq Y \leq \chi_{\frac{\gamma}{2}}^{2, n-1}\right) = \gamma$$
- $$P\left(\chi_{\frac{1-\gamma}{2}}^{2, n-1} \leq \frac{(n-1)S^2(X)}{\sigma^2(X)} \leq \chi_{\frac{\gamma}{2}}^{2, n-1}\right) = \gamma$$
- $$P\left(\frac{(n-1)S^2(X)}{\chi_{\frac{1-\gamma}{2}}^{2, n-1}} \leq \sigma^2(X) \leq \frac{(n-1)S^2(X)}{\chi_{\frac{\gamma}{2}}^{2, n-1}}\right) = \gamma$$
- $$P\left(\sqrt{\frac{(n-1)S^2(X)}{\chi_{\frac{1-\gamma}{2}}^{2, n-1}}} \leq \sigma(X) \leq \sqrt{\frac{(n-1)S^2(X)}{\chi_{\frac{\gamma}{2}}^{2, n-1}}}\right) = \gamma$$
- $$T_n^L(\text{var}(X)) = \frac{(n-1)S^2(X)}{\chi_{\frac{1-\gamma}{2}}^{2, n-1}} \quad T_n^R(\text{var}(X)) = \frac{(n-1)S^2(X)}{\chi_{\frac{\gamma}{2}}^{2, n-1}}$$
- to kwantyle rozkładu Chi-kwadrat o n-1 stopniach swobody

RPIS 2023/2024 4

Znajdowanie estymatorów

– metoda największej wiarygodności

- Idea: To co zaobserwaliśmy było najbardziej prawdopodobne spośród wszystkich możliwych prób.
- Prawdopodobieństwo wylosowania próby x_1, x_2, \dots, x_n

$$P(x_1, x_2, \dots, x_n) = \prod_{i=1}^n f(x_i; \theta_1, \theta_2, \dots, \theta_p) dx_i$$
- Funkcja (największej) wiarygodności**

$$\tilde{L}(\theta_1, \theta_2, \dots, \theta_p) = \prod_{i=1}^n f(x_i; \theta_1, \theta_2, \dots, \theta_p)$$
- Metoda największej wiarygodności** polega na szukaniu wartości parametrów $\theta_1, \theta_2, \dots, \theta_p$, dla których funkcja największej wiarygodności osiąga maksimum. Tak otrzymane wartości przyjmujemy za estymatory parametrów $\theta_1, \theta_2, \dots, \theta_p$.

RPIS 2023/2024 5

Metoda największej wiarygodności

- Uwaga: często wygodniej szukać maksimum funkcji

$$L(\theta_1, \theta_2, \dots, \theta_p) = \ln(\tilde{L}(\theta_1, \theta_2, \dots, \theta_p))$$
- $L(\theta_1, \theta_2, \dots, \theta_p)$ nazywamy **(logarytmiczną) funkcją (największej) wiarygodności**.
- Estymatory otrzymane metodą największej wiarygodności są zgodne, asymptotycznie nieobciążone i asymptotycznie najbardziej efektywne.
- Przykład: Estymatory parametrów rozkładu normalnego.

RPIS 2023/2024 6

Metoda największej wiarygodności - przykład: estymatory parametrów rozkładu normalnego

- Szukamy estymatorów parametrów θ_1 i θ_2 rozkładu $f_X(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$
- Mając do dyspozycji próbę (x_1, x_2, \dots, x_n) budujemy logarytmiczną funkcję największej wiarygodności L

$$L = \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x_i-\mu)^2}{2\sigma^2}} = \frac{1}{(2\pi)^{\frac{n}{2}} \sigma^n} e^{-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i-\mu)^2}$$

$$L = \ln(L, \dots, \dots, \tau) = \ln\left(\frac{1}{(2\pi)^{\frac{n}{2}} \sigma^n} e^{-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i-\mu)^2}\right) = -\frac{n}{2} \ln(2\pi) - n \ln(\sigma) - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \theta_1)^2$$
- I szukamy jej maksimum $\frac{\partial L}{\partial \theta_1} = 0$ $\frac{\partial L}{\partial \theta_2} = 0$

$$\frac{\partial L}{\partial \theta_1} = -\frac{1}{2\sigma^2} \sum_{i=1}^n 2(x_i - \theta_1)(-1) = \frac{1}{\sigma^2} \sum_{i=1}^n (x_i - \theta_1)$$

$$\frac{\partial L}{\partial \theta_2} = -n \frac{1}{\sigma^3} \cdot (-1) \cdot 2\theta_2 \sum_{i=1}^n (x_i - \theta_1)^2 = \frac{n}{\sigma^3} + \frac{1}{\sigma^2} \sum_{i=1}^n (x_i - \theta_1)^2$$

(proszę sprawdzić drugie pochodne)

RPIS 2023/2024 7

Metoda największej wiarygodności - przykład: estymatory parametrów rozkładu normalnego

- Porównujemy pochodne do zera; wiemy, że $\theta_2 \neq 0$

$$\frac{\partial L}{\partial \theta_1} = 0 \rightarrow \sum_{i=1}^n (x_i - \theta_1) = 0 \rightarrow (\sum_{i=1}^n x_i) - n\theta_1 = 0 \rightarrow \theta_1 = \frac{1}{n} \sum_{i=1}^n x_i$$

$$\frac{\partial L}{\partial \theta_2} = 0 \rightarrow$$

$$-\frac{n}{\sigma^3} + \frac{n}{\sigma^2} \sum_{i=1}^n (x_i - \theta_1)^2 = 0 \quad / \cdot \theta_2 \rightarrow \frac{1}{\theta_2} \sum_{i=1}^n (x_i - \theta_1)^2 = n \rightarrow \frac{1}{n} \sum_{i=1}^n (x_i - \theta_1)^2 = \theta_2^2$$
- Ostatecznie przyjmujemy

$$T_1(\theta_1) = \frac{1}{n} \sum_{i=1}^n x_i \equiv \bar{x}$$

$$T_2(\theta_2^2) = \frac{1}{n} \sum_{i=1}^n (x_i - \theta_1)^2 = \frac{1}{n} \sum_{i=1}^n (x_i - T_1(\theta_1))^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$$

$$T_2(\theta_2) = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}$$
- Są to te same estymatory jakie wynikają z metody momentów; estymator wariancji jest obciążony.

RPIS 2023/2024 8

Znajdowanie estymatorów – metoda najmniejszych kwadratów

- Idea: Szukamy estymatora parametrów $\theta_1, \theta_2, \dots, \theta_p$ występujących w równaniu $g(y_1, y_2, \dots, y_n; \theta_1, \theta_2, \dots, \theta_p) = 0$, gdzie (y_1, y_2, \dots, y_n) to wynik n-elementowej próby.
- **Metoda najmniejszych kwadratów** polega na szukaniu wartości parametrów $\theta_1, \theta_2, \dots, \theta_p$, dla których funkcja
$$\sum_{i=1}^n w_i (g(y_i; \theta_1, \theta_2, \dots, \theta_p))^2$$
 osiąga minimum. Współczynniki liczbowe w_i określają wagę jaką przykładamy do kolejnych wartości y_i , mogą być to na przykład odwrotności kwadratów błędów pomiaru y_i . Tak otrzymane wartości przyjmujemy za estymatory parametrów $\theta_1, \theta_2, \dots, \theta_p$.

RPIS 2023/2024 9

Metoda najmniejszych kwadratów

- Np. zmierzono n razy zmienną Y uzyskując wartości y_1, y_2, \dots, y_n . Ile wynosi prawdziwa wartość zmiennej Y (oznaczamy ją przez θ)? Rozpatrzmy $g(Y, \theta) = y_i - \theta$
- Gdyby pomiar był dokładny to $g(Y, \theta) = 0$.

RPIS 2023/2024 10

Metoda najmniejszych kwadratów

- Np. zmierzono n razy zmienną Y uzyskując wartości y_1, y_2, \dots, y_n . Ile wynosi prawdziwa wartość zmiennej Y (oznaczamy ją przez θ)? Rozpatrzmy $g(Y, \theta) = y_i - \theta$
- Gdyby pomiar był dokładny to $g(Y, \theta) = 0$.

RPIS 2023/2024 11

Metoda najmniejszych kwadratów


- Np. zmierzono n razy zmienną Y uzyskując wartości y_1, y_2, \dots, y_n . Ile wynosi prawdziwa wartość zmiennej Y (oznaczamy ją przez θ)? Rozpatrzmy $g(Y, \theta) = y_i - \theta$
- Gdyby pomiar był dokładny to $g(Y, \theta) = 0$.

RPIS 2023/2024 12

Metoda najmniejszych kwadratów

- Np. zmierzono n razy zmienną Y uzyskując wartości y_1, y_2, \dots, y_n . Ile wynosi prawdziwa wartość zmiennej Y (oznaczamy ją przez θ)? Rozpatrzmy $g(Y, \theta) = y_i - \theta$

Gdyby pomiar był dokładny to $g(Y, \theta) = 0$.




RPiS 2023/2024 13

Metoda najmniejszych kwadratów

- Np. zmierzono n razy zmienną Y uzyskując wartości y_1, y_2, \dots, y_n . Ile wynosi prawdziwa wartość zmiennej Y (oznaczamy ją przez θ)? Rozpatrzmy $g(Y, \theta) = y_i - \theta$

Gdyby pomiar był dokładny to $g(Y, \theta) = 0$.




RPiS 2023/2024 14

Metoda najmniejszych kwadratów

- Np. zmierzono n razy zmienną Y uzyskując wartości y_1, y_2, \dots, y_n . Ile wynosi prawdziwa wartość zmiennej Y (oznaczamy ją przez θ)? Rozpatrzmy $g(Y, \theta) = y_i - \theta$

Gdyby pomiar był dokładny to $g(Y, \theta) = 0$.




RPiS 2023/2024 15

Metoda najmniejszych kwadratów

- Np. zmierzono n razy zmienną Y uzyskując wartości y_1, y_2, \dots, y_n . Ile wynosi prawdziwa wartość zmiennej Y (oznaczamy ją przez θ)? Rozpatrzmy $g(Y, \theta) = y_i - \theta$

Gdyby pomiar był dokładny to $g(Y, \theta) = 0$.



RPiS 2023/2024 16

Metoda najmniejszych kwadratów

- Np. zmierzono n razy zmienną Y uzyskując wartości y_1, y_2, \dots, y_n . Ile wynosi prawdziwa wartość zmiennej Y (oznaczamy ją przez θ)? Rozpatrzmy $g(Y, \theta) = y_i - \theta$

Gdyby pomiar był dokładny to $g(Y, \theta) = 0$.

W praktyce minimalizujemy

$$\sum_{i=1}^n (y_i - \theta)^2 \rightarrow \frac{d}{d\theta} \left(\sum_{i=1}^n (y_i - \theta)^2 \right) = -2 \sum_{i=1}^n (y_i - \theta)$$

$$-2 \sum_{i=1}^n (y_i - \theta) = 0 \quad /: (-2)$$

$$\sum_{i=1}^n y_i - \sum_{i=1}^n \theta = 0$$

$$\sum_{i=1}^n y_i = n\theta \rightarrow T_n(\theta) = \frac{1}{n} \sum_{i=1}^n y_i$$

RPiS 2023/2024 17

Metoda najmniejszych kwadratów

- W ogólnym przypadku estymatory pochodzące z metody najmniejszych kwadratów nie mają optymalnych własności (nawet asymptotycznie).

Wyjątki:

- Wyniki pomiaru y_i mają rozkład normalny i są nieskorelowane: wtedy metoda najmniejszych kwadratów jest równoważna metodzie największej wiarygodności.
- Szukane parametry są liniowymi współczynnikami w funkcji regresji.

RPiS 2023/2024 18

Funkcja regresji

- Funkcją regresji I rodzaju zmiennej Y względem zmiennej X nazywamy warunkową wartość oczekiwaną $E(Y|X)$ traktowaną jako funkcję zmiennej X.

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

$$f_{Y|X}(y|x) = f_{X,Y}(x,y) / f_X(x)$$
- Tw: Wartość oczekiwana kwadratu odchyłek zmiennej losowej Y od dowolnej funkcji u(X) jest minimalna gdy $u(X)=E(Y|X)$

$$E[(Y-u(X))^2] \geq E[(Y-E(Y|X))^2]$$
- Dow:

$$E[(Y-u(X))^2] = \iint dx dy f_{X,Y}(x,y) (y-u(x))^2 =$$

$$= \iint dx dy f_X(x) f_{Y|X}(y|x) (y-u(x))^2 =$$

$$= \int dx f_X(x) \int dy f_{Y|X}(y|x) (y-u(x))^2 =$$

RPIS 2023/2024 19

Funkcja regresji

$$\int dy f_{Y|X}(y|x) (y-u(x))^2 =$$

$$= \int dy f_{Y|X}(y|x) [(y-E(Y|X)+E(Y|X)-u(x))^2] =$$

$$= \int dy f_{Y|X}(y|x) [(y-E(Y|X))^2 + 2(y-E(Y|X))(E(Y|X)-u(x)) + (E(Y|X)-u(x))^2] =$$

$$= \int dy f_{Y|X}(y|x) [(y-E(Y|X))^2 + (E(Y|X)-u(x))^2] +$$

$$+ 2(E(Y|X)-u(x)) \int dy f_{Y|X}(y|x) (y-E(Y|X)) =$$

$$= \int dy f_{Y|X}(y|x) [(y-E(Y|X))^2 + (E(Y|X)-u(x))^2] +$$

$$+ 2(E(Y|X)-u(x)) \left[\int dy f_{Y|X}(y|x) y - E(Y|X) \int dy f_{Y|X}(y|x) \right]$$

$$= \int dy f_{Y|X}(y|x) [(y-E(Y|X))^2 + (E(Y|X)-u(x))^2] +$$

$$+ 2(E(Y|X)-u(x)) [E(Y|X) - E(Y|X) \cdot 1] =$$

$$= \int dy f_{Y|X}(y|x) [(y-E(Y|X))^2 + (E(Y|X)-u(x))^2]$$

RPIS 2023/2024 20

Funkcja regresji

- Zatem

$$E[(Y-u(X))^2] = \int dx f_X(x) \int dy f_{Y|X}(y|x) (y-u(x))^2 =$$

$$= \int dx f_X(x) \int dy f_{Y|X}(y|x) [(y-E(Y|X))^2 + (E(Y|X)-u(x))^2] =$$

$$= \iint dx dy f_X(x) f_{Y|X}(y|x) [(y-E(Y|X))^2] +$$

$$+ \iint dx dy f_X(x) f_{Y|X}(y|x) [(E(Y|X)-u(x))^2] \geq$$

$$\geq \iint dx dy f_X(x) f_{Y|X}(y|x) [(y-E(Y|X))^2] =$$

$$= \iint dx dy f_{X,Y}(x,y) [(y-E(Y|X))^2] = E[(Y-E(Y|X))^2]$$
- Pozwala to szukać funkcji u(x), zależnej od pewnych parametrów, aproksymującej funkcję regresji I rodzaju $E(Y|X)$ przez minimalizowanie kwadratów odchyłek u(x) od y: $\sum_{i=1}^n (y_i - u(x_i))^2$

RPIS 2023/2024 21

Liniowa funkcja regresji II rodzaju

- Liniowa funkcja regresji II rodzaju przybliża liniowo $E(Y|X)$

$$E(Y|X) \approx u(x) = ax + b$$
- Regresja krzywoliniowa to nieliniowa funkcja u(x) przybliżająca $E(Y|X)$, której parametry znajdujemy korzystając z metody najmniejszych kwadratów.
- Przypadek I: Parametry $\theta_1, \theta_2, \dots, \theta_p$ wchodzą do u(x) liniowo, np. jako współczynniki wielomianów, wtedy dostajemy układ równań liniowych. Esymatory $\theta_1, \theta_2, \dots, \theta_p$ pochodzące z metody najmniejszych kwadratów są nieobciążone, najbardziej efektywne i są liniowymi funkcjami y. Te własności nie zależą od rozkładu zmiennej Y i są spełnione nawet dla niewielkich prób.
- Przypadek II: Parametry u(x) wchodzą do niej nieliniowo, np. jako współczynniki wielomianów, wtedy dostajemy układ równań nieliniowych.

RPIS 2023/2024 22

Regresja krzywoliniowa - przykład

- Syt. W wyniku pomiaru otrzymaliśmy n par punktów (X_i, Y_i) $i=1, \dots, n$. Zakładamy, że pomiary są niezależne, a ich dokładność może być różna (tzn. odchylenia standardowe Y_i mogą być różne). Funkcję regresji przybliżamy funkcją $y = \sum_{j=1}^m \theta_j f_j(x)$, gdzie $f_j(x)$ to dowolne funkcje np. wielomiany
- Zatem chcemy minimalizować

$$Q^2 = \sum_{i=1}^n \frac{1}{\sigma_i^2} (y_i - \sum_{j=1}^m \theta_j f_j(x_i))^2$$

$$\frac{\partial Q^2}{\partial \theta_k} = \sum_{i=1}^n \frac{2}{\sigma_i^2} (y_i - \sum_{j=1}^m \theta_j f_j(x_i)) (-f_k(x_i))$$

$$\sum_{i=1}^n \frac{2}{\sigma_i^2} (y_i - \sum_{j=1}^m \theta_j f_j(x_i)) (-f_k(x_i)) = 0$$

Układ m równań do rozwiązania (k=1,...,m)

RPIS 2023/2024 23

Regresja krzywoliniowa - przykład

- Zapis macierzowy

$$B_{ij} = \delta_{ij} \frac{1}{(\sigma_i)^2} = \begin{pmatrix} (\sigma_1)^{-2} & 0 & \dots & 0 \\ 0 & (\sigma_2)^{-2} & & \vdots \\ \vdots & & \ddots & \vdots \\ 0 & \dots & \dots & (\sigma_n)^{-2} \end{pmatrix}$$

$$A_j = \begin{pmatrix} f_1(x_1) & f_2(x_1) & \dots & f_m(x_1) \\ f_1(x_2) & f_2(x_2) & & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ f_1(x_n) & \dots & \dots & f_m(x_n) \end{pmatrix}$$

$$\vec{y} = \begin{pmatrix} Y_1 \\ \vdots \\ Y_n \end{pmatrix} \quad \vec{\theta} = \begin{pmatrix} \theta_1 \\ \vdots \\ \theta_m \end{pmatrix}$$

$$Q^2 = (\vec{y} - A\vec{\theta})^T B (\vec{y} - A\vec{\theta})$$

$$\frac{\partial Q^2}{\partial \theta_k} = [-2A^T B (\vec{y} - A\vec{\theta})]_k$$

$$\frac{\partial Q^2}{\partial \theta_k} = 0 \rightarrow A^T B (\vec{y} - A\vec{\theta}) = 0$$

$$A^T B \vec{y} = A^T B A \vec{\theta} \quad / (A^T B A)^{-1}$$

$$\vec{\theta} = (A^T B A)^{-1} A^T B \vec{y}$$

RPIS 2023/2024 24

Regresja krzywoliniowa – przykład liniowy

$$\vec{\theta} = (A^T B A)^{-1} A^T B \vec{Y}$$

- Wniosek: liniowy związek Y i θ .
- Współczynniki θ łatwe do wyliczenia (odwracanie macierzy)
- Przykład: regresja liniowa ($m=2$, $f_1(x)=x$, $f_2(x)=1$), dodatkowo zakładamy $\sigma_1=\sigma_2=\dots=\sigma_n=\sigma_y$.

$$Y = \theta_1 f_1(X) + \theta_2 f_2(X) = \theta_1 X + \theta_2$$

$$\rightarrow \begin{pmatrix} \theta_1 \\ \theta_2 \end{pmatrix} = \frac{1}{n \sum_{i=1}^n x_i^2 - \left(\sum_{i=1}^n x_i \right)^2} \begin{pmatrix} n \sum_{i=1}^n x_i y_i - \sum_{i=1}^n x_i \sum_{i=1}^n y_i \\ \sum_{i=1}^n x_i^2 \sum_{i=1}^n y_i - \sum_{i=1}^n x_i \sum_{i=1}^n x_i y_i \end{pmatrix}$$

- Jest to **regresja zwyczajna**.
- Istnieją też inne odmiany regresji: **klasyczna** (nic nie wiemy o σ_1), **ważona** (różne σ_1), **efektywna** (uwzględnić także niepewność x_i).