

Kartkówka nr 4 z wykładu
– dzisiaj pojawią się zagadnienia

Poprzednim razem

- Metoda największej wiarygodności
- Metoda najmniejszych kwadratów
- Funkcja regresji $E(Y|X)$

1

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 2024/2025 2

2

Regresja krzywoliniowa - przykład

- Zapis macierzowy

$$B_{ij} = \delta_{i,j} \frac{1}{(\sigma_i)^2} = \begin{pmatrix} (\sigma_1)^{-2} & 0 & \dots & 0 \\ 0 & (\sigma_2)^{-2} & & \vdots \\ \vdots & & \ddots & \vdots \\ 0 & \dots & \dots & (\sigma_n)^{-2} \end{pmatrix} \quad A_j = \begin{pmatrix} f_1(x_1) & f_2(x_1) & \dots & f_m(x_1) \\ f_1(x_2) & f_2(x_2) & & \vdots \\ \vdots & & \ddots & \vdots \\ f_1(x_n) & \dots & \dots & f_m(x_n) \end{pmatrix}$$

$$Q^2 = (\vec{Y} - A\vec{\theta})^T B (\vec{Y} - A\vec{\theta}) \quad \vec{Y} = \begin{pmatrix} Y_1 \\ \vdots \\ Y_n \end{pmatrix} \quad \vec{\theta} = \begin{pmatrix} \theta_1 \\ \vdots \\ \theta_m \end{pmatrix}$$

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

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

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

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

RPIS 2024/2025 3

3

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, $f_1(x)=x_1$, $f_2(x)=1$), dodatkowo zakładamy $\sigma_1 = \sigma_2 = \dots = \sigma_n = \sigma_y$.

RPIS 2024/2025 4

4

Przykład: regresja liniowa zwyczajna

- regresja liniowa ($f_1(x)=x_1$, $f_2(x)=1$); zakładamy $\sigma_1 = \sigma_2 = \dots = \sigma_n = \sigma_y$.

$$f_1(x_i) = x_i \quad f_2(x_i) = 1$$

$$y_i = \theta_1 x_i + \theta_2 \quad \vec{Y} = \begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix} \quad \vec{\theta} = \begin{pmatrix} \theta_1 \\ \theta_2 \end{pmatrix}$$

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

$$A_j = \begin{pmatrix} f_1(x_1) & f_2(x_1) & \dots & f_m(x_1) \\ f_1(x_2) & f_2(x_2) & & \vdots \\ \vdots & & \ddots & \vdots \\ f_1(x_n) & \dots & \dots & f_m(x_n) \end{pmatrix} \rightarrow A_j = \begin{pmatrix} x_1 & 1 \\ x_2 & 1 \\ \vdots & \vdots \\ x_n & 1 \end{pmatrix}$$

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

RPIS 2024/2025 5

5

Przykład: regresja liniowa zwyczajna

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

$$\begin{pmatrix} \theta_1 \\ \theta_2 \end{pmatrix} = \begin{pmatrix} x_1 & 1 \\ x_2 & 1 \\ \vdots & \vdots \\ x_n & 1 \end{pmatrix}^{-1} \frac{1}{\sigma_y^2} \begin{pmatrix} x_1 & 1 \\ x_2 & 1 \\ \vdots & \vdots \\ x_n & 1 \end{pmatrix} \begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix}$$

W macierzy do odwracania: macierz jednostkową pomijamy

$$\begin{pmatrix} x_1 & 1 \\ x_2 & 1 \\ \vdots & \vdots \\ x_n & 1 \end{pmatrix} = \begin{pmatrix} \sum x_i^2 & \sum x_i \\ \sum x_i & n \end{pmatrix} \quad \begin{bmatrix} a & b \\ c & d \end{bmatrix}^{-1} = \frac{1}{ad-bc} \begin{bmatrix} d & -b \\ -c & a \end{bmatrix}$$

$$(A^T B A)^{-1} = \frac{\sigma_y^2}{\det A^T A} \begin{pmatrix} n & -\sum x_i \\ -\sum x_i & \sum x_i^2 \end{pmatrix} = \frac{\sigma_y^2}{n \sum x_i^2 - (\sum x_i)^2} \begin{pmatrix} n & -\sum x_i \\ -\sum x_i & \sum x_i^2 \end{pmatrix}$$

RPIS 2024/2025 6

6

Przykład: regresja liniowa zwyczajna

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

Zatem $(A^T B A)^{-1} A^T B = \frac{\sigma_y^2}{n \sum x_i^2 - (\sum x_i)^2} \begin{pmatrix} n & -\sum x_i \\ -\sum x_i & \sum x_i^2 \end{pmatrix} \frac{1}{\sigma_y^2} \begin{pmatrix} 1 & 1 \\ 1 & 1 \end{pmatrix} =$

$$= \frac{1}{n \sum x_i^2 - (\sum x_i)^2} \begin{pmatrix} n x_i - \sum x_i & \dots & n x_i - \sum x_i \\ -x_i \sum x_i + \sum x_i^2 & \dots & -x_i \sum x_i + \sum x_i^2 \end{pmatrix}$$

i ostatecznie

$$\begin{pmatrix} \theta_1 \\ \theta_2 \end{pmatrix} = \frac{1}{n \sum x_i^2 - (\sum x_i)^2} \begin{pmatrix} n x_i - \sum x_i & \dots & n x_i - \sum x_i \\ -x_i \sum x_i + \sum x_i^2 & \dots & -x_i \sum x_i + \sum x_i^2 \end{pmatrix} \begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix} =$$

$$= \frac{1}{n \sum x_i^2 - (\sum x_i)^2} \begin{pmatrix} n x_1 y_1 - y_1 \sum x_i + n x_2 y_2 - y_2 \sum x_i + \dots & \dots & n x_n y_n - y_n \sum x_i \\ -x_1 y_1 \sum x_i + y_1 \sum x_i^2 - x_2 y_2 \sum x_i + y_2 \sum x_i^2 - \dots & \dots & x_n y_n \sum x_i + y_n \sum x_i^2 \end{pmatrix} =$$

$$= \frac{1}{n \sum x_i^2 - (\sum x_i)^2} \begin{pmatrix} n \sum x_i y_i - \sum x_i \sum y_i \\ -\sum x_i \sum x_i y_i + \sum x_i^2 \sum y_i \end{pmatrix}$$

RPIS 2024/2025 7

7

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, $f_1(x)=x_i$, $f_2(x)=1$), 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_i), **ważona** (różne σ_i), **efektywna** (uwzględnia także niepewność x_i).

RPIS 2024/2025 8

8

Prawo przenoszenia błędów

- Dla liniowych związków pomiędzy Y i Θ znajdujemy macierz kowariancji $C(\Theta)$ (ćwiczenia)

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

$$\theta_i = T_{ij} Y_j$$

$$E(\theta_i) = T_{ij} E(Y_j)$$

$$C_{ij}(\vec{\theta}) \equiv \text{Cov}(\theta_i, \theta_j) = \sum_{k=1}^n \sum_{l=1}^n T_{ik} T_{jl} \text{Cov}(Y_k, Y_l)$$

$$C(\vec{\theta}) = T C(\vec{Y}) T^T$$

RPIS 2024/2025 9

9

Prawo przenoszenia błędów

- W naszym przykładzie

$$C(\vec{Y}) = B^{-1} \rightarrow$$

$$C(\vec{\theta}) = (A^T B A)^{-1} A^T B B^{-1} [(A^T B A)^{-1} A^T B]^T =$$

$$= (A^T B A)^{-1} A^T [A^{-1} B^{-1} (A^T)^{-1} A^T B]^T =$$

$$= (A^T B A)^{-1} A^T (A^{-1})^T = (A^T B A)^{-1} A^T (A^T)^{-1} = (A^T B A)^{-1}$$

$$C_{ij}(\vec{\theta}) = \begin{pmatrix} \text{var}(\theta_1) & \text{cov}(\theta_1, \theta_2) \\ \text{cov}(\theta_1, \theta_2) & \text{var}(\theta_2) \end{pmatrix} =$$

$$= \sigma_y^2 [A^T A]^{-1} = \frac{\sigma_y^2}{n \sum_{i=1}^n x_i^2 - \left(\sum_{i=1}^n x_i\right)^2} \begin{pmatrix} n & -\sum_{i=1}^n x_i \\ -\sum_{i=1}^n x_i & \sum_{i=1}^n x_i^2 \end{pmatrix}$$

RPIS 2024/2025 10

10

Paradoks Simpsona

$y=1.99x+8.0$
 $y=2.15x-11.75$
 $y=-1.0883x+14.117$

- Paradoks Simpsona – połączenie różnych grup może zmienić interpretację wyników. Prowadzi to do praktycznych problemów np. związanych z wyborem kuracji osoby chorej. Rozwiązanie problemu prowadzi do sieci Bayesowskich i teorii grafów i polega na przesledzeniu zależności pomiędzy zmiennymi X_i , Y i innymi zmiennymi, które mogą mieć wpływ na zmienną X i Y.

RPIS 2024/2025 11

11

Miara jakości dopasowania – „test Chi-kwadrat”

Zał. σ_i mają rozkład normalny

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

- $E(M)=n-p$ – dla rozkładu Chi-kwadrat o n-p stopniach swobody.
- Gdy $M > \chi_{2, n-p}^2$ (n- liczba pomiarów, p liczba parametrów) to na poziomie ufności γ odrzucamy wynik dopasowania.
- Dla regresji liniowej mamy (p=2)

$$M = \sum_{i=1}^n \frac{(y_i - a x_i - b)^2}{\sigma_i^2}$$

- W praktyce sprawdzamy czy $M/(n-2) \approx 1$ – prosta dobrze przybliża.
- $M/(n-2) < 1$ prosta, ale za duże σ_i ; $M/(n-2) > 1$ inna krzywa, za małe σ_i lub niektóre pomiary odstają od prostej.

RPIS 2024/2025 12

12