

Metody numeryczne
Własności estymatorów
Pseudolinearyzacja

P. F. Góra

https://zfs.fais.uj.edu.pl/pawel_gora

2025

Własności wektora estymatorów

Wektor \mathbf{p} obliczamy rozwiązując równanie

$$\mathbf{A}^T \mathbf{G}^{-1} \mathbf{A} \mathbf{p} = \mathbf{A}^T \mathbf{G}^{-1} \mathbf{y} \quad (1)$$

dla takich wartości pomiarów, jakie faktycznie mamy. Tak obliczony wektor \mathbf{p} jest wektorem estymatorów. Pamiętajmy, że pomiary są obarczone błędami losowymi, a więc także obliczone estymatory są, formalnie, *gaussowskimi liczbami losowymi*. Co można powiedzieć o tych liczbach? $\mathbf{y} = \mathbf{A} \mathbf{p}^* + \boldsymbol{\xi}$, gdzie \mathbf{p}^* jest zbudowany z “prawdziwych”, nieznanymi wartościami $[a_1, \dots, a_s]^T$ występujących w równaniu

$$\tilde{y}_i = a_1 \cdot f_1(x_i) + a_2 \cdot f_2(x_i) + \dots + a_s \cdot f_s(x_i). \quad (2)$$

Widać, że

$$\mathbf{A}^T \mathbf{G}^{-1} \mathbf{A} (\mathbf{p} - \mathbf{p}^*) = \mathbf{A}^T \mathbf{G}^{-1} \boldsymbol{\xi} \quad (3)$$

wobec czego

$$\langle \mathbf{p} \rangle = \mathbf{p}^*, \quad (4)$$

gdyż $\langle \boldsymbol{\xi} \rangle = 0$. Obliczone estymatory są przybliżeniem “prawdziwych” wartości parametrów w sensie równania (4).

Macierz kowariancji estymatorów wynosi

$$\begin{aligned} \mathbf{C}_p &= \langle (\mathbf{p} - \mathbf{p}^*)(\mathbf{p} - \mathbf{p}^*)^T \rangle \\ &= (\mathbf{A}^T \mathbf{G}^{-1} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{G}^{-1} \langle \boldsymbol{\xi} \boldsymbol{\xi}^T \rangle \mathbf{G}^{-1} \mathbf{A} (\mathbf{A}^T \mathbf{G}^{-1} \mathbf{A})^{-1}, \end{aligned} \quad (5)$$

gdzie skorzystaliśmy z symetrii macierzy \mathbf{G}^{-1} i macierzy $\mathbf{A}^T \mathbf{G}^{-1} \mathbf{A}$. Korzystając z równania

$$\langle \boldsymbol{\xi} \boldsymbol{\xi}^T \rangle = \mathbf{G} \quad (6)$$

otrzymujemy

$$\begin{aligned} \mathbf{C}_p &= (\mathbf{A}^T \mathbf{G}^{-1} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{G}^{-1} \overbrace{\underbrace{\mathbf{G} \mathbf{G}^{-1}}_{\langle \boldsymbol{\xi} \boldsymbol{\xi}^T \rangle}}^{\mathbb{I}} \mathbf{A} (\mathbf{A}^T \mathbf{G}^{-1} \mathbf{A})^{-1}, \\ &= (\mathbf{A}^T \mathbf{G}^{-1} \mathbf{A})^{-1} \underbrace{\mathbf{A}^T \mathbf{G}^{-1} \mathbf{A} (\mathbf{A}^T \mathbf{G}^{-1} \mathbf{A})^{-1}}_{\mathbb{I}} \\ &= (\mathbf{A}^T \mathbf{G}^{-1} \mathbf{A})^{-1}. \end{aligned} \quad (7)$$

Pseudolinearyzacja

Rozważamy nieliniowe zagadnienie najmniejszych kwadratów dla pomiarów niezależnych (nieskorelowanych) i obarczonych statystycznie takimi samymi błędami

$$Q = \text{const} \cdot \frac{1}{2} \sum_{i=1}^N (y_i - \tilde{y}_i)^2 = \text{const} \cdot \frac{1}{2} \sum_{i=1}^N (y_i - f(x_i; \mathbf{p}))^2, \quad (8)$$

gdzie \tilde{y}_i oznaczają wartości “idealne”, teoretyczne.

Czasami do znalezienia minimum Q stosuje się metodę *pseudolinearyzacji*. Przypuśćmy, że \mathbf{p}_n jest aktualnym przybliżeniem poszukiwanej wartości parametrów \mathbf{p} . Stawiamy hipotezę, iż “prawdziwe” wartości parametrów są małą poprawką w stosunku do \mathbf{p}_n : $\mathbf{p} \simeq \mathbf{p}_n + \delta\mathbf{p}$ i rozwijamy $\tilde{y}_i = f(x_i; \mathbf{p})$ w szereg Taylora do pierwszego rzędu:

$$\tilde{y}_i = f(x_i; \mathbf{p}_n + \delta \mathbf{p}) \simeq f(x_i; \mathbf{p}_n) + [\nabla_{\mathbf{p}} f|_{\mathbf{p}_n}]^T \delta \mathbf{p}. \quad (9)$$

Podstawiamy to rozwinięcie do (8). Funkcja

$$Q = \frac{1}{2} \sum_{i=1}^N \left(y_i - f(x_i; \mathbf{p}_n) - [\nabla_{\mathbf{p}} f|_{\mathbf{p}_n}]^T \delta \mathbf{p} \right)^2 \quad (10)$$

jest formą kwadratową w poprawkach $\delta \mathbf{p}$. Po znalezieniu znanymi metodami wartości $\delta \mathbf{p}_{\min}$, odpowiadających (jedynemu) minimum (10), podstawiamy $\mathbf{p}_{n+1} = \mathbf{p}_n + \delta \mathbf{p}_{\min}$ i powtarzamy całą procedurę.

Taka procedura dość dobrze działa w wypadku nieliniowej metody najmniejszych kwadratów, choć **nie należy** jej polecać jako ogólnej metody

minimalizacji. Pseudolinearyzacja ma tylko jedno niewątpliwe zastosowanie: Po znalezieniu **ostatecznych** wartości minimalizujących funkcję (8), za pomocą pseudolinearyzacji wokół tego punktu znajdujemy macierz kowariancji estymatorów, będącą charakterystyką **liniową**.

Przykład

Przypuśćmy, że do danych dopasowujemy funkcję Gaussa

$$y(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(x - \bar{x})^2}{2\sigma^2}\right), \quad (11)$$

zaś aktualnymi przybliżeniami parametrów są \bar{x}_n, σ_n^2 . Obliczamy

$$f(x; \bar{x}, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(x - \bar{x})^2}{2\sigma^2}\right), \quad (12a)$$

$$\left. \frac{\partial f}{\partial \bar{x}} \right|_{\bar{x}_n, \sigma_n^2} = \frac{1}{\sqrt{2\pi\sigma_n^2}} \exp\left(-\frac{(x - \bar{x}_n)^2}{2\sigma_n^2}\right) \cdot \frac{x - \bar{x}_n}{\sigma_n^2}, \quad (12b)$$

$$\left. \frac{\partial f}{\partial (\sigma^2)} \right|_{\bar{x}_n, \sigma_n^2} = \frac{1}{\sqrt{2\pi\sigma_n^2}} \exp\left(-\frac{(x - \bar{x}_n)^2}{2\sigma_n^2}\right) \cdot \left[\frac{(x - \bar{x}_n)^2}{4(\sigma_n^2)^2} - \frac{1}{2\sigma_n^2} \right] \quad (12c)$$

Wyrażenie

$$Q = \frac{1}{2} \sum_{i=1}^N \left(y_i - \frac{1}{\sqrt{2\pi\sigma_n^2}} \exp\left(-\frac{(x_i - \bar{x}_n)^2}{2\sigma_n^2}\right) \cdot \left\{ 1 + \frac{x_i - \bar{x}_n}{\sigma_n^2} \delta\bar{x} + \left[\frac{(x_i - \bar{x}_n)^2}{4(\sigma_n^2)^2} - \frac{1}{2\sigma_n^2} \right] \delta\sigma^2 \right\} \right)^2 \quad (13)$$

jest formą kwadratową w zmiennych $\delta\bar{x}$, $\delta\sigma^2$.