

10.

Metody obliczeniowe najmniejszych kwadratów

1. Dowód twierdzenia o faktoryzacji macierzy

Twierdzenie 1 Każdą dodatnio określoną i symetryczną macierz \mathbf{M} można przedstawić w postaci

$$\mathbf{M} = \mathbf{P}\mathbf{P}^T$$

gdzie \mathbf{P} jest macierzą nieosobliwą (nazywaną pierwiastkiem macierzy \mathbf{M}).

Dowód

oznaczymy

$$\begin{aligned} w_i &- \text{wektory własne macierzy } M, & i &= 1, 2, \dots, s \\ \lambda_i &- \text{wartości własne macierzy } M, & i &= 1, 2, \dots, s \end{aligned}$$

własność

$$Mw_i = \lambda_i w_i$$

oznaczając

$$W = [w_1, w_2, \dots, w_s] \text{ oraz } \Lambda = \text{diag}(\lambda_i) = \begin{bmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & 0 & \dots \\ \dots & 0 & \dots & 0 \\ 0 & \dots & 0 & \lambda_s \end{bmatrix}$$

ponieważ macierz M jest symetryczna, to

$$\begin{aligned} \lambda_i &- \text{rzeczywiste} \\ w_i &- \text{parami ortogonalne} \end{aligned}$$

ponieważ macierz M jest dodatnio określona ($M > 0$), to

$$\lambda_i > 0 \text{ dla każdego } i = 1, 2, \dots, s$$

wniosek

$$W - \text{macierz ortogonalna}$$
$$W^T W = I \implies W^{-1} = W^T$$

a zatem

$$MW = W\Lambda$$
$$M = W\Lambda W^{-1} = W\Lambda W^T \text{ (tzw. rozkład spektralny macierzy)}$$

oznaczając

$$\Lambda = \Lambda^{1/2} \Lambda^{1/2}, \text{ gdzie } \Lambda^{1/2} = \text{diag}(\sqrt{\lambda_i}) = \begin{bmatrix} \sqrt{\lambda_1} & 0 & \dots & 0 \\ 0 & \sqrt{\lambda_2} & 0 & \dots \\ \dots & 0 & \dots & 0 \\ 0 & \dots & 0 & \sqrt{\lambda_s} \end{bmatrix}$$

otrzymujemy

$$W\Lambda W^T = W\Lambda^{1/2} \left(W\Lambda^{1/2}\right)^T$$

stąd

$$M = PP^T, \text{ gdzie } P = W\Lambda^{1/2} \text{ (c.k.d.) } \blacksquare$$

2. Klasyfikacja metod obliczeniowych NK

- 1) Algorytmy równań normalnych
- 2) Algorytmy ortogonalizacji (przekształceń ortogonalnych)

Ad 1) podejście trywialne – ogromny problem z odwracaniem macierzy

$$\left. \begin{array}{l} X_N \\ Y_N \end{array} \right\} \left. \begin{array}{l} X_N^T X_N \rightarrow (X_N^T X_N)^{-1} \\ X_N^T Y_N \end{array} \right\} a_N = (X_N^T X_N)^{-1} X_N^T Y_N$$

zadania źle uwarunkowane, np.

$$X_N^T X_N = \begin{bmatrix} 1 & 0 \\ 0 & \varepsilon \end{bmatrix}, \quad \det(X_N^T X_N) = \varepsilon - \text{bliskie zeru}$$

$$\text{dla } \varepsilon = 0.001 \rightarrow (X_N^T X_N)^{-1} = \begin{bmatrix} 1 & 0 \\ 0 & 1000 \end{bmatrix}$$

$$\text{dla } \varepsilon = 0.0001 \rightarrow (X_N^T X_N)^{-1} = \begin{bmatrix} 1 & 0 \\ 0 & 10000 \end{bmatrix} - \text{różnica rzędu wielkości}$$

3. Metoda eliminacji Gaussa

mamy równanie

$$Ma = b$$

$$\begin{aligned} [M, b, I] &\rightarrow \text{operacje liniowe na wierszach i kolumnach (mnożenie przez } M^{-1}) \rightarrow \\ &\rightarrow [I, a_N, M^{-1}] \end{aligned}$$

Zalety metody:

- 1) stabilna numerycznie
- 2) oprócz a_N uzyskujemy także ocenę jakości a_N , czyli macierz kowariancji

$$\text{cov}(a_N) = (X_N^T X_N)^{-1} \sigma_z^2 = M^{-1} \sigma_z^2$$

4. Metoda Cholesky'ego, rozkład LU

$$Ma = b$$

M – dodatnio określona ($M > 0$), symetryczna ($M^T = M$)

na podstawie twierdzenia o faktoryzacji

$$M = PP^T$$

P – macierz nieosobliwa, tzw. pierwiastek macierzy M

dowiedliśmy, że

$$M = W\Lambda W^T \text{ (tzw. rozkład spektralny macierzy)}$$

$$\Lambda = \text{diag}(\lambda_i), \lambda_i > 0$$

istnieje inny rozkład macierzy M , tzw. rozkład LU

$$M = LDL^T$$

gdzie

L – macierz trójkątna dolna, tzn. dla $i < j$ zachodzi $L[i, j] = 0$

D – macierz diagonalna, $D = \text{diag}(d_i), d_i > 0$

stąd mamy

$$M = LD^{1/2}D^{1/2}L^T$$

gdzie $D^{1/2} = \text{diag}(\sqrt{d_i})$

przyjmując oznaczenie

$$\bar{L} = LD^{1/2}$$

otrzymujemy

$$M = \overline{L}\overline{L}^T$$

\overline{L} – macierz trójkątna dolna
 \overline{L}^T – macierz trójkątna górna

$$\det M = \det \overline{L}\overline{L}^T = \det \overline{L} \det \overline{L}^T > 0$$

Schemat metody obliczeniowej

$$\overline{L}\overline{L}^T a = b$$

Etap 1.

oznaczając $\alpha = \overline{L}^T a$ rozwiązujemy równanie ”zewnętrzne”

$$\overline{L}\alpha = b$$

ponieważ $\det \overline{L} > 0$ to elementy diagonalne \overline{L} są różne od zera, rozwiązanie α_N istnieje i jest jednoznaczne

Etap 2.

wartość α_N jest znana z etapu 1

rozwiązujemy równanie ”wewnętrzne”

$$\overline{L}^T a = \alpha_N$$

ponieważ $\det \overline{L}^T > 0$ to elementy diagonalne \overline{L}^T są różne od zera, rozwiązanie a_N istnieje i jest jednoznaczne

Zalety metody

1) prostota operacji przy rozwiązywaniu równań

Etap 1 – tzw. metoda podstawiania ”od góry”

Etap 2 – tzw. metoda podstawiania ”od dołu”

2) dobre uwarunkowanie zadania, gdyż

$$\begin{aligned}\det M &= (\det \bar{L})^2 \\ \det \bar{L} &= \sqrt{\det M}\end{aligned}$$

zatem dla $0 < \det M < 1$

$$\det \bar{L} = \det \bar{L}^T > \det M$$

czyli zadania z etapów 1 i 2 są lepiej uwarunkowane

Ad 2) metody przekształceń ortogonalnych – nie wymagają tworzenia równań normalnych

5. Metoda odbić Householdera

Definicja 1 *Macierzą odbicia Householdera nazywamy macierz postaci*

$$P = I - 2ww^T$$

gdzie $\|w\| = 1$, tj. $w^T w = 1$.

Interpretacja

$$Pw = (I - 2ww^T)w = w - 2ww^T w = w - 2w = -w$$

Własności:

- (i) $P = P^T$ (symetria)
- (ii) $P^T P = P P^T = I$ (ortogonalność)
- (iii) dla każdego wektora x istnieje macierz P_j , taka że

$$P_j x = \pm \|x\| e_j, \text{ gdzie } e_j \text{ jest } j\text{-tym wektorem } e_j = \begin{bmatrix} 0 \\ 0 \\ 1 \\ 0 \end{bmatrix}$$

- (iiii) dla ciągu macierzy Householdera P_1, P_2, \dots, P_s przekształcenie złożenia

$$\Psi = P_s \cdot P_{s-1} \cdot \dots \cdot P_2 \cdot P_1$$

jest macierzą ortogonalną, tj.

$$\Psi^T \Psi = I$$

Dowody

(i) oczywiste – różnica macierzy symetrycznych jest symetryczna

(ii)

$$PP^T = (I - 2ww^T)(I - 2ww^T) = I - 2ww^T - 2ww^T + 4ww^Tww^T = I - 4ww^T + 4ww^T = I$$

(iii)

x – dowolny wektor

$$u_j = x \pm \|x\| e_j$$

$$P_j = I - \frac{u_j u_j^T}{H_j}, \text{ gdzie } H_j = \frac{1}{2} \|u_j\|^2 = \frac{1}{2} u_j^T u_j$$

macierz P_j jest macierzą Householdera, ponieważ

$$P_j = I - 2 \frac{u_j}{\|u_j\|} \frac{u_j^T}{\|u_j\|} \text{ (wektory o długości 1)}$$

$$\begin{aligned} P_j x &= \left(I - \frac{u_j u_j^T}{H_j} \right) x = x - u_j \frac{2u_j^T x}{u_j^T u_j} = x - u_j \frac{2(x \pm \|x\| e_j)^T x}{(x \pm \|x\| e_j)^T (x \pm \|x\| e_j)} = \\ &= \dots = x - u_j = x - x \pm \|x\| e_j = \pm \|x\| e_j \end{aligned}$$

(iii)

$$\Psi^T \Psi = P_1^T P_2^T \dots P_{s-1}^T \underbrace{P_s^T P_s}_{=I} P_{s-1} \dots P_2 P_1 = I$$

Lemat 1 Dla każdej macierzy $X_{N \times s}$ istnieje taki ciąg macierzy Householdera $\{\tilde{P}_1, \tilde{P}_2, \dots, \tilde{P}_s\}$, że przekształcenie

$$\Psi = \tilde{P}_s \tilde{P}_{s-1}, \dots, \tilde{P}_2 \tilde{P}_1$$

ma własność

$$\Psi X_{N \times s} = \begin{bmatrix} R \\ 0 \end{bmatrix}$$

gdzie R jest macierzą trójkątną górną o rozmiarach $s \times s$.

Twierdzenie 2 Oszacowanie NK jest równoważne rozwiązaniu układu równań

$$Ra = \eta_R$$

gdzie η_R jest wektorem zawierającym s pierwszych elementów wektora ΨY_N .

Rozwiązanie tego układu równań istnieje i jest jednoznaczne. Pytanie dotyczy samego oszacowania NK.

Dowód

$$\begin{aligned} Q(a) &= \|X_N a - Y_N\|_e^2 \rightarrow \min_a \\ Q(a) &= (X_N a - Y_N)^T (X_N a - Y_N) = \\ &= (X_N a - Y_N)^T \Psi^T \Psi (X_N a - Y_N) = \\ &= [\Psi (X_N a - Y_N)]^T [\Psi (X_N a - Y_N)] = \\ &= [\Psi X_N a - \Psi Y_N]^T [\Psi X_N a - \Psi Y_N] = \\ &= \left[\begin{bmatrix} R \\ 0 \end{bmatrix} a - \begin{bmatrix} \eta_R \\ \eta_z \end{bmatrix} \right]^T \left[\begin{bmatrix} R \\ 0 \end{bmatrix} a - \begin{bmatrix} \eta_R \\ \eta_z \end{bmatrix} \right] = \\ &= \begin{bmatrix} Ra - \eta_R \\ -\eta_z \end{bmatrix}^T \begin{bmatrix} Ra - \eta_R \\ -\eta_z \end{bmatrix} = (Ra - \eta_R)^T (Ra - \eta_R) + \eta_z^T \eta_z = \\ &= \|Ra - \eta_R\|_e^2 + \|\eta_z\|_e^2 \rightarrow \min_a \end{aligned}$$

zatem

$$Q(a) \rightarrow \min_a \Rightarrow Ra = \eta_R$$