

## Zad. 11. Program ilustrujący przykładowe zastosowanie rozkładu SVD macierzy

e-mail: [andrzej.kedziorski@fizyka.umk.pl](mailto:andrzej.kedziorski@fizyka.umk.pl)

tel.: 56611-3274

pokój: 485

<http://www.fizyka.umk.pl/~tecumseh/EDU/MNII/>

## Zadanie 11

Napisać program rozwiązujący nadokreślony układ równań liniowych

$$\mathbf{A}\mathbf{a} \approx \mathbf{b}$$

dla zagadnień najmniejszych kwadratów korzystając z rozkładu SVD macierzy  $\mathbf{A}$ .

# Przypomnienie: Ogólna liniowa metoda najmniejszych kwadratów

- ▶ Postać danych  $(x_i, y_i, \sigma_{y_i})$ ,  $i = 1, \dots, N$ , gdzie  $\sigma_{y_i}$  jest oszacowaniem błędu  $y_i$ <sup>1</sup>; zakładamy, że błąd  $x_i$  jest zanedbywalnie mały
- ▶ Do danych chcemy dopasować funkcję (model liniowy ze względu na parametry)

$$y(x) = \sum_{k=1}^M a_k F_k(x),$$

gdzie  $F_k(x)$  są ustalonymi funkcjami,  $a_k$  - parametry modelu,  $N \geq M$

- ▶ Wartości parametrów  $a_k$  wyznaczamy z warunku

$$\chi^2 \equiv \sum_{i=1}^N \left( \frac{y_i - \sum_{k=1}^M a_k F_k(x_i)}{\sigma_{y_i}} \right)^2 = \min,$$

co prowadzi do układu  $M$  równań normalnych (liniowych) na parametry  $a_k$

$$\frac{\partial(\chi^2)}{\partial a_k} = 0, \quad k = 1, \dots, M$$

---

<sup>1</sup>Wprowadzam oznaczenie  $\sigma_{y_i}$  na błąd wielkości  $y_i$ , żeby odróżnić je od wartości szczególnych  $\sigma_i$  w rozkładzie SVD macierzy, który będzie wykorzystywany w dalszej części zajęć

# Przypomnienie: Równania normalne

(Wyprowadzenie równań normalnych - patrz zad. 7)

Układ  $M$  równań liniowych na parametry  $a_k$ ,  $k = 1, \dots, M$

$$\alpha \mathbf{a} = \beta,$$

gdzie  $\alpha = \mathbf{A}^T \mathbf{A}$ ,  $\beta = \mathbf{A}^T \mathbf{b}$  oraz

$$\mathbf{A} = \begin{pmatrix} \frac{F_1(x_1)}{\sigma_{y1}} & \frac{F_2(x_1)}{\sigma_{y1}} & \dots & \frac{F_M(x_1)}{\sigma_{y1}} \\ \frac{F_1(x_2)}{\sigma_{y2}} & \frac{F_2(x_2)}{\sigma_{y2}} & \dots & \frac{F_M(x_2)}{\sigma_{y2}} \\ \vdots & \vdots & \dots & \vdots \\ \frac{F_1(x_N)}{\sigma_{yN}} & \frac{F_2(x_N)}{\sigma_{yN}} & \dots & \frac{F_M(x_N)}{\sigma_{yN}} \end{pmatrix} \quad \mathbf{a} = \begin{pmatrix} a_1 \\ a_2 \\ \vdots \\ a_M \end{pmatrix} \quad \mathbf{b} = \begin{pmatrix} \frac{y_1}{\sigma_{y1}} \\ \frac{y_2}{\sigma_{y2}} \\ \vdots \\ \frac{y_N}{\sigma_{yN}} \end{pmatrix}$$

Widać, że

$$\mathbf{A}_{N \times M}, \mathbf{a}_{M \times 1}, \mathbf{b}_{N \times 1}, \alpha_{M \times M}, \beta_{M \times 1}, \text{cond}(\alpha) = \text{cond}(\mathbf{A})^2$$

Nadokreślony układ równań liniowych

$$\mathbf{Aa} \approx \mathbf{b} \quad \Leftrightarrow \quad y_i \approx \sum_{k=1}^M a_k F_k(x_i), \quad i = 1, 2, \dots, N$$

prowadzi do innego sposobu rozwiązania problemu...

# Uwagi

- ▶ Zagadnienie optymalizacji parametrów  $a_k$

$$\chi^2 \equiv \sum_{i=1}^N \left( \frac{y_i - \sum_{k=1}^M a_k F_k(x_i)}{\sigma_{y_i}} \right)^2 = \min,$$

sprowadza się do minimalizacji (kwadratu) normy euklidesowej (zob. zad. 6 i 7)

$$(\|\mathbf{b} - \mathbf{Aa}\|_2)^2 = \min \Leftrightarrow \|\mathbf{b} - \mathbf{Aa}\|_2 = \min$$

gdzie  $\|\mathbf{x}\|_2 = \sqrt{\sum_{i=1}^N x_i^2}$

- ▶ Wynika stąd, że  $\mathbf{b} - \mathbf{Aa} \approx \mathbf{0}$ , czyli  $\mathbf{Aa} \approx \mathbf{b}$
- ▶ Rozwiązanie w sensie minimalizowania normy euklidesowej zagadnienie  $\|\mathbf{Aa} - \mathbf{b}\|_2 = \min$  jest równe  $\mathbf{a} = \mathbf{A}^+\mathbf{b}$

# Przypomnienie: macierz pseudoodwrotna

- ▶ Rozkład SVD macierzy  $\mathbf{A}_{N \times M}$  i macierz pseudoodwrotna  $\mathbf{A}_{M \times N}^+$

$$\mathbf{A} = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^T \quad \mathbf{A}^+ = \mathbf{V}\mathbf{\Sigma}^+\mathbf{U}^T,$$

gdzie  $\mathbf{U}_{N \times N}$  i  $\mathbf{V}_{M \times M}$  to macierze ortogonalne, macierz diagonalna  $\mathbf{\Sigma}_{N \times M}$  ma na głównej diagonalu wartości szczególne  $\sigma_i \geq 0$  w kolejności od największej do najmniejszej, tzn.  $\sigma_1 > \sigma_2 > \dots > \sigma_{\min(N,M)}$ , a macierz  $\mathbf{\Sigma}^+_{M \times N}$  ma na głównej diagonalu pseudoodwrotności  $\sigma_i^+$ , tzn.

$$\sigma_i^+ = \begin{cases} \sigma_i^{-1}, & \sigma_i > 0 \\ 0, & \sigma_i = 0 \end{cases}$$

- ▶ Dla ustalenia uwagi:  $N \geq M$ , jak w zagadnieniu aproksymacji  $\chi^2$
- ▶ Wartości szczególne  $\sigma_i$  oraz kolumny macierzy ortogonalnych  $\mathbf{U}$  i  $\mathbf{V}$

$$(\mathbf{A}^T \mathbf{A}) \mathbf{v}_k = \sigma_k^2 \mathbf{v}_k, \quad k = 1, \dots, M \Rightarrow \mathbf{V} = [\mathbf{v}_1 \ \mathbf{v}_2 \ \dots \ \mathbf{v}_M] \quad (1)$$

$$\mathbf{u}_j = \frac{1}{\sigma_j} \mathbf{A} \mathbf{v}_j, \quad \sigma_j > 0 \Rightarrow \mathbf{U} = [\mathbf{u}_1 \ \mathbf{u}_2 \ \dots \ \mathbf{u}_{j_{\max}} \ \dots], \quad j_{\max} \leq M \quad (2)$$

gdzie kolejność kolumn zdeterminowana jest uporządkowaniem  $\sigma_1 \geq \sigma_2 \geq \sigma_3 \geq \dots \geq \sigma_{j_{\max}} > 0$  oraz  $j_{\max} \leq M$

## Jawne wyrażenie na parametry $a_k$ (wektor $\mathbf{a}$ )

- ▶ Przypomnienie: Rozkład SVD macierzy  $\mathbf{A}_{N \times M}$ , gdzie  $N \geq M$ , możemy zapisać następująco

$$\mathbf{A}_{N \times M} = \mathbf{U}_{N \times N} \mathbf{\Sigma}_{N \times M} \mathbf{V}_{M \times M}^T = \sum_{\sigma_i > 0} \sigma_i \mathbf{E}_i,$$

gdzie każda macierz  $\mathbf{E}_i = \mathbf{u}_i \mathbf{v}_i^T$  jest rzędu 1. Analogicznie możemy przedstawić macierz pseudoodwrotną

$$\mathbf{A}_{M \times N}^+ = \mathbf{V}_{M \times M} \mathbf{\Sigma}_{M \times N}^+ \mathbf{U}_{N \times N}^T = \sum_{\sigma_i > 0} \frac{1}{\sigma_i} \mathbf{v}_i \mathbf{u}_i^T$$

- ▶ Wobec tego rozwiązanie nadmiarowego układu równań liniowych  $\mathbf{A}_{N \times M} \mathbf{a}_{M \times 1} \approx \mathbf{b}_{N \times 1}$  w sensie minimalizacji metodą najmniejszych kwadratów, czyli  $\mathbf{a} = \mathbf{A}^+ \mathbf{b}$ , można zapisać w następującej postaci

$$\mathbf{a} = \sum_{\sigma_i > 0} \frac{\mathbf{u}_i^T \mathbf{b}}{\sigma_i} \mathbf{v}_i,$$

gdzie  $\mathbf{u}_i$ , to  $i$ -ta kolumna macierzy  $\mathbf{U}_{N \times N}$ , a  $\mathbf{v}_i$ , to  $i$ -ta kolumna macierzy  $\mathbf{V}_{M \times M}$ , oraz  $\mathbf{u}_i^T \mathbf{b}$  jest iloczynem skalarnym wektorów (kolumn  $N \times 1$ )

- ▶ Zauważmy, że potrzebujemy co najwyżej  $M$  początkowych kolumn macierzy  $\mathbf{U}$

# Do zrobienia

- ▶ Utworzyć macierze  $\mathbf{A}_{N \times M}$  i  $\mathbf{b}_{N \times 1}$ ,  $N \geq M$
- ▶ Dokonać rozkładu SVD macierzy  $\mathbf{A}_{N \times M}$ ; obliczamy co najwyżej  $M$  początkowych kolumn macierzy  $\mathbf{U}$  wg wzoru

$$\mathbf{u}_i = \frac{1}{\sigma_i} \mathbf{A} \mathbf{v}_i, \quad \sigma_i > \epsilon$$

gdzie  $\epsilon > 0$  i  $\epsilon \sim 0$ .

- ▶ Wyznaczamy parametry  $a_k$  (wektor  $\mathbf{a}$ )

$$\mathbf{a} = \sum_{\sigma_i > \epsilon} \frac{\mathbf{u}_i^T \mathbf{b}}{\sigma_i} \mathbf{v}_i,$$

- ▶ Lub po prostu

$$\mathbf{a} = \mathbf{A}^+ \mathbf{b}$$