

## Zad. 10. Wyznaczanie rozkładu SVD macierzy prostokątnej

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

tel.: 56611-3274

pokój: 485B

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

## Zadanie 10

Napisz program wyznaczający rozkład SVD macierzy prostokątnej **A**. Na podstawie rozkładu SVD wyznaczyć macierz pseudoodwrotną do macierzy **A**.

## Rozkład wg wartości szczególnych/osobliwych (SVD)

SVD (*Singular Value Decomposition*) to metoda pozwalająca na wyodrębnienie liniowo niezależnych kolumn z macierzy prostokątnej  $m \times n$ .

$$A = U\Sigma V^T$$

- $U$  i  $V$  są macierzami ortogonalnymi o wymiarach  $m \times m$  i  $n \times n$
- $\Sigma$  jest macierzą diagonalną  $m \times n$  z nieujemnymi elementami rzeczywistymi  $\sigma_i$ <sup>15</sup> uporządkowanymi malejąco, tzn.

$$\sigma_1 \geq \sigma_2 \dots \geq \sigma_{\min(m,n)} \geq 0$$

$\sigma_i$  to wartości szczególne  $A$ , a  $\min(m, n)$  kolumn macierzy  $U$  i  $V$  są lewymi i prawymi wektorami szczególnymi  $A$ . Mamy

$$Av_j = \sigma_j u_j, \quad A^T u_j = \sigma_j v_j, \quad A^T Av_j = \sigma_j^2 v_j, \quad AA^T u_j = \sigma_j^2 u_j$$

---

<sup>15</sup>Tutaj  $\sigma_i$  nie mają nic wspólnego z odchyleniem standardowym danych doświadczalnych!

## Prostokątna macierz diagonalna - przykład $4 \times 3$

$$\mathbf{\Sigma} = \begin{pmatrix} \sigma_1 & 0 & 0 \\ 0 & \sigma_2 & 0 \\ 0 & 0 & \sigma_3 \\ 0 & 0 & 0 \end{pmatrix} \quad \mathbf{\Sigma}^{Tr} = \begin{pmatrix} \sigma_1 & 0 & 0 & 0 \\ 0 & \sigma_2 & 0 & 0 \\ 0 & 0 & \sigma_3 & 0 \end{pmatrix}$$

$$\mathbf{\Sigma}^{Tr} \mathbf{\Sigma} = \begin{pmatrix} \sigma_1^2 & 0 & 0 \\ 0 & \sigma_2^2 & 0 \\ 0 & 0 & \sigma_3^2 \end{pmatrix}$$

$$\mathbf{\Sigma} \mathbf{\Sigma}^{Tr} = \begin{pmatrix} \sigma_1^2 & 0 & 0 & 0 \\ 0 & \sigma_2^2 & 0 & 0 \\ 0 & 0 & \sigma_3^2 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix}$$

# Rozkład SVD - przekształcenia (1)

$$\mathbf{A}_{m \times n} = \mathbf{U}_{m \times m} \mathbf{\Sigma}_{m \times n} \mathbf{V}_{n \times n}^{Tr} \quad | \cdot \mathbf{V}_{n \times n} \quad (\mathbf{V}^{Tr} \mathbf{V} = \mathbf{1})$$

$$\mathbf{A}_{m \times n} \mathbf{V}_{n \times n} = \mathbf{U}_{m \times m} \mathbf{\Sigma}_{m \times n}$$

$$\sum_{k=1}^n A_{ik} V_{kj} = \underbrace{\sum_{\ell=1}^{\min(m,n)} U_{i\ell} \sigma_{\ell} \delta_{\ell j}}_{U_{ij} \sigma_j} \quad i = 1, \dots, m, \quad j = 1, \dots, n$$

⇓

$$\mathbf{A} \mathbf{v}_j = \sigma_j \mathbf{u}_j, \quad j = 1, \dots, \min(m, n)$$

$\mathbf{v}_j$  oraz  $\mathbf{u}_j$  to kolumny macierzy  $\mathbf{V}$  i  $\mathbf{U}$

## Rozkład SVD - przekształcenia (2)

$$\mathbf{A}_{m \times n} = \mathbf{U}_{m \times m} \mathbf{\Sigma}_{m \times n} \mathbf{V}_{n \times n}^{Tr}$$

$$\begin{aligned} \mathbf{A}_{n \times m}^{Tr} &= (\mathbf{U}_{m \times m} \mathbf{\Sigma}_{m \times n} \mathbf{V}_{n \times n}^{Tr})^{Tr} = (\mathbf{V}_{n \times n}^{Tr})^{Tr} (\mathbf{U}_{m \times m} \mathbf{\Sigma}_{m \times n})^{Tr} \\ &= \mathbf{V}_{n \times n} \mathbf{\Sigma}_{n \times m}^{Tr} \mathbf{U}_{m \times m}^{Tr} \end{aligned}$$

$$\mathbf{A}_{n \times m}^{Tr} = \mathbf{V}_{n \times n} \mathbf{\Sigma}_{n \times m}^{Tr} \mathbf{U}_{m \times m}^{Tr} \quad | \cdot \mathbf{U}_{m \times m} \quad (\mathbf{U}^{Tr} \mathbf{U} = \mathbf{1})$$

$$\mathbf{A}_{n \times m}^{Tr} \mathbf{U}_{m \times m} = \mathbf{V}_{n \times n} \mathbf{\Sigma}_{n \times m}^{Tr}$$

$$\sum_{k=1}^m (\mathbf{A}^{Tr})_{ik} U_{kj} = \underbrace{\sum_{\ell=1}^{\min(m,n)} V_{i\ell} \sigma_{\ell} \delta_{\ell j}}_{V_{ij} \sigma_j} \quad i = 1, \dots, n, \quad j = 1, \dots, m$$

⇓

$$\mathbf{A}^{Tr} \mathbf{u}_j = \sigma_j \mathbf{v}_j, \quad j = 1, \dots, \min(m, n)$$

$\mathbf{v}_j$  oraz  $\mathbf{u}_j$  to kolumny macierzy  $\mathbf{V}$  i  $\mathbf{U}$

## Rozkład SVD - przekształcenia (3)

$$\mathbf{A}_{m \times n} = \mathbf{U}_{m \times m} \mathbf{\Sigma}_{m \times n} \mathbf{V}_{n \times n}^{Tr} \quad \mathbf{A}_{n \times m}^{Tr} = \mathbf{V}_{n \times n} \mathbf{\Sigma}_{n \times m}^{Tr} \mathbf{U}_{m \times m}^{Tr}$$

$$\mathbf{A}^{Tr} \mathbf{A} = \mathbf{V} \mathbf{\Sigma}^{Tr} \underbrace{\mathbf{U}^{Tr} \mathbf{U}}_1 \mathbf{\Sigma} \mathbf{V}^{Tr} = \mathbf{V} \mathbf{\Sigma}^{Tr} \mathbf{\Sigma} \mathbf{V}^{Tr}$$

$$\mathbf{A}^{Tr} \mathbf{A} = \mathbf{V} \mathbf{\Sigma}^{Tr} \mathbf{\Sigma} \mathbf{V}^{Tr} \quad | \cdot \mathbf{V}$$

$$(\mathbf{A}^{Tr} \mathbf{A})_{n \times n} \mathbf{V}_{n \times n} = \mathbf{V}_{n \times n} (\mathbf{\Sigma}^{Tr} \mathbf{\Sigma})_{n \times n}$$

$$\sum_{k=1}^n (\mathbf{A}^{Tr} \mathbf{A})_{ik} V_{kj} = \underbrace{\sum_{\ell=1}^{\min(m,n)} V_{i\ell} \sigma_{\ell}^2 \delta_{\ell j}}_{V_{ij} \sigma_j^2}$$

$\Downarrow$

$$\mathbf{A}^{Tr} \mathbf{A} \mathbf{v}_j = \sigma_j^2 \mathbf{v}_j, \quad j = 1, \dots, \min(m, n)$$

Kolumna  $\mathbf{v}_j$  jest wektorem własnym symetrycznej macierzy  $\mathbf{A}^{Tr} \mathbf{A}$  przy wartości własnej  $\sigma_j^2$

## Rozkład SVD - przekształcenia (4)

$$\mathbf{A}_{m \times n} = \mathbf{U}_{m \times m} \mathbf{\Sigma}_{m \times n} \mathbf{V}_{n \times n}^{Tr} \quad \mathbf{A}_{n \times m}^{Tr} = \mathbf{V}_{n \times n} \mathbf{\Sigma}_{n \times m}^{Tr} \mathbf{U}_{m \times m}^{Tr}$$

$$\mathbf{A} \mathbf{A}^{Tr} = \mathbf{U} \mathbf{\Sigma} \underbrace{\mathbf{V}^{Tr} \mathbf{V}}_1 \mathbf{\Sigma}^{Tr} \mathbf{U}^{Tr} = \mathbf{U} \mathbf{\Sigma} \mathbf{\Sigma}^{Tr} \mathbf{U}^{Tr}$$

$$\mathbf{A} \mathbf{A}^{Tr} = \mathbf{U} \mathbf{\Sigma} \mathbf{\Sigma}^{Tr} \mathbf{U}^{Tr} \quad | \cdot \mathbf{U}$$

$$(\mathbf{A} \mathbf{A}^{Tr})_{m \times m} \mathbf{U}_{m \times m} = \mathbf{U}_{m \times m} (\mathbf{\Sigma} \mathbf{\Sigma}^{Tr})_{m \times m}$$

$$\sum_{k=1}^m (\mathbf{A} \mathbf{A}^{Tr})_{ik} U_{kj} = \underbrace{\sum_{\ell=1}^{\min(m,n)} U_{i\ell} \sigma_{\ell}^2 \delta_{\ell j}}_{U_{ij} \sigma_j^2}$$

$\Downarrow$

$$\mathbf{A} \mathbf{A}^{Tr} \mathbf{u}_j = \sigma_j^2 \mathbf{u}_j, \quad j = 1, \dots, \min(m, n)$$

Kolumna  $\mathbf{u}_j$  jest wektorem własnym symetrycznej macierzy  $\mathbf{A} \mathbf{A}^{Tr}$  przy wartości własnej  $\sigma_j^2$



## Zastosowania SVD

- Norma euklidesowa

$$\|A\|_2 = \max_{x \neq 0} \frac{\|Ax\|_2}{\|x\|_2} = \sigma_{\max}$$

- Rząd macierzy. W teorii rząd macierzy jest określony przez liczbę niezerowych wartości szczególnych. W praktyce przez liczbę wartości szczególnych, które są większe od zadanego progu (*rząd numeryczny macierzy*).

## Zastosowania SVD

- Wskaźnik uwarunkowania macierzy (prostokątnych i kwadratowych)

$$\text{cond}(\mathbf{A}) = \sigma_{\max}/\sigma_{\min}$$

Dla macierzy kwadratowych ten wskaźnik jest miarą osobliwości, a dla macierzy prostokątnych – liczby liniowo zależnych kolumn.

- Rozwiązywanie równań liniowych dla zagadnień najmniejszych kwadratów. Rozwiązanie minimalizujące normę euklidesową dla równania  $\mathbf{Ax} \approx \mathbf{b}$  wynosi

$$\mathbf{x} = \sum_{\sigma_i \neq 0} \frac{\mathbf{u}_i^T \mathbf{b}}{\sigma_i} \mathbf{v}_i$$

SVD jest szczególnie przydatna przy rozwiązywaniu zagadnień źle uwarunkowanych lub o macierzach o obniżonym rzędzie, gdyż w sumie można opuścić wyrazy ze zbyt małymi wartościami szczególnymi (rozwiązanie jest mniej czułe na zaburzenie danych).

## Zastosowania SVD

- Pseudoodwrotność macierzy. Pseudoodwrotnością skalarnej wartości  $\sigma$  jest  $1/\sigma$ , jeśli  $\sigma \neq 0$  lub – w przeciwnym przypadku – zero. To pozwala zdefiniować pseudoodwrotność macierzy diagonalnej  $\Sigma^+$ , która na diagonalnej ma pseudoodwrotności wartości szczególnych. Wówczas

$$A^+ = V\Sigma^+U^T$$

$A^+$  istnieje zawsze niezależnie od tego, czy macierz jest kwadratowa, czy pełnego rzędu. Jeśli macierz jest kwadratowa i nieosobliwa, to jest ona równoważna macierzy odwrotnej  $A^{-1}$ .

Rozwiązanie w sensie minimalizowania normy euklidesowej zagadnienia  $Ax \approx b$  jest równe  $A^+b$ .

## Pseudoodwrotność $\Sigma$ - przykład $4 \times 3$

$$\Sigma = \begin{pmatrix} \sigma_1 & 0 & 0 \\ 0 & \sigma_2 & 0 \\ 0 & 0 & \sigma_3 \\ 0 & 0 & 0 \end{pmatrix} \Rightarrow \Sigma^+ = \begin{pmatrix} \frac{1}{\sigma_1} & 0 & 0 & 0 \\ 0 & \frac{1}{\sigma_2} & 0 & 0 \\ 0 & 0 & \frac{1}{\sigma_3} & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix}$$

gdzie założono, że  $\sigma_i \neq 0$ ,  $i = 1, 2, 3$

$$\Sigma \Sigma^+ = \begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix} \quad \Sigma^+ \Sigma = \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \\ 0 & 0 & 0 \end{pmatrix}$$

Pseudodwrotność  $\mathbf{A}_{m \times n}$ , gdzie  $m \geq n$  oraz  $\sigma_{\min} \neq 0$

$$\mathbf{A}_{m \times n} = \mathbf{U}_{m \times m} \boldsymbol{\Sigma}_{m \times n} \mathbf{V}_{n \times n}^{Tr} \quad \mathbf{A}_{n \times m}^+ = \mathbf{V}_{n \times n} \boldsymbol{\Sigma}_{n \times m}^+ \mathbf{U}_{m \times m}^{Tr}$$

$$\mathbf{A}^+ \mathbf{A} = \mathbf{V} \boldsymbol{\Sigma}^+ \underbrace{\mathbf{U}^{Tr} \mathbf{U}}_{\mathbf{1}} \boldsymbol{\Sigma} \mathbf{V}^{Tr} = \mathbf{V} \underbrace{\boldsymbol{\Sigma}^+ \boldsymbol{\Sigma}}_{\mathbf{1}} \mathbf{V}^{Tr} = \mathbf{V} \mathbf{V}^{Tr} = \mathbf{1}_{n \times n}$$

$$\mathbf{A} \mathbf{A}^+ = \mathbf{U} \boldsymbol{\Sigma} \underbrace{\mathbf{V}^{Tr} \mathbf{V}}_{\mathbf{1}} \boldsymbol{\Sigma}^+ \mathbf{U}^{Tr} = \mathbf{U} \underbrace{\boldsymbol{\Sigma} \boldsymbol{\Sigma}^+}_{\tilde{\mathbf{1}}} \mathbf{U}^{Tr} = \mathbf{U} \tilde{\mathbf{1}} \mathbf{U}^{Tr} = \tilde{\mathbf{1}}_{m \times m}$$

$$\tilde{\mathbf{1}} = \begin{pmatrix} \mathbf{1}_{n \times n} & \mathbf{0}_{n \times (m-n)} \\ \mathbf{0}_{(m-n) \times n} & \mathbf{0}_{(m-n) \times (m-n)} \end{pmatrix}_{m \times m}$$

## Zastosowania SVD

- Bazy ortonormalne. Kolumny  $V$  odpowiadające zerowym wartościom  $\sigma$  tworzą bazę przestrzeni zerowej  $A$  (jądro przekształcenia). Pozostałe wektory  $V$  tworzą bazę ortogonalnego uzupełnienia przestrzeni zerowej. Kolumny  $U$  odpowiadające niezerowym wartościom szczególnym tworzą bazę przestrzeni będącej obrazem przekształcenia określonego przez macierz  $A$ . Pozostałe kolumny stanowią bazę ortogonalnego uzupełnienia tej przestrzeni.

## Zastosowania SVD

- Przybliżanie macierzy przez macierz o mniejszym rzędzie:

$$\mathbf{A} = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^T = \sigma_1\mathbf{E}_1 + \sigma_2\mathbf{E}_2 + \dots + \sigma_n\mathbf{E}_n$$

Każda macierz  $\mathbf{E}_i = \mathbf{u}_i\mathbf{v}_i^T$  jest rzędu 1.

Zwarte przybliżenie macierzy  $\mathbf{A}$  – suma z pominięciem wyrazów odpowiadających małym wartościom  $\sigma_i$ .

Jeśli  $\mathbf{A}$  jest przybliżona przez sumę zbudowaną przy pomocy  $k$  największych wartości szczególnych, to otrzymujemy przybliżenie  $\mathbf{A}$  najlepsze w sensie normy Frobeniusa (norma euklidesowa macierzy traktowanej jako wektor w przestrzeni  $\mathcal{R}^{mn}$ ).

Takie przybliżenie jest przydatne przy przetwarzaniu obrazów, kompresji danych, kryptografii, itp.

# „Naturalna” metoda rozkładu SVD macierzy $\mathbf{A}_{m \times n}$

„Naturalna” metoda: rozwiązać zagadnienie własne dla mniejszej macierzy symetrycznej

1.  $m \geq n$  :  $\mathbf{A}^{Tr} \mathbf{A} \mathbf{v}_j = \sigma_j^2 \mathbf{v}_j, \quad j = 1, \dots, n$
2.  $m < n$  :  $\mathbf{A} \mathbf{A}^{Tr} \mathbf{u}_k = \sigma_k^2 \mathbf{u}_k, \quad k = 1, \dots, m$

Problemy

- ▶ Najmniejsze wartości własne, a w konsekwencji  $\sigma_i$ , są narażone na **duże błędy numeryczne**
- ▶ Metoda QR ma problem ze zbieżnością, gdy  $\sigma_i = \sigma_{i+1}$
- ▶ W metodzie QR wykorzystującej ortogonalizację Grama-Schmidta problem, gdy  $\sigma_i \approx 0 \Rightarrow$  rozwiązać zagadnienie własne dla  $\mathbf{A}^{Tr} \mathbf{A} - s \mathbf{1}$  (albo  $\mathbf{A} \mathbf{A}^{Tr} - s \mathbf{1}$ ), gdzie np.  $s = 1$ ; lepiej zastosować inną metodę rozkładu QR np. używając transformacji Householdera
- ▶ Ortogonalizacja Grama-Schmidta (GS) ma swoje dodatkowe problemy... zob. zmodyfikowana metoda GS (MGS)



## Metoda rozkładu SVD macierzy $\mathbf{A}_{m \times n}$ , zał. $m \geq n$

$$\mathbf{A}_{m \times n} = \mathbf{U}_{m \times m} \mathbf{\Sigma}_{m \times n} \mathbf{V}_{n \times n}^{Tr}$$

1. Dokonać rozkładu  $\mathbf{A}_{m \times n} = \mathbf{P}_{m \times m} \mathbf{J}_{m \times n} \mathbf{Q}_{n \times n}^{Tr}$ , gdzie  $\mathbf{P}$  i  $\mathbf{Q}$  to macierze ortogonalne, a  $\mathbf{J}$  jest macierzą dwudiagonalną
2. Dokonać rozkładu SVD macierzy  $\mathbf{J}_{m \times n} = \mathbf{X}_{m \times m} \mathbf{\Sigma}_{m \times n} \mathbf{Y}_{n \times n}^{Tr}$ , gdzie  $\mathbf{X}$  i  $\mathbf{Y}$  to macierze ortogonalne, a macierz  $\mathbf{J}$  ma takie same wartości szczególne co macierz  $\mathbf{A}$
3. Obliczyć macierze ortogonalne  $\mathbf{U}$  i  $\mathbf{V}$

$$\begin{aligned} \mathbf{A} &= \mathbf{P} \mathbf{J} \mathbf{Q}^{Tr} = \mathbf{P} (\mathbf{X} \mathbf{\Sigma} \mathbf{Y}^{Tr}) \mathbf{Q}^{Tr} \\ &= (\mathbf{P} \mathbf{X}) \mathbf{\Sigma} (\mathbf{Q} \mathbf{Y})^{Tr}, \end{aligned}$$

więc

$$\mathbf{U} = \mathbf{P} \mathbf{X} \quad \mathbf{V} = \mathbf{Q} \mathbf{Y}$$

Rozkład  $\mathbf{A}_{m \times n} = \mathbf{P}_{m \times m} \mathbf{J}_{m \times n} \mathbf{Q}_{n \times n}^{Tr}$ , zał.  $m \geq n$

Macierz dwudiagonalna

$$J = \begin{pmatrix} \alpha_1 & \beta_1 & 0 & \cdot & \cdot & \cdot & 0 \\ & \alpha_2 & \beta_2 & 0 & \cdot & \cdot & \cdot \\ \mathbf{0} & & \cdot & \cdot & \cdot & \cdot & \\ & & & \cdot & \cdot & \cdot & \\ & & & & \cdot & \cdot & \\ & & & & & \cdot & \beta_{n-1} \\ & & & & & & \alpha_n \\ & & \mathbf{0} & & & & \end{pmatrix} \cdot \left. \vphantom{\begin{pmatrix} \alpha_1 \\ \alpha_2 \\ \mathbf{0} \\ \cdot \\ \cdot \\ \cdot \\ \mathbf{0} \end{pmatrix}} \right\} (m - n) \times n$$

G. Golub, W. Kahan, *Calculating the singular values and pseudo-inverse of a matrix*, J. SIAM Numer. Anal. B 2, 205-224 (1965).

Rozkład  $\mathbf{A}_{m \times n} = \mathbf{P}_{m \times m} \mathbf{J}_{m \times n} \mathbf{Q}_{n \times n}^T$ , zał.  $m \geq n$

Procedura korzystająca z transformacji Householdera

- ▶ Tworzymy kolejne macierze  $\mathbf{A}^{(1)}$ ,  $\mathbf{A}^{(3/2)}$ , ...,  $\mathbf{A}^{(k)}$ ,  $\mathbf{A}^{(k+1/2)}$ , ...,  $\mathbf{A}^{(n)}$ ,  $\mathbf{A}^{(n+1/2)}$

$$\mathbf{A}^{(1)} = \mathbf{A}$$

$$\mathbf{A}^{(k+1/2)} = \mathbf{P}^{(k)} \mathbf{A}^{(k)}, \quad k = 1, 2, \dots, n$$

$$\mathbf{A}^{(k+1)} = \mathbf{A}^{(k+1/2)} \mathbf{Q}^{(k)}, \quad k = 1, 2, \dots, n-1, \text{ właściwie do } n-2.$$

Zauważ, że  $\mathbf{J} = \mathbf{A}^{(n+1/2)}$ , ale  $\mathbf{J}$  można skonstruować osobno...

- ▶ Symetryczne i ortogonalne macierze Householdera  $\mathbf{P}^{(k)}$  i  $\mathbf{Q}^{(k)}$

$$\mathbf{P}^{(k)} = \mathbf{1} - 2\mathbf{x}^{(k)}(\mathbf{x}^{(k)})^T, \quad (\mathbf{x}^{(k)})^T \mathbf{x}^{(k)} = 1$$

$$\mathbf{Q}^{(k)} = \mathbf{1} - 2\mathbf{y}^{(k)}(\mathbf{y}^{(k)})^T, \quad (\mathbf{y}^{(k)})^T \mathbf{y}^{(k)} = 1$$

wyznaczamy z warunków

$$\mathbf{P}^{(k)} : A_{ik}^{(k+1/2)} = 0, \quad i = k+1, \dots, m$$

$$\mathbf{Q}^{(k)} : A_{kj}^{(k+1)} = 0, \quad j = k+2, \dots, n$$



Rozkład  $\mathbf{A}_{m \times n} = \mathbf{P}_{m \times m} \mathbf{J}_{m \times n} \mathbf{Q}_{n \times n}^{Tr}$ , zał.  $m \geq n$

Wyznaczenie wektora jednostkowego  $\mathbf{x}^{(k)}$  i elementu diagonalnego  $\alpha_k$

$$s_k = \sqrt{\sum_{i=k}^m |A_{ik}^{(k)}|^2}$$

$$\alpha_k = -s_k \operatorname{sign}(A_{kk}^{(k)})$$

$$x_i^{(k)} = 0, \quad i < k$$

$$x_k^{(k)} = \sqrt{\frac{1}{2} \left( 1 + \frac{|A_{kk}^{(k)}|}{s_k} \right)}$$

$$x_i^{(k)} = c_k A_{i,k}^{(k)}, \quad i = k + 1, \dots, m$$

gdzie

$$c_k = \frac{\operatorname{sign}(A_{kk}^{(k)})}{2s_k x_k^{(k)}}$$

Jeżeli  $s_k = 0$ , wtedy  $\alpha_k = 0$  i  $\mathbf{x}^{(k)} = \mathbf{0}$

G. Golub, W. Kahan, *Calculating the singular values and pseudo-inverse of a matrix*, J. SIAM Numer. Anal. B 2, 205-224 (1965).

Rozkład  $\mathbf{A}_{m \times n} = \mathbf{P}_{m \times m} \mathbf{J}_{m \times n} \mathbf{Q}_{n \times n}^T$ , zał.  $m \geq n$

Wyznaczenie wektora jednostkowego  $\mathbf{y}^{(k)}$  i elementu pozadiagonalnego  $\beta_k$

$$t_k = \sqrt{\sum_{j=k+1}^n |A_{kj}^{(k+1/2)}|^2}$$

$$\beta_k = -t_k \operatorname{sign}(A_{k,k+1}^{(k+1/2)})$$

$$y_j^{(k)} = 0, \quad j \leq k$$

$$y_{k+1}^{(k)} = \sqrt{\frac{1}{2} \left( 1 + \frac{|A_{k,k+1}^{(k+1/2)}|}{t_k} \right)}$$

$$y_j^{(k)} = d_k A_{k,j}^{(k+1/2)}, \quad j = k+2, \dots, n$$

gdzie

$$d_k = \frac{\operatorname{sign}(A_{k,k+1}^{(k+1/2)})}{2t_k y_{k+1}^{(k)}}$$

Jeżeli  $t_k = 0$ , wtedy  $\beta_k = 0$  i  $\mathbf{y}^{(k)} = \mathbf{0}$

G. Golub, W. Kahan, *Calculating the singular values and pseudo-inverse of a matrix*, J. SIAM Numer. Anal. B 2, 205-224 (1965).

Rozkład  $\mathbf{A}_{m \times n} = \mathbf{P}_{m \times m} \mathbf{J}_{m \times n} \mathbf{Q}_{n \times n}^T$ , zał.  $m \geq n$

$$\mathbf{A}^{(1)} = \mathbf{A}$$

$$\mathbf{A}^{(k+1/2)} = \mathbf{P}^{(k)} \mathbf{A}^{(k)}, \quad k = 1, 2, \dots, n$$

$$\mathbf{A}^{(k+1)} = \mathbf{A}^{(k+1/2)} \mathbf{Q}^{(k)}, \quad k = 1, 2, \dots, n-1.$$

$$\mathbf{A}^{(n+1/2)} = \mathbf{J}$$

↓

$$\mathbf{A}^{(3/2)} = \mathbf{P}^{(1)} \mathbf{A}^{(1)}$$

$$\mathbf{A}^{(2)} = \mathbf{P}^{(1)} \mathbf{A}^{(1)} \mathbf{Q}^{(1)}$$

$$\mathbf{A}^{(5/2)} = \mathbf{P}^{(2)} \mathbf{P}^{(1)} \mathbf{A}^{(1)} \mathbf{Q}^{(1)}$$

$$\mathbf{A}^{(3)} = \mathbf{P}^{(2)} \mathbf{P}^{(1)} \mathbf{A}^{(1)} \mathbf{Q}^{(1)} \mathbf{Q}^{(2)}$$

⋮

$$\mathbf{A}^{(n+1/2)} = \mathbf{P}^{(n)} \dots \mathbf{P}^{(2)} \mathbf{P}^{(1)} \mathbf{A}^{(1)} \mathbf{Q}^{(1)} \mathbf{Q}^{(2)} \dots \mathbf{Q}^{(n-1)}$$

Rozkład  $\mathbf{A}_{m \times n} = \mathbf{P}_{m \times m} \mathbf{J}_{m \times n} \mathbf{Q}_{n \times n}^{Tr}$ , zał.  $m \geq n$

$$\mathbf{A}^{(1)} = \mathbf{A}$$

$$\mathbf{A}^{(k+1/2)} = \mathbf{P}^{(k)} \mathbf{A}^{(k)}, \quad k = 1, 2, \dots, n$$

$$\mathbf{A}^{(k+1)} = \mathbf{A}^{(k+1/2)} \mathbf{Q}^{(k)}, \quad k = 1, 2, \dots, n-1.$$

$$\mathbf{A}^{(n+1/2)} = \mathbf{J}$$

↓

$$(\mathbf{P}^{(n)})^{Tr} \mid \mathbf{J} = \mathbf{P}^{(n)} \dots \mathbf{P}^{(2)} \mathbf{P}^{(1)} \mathbf{A} \mathbf{Q}^{(1)} \mathbf{Q}^{(2)} \dots \mathbf{Q}^{(n-1)} \mid (\mathbf{Q}^{(n-1)})^{Tr}$$

$$(\mathbf{P}^{(n-1)})^{Tr} \mid \mathbf{P}^{(n)} \mathbf{J} \mathbf{Q}^{(n-1)} = \mathbf{P}^{(n-1)} \dots \mathbf{P}^{(2)} \mathbf{P}^{(1)} \mathbf{A} \mathbf{Q}^{(1)} \mathbf{Q}^{(2)} \dots \mathbf{Q}^{(n-2)} \mid (\mathbf{Q}^{(n-2)})^{Tr}$$

$$\mathbf{P}^{(n-1)} \mathbf{P}^{(n)} \mathbf{J} \mathbf{Q}^{(n-1)} \mathbf{Q}^{(n-2)} = \mathbf{P}^{(n-2)} \dots \mathbf{P}^{(2)} \mathbf{P}^{(1)} \mathbf{A} \mathbf{Q}^{(1)} \mathbf{Q}^{(2)} \dots \mathbf{Q}^{(n-3)}$$

⋮

$$\mathbf{P}^{(2)} \dots \mathbf{P}^{(n-1)} \mathbf{P}^{(n)} \mathbf{J} \mathbf{Q}^{(n-1)} \mathbf{Q}^{(n-2)} \dots \mathbf{Q}^{(2)} = \mathbf{P}^{(1)} \mathbf{A} \mathbf{Q}^{(1)}$$

$$\underbrace{\mathbf{P}^{(1)} \mathbf{P}^{(2)} \dots \mathbf{P}^{(n-1)} \mathbf{P}^{(n)}}_{\mathbf{P}} \mathbf{J} \underbrace{\mathbf{Q}^{(n-1)} \mathbf{Q}^{(n-2)} \dots \mathbf{Q}^{(2)} \mathbf{Q}^{(1)}}_{\mathbf{Q}^{Tr}} = \mathbf{A}$$



Rozkład  $\mathbf{A}_{m \times n} = \mathbf{P}_{m \times m} \mathbf{J}_{m \times n} \mathbf{Q}_{n \times n}^{Tr}$ , zał.  $m \geq n$

$$\mathbf{A}^{(1)} = \mathbf{A}$$

$$\mathbf{A}^{(k+1/2)} = \mathbf{P}^{(k)} \mathbf{A}^{(k)}, \quad k = 1, 2, \dots, n$$

$$\mathbf{A}^{(k+1)} = \mathbf{A}^{(k+1/2)} \mathbf{Q}^{(k)}, \quad k = 1, 2, \dots, n-1.$$

$$\mathbf{A}^{(n+1/2)} = \mathbf{J}$$

⇓

Macierze ortogonalne

$$\mathbf{P} = \mathbf{P}^{(1)} \mathbf{P}^{(2)} \dots \mathbf{P}^{(n)}$$

$$\mathbf{Q}^{Tr} = \mathbf{Q}^{(n-1)} \dots \mathbf{Q}^{(2)} \mathbf{Q}^{(1)}$$

Przy okazji wyznaczania wektorów  $\mathbf{x}^{(k)}$  i  $\mathbf{y}^{(k)}$  obliczyliśmy elementy diagonalne  $\alpha_k$  i pozadiagonalne  $\beta_k$  macierz dwudiagonalnej  $\mathbf{J}$

## Dygresja: Równość wartości szczególnych macierzy $\mathbf{J}$ i $\mathbf{A}$

Mamy następujące rozkłady macierzy

$$\mathbf{A} = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^{Tr}, \quad \mathbf{A} = \mathbf{P}\mathbf{J}\mathbf{Q}^{Tr}, \quad \mathbf{J} = \mathbf{X}\mathbf{\Sigma}'\mathbf{Y}^{Tr}.$$

Pokażemy, że  $\mathbf{\Sigma} = \mathbf{\Sigma}'$ :

$$\begin{aligned} \mathbf{P}^{Tr} \times | \quad \mathbf{P}\mathbf{J}\mathbf{Q}^{Tr} = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^{Tr} \quad | \times \mathbf{Q} \\ \mathbf{J} = \mathbf{P}^{Tr}\mathbf{U}\mathbf{\Sigma}\mathbf{V}^{Tr}\mathbf{Q} \end{aligned}$$

Ponieważ  $\mathbf{P}^{Tr}\mathbf{U}$  i  $\mathbf{V}^{Tr}\mathbf{Q}$  są macierzami ortogonalnymi, to uzyskaliśmy rozkład SVD macierzy  $\mathbf{J}$ , więc z jednoznaczności<sup>1</sup> SVD mamy w szczególności  $\mathbf{\Sigma}' = \mathbf{\Sigma}$ .

---

<sup>1</sup>SVD nie jest w pełni jednoznaczny, ale dla danej macierzy mamy na pewno jeden zbiór wartości szczególnych.

Rozkład SVD macierzy dwudiagonalnej  $\mathbf{J}_{m \times n} = \mathbf{X}_{m \times m} \mathbf{\Sigma}_{m \times n} \mathbf{Y}_{n \times n}^T$

1. Znaleźć wartości własne  $\lambda_i$  symetrycznej macierzy trójdzielnej  $\mathbf{K}_{n \times n} = \mathbf{J}^T \mathbf{J}$ , gdzie  $\lambda_{n-i+1} = \sigma_i^2$  oraz  $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_n$
2. Znaleźć wektory własne  $\mathbf{y}_i$  macierzy  $\mathbf{K}$ , tzn. takie, że  $\mathbf{K} \mathbf{y}_i = \sigma_i^2 \mathbf{y}_i$ ;  $\mathbf{y}_i$  jest  $i$ -tą kolumną ortogonalnej macierzy  $\mathbf{Y}$  (zobacz zad. 9)

Uwaga: Każdy wektor własny  $\mathbf{y}_i$  musi być unormowany w sensie normy Euklidesowej, tzn.

$$\|\mathbf{y}\|_2 = \sqrt{\sum_{j=1}^n |y_j|^2} = 1$$

Normowanie wektora:  $\mathbf{y}_i \rightarrow \frac{\mathbf{y}_i}{\|\mathbf{y}_i\|_2}$

3. Znaleźć kolumny  $\mathbf{x}_j$  macierzy  $\mathbf{X}$

$$\mathbf{x}_j = \frac{1}{\sigma_j} \mathbf{J} \mathbf{y}_j, \quad \sigma_j > 0$$

Na razie problemy w punktach 2. i 3., gdy  $\sigma_j \sim 0 \dots$

# Wartości własne symetrycznej i trójdzielnej macierzy $\mathbf{K}$

Macierz symetryczna trójdzielna

$$\mathbf{K}_{n \times n} = \begin{pmatrix} c_1 & b_2 & 0 & \dots & \dots & \dots & \dots & \dots & 0 \\ b_2 & c_2 & b_3 & 0 & \dots & \dots & \dots & \dots & 0 \\ 0 & b_3 & c_3 & b_4 & 0 & \dots & \dots & \dots & 0 \\ \vdots & \ddots & \ddots & \ddots & \ddots & \ddots & & & \vdots \\ 0 & \dots & 0 & b_k & c_k & b_{k+1} & 0 & \dots & 0 \\ \vdots & & & \ddots & \ddots & \ddots & \ddots & \ddots & \vdots \\ 0 & \dots & \dots & \dots & 0 & b_{n-2} & c_{n-2} & b_{n-1} & 0 \\ 0 & \dots & \dots & \dots & \dots & 0 & b_{n-1} & c_{n-1} & b_n \\ 0 & \dots & \dots & \dots & \dots & \dots & 0 & b_n & c_n \end{pmatrix}$$

W. Barth, R. S. Martin and J. H. Wilkinson, *Calculation of the Eigenvalues of a Symmetric Tridiagonal*

*Matrix by the Method of Bisection*, Numerische Mathematik 9, 386-393 (1967) .

# Wartości własne symetrycznej i trójdzielnej macierzy $\mathbf{K}$

## Oznaczenia

- ▶  $\mathbf{c} = [c_1, c_2, \dots, c_n]^T$  - wektor reprezentujący główną diagonalę macierzy  $\mathbf{K}_{n \times n}$
- ▶  $\mathbf{b} = [0, b_2, \dots, b_n]^T$  - wektor reprezentujący elementy pozadiagonalne macierzy  $\mathbf{K}_{n \times n}$

W. Barth, R. S. Martin and J. H. Wilkinson, *Calculation of the Eigenvalues of a Symmetric Tridiagonal Matrix by the Method of Bisection*, Numerische Mathematik 9, 386-393 (1967) .

# Wartości własne symetrycznej i trójdzielnej macierzy $\mathbf{K}$

## Twierdzenie:

Wartości własne  $\lambda_i$  macierzy  $\mathbf{K}$  znajdują się w przedziale  $[\lambda_{min}, \lambda_{max}]$ , gdzie  $(b_1 = b_{n+1} = 0)$

$$\lambda_{min} = \min_{i=1, \dots, n} [c_i - (|b_i| + |b_{i+1}|)]$$

$$\lambda_{max} = \max_{i=1, \dots, n} [c_i + (|b_i| + |b_{i+1}|)],$$

W. Barth, R. S. Martin and J. H. Wilkinson, *Calculation of the Eigenvalues of a Symmetric Tridiagonal Matrix by the Method of Bisection*, Numerische Mathematik 9, 386-393 (1967) .

# Wartości własne symetrycznej i trójkątnej macierzy $\mathbf{K}$

## Twierdzenie ( $\sim$ Sturma):

Mamy ciąg ( $\sim$ Sturma)

$$q_1(\lambda) = c_1 - \lambda$$

$$q_i(\lambda) = (c_i - \lambda) - b_i^2/q_{i-1}(\lambda), \quad i = 2, \dots, n$$

Liczba  $a(\lambda)$ , będąca liczbą ujemnych wyrazów ciągu  $\{q_i(\lambda)\}_{i=1}^n$  jest równa liczbie wartości własnych macierzy  $\mathbf{K}$  mniejszych od  $\lambda$

Uwaga techniczna: gdy  $q_{i-1} = 0$ , wtedy  $q_i(\lambda) = (c_i - \lambda) - |b_i|/\epsilon_{mach}$ , gdzie  $\epsilon_{mach}$  jest najmniejszą wartością  $\epsilon$ , dla której  $1 + \epsilon > 1$ .

W. Barth, R. S. Martin and J. H. Wilkinson, *Calculation of the Eigenvalues of a Symmetric Tridiagonal Matrix by the Method of Bisection*, Numerische Mathematik 9, 386-393 (1967) .

# Wartości własne symetrycznej i trójdzielnej macierzy $\mathbf{K}$

Bisekcja poszukująca wartości własne  $\lambda_k \in [\lambda_{min}, \lambda_{max}]$ ,  
 $k = n, n - 1, \dots, 1$  macierzy  $\mathbf{K}$ . Niech  $\lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_n$ .

Na początku  $x_l = \lambda_{min}$ ,  $x_u = \lambda_{max}$

1. Jeżeli  $x_u - x_l < \epsilon$ , to kończymy
2. Wyznaczamy środek przedziału (bisekcja)  $x = (x_l + x_u)/2$
3. Jeżeli  $a(x) < k$  to  $x_l = x$ , w przeciwnym wypadku  $x_u = x$

Uwagi:

- ▶ Można **bardzo precyzyjnie** wyznaczyć wszystkie wartości własne <sup>2</sup>
- ▶ Na podstawie bieżących obliczeń, można przy okazji wyciągać informacje dla pozostałych wartości własnych, tzn. zacieśniać ich przedziały przeszukiwania (zob. na następnej stronie)

W. Barth, R. S. Martin and J. H. Wilkinson, *Calculation of the Eigenvalues of a Symmetric Tridiagonal Matrix by the Method of Bisection*, Numerische Mathematik 9, 386-393 (1967) .

---

<sup>2</sup>Z ograniczoną precyzją dla  $\lambda_k \sim 0$



# Wartości własne symetrycznej i trójkątnej macierzy $K$

## Modyfikacja bisekcji

- ▶ Wektor  $\mathbf{w} = [w_1, \dots, w_n]^T$  przechowuje bieżące dolne ograniczenia na wartości własne
- ▶ Wektor  $\mathbf{x} = [x_1, \dots, x_n]^T$  przechowuje bieżące górne ograniczenia na wartości własne, docelowo będzie zawierał wyznaczone wartości własne
- ▶ Na początku  $w_i = \lambda_{min}$ ,  $x_i = \lambda_{max}$ .
- ▶ Bisekcja dla  $k = n, \dots, 1$ , gdzie  $\lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_n$ .
  1.  $x_l = w_k$ ,  $x_u = x_k$ , jeżeli  $x_u - x_l < \epsilon$ , to kończymy
  2. Wyznaczamy środek przedziału (bisekcja)  $x_k = (x_l + x_u)/2$
  3. Jeżeli  $a(x_k) < k$  to  $x_l = x_k$ , w przeciwnym wypadku  $x_u = x_k$ .  
Przy okazji jeżeli  $a(x_k) < k$ , to  $x_k$  ogranicza wartości  $\lambda_1, \dots, \lambda_a$  z góry, jednocześnie ogranicza z dołu wartości  $\lambda_{a+1}, \lambda_{a+2}, \dots, \lambda_k$ .
    - ▶ Oznacza to, że dla  $i = 1, \dots, a$  jeżeli  $x_i > x_k$ , to  $x_i = x_k$ .
    - ▶ Także to oznacza, że dla  $i = a + 1, \dots, k$  jeżeli  $w_i < x_k$ , to  $w_i = x_k$ .

# Do zrobienia

1. Wczytać prostokątną macierz  $\mathbf{A}_{m \times n}$  o elementach rzeczywistych
2. Wyznaczyć macierze  $\mathbf{U}_{m \times m}$ ,  $\mathbf{\Sigma}_{m \times n}$   $\mathbf{V}_{n \times n}$
3. Sprawdzić czy  $\mathbf{A} = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^{Tr}$
4. Wyznaczyć macierz pseudoodwrotną  $\mathbf{A}^+ = \mathbf{V}\mathbf{\Sigma}^+\mathbf{U}^{Tr}$ , gdzie

$$\mathbf{A}_{n \times m}^+, \mathbf{V}_{n \times n}, \mathbf{\Sigma}_{n \times m}^+, \mathbf{U}_{m \times m}^{Tr}$$

5. Sprawdzić, czy  $\mathbf{A}^+\mathbf{A} = \mathbf{1}_{n \times n}$  (czy  $\mathbf{A}\mathbf{A}^+ = \mathbf{1}_{m \times m}$ ?) (spr.  $\mathbf{\Sigma}^+\mathbf{\Sigma}$  oraz  $\mathbf{\Sigma}\mathbf{\Sigma}^+$ )
6. Czy do zastosowań rozkładu SVD potrzebujemy wszystkich kolumn większej macierzy ortogonalnej? Jeżeli nie, to których?

# Przykłady

$$\mathbf{A}_1 = \begin{pmatrix} 1 & 2 \\ 3 & 4 \\ 5 & 6 \end{pmatrix}$$

$$\mathbf{A}_2 = \begin{pmatrix} 1 & 2 & 3 \\ 2 & 3 & 4 \\ 3 & 4 & 5 \\ 4 & 6 & 5 \end{pmatrix} \quad \mathbf{A}_3 = \begin{pmatrix} 1 & 2 & 3 \\ 2 & 3 & 4 \\ 3 & 4 & 5 \\ 4 & 5 & 6 \end{pmatrix}$$

$$\mathbf{A}_4 = \begin{pmatrix} 21 & 0 & 770 & 0 & 50666 \\ 0 & 770 & 0 & 50666 & 0 \\ 770 & 0 & 50666 & 0 & 3956810 \\ 0 & 50666 & 0 & 3956810 & 0 \\ 50666 & 0 & 3956810 & 0 & 335462666 \end{pmatrix}$$

# Dodatek: Rozkład SVD macierzy prostokątnych z wykorzystaniem metody QR

Rozkład SVD macierzy prostokątnej

$$\mathbf{A}_{N \times M} = \mathbf{U}_{N \times N} \mathbf{\Sigma}_{N \times M} \mathbf{V}_{M \times M}^{Tr}$$

Wyznaczamy mniejszą z macierzy ortogonalnych  $\mathbf{V}$  albo  $\mathbf{U}$ , tzn.

$$1^\circ N \geq M$$

$$2^\circ N < M$$

$$(\mathbf{A}^{Tr} \mathbf{A}) \mathbf{v}_k = \sigma_k^2 \mathbf{v}_k, \quad k = 1, \dots, M$$

$$(\mathbf{A} \mathbf{A}^{Tr}) \mathbf{u}_j = \sigma_j^2 \mathbf{u}_j, \quad j = 1, \dots, N$$

↓

↓

$$\mathbf{V} = [\mathbf{v}_1 \ \mathbf{v}_2 \ \dots \ \mathbf{v}_M]$$

$$\mathbf{U} = [\mathbf{u}_1 \ \mathbf{u}_2 \ \dots \ \mathbf{u}_N]$$

Kolejność kolumn w  $\mathbf{V}$  (albo  $\mathbf{U}$ ) jest wyznaczona relacją

$$\sigma_1 > \sigma_2 > \dots > \sigma_r, \quad r = \min(N, M)$$

Jeżeli powyższe równanie własne macierzy symetrycznych  $\mathbf{A}^{Tr} \mathbf{A}$  (albo  $\mathbf{A} \mathbf{A}^{Tr}$ ) rozwiązujemy metodą QR z ortogonalizacją Grama-Schmidta, to dla macierzy symetrycznych, kolumny macierzy ortogonalnej  $\mathbf{Q} = \mathbf{Q}_1 \mathbf{Q}_2 \dots \mathbf{Q}_{k_{max}}$ , są wektorami własnymi rozpatrywanej macierzy symetrycznej, tzn. w naszym przypadku  $\mathbf{Q} = \mathbf{V}$  (albo  $\mathbf{Q} = \mathbf{U}$ ) o ile kolumny macierzy  $\mathbf{Q}$  zostały przesortowane tak, że  $\sigma_1 > \sigma_2 > \sigma_3 > \dots > \sigma_r$ . Macierze ortogonalne  $\mathbf{Q}_k$  pochodzą z  $k$ -tej iteracji metody QR znajdowania wartości własnych macierzy kwadratowych.

# Dodatek: Rozkład SVD macierzy prostokątnych z wykorzystaniem metody QR

Rozkład SVD macierzy prostokątnej

$$\mathbf{A}_{N \times M} = \mathbf{U}_{N \times N} \mathbf{\Sigma}_{N \times M} \mathbf{V}_{M \times M}^{Tr}$$

Wyznaczamy mniejszą z macierzy ortogonalnych  $\mathbf{V}$  albo  $\mathbf{U}$ , tzn.

$$1^\circ N \geq M$$

$$2^\circ N < M$$

$$(\mathbf{A}^{Tr} \mathbf{A}) \mathbf{v}_k = \sigma_k^2 \mathbf{v}_k, \quad k = 1, \dots, M$$

$$(\mathbf{A} \mathbf{A}^{Tr}) \mathbf{u}_j = \sigma_j^2 \mathbf{u}_j, \quad j = 1, \dots, N$$

↓

↓

$$\mathbf{V} = [\mathbf{v}_1 \ \mathbf{v}_2 \ \dots \ \mathbf{v}_M]$$

$$\mathbf{U} = [\mathbf{u}_1 \ \mathbf{u}_2 \ \dots \ \mathbf{u}_N]$$

Kolejność kolumn w  $\mathbf{V}$  (albo  $\mathbf{U}$ ) jest wyznaczona relacją

$$\sigma_1 > \sigma_2 > \dots > \sigma_r, \quad r = \min(N, M)$$

Jeżeli powyższe równanie własne macierzy symetrycznych  $\mathbf{A}^{Tr} \mathbf{A}$  (albo  $\mathbf{A} \mathbf{A}^{Tr}$ ) rozwiązujemy metodą QR z ortogonalizacją Grama-Schmidta, to możemy napotkać na następujące trudności

1.  $\sigma_k = \sigma_{k+1} \Rightarrow$  mogą wystąpić problemy ze zbieżnością metody QR
2.  $\sigma_r \approx 0 \Rightarrow$  ortogonalizacja Grama-Schmidta będzie narażona na duże błędy numeryczne lub zupełnie zawiedzie

Wskazówka: rozwiązać równanie własne dla  $\mathbf{A}^{Tr} \mathbf{A} + s \mathbf{1}$  (albo  $\mathbf{A} \mathbf{A}^{Tr} + s \mathbf{1}$ ), gdzie np.  $s \sim 1$

# Dodatek: Wyznaczenie drugiej (większej) macierzy ortogonalnej

Rozkład SVD macierzy prostokątnej

$$\mathbf{A}_{N \times M} = \mathbf{U}_{N \times N} \mathbf{\Sigma}_{N \times M} \mathbf{V}_{M \times M}^T$$

$$1^\circ N \geq M$$

Obliczamy  $M$  początkowych kolumn macierzy  $\mathbf{U}$  wg wzoru

$$\mathbf{u}_i = \frac{1}{\sigma_i} \mathbf{A} \mathbf{v}_i, \quad \sigma_i > 0$$

Co się dzieje, gdy  $\sigma_r = 0$  (lub  $\sigma_r \approx 0$ ) dla  $r \leq \min(N, M)$ ?

$$\sigma_r \mathbf{u}_r = \mathbf{A} \mathbf{v}_r, \quad \sigma_r = 0$$



$$\mathbf{A} \mathbf{v}_r = \mathbf{0}$$

Kolumna  $\mathbf{u}_r$  (lub  $\mathbf{v}_r$ ) wyznaczamy z warunków dla  $i = 1, 2, \dots, r - 1$

$$\mathbf{u}_i^T \mathbf{u}_r = \delta_{ir}$$

$$\mathbf{A}_{M \times N}^T = \mathbf{V}_{M \times M} \mathbf{\Sigma}_{M \times N}^T \mathbf{U}_{N \times N}^T$$

$$2^\circ N < M$$

Obliczamy  $N$  początkowych kolumn macierzy  $\mathbf{V}$  wg wzoru

$$\mathbf{v}_i = \frac{1}{\sigma_i} \mathbf{A}^T \mathbf{u}_i, \quad \sigma_i > 0$$

$$\sigma_r \mathbf{v}_r = \mathbf{A}^T \mathbf{u}_r, \quad \sigma_r = 0$$



$$\mathbf{A}^T \mathbf{u}_r = \mathbf{0}$$

$$\mathbf{v}_i^T \mathbf{v}_r = \delta_{ir}$$

## Dodatek: Wyznaczenie drugiej (większej) macierzy ortogonalnej

Rozkład SVD macierzy prostokątnej

$$\mathbf{A}_{N \times M} = \mathbf{U}_{N \times N} \mathbf{\Sigma}_{N \times M} \mathbf{V}_{M \times M}^{Tr}$$

$$1^\circ N \geq M$$

Obliczamy  $M$  początkowych kolumn macierzy  $\mathbf{U}$  wg wzoru

$$\mathbf{u}_i = \frac{1}{\sigma_i} \mathbf{A} \mathbf{v}_i, \quad \sigma_i > 0$$

Kolumny  $\mathbf{u}_i$  (lub  $\mathbf{v}_i$ ), gdzie  $i > \min(N, M)$ , wyznaczamy z warunków dla  $j = 1, 2, \dots, i - 1$

$$\mathbf{u}_j^{Tr} \mathbf{u}_i = \delta_{ji}, \quad i = M + 1, \dots, N$$

$$\mathbf{A}_{M \times N}^{Tr} = \mathbf{V}_{M \times M} \mathbf{\Sigma}_{M \times N}^{Tr} \mathbf{U}_{N \times N}^{Tr}$$

$$2^\circ N < M$$

Obliczamy  $N$  początkowych kolumn macierzy  $\mathbf{V}$  wg wzoru

$$\mathbf{v}_i = \frac{1}{\sigma_i} \mathbf{A}^{Tr} \mathbf{u}_i, \quad \sigma_i > 0$$

$$\mathbf{v}_j^{Tr} \mathbf{v}_i = \delta_{ji}, \quad i = N + 1, \dots, M$$

## Dodatek: „Uzupełnienie” macierzy ortogonalnej

- ▶  $\mathbf{Q}$  jest macierzą kwadratową  $n \times n$
- ▶ Znamy  $m < n$  początkowych kolumn  $\mathbf{q}_i$ , gdzie  $i = 1, \dots, m$ , macierzy  $\mathbf{Q}$  spełniających warunki

$$\mathbf{q}_i^T \mathbf{q}_j = \delta_{ij}, \quad i, j = 1, 2, \dots, m$$

- ▶ Chcemy, żeby cała macierz była ortogonalna tzn., że wszystkie kolumny są wzajemnie ortogonalne i unormowane do 1
  1. Wypełniamy (nieznane) kolumny  $\mathbf{q}_k$ , gdzie  $k > m$  liczbami (pseudo)losowymi, aby uniknąć liniowych zależności (co zrobić jeżeli okaże się, że dana kolumna  $\mathbf{q}_k$ , gdzie  $k > m$ , jest jednak liniowo zależna?)
  2. Kolejno dla kolumn  $\mathbf{q}_k$ , gdzie  $k = m + 1, \dots, n$ , dokonujemy ortogonalizacji Grama-Schmidta, tzn.

$$\mathbf{q}'_k = \mathbf{q}_k - \sum_{i=1}^{k-1} (\mathbf{q}_k^T \mathbf{q}_i) \mathbf{q}_i \quad \text{ortogonalizacja}$$

$$\mathbf{q}''_k = \frac{\mathbf{q}'_k}{\|\mathbf{q}'_k\|_2} \quad \text{normalizacja}$$

gdzie

$$\|\mathbf{q}'_k\|_2 = \sqrt{\mathbf{q}'_k{}^T \mathbf{q}'_k} = \sqrt{\sum_{i=1}^n (q'_{ik})^2}$$