

# Szinguláris értékek

Wettl Ferenc

2014. október 13.

- 1 Szinguláris érték
- 2 Alkalmazások
- 3 Norma
- 4 Mátrixnorma

- D A pozitív  $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r > 0$  számok az  $r$ -rangú valós (komplex) **A** mátrix **szinguláris értékei**, ha van olyan  $\{\mathbf{v}_1, \dots, \mathbf{v}_r\}$  ONB-a a sortérnek (konjugáltjának) és  $\{\mathbf{u}_1, \dots, \mathbf{u}_r\}$  ONB-a az oszloptérnek (konjugáltjának), hogy

$$\mathbf{A}\mathbf{v}_i = \sigma_i\mathbf{u}_i, \quad i = 1, \dots, r.$$

- D A pozitív  $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r > 0$  számok az  $r$ -rangú valós (komplex) **A** mátrix **szinguláris értékei**, ha van olyan  $\{\mathbf{v}_1, \dots, \mathbf{v}_r\}$  ONB-a a sortérnek (konjugáltjának) és  $\{\mathbf{u}_1, \dots, \mathbf{u}_r\}$  ONB-a az oszloptérnek (konjugáltjának), hogy

$$\mathbf{A}\mathbf{v}_i = \sigma_i\mathbf{u}_i, \quad i = 1, \dots, r.$$

A  $\mathbf{v}_i$  vektorokat **bal**, az  $\mathbf{u}_i$  vektorokat **jobb szinguláris vektoroknak** nevezzük.

- D A pozitív  $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r > 0$  számok az  $r$ -rangú valós (komplex)  $\mathbf{A}$  mátrix **szinguláris értékei**, ha van olyan  $\{\mathbf{v}_1, \dots, \mathbf{v}_r\}$  ONB-a a sortérnek (konjugáltjának) és  $\{\mathbf{u}_1, \dots, \mathbf{u}_r\}$  ONB-a az oszloptérnek (konjugáltjának), hogy

$$\mathbf{A}\mathbf{v}_i = \sigma_i\mathbf{u}_i, \quad i = 1, \dots, r.$$

A  $\mathbf{v}_i$  vektorokat **bal**, az  $\mathbf{u}_i$  vektorokat **jobb szinguláris vektoroknak** nevezzük.

- M  $|\mathbf{u}_i| = 1$  ( $i = 1, 2, \dots, r$ )  $\rightsquigarrow |\mathbf{A}\mathbf{v}_i| = \sigma_i$ .

- D A pozitív  $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r > 0$  számok az  $r$ -rangú valós (komplex)  $\mathbf{A}$  mátrix **szinguláris értékei**, ha van olyan  $\{\mathbf{v}_1, \dots, \mathbf{v}_r\}$  ONB-a a sortérnek (konjugáltjának) és  $\{\mathbf{u}_1, \dots, \mathbf{u}_r\}$  ONB-a az oszloptérnek (konjugáltjának), hogy

$$\mathbf{A}\mathbf{v}_i = \sigma_i\mathbf{u}_i, \quad i = 1, \dots, r.$$

A  $\mathbf{v}_i$  vektorokat **bal**, az  $\mathbf{u}_i$  vektorokat **jobb szinguláris vektoroknak** nevezzük.

- M  $|\mathbf{u}_i| = 1$  ( $i = 1, 2, \dots, r$ )  $\rightsquigarrow |\mathbf{A}\mathbf{v}_i| = \sigma_i$ .

Lehetne így:  $k = \min(m, n)$ , és  $\sigma_{r+1} = \sigma_{r+2} = \dots = \sigma_k = 0$ .

- D A pozitív  $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r > 0$  számok az  $r$ -rangú valós (komplex)  $\mathbf{A}$  mátrix **szinguláris értékei**, ha van olyan  $\{\mathbf{v}_1, \dots, \mathbf{v}_r\}$  ONB-a a sortérnek (konjugáltjának) és  $\{\mathbf{u}_1, \dots, \mathbf{u}_r\}$  ONB-a az oszloptérnek (konjugáltjának), hogy

$$\mathbf{A}\mathbf{v}_i = \sigma_i\mathbf{u}_i, \quad i = 1, \dots, r.$$

A  $\mathbf{v}_i$  vektorokat **bal**, az  $\mathbf{u}_i$  vektorokat **jobb szinguláris vektoroknak** nevezzük.

- M  $|\mathbf{u}_i| = 1$  ( $i = 1, 2, \dots, r$ )  $\rightsquigarrow |\mathbf{A}\mathbf{v}_i| = \sigma_i$ .

Lehetne így:  $k = \min(m, n)$ , és  $\sigma_{r+1} = \sigma_{r+2} = \dots = \sigma_k = 0$ .

- P  $\{\mathbf{v}_1, \mathbf{v}_2\} = \left\{ \left( \frac{4}{5}, -\frac{3}{5} \right), \left( \frac{3}{5}, \frac{4}{5} \right) \right\}$ ,  $\{\mathbf{u}_1, \mathbf{u}_2\} = \left\{ \left( -\frac{5}{13}, \frac{12}{13} \right), \left( \frac{12}{13}, \frac{5}{13} \right) \right\}$

$$\begin{bmatrix} -4/13 & 6 \\ 111/13 & -4 \end{bmatrix} \begin{bmatrix} 4/5 \\ -3/5 \end{bmatrix} = 10 \begin{bmatrix} -5/13 \\ 12/13 \end{bmatrix}, \quad \begin{bmatrix} -4/13 & 6 \\ 111/13 & -4 \end{bmatrix} \begin{bmatrix} 3/5 \\ 4/5 \end{bmatrix} = 5 \begin{bmatrix} 12/13 \\ 5/13 \end{bmatrix},$$

- D A pozitív  $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r > 0$  számok az  $r$ -rangú valós (komplex)  $\mathbf{A}$  mátrix **szinguláris értékei**, ha van olyan  $\{\mathbf{v}_1, \dots, \mathbf{v}_r\}$  ONB-a a sortérnek (konjugáltjának) és  $\{\mathbf{u}_1, \dots, \mathbf{u}_r\}$  ONB-a az oszloptérnek (konjugáltjának), hogy

$$\mathbf{A}\mathbf{v}_i = \sigma_i\mathbf{u}_i, \quad i = 1, \dots, r.$$

A  $\mathbf{v}_i$  vektorokat **bal**, az  $\mathbf{u}_i$  vektorokat **jobb szinguláris vektoroknak** nevezzük.

- M  $|\mathbf{u}_i| = 1$  ( $i = 1, 2, \dots, r$ )  $\rightsquigarrow |\mathbf{A}\mathbf{v}_i| = \sigma_i$ .

Lehetne így:  $k = \min(m, n)$ , és  $\sigma_{r+1} = \sigma_{r+2} = \dots = \sigma_k = 0$ .

- P  $\{\mathbf{v}_1, \mathbf{v}_2\} = \left\{ \left( \frac{4}{5}, -\frac{3}{5} \right), \left( \frac{3}{5}, \frac{4}{5} \right) \right\}$ ,  $\{\mathbf{u}_1, \mathbf{u}_2\} = \left\{ \left( -\frac{5}{13}, \frac{12}{13} \right), \left( \frac{12}{13}, \frac{5}{13} \right) \right\}$

$$\begin{bmatrix} -4/13 & 6 \\ 111/13 & -4 \end{bmatrix} \begin{bmatrix} 4/5 \\ -3/5 \end{bmatrix} = 10 \begin{bmatrix} -5/13 \\ 12/13 \end{bmatrix}, \quad \begin{bmatrix} -4/13 & 6 \\ 111/13 & -4 \end{bmatrix} \begin{bmatrix} 3/5 \\ 4/5 \end{bmatrix} = 5 \begin{bmatrix} 12/13 \\ 5/13 \end{bmatrix},$$

$$\rightsquigarrow \sigma_1 = 10, \sigma_2 = 5.$$



## J Jelölések

$$\Sigma_1 = \text{diag}(\sigma_1, \dots, \sigma_r) = \begin{bmatrix} \sigma_1 & 0 & \dots & 0 \\ 0 & \sigma_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sigma_r \end{bmatrix}$$

$$\mathbf{U}_1 = \{\mathbf{u}_1, \dots, \mathbf{u}_r\}$$

$$\mathbf{V}_1 = \{\mathbf{v}_1, \dots, \mathbf{v}_r\}$$

## J Jelölések

$$\Sigma_1 = \text{diag}(\sigma_1, \dots, \sigma_r) = \begin{bmatrix} \sigma_1 & 0 & \dots & 0 \\ 0 & \sigma_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sigma_r \end{bmatrix}$$

$$\mathbf{U}_1 = \{\mathbf{u}_1, \dots, \mathbf{u}_r\}$$

$$\mathbf{V}_1 = \{\mathbf{v}_1, \dots, \mathbf{v}_r\}$$

$$\mathbf{A}\mathbf{v}_j = \sigma_j \mathbf{u}_j \rightsquigarrow \mathbf{A}\mathbf{V}_1 = \mathbf{U}_1 \Sigma_1$$

$$\mathbf{A} \begin{bmatrix} \mathbf{v}_1 & \mathbf{v}_2 & \dots & \mathbf{v}_r \end{bmatrix} = \begin{bmatrix} \mathbf{u}_1 & \mathbf{u}_2 & \dots & \mathbf{u}_r \end{bmatrix} \begin{bmatrix} \sigma_1 & 0 & \dots & 0 \\ 0 & \sigma_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sigma_r \end{bmatrix}$$

## J Jelölések

$$\Sigma_1 = \text{diag}(\sigma_1, \dots, \sigma_r) = \begin{bmatrix} \sigma_1 & 0 & \dots & 0 \\ 0 & \sigma_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sigma_r \end{bmatrix}$$

$$\mathbf{U}_1 = \{\mathbf{u}_1, \dots, \mathbf{u}_r\}$$

$$\mathbf{V}_1 = \{\mathbf{v}_1, \dots, \mathbf{v}_r\}$$

$$\mathbf{A}\mathbf{v}_j = \sigma_j \mathbf{u}_j \rightsquigarrow \mathbf{A}\mathbf{V}_1 = \mathbf{U}_1 \Sigma_1$$

$$\mathbf{A} \begin{bmatrix} \mathbf{v}_1 & \mathbf{v}_2 & \dots & \mathbf{v}_r \end{bmatrix} = \begin{bmatrix} \mathbf{u}_1 & \mathbf{u}_2 & \dots & \mathbf{u}_r \end{bmatrix} \begin{bmatrix} \sigma_1 & 0 & \dots & 0 \\ 0 & \sigma_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sigma_r \end{bmatrix}$$

$\{\mathbf{v}_1, \dots, \mathbf{v}_r\}$ -ből  $\{\mathbf{u}_1, \dots, \mathbf{u}_r\}$ -ből ONB:

$$\mathbf{V}_2 = \begin{bmatrix} \mathbf{v}_{r+1} & \dots & \mathbf{v}_n \end{bmatrix}$$

$$\mathbf{U}_2 = \begin{bmatrix} \mathbf{u}_{r+1} & \dots & \mathbf{u}_m \end{bmatrix}$$

$\mathbb{R}$ -ben  $\mathbf{V}_2$  oszlopvektorai  $\perp \mathcal{S}$  ( $\mathbb{C}$ -ben  $\perp \bar{\mathcal{S}}$ -re)  $\rightsquigarrow r < i \leq n$  esetén  $\mathbf{A}\mathbf{v}_i = \mathbf{0}$ .

$\mathbb{R}$ -ben  $\mathbf{V}_2$  oszlopvektorai  $\perp \mathcal{S}$  ( $\mathbb{C}$ -ben  $\perp \bar{\mathcal{S}}$ -re)  $\rightsquigarrow r < i \leq n$  esetén  $\mathbf{A}\mathbf{v}_i = \mathbf{0}$ .

$$\mathbf{A}\mathbf{V} = [\mathbf{A}\mathbf{v}_1 \quad \dots \quad \mathbf{A}\mathbf{v}_r \mid \mathbf{A}\mathbf{v}_{r+1} \quad \dots \quad \mathbf{A}\mathbf{v}_n]$$

$$= [\sigma_1 \mathbf{u}_1 \quad \dots \quad \sigma_r \mathbf{u}_r \mid \mathbf{0} \quad \dots \quad \mathbf{0}]$$

$$= [\mathbf{u}_1 \quad \dots \quad \mathbf{u}_r \mid \mathbf{u}_{r+1} \quad \dots \quad \mathbf{u}_m]$$

$$\left[ \begin{array}{cccc|ccc} \sigma_1 & 0 & \dots & 0 & 0 & \dots & 0 \\ 0 & \sigma_2 & \dots & 0 & 0 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots & \dots & \vdots \\ 0 & 0 & \dots & \sigma_r & 0 & \dots & 0 \\ \hline 0 & 0 & \dots & 0 & 0 & \dots & 0 \\ \vdots & \vdots & \dots & \vdots & \vdots & \dots & \vdots \\ 0 & 0 & \dots & 0 & 0 & \dots & 0 \end{array} \right]$$

$$= \mathbf{U}\mathbf{\Sigma},$$

$\mathbb{R}$ -ben  $\mathbf{V}_2$  oszlopvektorai  $\perp \mathcal{S}$  ( $\mathbb{C}$ -ben  $\perp \bar{\mathcal{S}}$ -re)  $\rightsquigarrow r < i \leq n$  esetén  $\mathbf{A}\mathbf{v}_i = \mathbf{0}$ .

$$\mathbf{A}\mathbf{V} = [\mathbf{A}\mathbf{v}_1 \quad \dots \quad \mathbf{A}\mathbf{v}_r \mid \mathbf{A}\mathbf{v}_{r+1} \quad \dots \quad \mathbf{A}\mathbf{v}_n]$$

$$= [\sigma_1 \mathbf{u}_1 \quad \dots \quad \sigma_r \mathbf{u}_r \mid \mathbf{0} \quad \dots \quad \mathbf{0}]$$

$$= [\mathbf{u}_1 \quad \dots \quad \mathbf{u}_r \mid \mathbf{u}_{r+1} \quad \dots \quad \mathbf{u}_m] \left[ \begin{array}{cccc|ccc} \sigma_1 & 0 & \dots & 0 & 0 & \dots & 0 \\ 0 & \sigma_2 & \dots & 0 & 0 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots & \dots & \vdots \\ 0 & 0 & \dots & \sigma_r & 0 & \dots & 0 \\ \hline 0 & 0 & \dots & 0 & 0 & \dots & 0 \\ \vdots & \vdots & \dots & \vdots & \vdots & \dots & \vdots \\ 0 & 0 & \dots & 0 & 0 & \dots & 0 \end{array} \right]$$

$$= \mathbf{U}\Sigma,$$

azaz  $\mathbf{A}_{m \times n} \mathbf{V}_{n \times n} = \mathbf{U}_{m \times m} \Sigma_{m \times n}$ , blokkmátrix alakban

$$\mathbf{A} [\mathbf{V}_1 \mid \mathbf{V}_2] = [\mathbf{U}_1 \mid \mathbf{U}_2] \left[ \begin{array}{c|c} \Sigma_1 & \mathbf{0} \\ \hline \mathbf{0} & \mathbf{0} \end{array} \right].$$

D Szinguláris érték szerinti felbontás, vagy szinguláris felbontás:

$$\mathbf{A} = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^H$$

D Szinguláris érték szerinti felbontás, vagy szinguláris felbontás:

$$\mathbf{A} = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^H$$

Redukált szinguláris felbontás:  $\mathbf{A} = \mathbf{U}_1\mathbf{\Sigma}_1\mathbf{V}_1^H$



D Szinguláris érték szerinti felbontás, vagy szinguláris felbontás:

$$\mathbf{A} = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^H$$

Redukált szinguláris felbontás:  $\mathbf{A} = \mathbf{U}_1\mathbf{\Sigma}_1\mathbf{V}_1^H$

Szinguláris érték szerinti diadikus felbontás vagy a szinguláris felbontás diadikus alakja

$$\mathbf{A} = \sigma_1 \mathbf{u}_1 \mathbf{v}_1^T + \sigma_2 \mathbf{u}_2 \mathbf{v}_2^T + \cdots + \sigma_r \mathbf{u}_r \mathbf{v}_r^T.$$

$$\begin{bmatrix} 0 & -2 & 2 \\ -2 & 3 & -2 \\ 4 & -2 & 0 \end{bmatrix} = \begin{bmatrix} 1/3 & -2/3 & 2/3 \\ -2/3 & 1/3 & 2/3 \\ 2/3 & 2/3 & 1/3 \end{bmatrix} \begin{bmatrix} 6 & 0 & 0 \\ 0 & 3 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} 2/3 & -2/3 & 1/3 \\ 2/3 & 1/3 & -2/3 \\ 1/3 & 2/3 & 2/3 \end{bmatrix}$$

$$\begin{bmatrix} 0 & -2 & 2 \\ -2 & 3 & -2 \\ 4 & -2 & 0 \end{bmatrix} = \begin{bmatrix} 1/3 & -2/3 & 2/3 \\ -2/3 & 1/3 & 2/3 \\ 2/3 & 2/3 & 1/3 \end{bmatrix} \begin{bmatrix} 6 & 0 & 0 \\ 0 & 3 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} 2/3 & -2/3 & 1/3 \\ 2/3 & 1/3 & -2/3 \\ 1/3 & 2/3 & 2/3 \end{bmatrix}$$

$$\begin{aligned}
 \begin{bmatrix} 0 & -2 & 2 \\ -2 & 3 & -2 \\ 4 & -2 & 0 \end{bmatrix} &= \begin{bmatrix} 1/3 & -2/3 & 2/3 \\ -2/3 & 1/3 & 2/3 \\ 2/3 & 2/3 & 1/3 \end{bmatrix} \begin{bmatrix} 6 & 0 & 0 \\ 0 & 3 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} 2/3 & -2/3 & 1/3 \\ 2/3 & 1/3 & -2/3 \\ 1/3 & 2/3 & 2/3 \end{bmatrix} \\
 &= \begin{bmatrix} 1/3 & -2/3 \\ -2/3 & 1/3 \\ 2/3 & 2/3 \end{bmatrix} \begin{bmatrix} 6 & 0 \\ 0 & 3 \end{bmatrix} \begin{bmatrix} 2/3 & -2/3 & 1/3 \\ 2/3 & 1/3 & -2/3 \end{bmatrix}
 \end{aligned}$$

$$\begin{aligned}
 \begin{bmatrix} 0 & -2 & 2 \\ -2 & 3 & -2 \\ 4 & -2 & 0 \end{bmatrix} &= \begin{bmatrix} 1/3 & -2/3 & 2/3 \\ -2/3 & 1/3 & 2/3 \\ 2/3 & 2/3 & 1/3 \end{bmatrix} \begin{bmatrix} 6 & 0 & 0 \\ 0 & 3 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} 2/3 & -2/3 & 1/3 \\ 2/3 & 1/3 & -2/3 \\ 1/3 & 2/3 & 2/3 \end{bmatrix} \\
 &= \begin{bmatrix} 1/3 & -2/3 \\ -2/3 & 1/3 \\ 2/3 & 2/3 \end{bmatrix} \begin{bmatrix} 6 & 0 \\ 0 & 3 \end{bmatrix} \begin{bmatrix} 2/3 & -2/3 & 1/3 \\ 2/3 & 1/3 & -2/3 \end{bmatrix} \\
 &= 6 \begin{bmatrix} 1/3 \\ -2/3 \\ 2/3 \end{bmatrix} \begin{bmatrix} 2/3 & -2/3 & 1/3 \end{bmatrix} + 3 \begin{bmatrix} -2/3 \\ 1/3 \\ 2/3 \end{bmatrix} \begin{bmatrix} 2/3 & 1/3 & -2/3 \end{bmatrix}
 \end{aligned}$$

$$\begin{aligned}
 \begin{bmatrix} 0 & -2 & 2 \\ -2 & 3 & -2 \\ 4 & -2 & 0 \end{bmatrix} &= \begin{bmatrix} 1/3 & -2/3 & 2/3 \\ -2/3 & 1/3 & 2/3 \\ 2/3 & 2/3 & 1/3 \end{bmatrix} \begin{bmatrix} 6 & 0 & 0 \\ 0 & 3 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} 2/3 & -2/3 & 1/3 \\ 2/3 & 1/3 & -2/3 \\ 1/3 & 2/3 & 2/3 \end{bmatrix} \\
 &= \begin{bmatrix} 1/3 & -2/3 \\ -2/3 & 1/3 \\ 2/3 & 2/3 \end{bmatrix} \begin{bmatrix} 6 & 0 \\ 0 & 3 \end{bmatrix} \begin{bmatrix} 2/3 & -2/3 & 1/3 \\ 2/3 & 1/3 & -2/3 \end{bmatrix} \\
 &= 6 \begin{bmatrix} \frac{1}{3} \\ -\frac{2}{3} \\ \frac{2}{3} \end{bmatrix} \begin{bmatrix} \frac{2}{3} & -\frac{2}{3} & \frac{1}{3} \end{bmatrix} + 3 \begin{bmatrix} -\frac{2}{3} \\ \frac{1}{3} \\ \frac{2}{3} \end{bmatrix} \begin{bmatrix} \frac{2}{3} & \frac{1}{3} & -\frac{2}{3} \end{bmatrix} \\
 &= \begin{bmatrix} 4/3 & -4/3 & 2/3 \\ -8/3 & 8/3 & -4/3 \\ 8/3 & -8/3 & 4/3 \end{bmatrix} + \begin{bmatrix} -4/3 & -2/3 & 4/3 \\ 2/3 & 1/3 & -2/3 \\ 4/3 & 2/3 & -4/3 \end{bmatrix}.
 \end{aligned}$$

M Ötlet:  $\mathbf{A}^H \mathbf{A} = (\mathbf{U} \mathbf{\Sigma} \mathbf{V}^H)^H \mathbf{U} \mathbf{\Sigma} \mathbf{V}^H = \mathbf{V} \mathbf{\Sigma}^H \mathbf{U}^H \mathbf{U} \mathbf{\Sigma} \mathbf{V}^H = \mathbf{V} \mathbf{\Sigma}^H \mathbf{\Sigma} \mathbf{V}^H$

M Ötlet:  $\mathbf{A}^H \mathbf{A} = (\mathbf{U} \mathbf{\Sigma} \mathbf{V}^H)^H \mathbf{U} \mathbf{\Sigma} \mathbf{V}^H = \mathbf{V} \mathbf{\Sigma}^H \mathbf{U}^H \mathbf{U} \mathbf{\Sigma} \mathbf{V}^H = \mathbf{V} \mathbf{\Sigma}^H \mathbf{\Sigma} \mathbf{V}^H$

Ez  $\mathbf{A}^H \mathbf{A}$  spektrálfelbontása:  $\mathbf{V}$  ortogonális (unitér),  $\mathbf{\Sigma}^H \mathbf{\Sigma}$  diagonális ( $\sigma_i \geq 0$ )  $\rightsquigarrow$   $\mathbf{A}^H \mathbf{A}$  sajátértékei épp a szinguláris értékek négyzetei, ui.  $\mathbf{\Sigma}^H \mathbf{\Sigma} = \text{diag}(\sigma_1^2, \sigma_2^2, \dots, \sigma_r^2, 0, \dots, 0)$ .



M Ötlet:  $\mathbf{A}^H \mathbf{A} = (\mathbf{U} \mathbf{\Sigma} \mathbf{V}^H)^H \mathbf{U} \mathbf{\Sigma} \mathbf{V}^H = \mathbf{V} \mathbf{\Sigma}^H \mathbf{U}^H \mathbf{U} \mathbf{\Sigma} \mathbf{V}^H = \mathbf{V} \mathbf{\Sigma}^H \mathbf{\Sigma} \mathbf{V}^H$

Ez  $\mathbf{A}^H \mathbf{A}$  spektrálfelbontása:  $\mathbf{V}$  ortogonális (unitér),  $\mathbf{\Sigma}^H \mathbf{\Sigma}$  diagonális ( $\sigma_i \geq 0$ )  $\rightsquigarrow$   $\mathbf{A}^H \mathbf{A}$  sajátértékei épp a szinguláris értékek négyzetei, ui.  $\mathbf{\Sigma}^H \mathbf{\Sigma} = \text{diag}(\sigma_1^2, \sigma_2^2, \dots, \sigma_r^2, 0, \dots, 0)$ .

SVD kiszámítása:

M Ötlet:  $\mathbf{A}^H \mathbf{A} = (\mathbf{U} \mathbf{\Sigma} \mathbf{V}^H)^H \mathbf{U} \mathbf{\Sigma} \mathbf{V}^H = \mathbf{V} \mathbf{\Sigma}^H \mathbf{U}^H \mathbf{U} \mathbf{\Sigma} \mathbf{V}^H = \mathbf{V} \mathbf{\Sigma}^H \mathbf{\Sigma} \mathbf{V}^H$

Ez  $\mathbf{A}^H \mathbf{A}$  spektrálfelbontása:  $\mathbf{V}$  ortogonális (unitér),  $\mathbf{\Sigma}^H \mathbf{\Sigma}$  diagonális ( $\sigma_i \geq 0$ )  $\rightsquigarrow$   $\mathbf{A}^H \mathbf{A}$  sajátértékei épp a szinguláris értékek négyzetei, ui.  $\mathbf{\Sigma}^H \mathbf{\Sigma} = \text{diag}(\sigma_1^2, \sigma_2^2, \dots, \sigma_r^2, 0, \dots, 0)$ .

SVD kiszámítása:

- 1 meghatározzuk  $\mathbf{A}^T \mathbf{A}$  sajátértékeit ( $\lambda_i$ ) és sajátvektorait ( $\mathbf{x}_i$ ),

$$M \quad \text{Ötlet: } \mathbf{A}^H \mathbf{A} = (\mathbf{U} \mathbf{\Sigma} \mathbf{V}^H)^H \mathbf{U} \mathbf{\Sigma} \mathbf{V}^H = \mathbf{V} \mathbf{\Sigma}^H \mathbf{U}^H \mathbf{U} \mathbf{\Sigma} \mathbf{V}^H = \mathbf{V} \mathbf{\Sigma}^H \mathbf{\Sigma} \mathbf{V}^H$$

Ez  $\mathbf{A}^H \mathbf{A}$  spektrálfelbontása:  $\mathbf{V}$  ortogonális (unitér),  $\mathbf{\Sigma}^H \mathbf{\Sigma}$  diagonális ( $\sigma_i \geq 0$ )  $\rightsquigarrow$   $\mathbf{A}^H \mathbf{A}$  sajátértékei épp a szinguláris értékek négyzetei, ui.  $\mathbf{\Sigma}^H \mathbf{\Sigma} = \text{diag}(\sigma_1^2, \sigma_2^2, \dots, \sigma_r^2, 0, \dots, 0)$ .

SVD kiszámítása:

- 1 meghatározzuk  $\mathbf{A}^T \mathbf{A}$  sajátértékeit ( $\lambda_i$ ) és sajátvektorait ( $\mathbf{x}_i$ ),
- 2 a sajátértékek gyökei a szinguláris értékek ( $\sigma_i = \sqrt{\lambda_i}$ ),

M Ötlet:  $\mathbf{A}^H \mathbf{A} = (\mathbf{U} \mathbf{\Sigma} \mathbf{V}^H)^H \mathbf{U} \mathbf{\Sigma} \mathbf{V}^H = \mathbf{V} \mathbf{\Sigma}^H \mathbf{U}^H \mathbf{U} \mathbf{\Sigma} \mathbf{V}^H = \mathbf{V} \mathbf{\Sigma}^H \mathbf{\Sigma} \mathbf{V}^H$

Ez  $\mathbf{A}^H \mathbf{A}$  spektrálfelbontása:  $\mathbf{V}$  ortogonális (unitér),  $\mathbf{\Sigma}^H \mathbf{\Sigma}$  diagonális ( $\sigma_i \geq 0$ )  $\rightsquigarrow$   $\mathbf{A}^H \mathbf{A}$  sajátértékei épp a szinguláris értékek négyzetei, ui.  $\mathbf{\Sigma}^H \mathbf{\Sigma} = \text{diag}(\sigma_1^2, \sigma_2^2, \dots, \sigma_r^2, 0, \dots, 0)$ .

SVD kiszámítása:

- 1 meghatározzuk  $\mathbf{A}^T \mathbf{A}$  sajátértékeit ( $\lambda_i$ ) és sajátvektorait ( $\mathbf{x}_i$ ),
- 2 a sajátértékek gyökei a szinguláris értékek ( $\sigma_i = \sqrt{\lambda_i}$ ),
- 3 a jobb szinguláris vektorok a sajátvektorok ( $\mathbf{v}_i = \mathbf{x}_i / |\mathbf{x}_i|$ ),

$$M \quad \text{Ötlet: } \mathbf{A}^H \mathbf{A} = (\mathbf{U} \mathbf{\Sigma} \mathbf{V}^H)^H \mathbf{U} \mathbf{\Sigma} \mathbf{V}^H = \mathbf{V} \mathbf{\Sigma}^H \mathbf{U}^H \mathbf{U} \mathbf{\Sigma} \mathbf{V}^H = \mathbf{V} \mathbf{\Sigma}^H \mathbf{\Sigma} \mathbf{V}^H$$

Ez  $\mathbf{A}^H \mathbf{A}$  spektrálfelbontása:  $\mathbf{V}$  ortogonális (unitér),  $\mathbf{\Sigma}^H \mathbf{\Sigma}$  diagonális ( $\sigma_i \geq 0$ )  $\rightsquigarrow$   $\mathbf{A}^H \mathbf{A}$  sajátértékei épp a szinguláris értékek négyzetei, ui.  $\mathbf{\Sigma}^H \mathbf{\Sigma} = \text{diag}(\sigma_1^2, \sigma_2^2, \dots, \sigma_r^2, 0, \dots, 0)$ .

SVD kiszámítása:

- 1 meghatározzuk  $\mathbf{A}^T \mathbf{A}$  sajátértékeit ( $\lambda_i$ ) és sajátvektorait ( $\mathbf{x}_i$ ),
- 2 a sajátértékek gyökei a szinguláris értékek ( $\sigma_i = \sqrt{\lambda_i}$ ),
- 3 a jobb szinguláris vektorok a sajátvektorok ( $\mathbf{v}_i = \mathbf{x}_i / |\mathbf{x}_i|$ ),
- 4 bal szinguláris vektorok: mivel  $\mathbf{A} \mathbf{v}_i = \sigma_i \mathbf{u}_i$ , ezért  $\mathbf{u}_i = \mathbf{A} \mathbf{v}_i / \sigma_i$ ,

M Ötlet:  $\mathbf{A}^H \mathbf{A} = (\mathbf{U} \mathbf{\Sigma} \mathbf{V}^H)^H \mathbf{U} \mathbf{\Sigma} \mathbf{V}^H = \mathbf{V} \mathbf{\Sigma}^H \mathbf{U}^H \mathbf{U} \mathbf{\Sigma} \mathbf{V}^H = \mathbf{V} \mathbf{\Sigma}^H \mathbf{\Sigma} \mathbf{V}^H$

Ez  $\mathbf{A}^H \mathbf{A}$  spektrálfelbontása:  $\mathbf{V}$  ortogonális (unitér),  $\mathbf{\Sigma}^H \mathbf{\Sigma}$  diagonális ( $\sigma_i \geq 0$ )  $\rightsquigarrow$   $\mathbf{A}^H \mathbf{A}$  sajátértékei épp a szinguláris értékek négyzetei, ui.  $\mathbf{\Sigma}^H \mathbf{\Sigma} = \text{diag}(\sigma_1^2, \sigma_2^2, \dots, \sigma_r^2, 0, \dots, 0)$ .

### SVD kiszámítása:

- 1 meghatározzuk  $\mathbf{A}^T \mathbf{A}$  sajátértékeit ( $\lambda_i$ ) és sajátvektorait ( $\mathbf{x}_i$ ),
- 2 a sajátértékek gyökei a szinguláris értékek ( $\sigma_i = \sqrt{\lambda_i}$ ),
- 3 a jobb szinguláris vektorok a sajátvektorok ( $\mathbf{v}_i = \mathbf{x}_i / |\mathbf{x}_i|$ ),
- 4 bal szinguláris vektorok: mivel  $\mathbf{A} \mathbf{v}_i = \sigma_i \mathbf{u}_i$ , ezért  $\mathbf{u}_i = \mathbf{A} \mathbf{v}_i / \sigma_i$ ,
- \*4 alternatíva: a bal szinguláris vektorok megegyeznek az  $\mathbf{A} \mathbf{A}^T$  sajátvektoraival,

$$M \quad \text{Ötlet: } \mathbf{A}^H \mathbf{A} = (\mathbf{U} \mathbf{\Sigma} \mathbf{V}^H)^H \mathbf{U} \mathbf{\Sigma} \mathbf{V}^H = \mathbf{V} \mathbf{\Sigma}^H \mathbf{U}^H \mathbf{U} \mathbf{\Sigma} \mathbf{V}^H = \mathbf{V} \mathbf{\Sigma}^H \mathbf{\Sigma} \mathbf{V}^H$$

Ez  $\mathbf{A}^H \mathbf{A}$  spektrálfelbontása:  $\mathbf{V}$  ortogonális (unitér),  $\mathbf{\Sigma}^H \mathbf{\Sigma}$  diagonális ( $\sigma_i \geq 0$ )  $\rightsquigarrow$   $\mathbf{A}^H \mathbf{A}$  sajátértékei épp a szinguláris értékek négyzetei, ui.  $\mathbf{\Sigma}^H \mathbf{\Sigma} = \text{diag}(\sigma_1^2, \sigma_2^2, \dots, \sigma_r^2, 0, \dots, 0)$ .

### SVD kiszámítása:

- 1 meghatározzuk  $\mathbf{A}^T \mathbf{A}$  sajátértékeit ( $\lambda_i$ ) és sajátvektorait ( $\mathbf{x}_i$ ),
- 2 a sajátértékek gyökei a szinguláris értékek ( $\sigma_i = \sqrt{\lambda_i}$ ),
- 3 a jobb szinguláris vektorok a sajátvektorok ( $\mathbf{v}_i = \mathbf{x}_i / |\mathbf{x}_i|$ ),
- 4 bal szinguláris vektorok: mivel  $\mathbf{A} \mathbf{v}_i = \sigma_i \mathbf{u}_i$ , ezért  $\mathbf{u}_i = \mathbf{A} \mathbf{v}_i / \sigma_i$ ,
- \*4 alternatíva: a bal szinguláris vektorok megegyeznek az  $\mathbf{A} \mathbf{A}^T$  sajátvektoraival,
- 5 a szinguláris vektorokból fölírható  $\mathbf{V}_1$  és  $\mathbf{U}_1$ , a redukált szinguláris felbontás és a diadikus alak,

$$M \quad \text{Ötlet: } \mathbf{A}^H \mathbf{A} = (\mathbf{U} \mathbf{\Sigma} \mathbf{V}^H)^H \mathbf{U} \mathbf{\Sigma} \mathbf{V}^H = \mathbf{V} \mathbf{\Sigma}^H \mathbf{U}^H \mathbf{U} \mathbf{\Sigma} \mathbf{V}^H = \mathbf{V} \mathbf{\Sigma}^H \mathbf{\Sigma} \mathbf{V}^H$$

Ez  $\mathbf{A}^H \mathbf{A}$  spektrálfelbontása:  $\mathbf{V}$  ortogonális (unitér),  $\mathbf{\Sigma}^H \mathbf{\Sigma}$  diagonális ( $\sigma_i \geq 0$ )  $\rightsquigarrow$   $\mathbf{A}^H \mathbf{A}$  sajátértékei épp a szinguláris értékek négyzetei, ui.  $\mathbf{\Sigma}^H \mathbf{\Sigma} = \text{diag}(\sigma_1^2, \sigma_2^2, \dots, \sigma_r^2, 0, \dots, 0)$ .

### SVD kiszámítása:

- 1 meghatározzuk  $\mathbf{A}^T \mathbf{A}$  sajátértékeit ( $\lambda_i$ ) és sajátvektorait ( $\mathbf{x}_i$ ),
- 2 a sajátértékek gyökei a szinguláris értékek ( $\sigma_i = \sqrt{\lambda_i}$ ),
- 3 a jobb szinguláris vektorok a sajátvektorok ( $\mathbf{v}_i = \mathbf{x}_i / |\mathbf{x}_i|$ ),
- 4 bal szinguláris vektorok: mivel  $\mathbf{A} \mathbf{v}_i = \sigma_i \mathbf{u}_i$ , ezért  $\mathbf{u}_i = \mathbf{A} \mathbf{v}_i / \sigma_i$ ,
- \*4 alternatíva: a bal szinguláris vektorok megegyeznek az  $\mathbf{A} \mathbf{A}^T$  sajátvektoraival,
- 5 a szinguláris vektorokból fölírható  $\mathbf{V}_1$  és  $\mathbf{U}_1$ , a redukált szinguláris felbontás és a diadikus alak,
- 6 a  $\mathbf{V}$ -hez ki kell egészíteni a  $\{\mathbf{v}_1, \dots, \mathbf{v}_r\}$  vektorokat ONB-sá (hasonlóképp  $\mathbf{U}$ -hoz)



T A szinguláris értékek létezése és egyértelműsége: Minden  $r$ -rangú komplex  $\mathbf{A}$  mátrixnak létezik  $r$  szinguláris értéke. Ezek megegyeznek  $\mathbf{A}^H \mathbf{A}$  (illetve az  $\mathbf{A} \mathbf{A}^H$ ) pozitív sajátértékeinek négyzetgyökeivel. A szinguláris értékek monoton csökkenő sorozata egyértelmű.

- T** **A szinguláris értékek létezése és egyértelműsége:** Minden  $r$ -rangú komplex  $\mathbf{A}$  mátrixnak létezik  $r$  szinguláris értéke. Ezek megegyeznek  $\mathbf{A}^H \mathbf{A}$  (illetve az  $\mathbf{A} \mathbf{A}^H$ ) pozitív sajátértékeinek négyzetgyökeivel. A szinguláris értékek monoton csökkenő sorozata egyértelmű.
- B**  $\mathbf{A}^H \mathbf{A}$  önadjungált:  $(\mathbf{A}^H \mathbf{A})^H = \mathbf{A}^H (\mathbf{A}^H)^H = \mathbf{A}^H \mathbf{A}$

- T** **A szinguláris értékek létezése és egyértelműsége:** Minden  $r$ -rangú komplex  $\mathbf{A}$  mátrixnak létezik  $r$  szinguláris értéke. Ezek megegyeznek  $\mathbf{A}^H \mathbf{A}$  (illetve az  $\mathbf{A} \mathbf{A}^H$ ) pozitív sajátértékeinek négyzetgyökeivel. A szinguláris értékek monoton csökkenő sorozata egyértelmű.
- B**  $\mathbf{A}^H \mathbf{A}$  önadjungált:  $(\mathbf{A}^H \mathbf{A})^H = \mathbf{A}^H (\mathbf{A}^H)^H = \mathbf{A}^H \mathbf{A}$   
 $\rightsquigarrow$  minden sajátértéke valós, így ortogonálisan diagonalizálható,

**T** A szinguláris értékek létezése és egyértelműsége: Minden  $r$ -rangú komplex  $\mathbf{A}$  mátrixnak létezik  $r$  szinguláris értéke. Ezek megegyeznek  $\mathbf{A}^H \mathbf{A}$  (illetve az  $\mathbf{A} \mathbf{A}^H$ ) pozitív sajátértékeinek négyzetgyökeivel. A szinguláris értékek monoton csökkenő sorozata egyértelmű.

**B**  $\mathbf{A}^H \mathbf{A}$  önadjungált:  $(\mathbf{A}^H \mathbf{A})^H = \mathbf{A}^H (\mathbf{A}^H)^H = \mathbf{A}^H \mathbf{A}$

$\rightsquigarrow$  minden sajátértéke valós, így ortogonálisan diagonalizálható,

$\mathbf{A}^H \mathbf{A}$  pozitív szemidefinit, így minden sajátértéke nemnegatív,

ui.  $\mathbf{x}^H \mathbf{A}^H \mathbf{A} \mathbf{x} = (\mathbf{A} \mathbf{x})^H (\mathbf{A} \mathbf{x}) = |\mathbf{A} \mathbf{x}|^2 \geq 0$ .

**T** **A szinguláris értékek létezése és egyértelműsége:** Minden  $r$ -rangú komplex  $\mathbf{A}$  mátrixnak létezik  $r$  szinguláris értéke. Ezek megegyeznek  $\mathbf{A}^H \mathbf{A}$  (illetve az  $\mathbf{A} \mathbf{A}^H$ ) pozitív sajátértékeinek négyzetgyökeivel. A szinguláris értékek monoton csökkenő sorozata egyértelmű.

**B**  $\mathbf{A}^H \mathbf{A}$  önadjungált:  $(\mathbf{A}^H \mathbf{A})^H = \mathbf{A}^H (\mathbf{A}^H)^H = \mathbf{A}^H \mathbf{A}$

$\rightsquigarrow$  minden sajátértéke valós, így ortogonálisan diagonalizálható,

$\mathbf{A}^H \mathbf{A}$  pozitív szemidefinit, így minden sajátértéke nemnegatív,

ui.  $\mathbf{x}^H \mathbf{A}^H \mathbf{A} \mathbf{x} = (\mathbf{A} \mathbf{x})^H (\mathbf{A} \mathbf{x}) = |\mathbf{A} \mathbf{x}|^2 \geq 0$ .

$r(\mathbf{A}^H \mathbf{A}) = r(\mathbf{A}) = r$ , így  $(\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n$  rendezés után),  $\lambda_i > 0$ , ha  $1 \leq i \leq r$ , és  $\lambda_i = 0$ , ha  $r < i \leq n$

**T** **A szinguláris értékek létezése és egyértelműsége:** Minden  $r$ -rangú komplex  $\mathbf{A}$  mátrixnak létezik  $r$  szinguláris értéke. Ezek megegyeznek  $\mathbf{A}^H \mathbf{A}$  (illetve az  $\mathbf{A} \mathbf{A}^H$ ) pozitív sajátértékeinek négyzetgyökeivel. A szinguláris értékek monoton csökkenő sorozata egyértelmű.

**B**  $\mathbf{A}^H \mathbf{A}$  önadjungált:  $(\mathbf{A}^H \mathbf{A})^H = \mathbf{A}^H (\mathbf{A}^H)^H = \mathbf{A}^H \mathbf{A}$

$\rightsquigarrow$  minden sajátértéke valós, így ortogonálisan diagonalizálható,

$\mathbf{A}^H \mathbf{A}$  pozitív szemidefinit, így minden sajátértéke nemnegatív,

ui.  $\mathbf{x}^H \mathbf{A}^H \mathbf{A} \mathbf{x} = (\mathbf{A} \mathbf{x})^H (\mathbf{A} \mathbf{x}) = |\mathbf{A} \mathbf{x}|^2 \geq 0$ .

$r(\mathbf{A}^H \mathbf{A}) = r(\mathbf{A}) = r$ , így  $(\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n$  rendezés után),  $\lambda_i > 0$ ,  
ha  $1 \leq i \leq r$ , és  $\lambda_i = 0$ , ha  $r < i \leq n$

$\sigma_i = \sqrt{\lambda_i} > 0$ , ha  $1 \leq i \leq r$

**T** **A szinguláris értékek létezése és egyértelműsége:** Minden  $r$ -rangú komplex  $\mathbf{A}$  mátrixnak létezik  $r$  szinguláris értéke. Ezek megegyeznek  $\mathbf{A}^H \mathbf{A}$  (illetve az  $\mathbf{A} \mathbf{A}^H$ ) pozitív sajátértékeinek négyzetgyökeivel. A szinguláris értékek monoton csökkenő sorozata egyértelmű.

**B**  $\mathbf{A}^H \mathbf{A}$  önadjungált:  $(\mathbf{A}^H \mathbf{A})^H = \mathbf{A}^H (\mathbf{A}^H)^H = \mathbf{A}^H \mathbf{A}$

$\rightsquigarrow$  minden sajátértéke valós, így ortogonálisan diagonalizálható,

$\mathbf{A}^H \mathbf{A}$  pozitív szemidefinit, így minden sajátértéke nemnegatív,

ui.  $\mathbf{x}^H \mathbf{A}^H \mathbf{A} \mathbf{x} = (\mathbf{A} \mathbf{x})^H (\mathbf{A} \mathbf{x}) = |\mathbf{A} \mathbf{x}|^2 \geq 0$ .

$r(\mathbf{A}^H \mathbf{A}) = r(\mathbf{A}) = r$ , így  $(\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n$  rendezés után),  $\lambda_i > 0$ , ha  $1 \leq i \leq r$ , és  $\lambda_i = 0$ , ha  $r < i \leq n$

$\sigma_i = \sqrt{\lambda_i} > 0$ , ha  $1 \leq i \leq r$

$\mathbf{A}^H \mathbf{A}$  sajátértékei egyértelműek, ezért  $\mathbf{A}$  szinguláris értékei is azok

**T** **A szinguláris értékek létezése és egyértelműsége:** Minden  $r$ -rangú komplex  $\mathbf{A}$  mátrixnak létezik  $r$  szinguláris értéke. Ezek megegyeznek  $\mathbf{A}^H \mathbf{A}$  (illetve az  $\mathbf{A} \mathbf{A}^H$ ) pozitív sajátértékeinek négyzetgyökeivel. A szinguláris értékek monoton csökkenő sorozata egyértelmű.

**B**  $\mathbf{A}^H \mathbf{A}$  önadjungált:  $(\mathbf{A}^H \mathbf{A})^H = \mathbf{A}^H (\mathbf{A}^H)^H = \mathbf{A}^H \mathbf{A}$

$\rightsquigarrow$  minden sajátértéke valós, így ortogonálisan diagonalizálható,

$\mathbf{A}^H \mathbf{A}$  pozitív szemidefinit, így minden sajátértéke nemnegatív,

ui.  $\mathbf{x}^H \mathbf{A}^H \mathbf{A} \mathbf{x} = (\mathbf{A} \mathbf{x})^H (\mathbf{A} \mathbf{x}) = |\mathbf{A} \mathbf{x}|^2 \geq 0$ .

$r(\mathbf{A}^H \mathbf{A}) = r(\mathbf{A}) = r$ , így  $(\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n$  rendezés után),  $\lambda_i > 0$ , ha  $1 \leq i \leq r$ , és  $\lambda_i = 0$ , ha  $r < i \leq n$

$\sigma_i = \sqrt{\lambda_i} > 0$ , ha  $1 \leq i \leq r$

$\mathbf{A}^H \mathbf{A}$  sajátértékei egyértelműek, ezért  $\mathbf{A}$  szinguláris értékei is azok


$\mathbf{A}^H \mathbf{A}$  és  $\mathbf{A} \mathbf{A}^H$  0-tól különböző sajátértékei megegyeznek



- P SVD hatása egységkörön 2-rangú  $2 \times 2$ -es mátrixszal:  $\mathbf{V}^T \mathbf{v}_i = \mathbf{e}_i$ ,  $\Sigma \mathbf{e}_i = \sigma_i \mathbf{e}_i$ ,  $\mathbf{U} \sigma_i \mathbf{e}_i = \sigma_i \mathbf{U} \mathbf{e}_i = \sigma_i \mathbf{u}_i$ , azaz  $\mathbf{V}^T$  a  $\{\mathbf{v}_i\}$  bázist a standardba viszi ortogonális leképezéssel (forgatás vagy tükrözés), ott  $\Sigma$  tengelyirányban nyújtja/összenyomja, végül az ortogonális  $\mathbf{U}$  hat rá.

P SVD hatása egységkörön 2-rangú  $2 \times 2$ -es mátrixszal:  $\mathbf{V}^T \mathbf{v}_i = \mathbf{e}_i$ ,  $\Sigma \mathbf{e}_i = \sigma_i \mathbf{e}_i$ ,  $\mathbf{U} \sigma \mathbf{e}_i = \sigma \mathbf{U} \mathbf{e}_i = \sigma \mathbf{u}_i$ , azaz  $\mathbf{V}^T$  a  $\{\mathbf{v}_i\}$  bázist a standardba viszi ortogonális leképezéssel (forgatás vagy tükrözés), ott  $\Sigma$  tengelyirányban nyújtja/összenyomja, végül az ortogonális  $\mathbf{U}$  hat rá.

$$\mathbf{A} = \mathbf{U}\Sigma\mathbf{V}^T : \mathbf{x} \mapsto \mathbf{U}\Sigma\mathbf{V}^T \mathbf{x}:$$



P  $2 \times 3$ -as, valós, 2-rangú mátrix:  $\mathbf{V}^T$  ortogonális, így hatása:  $\mathbf{V}^T \mathbf{v}_i = \mathbf{e}_i$  ( $i = 1, 2, 3$ ).

P  $2 \times 3$ -as, valós, 2-rangú mátrix:  $\mathbf{V}^T$  ortogonális, így hatása:  $\mathbf{V}^T \mathbf{v}_i = \mathbf{e}_i$  ( $i = 1, 2, 3$ ).

$\Sigma$  a két első tengely irányában nyújt/összenyom:  $\Sigma \mathbf{e}_i = \sigma_i \mathbf{e}_i$  ( $i = 1, 2$ ), a harmadik tengely irányával párhuzamosan vetít:  $\Sigma \mathbf{e}_3 = \mathbf{0}$ .

P  $2 \times 3$ -as, valós, 2-rangú mátrix:  $\mathbf{V}^T$  ortogonális, így hatása:  $\mathbf{V}^T \mathbf{v}_i = \mathbf{e}_i$  ( $i = 1, 2, 3$ ).

$\Sigma$  a két első tengely irányában nyújt/összenyom:  $\Sigma \mathbf{e}_i = \sigma_i \mathbf{e}_i$  ( $i = 1, 2$ ), a harmadik tengely irányával párhuzamosan vetít:  $\Sigma \mathbf{e}_3 = \mathbf{0}$ .

A kép nem egy ellipsziszvonal, hanem a teljes általa határolt tartomány.

P  $2 \times 3$ -as, valós, 2-rangú mátrix:  $\mathbf{V}^T$  ortogonális, így hatása:  $\mathbf{V}^T \mathbf{v}_i = \mathbf{e}_i$  ( $i = 1, 2, 3$ ).

$\Sigma$  a két első tengely irányában nyújt/összenyom:  $\Sigma \mathbf{e}_i = \sigma_i \mathbf{e}_i$  ( $i = 1, 2$ ), a harmadik tengely irányával párhuzamosan vetít:  $\Sigma \mathbf{e}_3 = \mathbf{0}$ .

A kép nem egy ellipsziszvonal, hanem a teljes általa határolt tartomány.


Végül az ortogonális  $\mathbf{U}$  ezt elforgatja vagy tükrözi egy egyenesre.

P  $2 \times 3$ -as, valós, 2-rangú mátrix:  $\mathbf{V}^T$  ortogonális, így hatása:  $\mathbf{V}^T \mathbf{v}_i = \mathbf{e}_i$  ( $i = 1, 2, 3$ ).

$\Sigma$  a két első tengely irányában nyújt/összenyom:  $\Sigma \mathbf{e}_i = \sigma_i \mathbf{e}_i$  ( $i = 1, 2$ ), a harmadik tengely irányával párhuzamosan vetít:  $\Sigma \mathbf{e}_3 = \mathbf{0}$ .

A kép nem egy ellipsziszvonal, hanem a teljes általa határolt tartomány.

Végül az ortogonális  $\mathbf{U}$  ezt elforgatja vagy tükrözi egy egyenesre.



T  $\mathbf{A}$  egy  $r$ -rangú,  $m \times n$ -es valós mátrix. Az  $\mathbf{x} \mapsto \mathbf{Ax}$  leképezés  $\mathbb{R}^n$  az  $\mathbf{e}^T \mathbf{e} = 1$  egyenletet kielégítő, egységgömb felületén lévő pontjait,  $\mathbb{R}^m$  egy  $r$ -dimenziós altere



- T  $\mathbf{A}$  egy  $r$ -rangú,  $m \times n$ -es valós mátrix. Az  $\mathbf{x} \mapsto \mathbf{Ax}$  leképezés  $\mathbb{R}^n$  az  $\mathbf{e}^T \mathbf{e} = 1$  egyenletet kielégítő, egységgömb felületén lévő pontjait,  $\mathbb{R}^m$  egy  $r$ -dimenziós altere
- egy ellipszoidjának felületére képi, ha  $r = n$ , és

- T  $\mathbf{A}$  egy  $r$ -rangú,  $m \times n$ -es valós mátrix. Az  $\mathbf{x} \mapsto \mathbf{Ax}$  leképezés  $\mathbb{R}^n$  az  $\mathbf{e}^T \mathbf{e} = 1$  egyenletet kielégítő, egységgömb felületén lévő pontjait,  $\mathbb{R}^m$  egy  $r$ -dimenziós altere
- egy ellipszoidjának felületére képi, ha  $r = n$ , és
  - egy ellipszoidja által határolt tartományára képi, ha  $r < n$ .

M Analógia: az  $re^{i\varphi}$  exp. alak egy nyújtás és egy forgatás szorzata

- M Analógia: az  $re^{i\varphi}$  exp. alak egy nyújtás és egy forgatás szorzata
- D Polárfelbontás: egy négyzetes mátrixnak egy pozitív szemidefinit és egy ortogonális (unitér) mátrix szorzatára való felbontása:  $\mathbf{A} = \mathbf{PQ}$ .

- M** Analógia: az  $re^{i\varphi}$  exp. alak egy nyújtás és egy forgatás szorzata
- D** **Polárfelbontás:** egy négyzetes mátrixnak egy **pozitív szemidefinit** és egy **ortogonális (unitér)** mátrix szorzatára való felbontása:  $\mathbf{A} = \mathbf{PQ}$ .
- T** Bármely komplex (valós) négyzetes  $\mathbf{A}$  mátrix előáll  $\mathbf{A} = \mathbf{PQ}$  alakban. Ha  $\mathbf{A}$  invertálható, akkor  $\mathbf{P}$  pozitív definit, és a felbontás egyértelmű.

- M** Analógia: az  $re^{i\varphi}$  exp. alak egy nyújtás és egy forgatás szorzata
- D** **Polárfelbontás:** egy négyzetes mátrixnak egy **pozitív szemidefinit** és egy **ortogonális (unitér)** mátrix szorzatára való felbontása:  $\mathbf{A} = \mathbf{PQ}$ .
- T** Bármely komplex (valós) négyzetes  $\mathbf{A}$  mátrix előáll  $\mathbf{A} = \mathbf{PQ}$  alakban. Ha  $\mathbf{A}$  invertálható, akkor  $\mathbf{P}$  pozitív definit, és a felbontás egyértelmű.
- B** A felbontás  $\mathbf{A} = \mathbf{U}\Sigma\mathbf{V}^H = \mathbf{U}\Sigma\mathbf{U}^H\mathbf{U}\mathbf{V}^H = (\mathbf{U}\Sigma\mathbf{U}^H)(\mathbf{U}\mathbf{V}^H)$ , ahonnan  $\mathbf{P} = \mathbf{U}\Sigma\mathbf{U}^H$ ,  $\mathbf{Q} = \mathbf{U}\mathbf{V}^H$ .

- M** Analógia: az  $re^{i\varphi}$  exp. alak egy nyújtás és egy forgatás szorzata
- D** **Polárfelbontás:** egy négyzetes mátrixnak egy **pozitív szemidefinit** és egy **ortogonális (unitér)** mátrix szorzatára való felbontása:  $\mathbf{A} = \mathbf{PQ}$ .
- T** Bármely komplex (valós) négyzetes  $\mathbf{A}$  mátrix előáll  $\mathbf{A} = \mathbf{PQ}$  alakban. Ha  $\mathbf{A}$  invertálható, akkor  $\mathbf{P}$  pozitív definit, és a felbontás egyértelmű.
- B** A felbontás  $\mathbf{A} = \mathbf{U}\Sigma\mathbf{V}^H = \mathbf{U}\Sigma\mathbf{U}^H\mathbf{U}\mathbf{V}^H = (\mathbf{U}\Sigma\mathbf{U}^H)(\mathbf{U}\mathbf{V}^H)$ , ahonnan  $\mathbf{P} = \mathbf{U}\Sigma\mathbf{U}^H$ ,  $\mathbf{Q} = \mathbf{U}\mathbf{V}^H$ .
- $\mathbf{P}$  önadjungált:  $(\mathbf{U}\Sigma\mathbf{U}^H)^H = \mathbf{U}\Sigma^H\mathbf{U}^H = \mathbf{U}\Sigma\mathbf{U}^H$ .

- M** Analógia: az  $re^{i\varphi}$  exp. alak egy nyújtás és egy forgatás szorzata
- D** **Polárfelbontás:** egy négyzetes mátrixnak egy **pozitív szemidefinit** és egy **ortogonális (unitér)** mátrix szorzatára való felbontása:  $\mathbf{A} = \mathbf{PQ}$ .
- T** Bármely komplex (valós) négyzetes  $\mathbf{A}$  mátrix előáll  $\mathbf{A} = \mathbf{PQ}$  alakban. Ha  $\mathbf{A}$  invertálható, akkor  $\mathbf{P}$  pozitív definit, és a felbontás egyértelmű.
- B** A felbontás  $\mathbf{A} = \mathbf{U}\Sigma\mathbf{V}^H = \mathbf{U}\Sigma\mathbf{U}^H\mathbf{U}\mathbf{V}^H = (\mathbf{U}\Sigma\mathbf{U}^H)(\mathbf{U}\mathbf{V}^H)$ , ahonnan  $\mathbf{P} = \mathbf{U}\Sigma\mathbf{U}^H$ ,  $\mathbf{Q} = \mathbf{U}\mathbf{V}^H$ .
- $\mathbf{P}$  önadjungált:  $(\mathbf{U}\Sigma\mathbf{U}^H)^H = \mathbf{U}\Sigma^H\mathbf{U}^H = \mathbf{U}\Sigma\mathbf{U}^H$ .
- $\mathbf{P}$  pozitív szemidef. (hasonló  $\Sigma$ -hez), ha  $\mathbf{A}$  invertálható,  $\Sigma$  pozitív def.



- M** Analógia: az  $re^{i\varphi}$  exp. alak egy nyújtás és egy forgatás szorzata
- D** **Polárfelbontás:** egy négyzetes mátrixnak egy **pozitív szemidefinit** és egy **ortogonális (unitér)** mátrix szorzatára való felbontása:  $\mathbf{A} = \mathbf{PQ}$ .
- T** Bármely komplex (valós) négyzetes  $\mathbf{A}$  mátrix előáll  $\mathbf{A} = \mathbf{PQ}$  alakban. Ha  $\mathbf{A}$  invertálható, akkor  $\mathbf{P}$  pozitív definit, és a felbontás egyértelmű.
- B** A felbontás  $\mathbf{A} = \mathbf{U}\Sigma\mathbf{V}^H = \mathbf{U}\Sigma\mathbf{U}^H\mathbf{U}\mathbf{V}^H = (\mathbf{U}\Sigma\mathbf{U}^H)(\mathbf{U}\mathbf{V}^H)$ , ahonnan  $\mathbf{P} = \mathbf{U}\Sigma\mathbf{U}^H$ ,  $\mathbf{Q} = \mathbf{U}\mathbf{V}^H$ .
- $\mathbf{P}$  önadjungált:  $(\mathbf{U}\Sigma\mathbf{U}^H)^H = \mathbf{U}\Sigma^H\mathbf{U}^H = \mathbf{U}\Sigma\mathbf{U}^H$ .
- $\mathbf{P}$  pozitív szemidef. (hasonló  $\Sigma$ -hez), ha  $\mathbf{A}$  invertálható,  $\Sigma$  pozitív def.
- $\mathbf{Q}$  unitér (ortogonális), hisz két unitér (ortogonális) mátrix szorzata.

- M** Analógia: az  $re^{i\varphi}$  exp. alak egy nyújtás és egy forgatás szorzata
- D** **Polárfelbontás:** egy négyzetes mátrixnak egy **pozitív szemidefinit** és egy **ortogonális (unitér)** mátrix szorzatára való felbontása:  $\mathbf{A} = \mathbf{PQ}$ .
- T** Bármely komplex (valós) négyzetes  $\mathbf{A}$  mátrix előáll  $\mathbf{A} = \mathbf{PQ}$  alakban. Ha  $\mathbf{A}$  invertálható, akkor  $\mathbf{P}$  pozitív definit, és a felbontás egyértelmű.
- B** A felbontás  $\mathbf{A} = \mathbf{U}\Sigma\mathbf{V}^H = \mathbf{U}\Sigma\mathbf{U}^H\mathbf{U}\mathbf{V}^H = (\mathbf{U}\Sigma\mathbf{U}^H)(\mathbf{U}\mathbf{V}^H)$ , ahonnan  $\mathbf{P} = \mathbf{U}\Sigma\mathbf{U}^H$ ,  $\mathbf{Q} = \mathbf{U}\mathbf{V}^H$ .
- $\mathbf{P}$  önadjungált:  $(\mathbf{U}\Sigma\mathbf{U}^H)^H = \mathbf{U}\Sigma^H\mathbf{U}^H = \mathbf{U}\Sigma\mathbf{U}^H$ .
- $\mathbf{P}$  pozitív szemidef. (hasonló  $\Sigma$ -hez), ha  $\mathbf{A}$  invertálható,  $\Sigma$  pozitív def.
- $\mathbf{Q}$  unitér (ortogonális), hisz két unitér (ortogonális) mátrix szorzata.
- $\mathbf{P}$  egyértelmű (nem csak akkor, ha pozitív definit), ugyanis

$$\mathbf{A}\mathbf{A}^H = \mathbf{PQ}\mathbf{Q}^H\mathbf{P}^H = \mathbf{P}\mathbf{P}^H = \mathbf{P}^2,$$

és pozitív szemidefinit önadjungált mátrix négyzetgyöke egyértelmű az önadjungált pozitív szemidefinit mátrixok körében.

- M** Analógia: az  $re^{i\varphi}$  exp. alak egy nyújtás és egy forgatás szorzata
- D** **Polárfelbontás:** egy négyzetes mátrixnak egy **pozitív szemidefinit** és egy **ortogonális (unitér)** mátrix szorzatára való felbontása:  $\mathbf{A} = \mathbf{PQ}$ .
- T** Bármely komplex (valós) négyzetes  $\mathbf{A}$  mátrix előáll  $\mathbf{A} = \mathbf{PQ}$  alakban. Ha  $\mathbf{A}$  invertálható, akkor  $\mathbf{P}$  pozitív definit, és a felbontás egyértelmű.
- B** A felbontás  $\mathbf{A} = \mathbf{U}\Sigma\mathbf{V}^H = \mathbf{U}\Sigma\mathbf{U}^H\mathbf{U}\mathbf{V}^H = (\mathbf{U}\Sigma\mathbf{U}^H)(\mathbf{U}\mathbf{V}^H)$ , ahonnan  $\mathbf{P} = \mathbf{U}\Sigma\mathbf{U}^H$ ,  $\mathbf{Q} = \mathbf{U}\mathbf{V}^H$ .
- $\mathbf{P}$  önadjungált:  $(\mathbf{U}\Sigma\mathbf{U}^H)^H = \mathbf{U}\Sigma^H\mathbf{U}^H = \mathbf{U}\Sigma\mathbf{U}^H$ .
- $\mathbf{P}$  pozitív szemidef. (hasonló  $\Sigma$ -hez), ha  $\mathbf{A}$  invertálható,  $\Sigma$  pozitív def.
- $\mathbf{Q}$  unitér (ortogonális), hisz két unitér (ortogonális) mátrix szorzata.
- $\mathbf{P}$  egyértelmű (nem csak akkor, ha pozitív definit), ugyanis

$$\mathbf{A}\mathbf{A}^H = \mathbf{PQ}\mathbf{Q}^H\mathbf{P}^H = \mathbf{P}\mathbf{P}^H = \mathbf{P}^2,$$

és pozitív szemidefinit önadjungált mátrix négyzetgyöke egyértelmű az önadjungált pozitív szemidefinit mátrixok körében.

Ha  $\mathbf{P}$  pozitív definit, akkor invertálható, így  $\mathbf{Q} = \mathbf{P}^{-1}\mathbf{A}$  is egyértelmű.

T SVD:  $\mathbf{A} = \mathbf{U}_1 \mathbf{\Sigma}_1 \mathbf{V}_1^T$ , illetve  $\mathbf{A} = \mathbf{U} \mathbf{\Sigma} \mathbf{V}^T$ . Ekkor

$$\mathbf{A}^+ = \mathbf{V}_1 \mathbf{\Sigma}_1^{-1} \mathbf{U}_1^T = \mathbf{V} \mathbf{\Sigma}^+ \mathbf{U}^T.$$

T SVD:  $\mathbf{A} = \mathbf{U}_1 \boldsymbol{\Sigma}_1 \mathbf{V}_1^T$ , illetve  $\mathbf{A} = \mathbf{U} \boldsymbol{\Sigma} \mathbf{V}^T$ . Ekkor

$$\mathbf{A}^+ = \mathbf{V}_1 \boldsymbol{\Sigma}_1^{-1} \mathbf{U}_1^T = \mathbf{V} \boldsymbol{\Sigma}^+ \mathbf{U}^T.$$

B  $\mathbf{U}_1$  teljes oszloprangú,  $\boldsymbol{\Sigma}_1 \mathbf{V}_1^T$  teljes sorrangú, így

$$\begin{aligned} \mathbf{A}^+ &= (\boldsymbol{\Sigma}_1 \mathbf{V}_1^T)^T \left( \boldsymbol{\Sigma}_1 \mathbf{V}_1^T (\boldsymbol{\Sigma}_1 \mathbf{V}_1^T)^T \right)^{-1} \left( \mathbf{U}_1^T \mathbf{U}_1 \right)^{-1} \mathbf{U}_1^T = \mathbf{V}_1 \boldsymbol{\Sigma}_1 \boldsymbol{\Sigma}_1^{-2} \mathbf{U}_1^T \\ &= \mathbf{V}_1 \boldsymbol{\Sigma}_1^{-1} \mathbf{U}_1^T. \end{aligned}$$

T SVD:  $\mathbf{A} = \mathbf{U}_1 \mathbf{\Sigma}_1 \mathbf{V}_1^T$ , illetve  $\mathbf{A} = \mathbf{U} \mathbf{\Sigma} \mathbf{V}^T$ . Ekkor

$$\mathbf{A}^+ = \mathbf{V}_1 \mathbf{\Sigma}_1^{-1} \mathbf{U}_1^T = \mathbf{V} \mathbf{\Sigma}^+ \mathbf{U}^T.$$

B  $\mathbf{U}_1$  teljes oszloprangú,  $\mathbf{\Sigma}_1 \mathbf{V}_1^T$  teljes sorrangú, így

$$\begin{aligned} \mathbf{A}^+ &= (\mathbf{\Sigma}_1 \mathbf{V}_1^T)^T \left( \mathbf{\Sigma}_1 \mathbf{V}_1^T (\mathbf{\Sigma}_1 \mathbf{V}_1^T)^T \right)^{-1} \left( \mathbf{U}_1^T \mathbf{U}_1 \right)^{-1} \mathbf{U}_1^T = \mathbf{V}_1 \mathbf{\Sigma}_1 \mathbf{\Sigma}_1^{-2} \mathbf{U}_1^T \\ &= \mathbf{V}_1 \mathbf{\Sigma}_1^{-1} \mathbf{U}_1^T. \end{aligned}$$

Ebből

$$\mathbf{V} \mathbf{\Sigma}^+ \mathbf{U}^T = \begin{bmatrix} \mathbf{V}_1 & \mathbf{V}_2 \end{bmatrix} \begin{bmatrix} \mathbf{\Sigma}_1^{-1} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} \end{bmatrix} \begin{bmatrix} \mathbf{U}_1^T \\ \mathbf{U}_2^T \end{bmatrix} = \mathbf{V}_1 \mathbf{\Sigma}_1^{-1} \mathbf{U}_1^T.$$

T Kis rangú approximáció tétele – Eckart–Young-tétel  $\mathbf{A}$   $r$ -rangú,  $k$ -adik szinguláris értéke  $\sigma_k$ , jobb és bal szinguláris vektora  $\mathbf{v}_k$ , illetve  $\mathbf{u}_k$ .  
Legyen

$$\mathbf{A}_k = \sum_{i=1}^k \sigma_i \mathbf{u}_i \mathbf{v}_i^T.$$

T Kis rangú approximáció tétele – Eckart–Young-tétel  $\mathbf{A}$   $r$ -rangú,  $k$ -adik szinguláris értéke  $\sigma_k$ , jobb és bal szinguláris vektora  $\mathbf{v}_k$ , illetve  $\mathbf{u}_k$ .  
Legyen


$$\mathbf{A}_k = \sum_{i=1}^k \sigma_i \mathbf{u}_i \mathbf{v}_i^T.$$


Ekkor  $\mathbf{A}_k$  az  $\mathbf{A}$  mátrix legjobb legfőbb  $k$ -rangú közelítése, azaz




$$\min_{r(\mathbf{B}) \leq k} \|\mathbf{A} - \mathbf{B}\|_F = \|\mathbf{A} - \mathbf{A}_k\|_F = \sqrt{\sum_{i=k+1}^r \sigma_i^2},$$





$$\min_{r(\mathbf{B}) \leq k} \|\mathbf{A} - \mathbf{B}\|_2 = \|\mathbf{A} - \mathbf{A}_k\|_2 = \sigma_{k+1}.$$




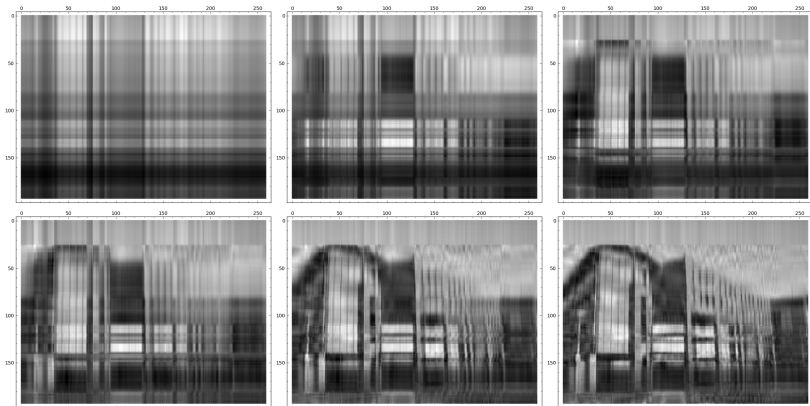





































1, 2, 3, 4, 8, 12, 40, 97, 194.



## A latent semantic indexing (LSI) vagy latent semantic analysis (LSA)

- A latent semantic indexing (LSI) vagy latent semantic analysis (LSA)
- Ö Az egy dokumentumban szereplő szavakat összekapcsolja a dokumentum tartalma, e kapcsolatokat – a szavak mögött lévő tartalmat – az SVD kiemeli, mint lényeges információt.

- A** latent semantic indexing (LSI) vagy latent semantic analysis (LSA)
- Ö** Az egy dokumentumban szereplő szavakat összekapcsolja a dokumentum tartalma, e kapcsolatokat – a szavak mögött lévő tartalmat – az SVD kiemeli, mint lényeges információt.
- A** sorai a szavakat, oszlopai a dokumentumokat reprezentálják.

A latent semantic indexing (LSI) vagy latent semantic analysis (LSA)

Ö Az egy dokumentumban szereplő szavakat összekapcsolja a dokumentum tartalma, e kapcsolatokat – a szavak mögött lévő tartalmat – az SVD kiemeli, mint lényeges információt.

**A** sorai a szavakat, oszlopai a dokumentumokat reprezentálják.

$t_{ij}$  az  $i$ -edik szó gyakorisága a  $j$ -edik dokumentumban és  $T_i$  a teljes szöveggyűjteményben

$$a_{ij} = \left( 1 + \sum_{k=1}^n \frac{t_{ik} \log \frac{t_{ik}}{T_i}}{\log n} \right) \log(1 + t_{ij}).$$

A latent semantic indexing (LSI) vagy latent semantic analysis (LSA)

Ö Az egy dokumentumban szereplő szavakat összekapcsolja a dokumentum tartalma, e kapcsolatokat – a szavak mögött lévő tartalmat – az SVD kiemeli, mint lényeges információt.

**A** sorai a szavakat, oszlopai a dokumentumokat reprezentálják.

$t_{ij}$  az  $i$ -edik szó gyakorisága a  $j$ -edik dokumentumban és  $T_i$  a teljes szöveggyűjteményben

$$a_{ij} = \left( 1 + \sum_{k=1}^n \frac{t_{ik} \log \frac{t_{ik}}{T_i}}{\log n} \right) \log(1 + t_{ij}).$$

az első tényező egy csak az  $i$ -edik szónak az egész gyűjteményhez való kapcsolatától függő globális súly, a második csak a lokális érték függvénye.



**A** latent semantic indexing (LSI) vagy latent semantic analysis (LSA)

**Ö** Az egy dokumentumban szereplő szavakat összekapcsolja a dokumentum tartalma, e kapcsolatokat – a szavak mögött lévő tartalmat – az SVD kiemeli, mint lényeges információt.

**A** sorai a szavakat, oszlopai a dokumentumokat reprezentálják.

$t_{ij}$  az  $i$ -edik szó gyakorisága a  $j$ -edik dokumentumban és  $T_i$  a teljes szöveggűjteményben

$$a_{ij} = \left( 1 + \sum_{k=1}^n \frac{t_{ik} \log \frac{t_{ik}}{T_i}}{\log n} \right) \log(1 + t_{ij}).$$

az első tényező egy csak az  $i$ -edik szónak az egész gyűjteményhez való kapcsolatától függő globális súly, a második csak a lokális érték függvénye.

$\mathbf{A} = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^T$  és közelítése  $\mathbf{A}_k = \mathbf{U}_k\mathbf{\Sigma}_k\mathbf{V}_k^T$

A latent semantic indexing (LSI) vagy latent semantic analysis (LSA)

Ö Az egy dokumentumban szereplő szavakat összekapcsolja a dokumentum tartalma, e kapcsolatokat – a szavak mögött lévő tartalmat – az SVD kiemeli, mint lényeges információt.

**A** sorai a szavakat, oszlopai a dokumentumokat reprezentálják.

$t_{ij}$  az  $i$ -edik szó gyakorisága a  $j$ -edik dokumentumban és  $T_i$  a teljes szöveggűjteményben

$$a_{ij} = \left( 1 + \sum_{k=1}^n \frac{t_{ik} \log \frac{t_{ik}}{T_i}}{\log n} \right) \log(1 + t_{ij}).$$

az első tényező egy csak az  $i$ -edik szónak az egész gyűjteményhez való kapcsolatától függő globális súly, a második csak a lokális érték függvénye.

$\mathbf{A} = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^T$  és közelítése  $\mathbf{A}_k = \mathbf{U}_k\mathbf{\Sigma}_k\mathbf{V}_k^T$

$\mathbf{U}_k$ , illetve  $\mathbf{V}_k$  oszlopainak vektorterében a szavak, illetve dokumentumok kapcsolatát a hozzájuk tartozó vektorok helyzete jellemzi

D Az  $\mathbf{x}$  vektor **euklideszi normája** vagy más néven abszolút értéke

$$\|\mathbf{x}\|_2 = \sqrt{\sum_{i=1}^n x_i^2} = \sqrt{\mathbf{x}^T \mathbf{x}}, \quad \text{ha } \mathbf{x} \in \mathbb{R}^n,$$

$$\|\mathbf{x}\|_2 = \sqrt{\sum_{i=1}^n |x_i|^2} = \sqrt{\mathbf{x}^H \mathbf{x}}, \quad \text{ha } \mathbf{x} \in \mathbb{C}^n.$$

D Az  $\mathbf{x}$  vektor **euklideszi normája** vagy más néven abszolút értéke

$$\|\mathbf{x}\|_2 = \sqrt{\sum_{i=1}^n x_i^2} = \sqrt{\mathbf{x}^T \mathbf{x}}, \quad \text{ha } \mathbf{x} \in \mathbb{R}^n,$$

$$\|\mathbf{x}\|_2 = \sqrt{\sum_{i=1}^n |x_i|^2} = \sqrt{\mathbf{x}^H \mathbf{x}}, \quad \text{ha } \mathbf{x} \in \mathbb{C}^n.$$

M Manhattan ( $|x| + |y|$ ), képméretezés ( $\max\{|x|, |y|\}$ ).

D Az  $\mathbf{x}$  vektor **euklideszi normája** vagy más néven abszolút értéke

$$\|\mathbf{x}\|_2 = \sqrt{\sum_{i=1}^n x_i^2} = \sqrt{\mathbf{x}^T \mathbf{x}}, \quad \text{ha } \mathbf{x} \in \mathbb{R}^n,$$

$$\|\mathbf{x}\|_2 = \sqrt{\sum_{i=1}^n |x_i|^2} = \sqrt{\mathbf{x}^H \mathbf{x}}, \quad \text{ha } \mathbf{x} \in \mathbb{C}^n.$$

M Manhattan ( $|x| + |y|$ ), képméretezés ( $\max\{|x|, |y|\}$ ).

D A  $p \geq 1$  valósra az  $\mathbf{x} \in \mathbb{C}^n$  vektor  **$p$ -normája**  $\|\mathbf{x}\|_p = (\sum_{i=1}^n |x_i|^p)^{1/p}$ ,  
míg ennek határértéke a  $\infty$ -norma, azaz  $\|\mathbf{x}\|_\infty = \lim_{p \rightarrow \infty} \|\mathbf{x}\|_p$ .

M 1-norma = rácsnorma = Manhattan-norma

M 1-norma = rácsnorma = Manhattan-norma

maximum norma =  $\infty$ -norma

$$\|\mathbf{x}\|_{\infty} = \lim_{p \rightarrow \infty} \|\mathbf{x}\|_p = \lim_{p \rightarrow \infty} \left( \sum_{i=1}^n |x_i|^p \right)^{1/p} = \max_i |x_i|.$$

M 1-norma = rácsnorma = Manhattan-norma

maximum norma =  $\infty$ -norma

$$\|\mathbf{x}\|_{\infty} = \lim_{p \rightarrow \infty} \|\mathbf{x}\|_p = \lim_{p \rightarrow \infty} \left( \sum_{i=1}^n |x_i|^p \right)^{1/p} = \max_i |x_i|.$$


B a legnagyobb abszolút értékű koordináta  $x_{\max}$  ( $|x_i|/|x_{\max}| \leq 1$ )

$$1 \leq \sum_{i=1}^n |x_i/x_{\max}|^p \leq n.$$


Mindegyik kifejezést  $1/p$ -edik hatványra emelve, majd  $|x_{\max}|$ -szal beszorozva kapjuk, hogy

$$|x_{\max}| \leq |x_{\max}| \left( \sum_{i=1}^n \left| \frac{x_i}{x_{\max}} \right|^p \right)^{1/p} \leq |x_{\max}| n^{1/p},$$







$$p = 1$$




$$p = \frac{3}{2}$$



$$p = 2$$



$$p = 3$$




$$p = \infty$$



$$p = 1$$



$$p = 2$$



$$p = \infty$$

## Á Az előző normák alaptulajdonságai:

Á Az előző normák alaptulajdonságai:

- $|\mathbf{x}| \geq 0$

Á Az előző normák alaptulajdonságai:

- $|\mathbf{x}| \geq 0$
- $|\mathbf{x}| = 0 \iff \mathbf{x} = \mathbf{0}$  ( $\rightsquigarrow$  a  $d(\mathbf{x}, \mathbf{y}) = |\mathbf{x} - \mathbf{y}|$  távolságfüggvény **szeparálja** a **pontokat**, azaz két különböző pont távolsága sosem 0)

Á Az előző normák alaptulajdonságai:

- $|\mathbf{x}| \geq 0$
- $|\mathbf{x}| = 0 \iff \mathbf{x} = \mathbf{0}$  ( $\rightsquigarrow$  a  $d(\mathbf{x}, \mathbf{y}) = |\mathbf{x} - \mathbf{y}|$  távolsággfüggvény **szeparálja a pontokat**, azaz két különböző pont távolsága sosem 0)
- $|c\mathbf{x}| = |c||\mathbf{x}|$  (**pozitív homogenitás**)

## Á Az előző normák alaptulajdonságai:

- $|\mathbf{x}| \geq 0$
- $|\mathbf{x}| = 0 \iff \mathbf{x} = \mathbf{0}$  ( $\rightsquigarrow$  a  $d(\mathbf{x}, \mathbf{y}) = |\mathbf{x} - \mathbf{y}|$  távolságfüggvény **szeparálja a pontokat**, azaz két különböző pont távolsága sosem 0)
- $|c\mathbf{x}| = |c||\mathbf{x}|$  (**pozitív homogenitás**)
- $|\mathbf{x} + \mathbf{y}| \leq |\mathbf{x}| + |\mathbf{y}|$  (**háromszögeyenlőtlenség**)

Á Az előző normák alaptulajdonságai:

- $|\mathbf{x}| \geq 0$
- $|\mathbf{x}| = 0 \iff \mathbf{x} = \mathbf{0}$  ( $\rightsquigarrow$  a  $d(\mathbf{x}, \mathbf{y}) = |\mathbf{x} - \mathbf{y}|$  távolságfüggvény **szeparálja a pontokat**, azaz két különböző pont távolsága sosem 0)
- $|c\mathbf{x}| = |c||\mathbf{x}|$  (**pozitív homogenitás**)
- $|\mathbf{x} + \mathbf{y}| \leq |\mathbf{x}| + |\mathbf{y}|$  (**háromszögegyenlőtlenség**)

D Az  $f: \mathbb{R}^n \rightarrow \mathbb{R}$ , vagy  $f: \mathbb{C}^n \rightarrow \mathbb{R}$  függvény **norma**, ha



Á Az előző normák alaptulajdonságai:

- $|\mathbf{x}| \geq 0$
- $|\mathbf{x}| = 0 \iff \mathbf{x} = \mathbf{0}$  ( $\rightsquigarrow$  a  $d(\mathbf{x}, \mathbf{y}) = |\mathbf{x} - \mathbf{y}|$  távolságfüggvény **szeparálja a pontokat**, azaz két különböző pont távolsága sosem 0)
- $|c\mathbf{x}| = |c||\mathbf{x}|$  (**pozitív homogenitás**)
- $|\mathbf{x} + \mathbf{y}| \leq |\mathbf{x}| + |\mathbf{y}|$  (**háromszögegyenlőtlenség**)

D Az  $f: \mathbb{R}^n \rightarrow \mathbb{R}$ , vagy  $f: \mathbb{C}^n \rightarrow \mathbb{R}$  függvény **norma**, ha

- $f(\mathbf{x}) \geq 0$  minden  $\mathbf{x}$  vektorra, és  $f(\mathbf{x}) = 0$  pontosan akkor áll fenn, ha  $\mathbf{x} = \mathbf{0}$ ,

Á Az előző normák alaptulajdonságai:

- $|\mathbf{x}| \geq 0$
- $|\mathbf{x}| = 0 \iff \mathbf{x} = \mathbf{0}$  ( $\rightsquigarrow$  a  $d(\mathbf{x}, \mathbf{y}) = |\mathbf{x} - \mathbf{y}|$  távolságfüggvény **szeparálja a pontokat**, azaz két különböző pont távolsága sosem 0)
- $|c\mathbf{x}| = |c||\mathbf{x}|$  (**pozitív homogenitás**)
- $|\mathbf{x} + \mathbf{y}| \leq |\mathbf{x}| + |\mathbf{y}|$  (**háromszögegyenlőtlenség**)

D Az  $f: \mathbb{R}^n \rightarrow \mathbb{R}$ , vagy  $f: \mathbb{C}^n \rightarrow \mathbb{R}$  függvény **norma**, ha

- $f(\mathbf{x}) \geq 0$  minden  $\mathbf{x}$  vektorra, és  $f(\mathbf{x}) = 0$  pontosan akkor áll fenn, ha  $\mathbf{x} = \mathbf{0}$ ,
- $f(c\mathbf{x}) = |c|f(\mathbf{x})$  minden  $\mathbf{x}$  vektorra,

Á Az előző normák alaptulajdonságai:

- $|\mathbf{x}| \geq 0$
- $|\mathbf{x}| = 0 \iff \mathbf{x} = \mathbf{0}$  ( $\rightsquigarrow$  a  $d(\mathbf{x}, \mathbf{y}) = |\mathbf{x} - \mathbf{y}|$  távolságfüggvény **szeparálja a pontokat**, azaz két különböző pont távolsága sosem 0)
- $|c\mathbf{x}| = |c||\mathbf{x}|$  (**pozitív homogenitás**)
- $|\mathbf{x} + \mathbf{y}| \leq |\mathbf{x}| + |\mathbf{y}|$  (**háromszögegyenlőtlenség**)

D Az  $f: \mathbb{R}^n \rightarrow \mathbb{R}$ , vagy  $f: \mathbb{C}^n \rightarrow \mathbb{R}$  függvény **norma**, ha

- $f(\mathbf{x}) \geq 0$  minden  $\mathbf{x}$  vektorra, és  $f(\mathbf{x}) = 0$  pontosan akkor áll fenn, ha  $\mathbf{x} = \mathbf{0}$ ,
- $f(c\mathbf{x}) = |c|f(\mathbf{x})$  minden  $\mathbf{x}$  vektorra,
- $f(\mathbf{x} + \mathbf{y}) \leq f(\mathbf{x}) + f(\mathbf{y})$ .

Á Az előző normák alaptulajdonságai:

- $|\mathbf{x}| \geq 0$
- $|\mathbf{x}| = 0 \iff \mathbf{x} = \mathbf{0}$  ( $\rightsquigarrow$  a  $d(\mathbf{x}, \mathbf{y}) = |\mathbf{x} - \mathbf{y}|$  távolságfüggvény **szeparálja a pontokat**, azaz két különböző pont távolsága sosem 0)
- $|c\mathbf{x}| = |c||\mathbf{x}|$  (**pozitív homogenitás**)
- $|\mathbf{x} + \mathbf{y}| \leq |\mathbf{x}| + |\mathbf{y}|$  (**háromszögegyenlőtlenség**)

D Az  $f: \mathbb{R}^n \rightarrow \mathbb{R}$ , vagy  $f: \mathbb{C}^n \rightarrow \mathbb{R}$  függvény **norma**, ha

- $f(\mathbf{x}) \geq 0$  minden  $\mathbf{x}$  vektorra, és  $f(\mathbf{x}) = 0$  pontosan akkor áll fenn, ha  $\mathbf{x} = \mathbf{0}$ ,
- $f(c\mathbf{x}) = |c|f(\mathbf{x})$  minden  $\mathbf{x}$  vektorra,
- $f(\mathbf{x} + \mathbf{y}) \leq f(\mathbf{x}) + f(\mathbf{y})$ .

M  $\|\mathbf{x}\| = \|-\mathbf{x}\|$  bármely  $\|\cdot\|$  normára igaz, hisz  
 $\|-\mathbf{x}\| = |-1| \|\mathbf{x}\| = \|\mathbf{x}\|$ .

Á Az előző normák alaptulajdonságai:

- $|\mathbf{x}| \geq 0$
- $|\mathbf{x}| = 0 \iff \mathbf{x} = \mathbf{0}$  ( $\rightsquigarrow$  a  $d(\mathbf{x}, \mathbf{y}) = |\mathbf{x} - \mathbf{y}|$  távolságfüggvény **szeparálja a pontokat**, azaz két különböző pont távolsága sosem 0)
- $|c\mathbf{x}| = |c||\mathbf{x}|$  (**pozitív homogenitás**)
- $|\mathbf{x} + \mathbf{y}| \leq |\mathbf{x}| + |\mathbf{y}|$  (**háromszögeyenlőtlenség**)

D Az  $f: \mathbb{R}^n \rightarrow \mathbb{R}$ , vagy  $f: \mathbb{C}^n \rightarrow \mathbb{R}$  függvény **norma**, ha

- $f(\mathbf{x}) \geq 0$  minden  $\mathbf{x}$  vektorra, és  $f(\mathbf{x}) = 0$  pontosan akkor áll fenn, ha  $\mathbf{x} = \mathbf{0}$ ,
- $f(c\mathbf{x}) = |c|f(\mathbf{x})$  minden  $\mathbf{x}$  vektorra,
- $f(\mathbf{x} + \mathbf{y}) \leq f(\mathbf{x}) + f(\mathbf{y})$ .

M  $\|\mathbf{x}\| = \|-\mathbf{x}\|$  bármely  $\|\cdot\|$  normára igaz, hisz  
 $\|-\mathbf{x}\| = |-1| \|\mathbf{x}\| = \|\mathbf{x}\|$ .

M háromszögeyenlőtlenség másik alakja:

$$\|\mathbf{z} - \mathbf{x}\| \geq \left| \|\mathbf{z}\| - \|\mathbf{x}\| \right|$$

M A háromszögegyenlőtlenség  $p$ -normánál: **Minkowski-egyenlőtlenség:**

$$\|\mathbf{x} + \mathbf{y}\|_p \leq \|\mathbf{x}\|_p + \|\mathbf{y}\|_p. \quad (1)$$

M A háromszögegyenlőtlenség  $p$ -normánál: **Minkowski-egyenlőtlenség:**

$$\|\mathbf{x} + \mathbf{y}\|_p \leq \|\mathbf{x}\|_p + \|\mathbf{y}\|_p. \quad (1)$$

M A **Hölder-egyenlőtlenség** a CBS-egyenlőtlenség általánosítása:

$$|\mathbf{x}^H \mathbf{y}| \leq \|\mathbf{x}\|_p \|\mathbf{y}\|_q, \text{ ahol } \frac{1}{p} + \frac{1}{q} = 1. \quad (2)$$

M A háromszögegyenlőtlenség  $p$ -normánál: **Minkowski-egyenlőtlenség**:

$$\|\mathbf{x} + \mathbf{y}\|_p \leq \|\mathbf{x}\|_p + \|\mathbf{y}\|_p. \quad (1)$$

M A **Hölder-egyenlőtlenség** a CBS-egyenlőtlenség általánosítása:

$$|\mathbf{x}^H \mathbf{y}| \leq \|\mathbf{x}\|_p \|\mathbf{y}\|_q, \text{ ahol } \frac{1}{p} + \frac{1}{q} = 1. \quad (2)$$

M Ha  $\mathbf{x} \mapsto \|\mathbf{x}\|$  egy norma, és  $A$  egy egy-egy értelmű lineáris leképezés, akkor az  $\mathbf{x} \mapsto \|A\mathbf{x}\|$  leképezés is norma és az

$$\mathbf{x} \mapsto \sup_{\mathbf{y} \neq \mathbf{0}} \frac{\mathbf{x} \cdot \mathbf{y}}{\|\mathbf{y}\|}$$



M A háromszögegyenlőtlenség  $p$ -normánál: **Minkowski-egyenlőtlenség:**

$$\|\mathbf{x} + \mathbf{y}\|_p \leq \|\mathbf{x}\|_p + \|\mathbf{y}\|_p. \quad (1)$$

M A **Hölder-egyenlőtlenség** a CBS-egyenlőtlenség általánosítása:

$$|\mathbf{x}^H \mathbf{y}| \leq \|\mathbf{x}\|_p \|\mathbf{y}\|_q, \text{ ahol } \frac{1}{p} + \frac{1}{q} = 1. \quad (2)$$

M Ha  $\mathbf{x} \mapsto \|\mathbf{x}\|$  egy norma, és  $A$  egy egy-egy értelmű lineáris leképezés, akkor az  $\mathbf{x} \mapsto \|A\mathbf{x}\|$  leképezés is norma és az

$$\mathbf{x} \mapsto \sup_{\mathbf{y} \neq \mathbf{0}} \frac{\mathbf{x} \cdot \mathbf{y}}{\|\mathbf{y}\|}$$

M  $\max_i \{|x_i|\} \leq \sqrt{|x_1|^2 + \cdots + |x_n|^2} \leq |x_1| + \cdots + |x_n|$  azaz

$$\|\mathbf{x}\|_\infty \leq \|\mathbf{x}\|_2 \leq \|\mathbf{x}\|_1.$$

M A háromszögegyenlőtlenség  $p$ -normánál: **Minkowski-egyenlőtlenség:**

$$\|\mathbf{x} + \mathbf{y}\|_p \leq \|\mathbf{x}\|_p + \|\mathbf{y}\|_p. \quad (1)$$

M A **Hölder-egyenlőtlenség** a CBS-egyenlőtlenség általánosítása:

$$|\mathbf{x}^H \mathbf{y}| \leq \|\mathbf{x}\|_p \|\mathbf{y}\|_q, \text{ ahol } \frac{1}{p} + \frac{1}{q} = 1. \quad (2)$$

M Ha  $\mathbf{x} \mapsto \|\mathbf{x}\|$  egy norma, és  $A$  egy egy-egy értelmű lineáris leképezés, akkor az  $\mathbf{x} \mapsto \|A\mathbf{x}\|$  leképezés is norma és az

$$\mathbf{x} \mapsto \sup_{\mathbf{y} \neq \mathbf{0}} \frac{\mathbf{x} \cdot \mathbf{y}}{\|\mathbf{y}\|}$$

M  $\max_i \{|x_i|\} \leq \sqrt{|x_1|^2 + \cdots + |x_n|^2} \leq |x_1| + \cdots + |x_n|$  azaz

$$\|\mathbf{x}\|_\infty \leq \|\mathbf{x}\|_2 \leq \|\mathbf{x}\|_1.$$

M Másrészt

$$\|\mathbf{x}\|_1 \leq \sqrt{n} \|\mathbf{x}\|_2, \quad \|\mathbf{x}\|_2 \leq \sqrt{n} \|\mathbf{x}\|_\infty \quad \text{és} \quad \|\mathbf{x}\|_1 \leq n \|\mathbf{x}\|_\infty.$$

M A háromszögegyenlőtlenség  $p$ -normánál: **Minkowski-egyenlőtlenség:**

$$\|\mathbf{x} + \mathbf{y}\|_p \leq \|\mathbf{x}\|_p + \|\mathbf{y}\|_p. \quad (1)$$

M A **Hölder-egyenlőtlenség** a CBS-egyenlőtlenség általánosítása:

$$|\mathbf{x}^H \mathbf{y}| \leq \|\mathbf{x}\|_p \|\mathbf{y}\|_q, \text{ ahol } \frac{1}{p} + \frac{1}{q} = 1. \quad (2)$$

M Ha  $\mathbf{x} \mapsto \|\mathbf{x}\|$  egy norma, és  $A$  egy egy-egy értelmű lineáris leképezés, akkor az  $\mathbf{x} \mapsto \|A\mathbf{x}\|$  leképezés is norma és az

$$\mathbf{x} \mapsto \sup_{\mathbf{y} \neq \mathbf{0}} \frac{\mathbf{x} \cdot \mathbf{y}}{\|\mathbf{y}\|}$$

M  $\max_i \{|x_i|\} \leq \sqrt{|x_1|^2 + \dots + |x_n|^2} \leq |x_1| + \dots + |x_n|$  azaz

$$\|\mathbf{x}\|_\infty \leq \|\mathbf{x}\|_2 \leq \|\mathbf{x}\|_1.$$

M Másrészt

$$\|\mathbf{x}\|_1 \leq \sqrt{n} \|\mathbf{x}\|_2, \quad \|\mathbf{x}\|_2 \leq \sqrt{n} \|\mathbf{x}\|_\infty \text{ és } \|\mathbf{x}\|_1 \leq n \|\mathbf{x}\|_\infty.$$

M Minden norma folytonos függvény.

D A  $\|\cdot\|_a$  és  $\|\cdot\|_b$  normák ekvivalensek, ha van olyan  $c$  és  $d$  pozitív valós szám, hogy  $\|\cdot\|_a \leq c \|\cdot\|_b$  és  $\|\cdot\|_b \leq d \|\cdot\|_a$ .

- D A  $\|\cdot\|_a$  és  $\|\cdot\|_b$  normák ekvivalensek, ha van olyan  $c$  és  $d$  pozitív valós szám, hogy  $\|\cdot\|_a \leq c \|\cdot\|_b$  és  $\|\cdot\|_b \leq d \|\cdot\|_a$ .
- M Az 1-, 2- és  $\infty$ -normák ekvivalensek

- D A  $\|\cdot\|_a$  és  $\|\cdot\|_b$  normák ekvivalensek, ha van olyan  $c$  és  $d$  pozitív valós szám, hogy  $\|\cdot\|_a \leq c \|\cdot\|_b$  és  $\|\cdot\|_b \leq d \|\cdot\|_a$ .
- M Az 1-, 2- és  $\infty$ -normák ekvivalensek
- T A  $\mathbb{K}^n$  téren értelmezett bármely két norma ekvivalens ( $\mathbb{K} = \mathbb{R}$  vagy  $\mathbb{C}$ ).

- D A  $\|\cdot\|_a$  és  $\|\cdot\|_b$  normák ekvivalensek, ha van olyan  $c$  és  $d$  pozitív valós szám, hogy  $\|\cdot\|_a \leq c \|\cdot\|_b$  és  $\|\cdot\|_b \leq d \|\cdot\|_a$ .
- M Az 1-, 2- és  $\infty$ -normák ekvivalensek
- T A  $\mathbb{K}^n$  téren értelmezett bármely két norma ekvivalens ( $\mathbb{K} = \mathbb{R}$  vagy  $\mathbb{C}$ ).
- M Ez csak véges dimenziós terekben igaz, itt tehát a konvergenciakérdésekhez bármelyik norma jó.

D Az  $\mathbf{A} \in \mathbb{C}^{m \times n}$  mátrix Frobenius-normája

$$\|\mathbf{A}\|_F = \sqrt{\sum_{i=1}^m \sum_{j=1}^n |a_{ij}|^2} = \sqrt{\sum_{i=1}^m \|\mathbf{A}_{i*}\|_2^2} = \sqrt{\sum_{j=1}^n \|\mathbf{A}_{*j}\|_2^2}.$$



D Az  $\mathbf{A} \in \mathbb{C}^{m \times n}$  mátrix Frobenius-normája

$$\|\mathbf{A}\|_F = \sqrt{\sum_{i=1}^m \sum_{j=1}^n |a_{ij}|^2} = \sqrt{\sum_{i=1}^m \|\mathbf{A}_{i*}\|_2^2} = \sqrt{\sum_{j=1}^n \|\mathbf{A}_{*j}\|_2^2}.$$

T Frobenius-norma ekvivalens alakjai:

$$\|\mathbf{A}\|_F = \sqrt{\text{trace}(\mathbf{A}^H \mathbf{A})} = \sqrt{\sum_{i=1}^{\min(m,n)} \sigma_i^2}.$$

D Az  $\mathbf{A} \in \mathbb{C}^{m \times n}$  mátrix Frobenius-normája

$$\|\mathbf{A}\|_F = \sqrt{\sum_{i=1}^m \sum_{j=1}^n |a_{ij}|^2} = \sqrt{\sum_{i=1}^m \|\mathbf{A}_{i*}\|_2^2} = \sqrt{\sum_{j=1}^n \|\mathbf{A}_{*j}\|_2^2}.$$

T Frobenius-norma ekvivalens alakjai:

$$\|\mathbf{A}\|_F = \sqrt{\text{trace}(\mathbf{A}^H \mathbf{A})} = \sqrt{\sum_{i=1}^{\min(m,n)} \sigma_i^2}.$$

B  $[\mathbf{A}^H \mathbf{A}]_{jj} = \|\mathbf{A}_{*j}\|_2^2$

D Az  $\mathbf{A} \in \mathbb{C}^{m \times n}$  mátrix Frobenius-normája

$$\|\mathbf{A}\|_F = \sqrt{\sum_{i=1}^m \sum_{j=1}^n |a_{ij}|^2} = \sqrt{\sum_{i=1}^m \|\mathbf{A}_{i*}\|_2^2} = \sqrt{\sum_{j=1}^n \|\mathbf{A}_{*j}\|_2^2}.$$

T Frobenius-norma ekvivalens alakjai:

$$\|\mathbf{A}\|_F = \sqrt{\text{trace}(\mathbf{A}^H \mathbf{A})} = \sqrt{\sum_{i=1}^{\min(m,n)} \sigma_i^2}.$$

B  $[\mathbf{A}^H \mathbf{A}]_{jj} = \|\mathbf{A}_{*j}\|_2^2$

nyom = sajátértékek összege

D Az  $\mathbf{A} \in \mathbb{C}^{m \times n}$  mátrix Frobenius-normája

$$\|\mathbf{A}\|_F = \sqrt{\sum_{i=1}^m \sum_{j=1}^n |a_{ij}|^2} = \sqrt{\sum_{i=1}^m \|\mathbf{A}_{i*}\|_2^2} = \sqrt{\sum_{j=1}^n \|\mathbf{A}_{*j}\|_2^2}.$$

T Frobenius-norma ekvivalens alakjai:

$$\|\mathbf{A}\|_F = \sqrt{\text{trace}(\mathbf{A}^H \mathbf{A})} = \sqrt{\sum_{i=1}^{\min(m,n)} \sigma_i^2}.$$

B  $[\mathbf{A}^H \mathbf{A}]_{jj} = \|\mathbf{A}_{*j}\|_2^2$

nyom = sajátértékek összege

Á Bármely  $\mathbf{x} \in \mathbb{C}^n$  vektorra és  $\mathbf{A} \in \mathbb{C}^{m \times n}$  mátrixra  $\|\mathbf{A}\mathbf{x}\|_2 \leq \|\mathbf{A}\|_F \|\mathbf{x}\|_2$ .

D Az  $\mathbf{A} \in \mathbb{C}^{m \times n}$  mátrix Frobenius-normája

$$\|\mathbf{A}\|_F = \sqrt{\sum_{i=1}^m \sum_{j=1}^n |a_{ij}|^2} = \sqrt{\sum_{i=1}^m \|\mathbf{A}_{i*}\|_2^2} = \sqrt{\sum_{j=1}^n \|\mathbf{A}_{*j}\|_2^2}.$$

T Frobenius-norma ekvivalens alakjai:

$$\|\mathbf{A}\|_F = \sqrt{\text{trace}(\mathbf{A}^H \mathbf{A})} = \sqrt{\sum_{i=1}^{\min(m,n)} \sigma_i^2}.$$

B  $[\mathbf{A}^H \mathbf{A}]_{jj} = \|\mathbf{A}_{*j}\|_2^2$

nyom = sajátértékek összege

Á Bármely  $\mathbf{x} \in \mathbb{C}^n$  vektorra és  $\mathbf{A} \in \mathbb{C}^{m \times n}$  mátrixra  $\|\mathbf{A}\mathbf{x}\|_2 \leq \|\mathbf{A}\|_F \|\mathbf{x}\|_2$ .

B Cauchy–Bunyakovszkij–Schwarz-egyenlőtlenségből:

$$\|\mathbf{A}\mathbf{x}\|_2^2 = \sum_{i=1}^n |\mathbf{A}_{i*}\mathbf{x}|^2 \leq \sum_{i=1}^n \|\mathbf{A}_{i*}\|_2^2 \|\mathbf{x}\|_2^2 = \|\mathbf{A}\|_F^2 \|\mathbf{x}\|_2^2.$$

D  $\|\cdot\| : \mathbb{K}^n \rightarrow \mathbb{R}$  mátrixnorma, ha

D  $\|\cdot\| : \mathbb{K}^n \rightarrow \mathbb{R}$  mátrixnorma, ha

- $\|\mathbf{A}\| \geq 0$ , és  $\|\mathbf{A}\| = 0$  pontosan akkor áll fenn, ha  $\mathbf{A} = \mathbf{O}$ ,

D  $\|\cdot\| : \mathbb{K}^n \rightarrow \mathbb{R}$  mátrixnorma, ha

- $\|\mathbf{A}\| \geq 0$ , és  $\|\mathbf{A}\| = 0$  pontosan akkor áll fenn, ha  $\mathbf{A} = \mathbf{O}$ ,
- $\|c\mathbf{A}\| = |c| \|\mathbf{A}\|$ ,



D  $\|\cdot\| : \mathbb{K}^n \rightarrow \mathbb{R}$  mátrixnorma, ha

- $\|\mathbf{A}\| \geq 0$ , és  $\|\mathbf{A}\| = 0$  pontosan akkor áll fenn, ha  $\mathbf{A} = \mathbf{O}$ ,
- $\|c\mathbf{A}\| = |c| \|\mathbf{A}\|$ ,
- $\|\mathbf{A} + \mathbf{B}\| \leq \|\mathbf{A}\| + \|\mathbf{B}\|$ ,

D  $\|\cdot\| : \mathbb{K}^n \rightarrow \mathbb{R}$  mátrixnorma, ha

- $\|\mathbf{A}\| \geq 0$ , és  $\|\mathbf{A}\| = 0$  pontosan akkor áll fenn, ha  $\mathbf{A} = \mathbf{O}$ ,
- $\|c\mathbf{A}\| = |c| \|\mathbf{A}\|$ ,
- $\|\mathbf{A} + \mathbf{B}\| \leq \|\mathbf{A}\| + \|\mathbf{B}\|$ ,
- $\|\mathbf{AC}\| \leq \|\mathbf{A}\| \|\mathbf{C}\|$ .

D  $\|\cdot\| : \mathbb{K}^n \rightarrow \mathbb{R}$  mátrixnorma, ha

- $\|\mathbf{A}\| \geq 0$ , és  $\|\mathbf{A}\| = 0$  pontosan akkor áll fenn, ha  $\mathbf{A} = \mathbf{O}$ ,
- $\|c\mathbf{A}\| = |c| \|\mathbf{A}\|$ ,
- $\|\mathbf{A} + \mathbf{B}\| \leq \|\mathbf{A}\| + \|\mathbf{B}\|$ ,
- $\|\mathbf{AC}\| \leq \|\mathbf{A}\| \|\mathbf{C}\|$ .

D  $\|\cdot\|$  egy tetszőleges vektornorma. Ekkor az

$$\|\mathbf{A}\| = \max_{\|\mathbf{x}\|=1} \|\mathbf{Ax}\|$$

egyenlőséggel definiált függvényt a vektornorma által **indukált** mátrixnormának nevezzük.

- D  $\|\cdot\| : \mathbb{K}^n \rightarrow \mathbb{R}$  mátrixnorma, ha
- $\|\mathbf{A}\| \geq 0$ , és  $\|\mathbf{A}\| = 0$  pontosan akkor áll fenn, ha  $\mathbf{A} = \mathbf{O}$ ,
  - $\|c\mathbf{A}\| = |c| \|\mathbf{A}\|$ ,
  - $\|\mathbf{A} + \mathbf{B}\| \leq \|\mathbf{A}\| + \|\mathbf{B}\|$ ,
  - $\|\mathbf{AC}\| \leq \|\mathbf{A}\| \|\mathbf{C}\|$ .
- D  $\|\cdot\|$  egy tetszőleges vektornorma. Ekkor az

$$\|\mathbf{A}\| = \max_{\|\mathbf{x}\|=1} \|\mathbf{Ax}\|$$

egyenlőséggel definiált függvényt a vektornorma által **indukált** mátrixnormának nevezzük.

- M Jelölés:  $\|\mathbf{A}\|_p = \max_{\|\mathbf{x}\|_p=1} \|\mathbf{Ax}\|_p$

- D  $\|\cdot\| : \mathbb{K}^n \rightarrow \mathbb{R}$  mátrixnorma, ha
- $\|\mathbf{A}\| \geq 0$ , és  $\|\mathbf{A}\| = 0$  pontosan akkor áll fenn, ha  $\mathbf{A} = \mathbf{O}$ ,
  - $\|c\mathbf{A}\| = |c| \|\mathbf{A}\|$ ,
  - $\|\mathbf{A} + \mathbf{B}\| \leq \|\mathbf{A}\| + \|\mathbf{B}\|$ ,
  - $\|\mathbf{AC}\| \leq \|\mathbf{A}\| \|\mathbf{C}\|$ .
- D  $\|\cdot\|$  egy tetszőleges vektornorma. Ekkor az

$$\|\mathbf{A}\| = \max_{\|\mathbf{x}\|=1} \|\mathbf{Ax}\|$$

egyenlőséggel definiált függvényt a vektornorma által **indukált** mátrixnormának nevezzük.

- M Jelölés:  $\|\mathbf{A}\|_p = \max_{\|\mathbf{x}\|_p=1} \|\mathbf{Ax}\|_p$
- M Ha lineáris leképezésre értelmezzük, **operátornormáról** beszélünk.

- D  $\|\cdot\| : \mathbb{K}^n \rightarrow \mathbb{R}$  mátrixnorma, ha
- $\|\mathbf{A}\| \geq 0$ , és  $\|\mathbf{A}\| = 0$  pontosan akkor áll fenn, ha  $\mathbf{A} = \mathbf{O}$ ,
  - $\|c\mathbf{A}\| = |c| \|\mathbf{A}\|$ ,
  - $\|\mathbf{A} + \mathbf{B}\| \leq \|\mathbf{A}\| + \|\mathbf{B}\|$ ,
  - $\|\mathbf{AC}\| \leq \|\mathbf{A}\| \|\mathbf{C}\|$ .
- D  $\|\cdot\|$  egy tetszőleges vektornorma. Ekkor az

$$\|\mathbf{A}\| = \max_{\|\mathbf{x}\|=1} \|\mathbf{Ax}\|$$

egyenlőséggel definiált függvényt a vektornorma által **indukált** mátrixnormának nevezzük.

- M Jelölés:  $\|\mathbf{A}\|_p = \max_{\|\mathbf{x}\|_p=1} \|\mathbf{Ax}\|_p$
- M Ha lineáris leképezésre értelmezzük, **operátornormáról** beszélünk.
- M A normák ekvivalenciájából  $\rightsquigarrow$  bármely normában az egységgömb korlátos és zárt  $\rightsquigarrow$  a  $\mathbf{x} \mapsto \mathbf{Ax}$  függvénynek van maximuma és minimuma

- D  $\|\cdot\| : \mathbb{K}^n \rightarrow \mathbb{R}$  mátrixnorma, ha
- $\|\mathbf{A}\| \geq 0$ , és  $\|\mathbf{A}\| = 0$  pontosan akkor áll fenn, ha  $\mathbf{A} = \mathbf{O}$ ,
  - $\|c\mathbf{A}\| = |c| \|\mathbf{A}\|$ ,
  - $\|\mathbf{A} + \mathbf{B}\| \leq \|\mathbf{A}\| + \|\mathbf{B}\|$ ,
  - $\|\mathbf{AC}\| \leq \|\mathbf{A}\| \|\mathbf{C}\|$ .
- D  $\|\cdot\|$  egy tetszőleges vektornorma. Ekkor az

$$\|\mathbf{A}\| = \max_{\|\mathbf{x}\|=1} \|\mathbf{Ax}\|$$

egyenlőséggel definiált függvényt a vektornorma által **indukált** mátrixnormának nevezzük.

- M Jelölés:  $\|\mathbf{A}\|_p = \max_{\|\mathbf{x}\|_p=1} \|\mathbf{Ax}\|_p$
- M Ha lineáris leképezésre értelmezzük, **operátornormáról** beszélünk.
- M A normák ekvivalenciájából  $\rightsquigarrow$  bármely normában az egységgömb korlátos és zárt  $\rightsquigarrow$  a  $\mathbf{x} \mapsto \mathbf{Ax}$  függvénynek van maximuma és minimuma
- M a definíció a ekvivalens alakjai

$$\|\mathbf{A}\| = \sup_{\|\mathbf{x}\| \neq 0} \frac{\|\mathbf{Ax}\|}{\|\mathbf{x}\|} = \max_{\|\mathbf{x}\| \neq 0} \frac{\|\mathbf{Ax}\|}{\|\mathbf{x}\|}.$$

T Legyen  $\mathbf{A} \in \mathbb{C}^{m \times n}$ , ekkor

$$\|\mathbf{A}\|_1 = \max_j \sum_{i=1}^n |a_{ij}| = \text{legnagyobb abszolút oszlopösszeg}, \quad (3)$$

$$\|\mathbf{A}\|_\infty = \max_i \sum_{j=1}^m |a_{ij}| = \text{legnagyobb abszolút sorösszeg}, \quad (4)$$

$$\|\mathbf{A}\|_2 = \left\| \mathbf{A}^H \right\|_2 = \max_{\|\mathbf{x}\|_2=1} \max_{\|\mathbf{y}\|_2=1} |\mathbf{y}^H \mathbf{A} \mathbf{x}| = \sigma_1, \quad (5)$$



T Legyen  $\mathbf{A} \in \mathbb{C}^{m \times n}$ , ekkor

$$\|\mathbf{A}\|_1 = \max_j \sum_{i=1}^n |a_{ij}| = \text{legnagyobb abszolút oszlopösszeg}, \quad (3)$$

$$\|\mathbf{A}\|_\infty = \max_i \sum_{j=1}^m |a_{ij}| = \text{legnagyobb abszolút sorösszeg}, \quad (4)$$

$$\|\mathbf{A}\|_2 = \left\| \mathbf{A}^H \right\|_2 = \max_{\|\mathbf{x}\|_2=1} \max_{\|\mathbf{y}\|_2=1} |\mathbf{y}^H \mathbf{A} \mathbf{x}| = \sigma_1, \quad (5)$$

Ha az  $\mathbf{A} \in \mathbb{C}^{n \times n}$  invertálható, akkor

$$\|\mathbf{A}^{-1}\|_2 = \max_{\|\mathbf{x}\|_2=1} \frac{1}{\|\mathbf{A} \mathbf{x}\|_2} = \frac{1}{\min_{\|\mathbf{x}\|_2=1} \|\mathbf{A} \mathbf{x}\|_2} = \frac{1}{\sigma_n}, \quad (6)$$

ahol  $\sigma_n$  az  $\mathbf{A}$  legkisebb (pozitív) szinguláris értéke.

T Legyen  $\mathbf{A} \in \mathbb{C}^{m \times n}$ , ekkor

$$\|\mathbf{A}\|_1 = \max_j \sum_{i=1}^n |a_{ij}| = \text{legnagyobb abszolút oszlopösszeg}, \quad (3)$$

$$\|\mathbf{A}\|_\infty = \max_i \sum_{j=1}^m |a_{ij}| = \text{legnagyobb abszolút sorösszeg}, \quad (4)$$

$$\|\mathbf{A}\|_2 = \left\| \mathbf{A}^H \right\|_2 = \max_{\|\mathbf{x}\|_2=1} \max_{\|\mathbf{y}\|_2=1} |\mathbf{y}^H \mathbf{A} \mathbf{x}| = \sigma_1, \quad (5)$$

Ha az  $\mathbf{A} \in \mathbb{C}^{n \times n}$  invertálható, akkor

$$\|\mathbf{A}^{-1}\|_2 = \max_{\|\mathbf{x}\|_2=1} \frac{1}{\|\mathbf{A} \mathbf{x}\|_2} = \frac{1}{\min_{\|\mathbf{x}\|_2=1} \|\mathbf{A} \mathbf{x}\|_2} = \frac{1}{\sigma_n}, \quad (6)$$

ahol  $\sigma_n$  az  $\mathbf{A}$  legkisebb (pozitív) szinguláris értéke.

M Az 1-, a  $\infty$ - és a 2-normára szokásos másik elnevezés: **oszlopnorma**, **sornorma** és **spektrálnorma**.