



BUDAPESTI MŰSZAKI  
MATEMATIKA  
ÉS GAZDASÁGTUDOMÁNYI  
INTÉZET  
EGYETEM



## Alkalmazott algebra

BMETE90MX57 (FELSŐBB MATEMATIKA INFORMATIKUSOKNAK)



## Szinguláris értékek

2018-11-05 EIC



## Wettl Ferenc


ALGEBRA TANSZÉK

- Szinguláris érték, jobb és bal szinguláris vektor meghatározása, szinguláris felbontás és geometriai interpretációja
- SVD alkalmazásai: pszeudo inverz, polárfelbontás, kis rangú approximáció (Eckart–Young-tétel)
- Norma, mátrixnorma, indukált norma

# Szinguláris érték

---

## Keressünk két ONB-t



Az **ortogonális diagonalizációt** igyekszünk megvalósítani a kitüntetett alterek ONB-aival, azzal az „apró” módosítással, hogy a sortér bázisának minden vektora az oszloptér bázisának pozitív konstansszorosába menjen (a nulltérbeli bázisvektorok a  $0$ -ba).

## Diagonális két ONB-ban

- m Az  $\mathbf{A} \in \mathbb{R}^{m \times n}$  mátrixhoz olyan ortonormált  $\{\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_n\} \subset \mathbb{R}^n$  és  $\{\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_m\} \subset \mathbb{R}^m$  ortonormált bázisokat keresünk, melyekben  $\mathbf{A}$  mátrixa diagonálissá válik. Ez azt jelenti, hogy léteznek olyan  $\sigma_i$  valósok, hogy  $\mathbf{A}\mathbf{v}_i = \sigma_i\mathbf{u}_i$ , ahol  $1 \leq i \leq \min(m, n)$ .
- Á Ha  $\mathbf{A} \in \mathbb{R}^{m \times n}$  és az egymásra merőleges  $\mathbf{x}, \mathbf{y} \in \mathbb{R}^n$  vektorok legalább egyike az  $\mathbf{A}^\top\mathbf{A}$  Gram-mátrix sajátvektora, akkor az  $\mathbf{A}\mathbf{x}, \mathbf{A}\mathbf{y} \in \mathbb{R}^m$  vektorok is merőlegesek egymásra.
- B A feltételek szerint  $\mathbf{x} \cdot \mathbf{y} = 0$ , és legyen például  $\mathbf{A}^\top\mathbf{A}\mathbf{y} = \lambda\mathbf{y}$ .  
Ekkor

$$\mathbf{A}\mathbf{x} \cdot \mathbf{A}\mathbf{y} = (\mathbf{A}\mathbf{x})^\top\mathbf{A}\mathbf{y} = \mathbf{x}^\top\mathbf{A}^\top\mathbf{A}\mathbf{y} = \mathbf{x} \cdot (\lambda\mathbf{y}) = \lambda(\mathbf{x} \cdot \mathbf{y}) = 0.$$

- $\mathbf{A}^T\mathbf{A}$  szimmetrikus és pozitív szemidefinit  $\rightsquigarrow$  ortogonálisan diagonalizálható, sajátértékei nem negatívak
- sv-okból kiválasztható  $\mathbb{R}^n$  egy ONB-a, a 0 sé-hez tartozók a  $\mathcal{N}(\mathbf{A}^T\mathbf{A}) = \mathcal{N}(\mathbf{A})$  tér ONB-át adják ( $\mathcal{N}(\mathbf{A}) = \{\mathbf{0}\}$  esetén a bázis  $\emptyset$ )
- a többi  $\mathcal{N}(\mathbf{A})^\perp = \mathcal{S}(\mathbf{A})$  ONB-a:  $\{\mathbf{v}_1, \dots, \mathbf{v}_r\}$ , ahol  $r$  az  $\mathbf{A}$  rangja
- ezek  $\mathbf{A}$  általi képei páronként merőlegesek egymásra  $\rightsquigarrow$  az  $\mathbf{A}\mathbf{v}_i$  vektorok ortogonális bázist alkotnak az oszloptérben.
- ha  $\mathbf{v}_i$  az  $\mathbf{A}^T\mathbf{A}$  mátrix  $\lambda_i > 0$  sé-hez tartozó egységnyi sv-a, akkor  $|\mathbf{A}\mathbf{v}_i| = \sqrt{\lambda_i}$ , ui.  $|\mathbf{A}\mathbf{v}_i|^2 = (\mathbf{A}\mathbf{v}_i)^T(\mathbf{A}\mathbf{v}_i) = \mathbf{v}_i^T\mathbf{A}^T\mathbf{A}\mathbf{v}_i = \lambda_i|\mathbf{v}_i|^2 = \lambda_i$ .
- L!  $\sigma_i = \sqrt{\lambda_i}$ , így  $\mathbf{A}\mathbf{v}_i = \sigma_i\mathbf{u}_i$   $|\mathbf{u}_i| = 1 \rightsquigarrow \{\mathbf{u}_1, \dots, \mathbf{u}_r\}$  ONB  $\mathcal{O}(\mathbf{A})$ -ban
- $\mathbf{A}\mathbf{v}_i = \sigma_i\mathbf{u}_i$ ,  $\mathbf{A}^T\mathbf{A}\mathbf{v}_i = \sigma_i^2\mathbf{v}_i \rightsquigarrow \mathbf{A}^T\mathbf{u}_i = \frac{1}{\sigma_i}\mathbf{A}^T\mathbf{A}\mathbf{v}_i = \frac{1}{\sigma_i}\sigma_i^2\mathbf{v}_i = \sigma_i\mathbf{v}_i$ :

$$\mathbf{A}\mathbf{v}_i = \sigma_i\mathbf{u}_i, \quad \mathbf{A}^T\mathbf{u}_i = \sigma_i\mathbf{v}_i$$

párba állítják a  $\mathbf{v}_i$  és  $\mathbf{u}_i$  vektorokat

- $\mathbf{v} \in \mathcal{N}(\mathbf{A})$ ,  $\mathbf{u} \in \mathcal{N}(\mathbf{A}^T)$ ,  $\sigma = 0$ :

$$\mathbf{A}\mathbf{v} = \sigma\mathbf{u}, \quad \mathbf{A}^T\mathbf{u} = \sigma\mathbf{v}$$

## Szinguláris értékek és vektorok

- D Az  $r$  rangú  $\mathbf{A} \in \mathbb{R}^{m \times n}$  mátrix **szinguláris értékének** nevezzük azt a nemnegatív  $\sigma$  valóst, melyhez van olyan  $\mathbf{v} \in \mathbb{R}^n$  és  $\mathbf{u} \in \mathbb{R}^m$  két nemzérus vektor, hogy

$$\mathbf{A}\mathbf{v} = \sigma\mathbf{u}, \quad \mathbf{A}^T\mathbf{u} = \sigma\mathbf{v}.$$

A  $\mathbf{v}$  vektort **jobb**, az  $\mathbf{u}$  vektort **bal szinguláris vektornak** nevezzük (ui.  $\mathbf{u}^T\mathbf{A} = \sigma\mathbf{v}^T$ ). A  $\sigma$  szinguláris érték **multiplicitása**  $s$ , ha legfeljebb  $s$  olyan **független**  $\mathbf{v}_1, \dots, \mathbf{v}_s$  jobb és  $\mathbf{u}_1, \dots, \mathbf{u}_s$  bal szinguláris vektor található, hogy minden  $i = 1, 2, \dots, s$  indexre

$$\mathbf{A}\mathbf{v}_i = \sigma\mathbf{u}_i, \quad \mathbf{A}^T\mathbf{u}_i = \sigma\mathbf{v}_i.$$

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

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

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

J Jelölések:

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

$$\mathbf{U}_1 = [\mathbf{u}_1 \mid \dots \mid \mathbf{u}_r]$$

$$\mathbf{V}_1 = [\mathbf{v}_1 \mid \dots \mid \mathbf{v}_r]$$

$$\mathbf{A}\mathbf{v}_i = \sigma_i\mathbf{u}_i \rightsquigarrow \mathbf{A}\mathbf{V}_1 = \mathbf{U}_1\Sigma_1$$

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

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

$$\mathbf{V}_2 = [\mathbf{v}_{r+1} \quad \dots \quad \mathbf{v}_n]$$

$$\mathbf{U}_2 = [\mathbf{u}_{r+1} \quad \dots \quad \mathbf{u}_m]$$



$\mathbb{R}$ -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

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

# Szinguláris (érték szerinti) felbontás, SVD

$V^T$ -tal ( $V^H$ -tal) jobbról szorozva ( $VV^T = I$ ):

$$A = [U_1 \mid U_2] \left[ \begin{array}{c|c} \Sigma_1 & \mathbf{0} \\ \hline \mathbf{0} & \mathbf{0} \end{array} \right] \begin{bmatrix} V_1^T \\ V_2^T \end{bmatrix} = U_1 \Sigma_1 V_1^T$$

- D !  $A \in \mathbb{K}^{m \times n}$  ( $\mathbb{K} = \mathbb{R}$  vagy  $\mathbb{C}$ ). **Szinguláris érték szerinti felbontás**, vagy **szinguláris felbontás**:  $A = U \Sigma V^H$ , ahol  $U$  és  $V$  unitér (ortogonális) és  $\Sigma$  diagonális, monoton csökkenő nemnegatív elemekkel a főátlóban.
- **Redukált szinguláris felbontás**:  $A = U_1 \Sigma_1 V_1^H$ , ahol  $V_1, U_1$  szemiunitér (szemiortogonális) és  $\Sigma_1$  négyzetes, diagonális, monoton csökkenő pozitív elemekkel a főátlóban.
  - **Szinguláris érték szerinti diadikus felbontás** vagy a **szinguláris felbontás diadikus alakja**:  $A = \sigma_1 u_1 v_1^T + \sigma_2 u_2 v_2^T + \dots + \sigma_r u_r v_r^T$ , ahol  $\{u_1, \dots, u_r\} \subset \mathbb{K}^m$ ,  $\{v_1, \dots, v_r\} \subset \mathbb{K}^n$  ONR,  $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r > 0$ .

## Példa a SVD három alakjára

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

# Szinguláris érték

---

Az SVD meghatározása

# SVD meghatározása $A^H A$ -ból

m Ötlet:  $A^H A = (U \Sigma V^H)^H U \Sigma V^H = V \Sigma^H U^H U \Sigma V^H = V \Sigma^H \Sigma V^H$

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

SVD kiszámítása:

- 1 kiszámoljuk  $A^H A$  poz.sé-eit ( $\lambda_i > 0$ ) és sv-ai közül kiválasztunk egy ONR-t (ez  $\mathcal{O}(A^H)$  ONB-a:  $\{\mathbf{v}_i\}_{i=1}^r$ ), ezek **jobb szinguláris vektorok**,
- 2 a sajátértékek gyökei a **szinguláris értékek** ( $\sigma_i = \sqrt{\lambda_i}$ ),
- 3 **bal szinguláris vektorok**: mivel  $A \mathbf{v}_i = \sigma_i \mathbf{u}_i$ , ezért  $\mathbf{u}_i = A \mathbf{v}_i / \sigma_i$ ,
- 4 a szinguláris vektorokból fölírható  $V_1$  és  $U_1$ , a **redukált szinguláris felbontás** és a **diadikus alak**,
- 5 az  $\mathcal{N}(A)$ , illetve  $\mathcal{N}(A^H)$  egy-egy tetszőleges ONB-ának vektoraival kiegészítve  $V V_1$  és  $U_1$  oszlopait megkapjuk a  $V$  és  $U$  mátrixokat, és a **teljes SVD-t**.

## Alternatíva $m < n$ esetére, ha a mátrix $m \times n$ -es

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

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

SVD kiszámítása:

- 1 meghatározzuk  $\mathbf{A}\mathbf{A}^H$  pozitív sajátértékeit ( $\lambda_i > 0$ ) és sajátvektorai közül kiválasztunk egy ONR-t ( $\mathbf{u}_i$ ), ezek **bal szinguláris vektorok**,
- 2 a sajátértékek gyökei a **szinguláris értékek** ( $\sigma_i = \sqrt{\lambda_i}$ ),
- 3  $\mathbf{v}_i = \mathbf{A}^H\mathbf{u}_i/\sigma_i$ , a **jobb szinguláris vektorok**
- 4 mint fönt ( $\mathbf{V}_1, \mathbf{U}_1$ ),
- 5 mint fönt (a nullterek bázisaival kiegészítés ONB-sá).

# Szinguláris érték

---

Szinguláris érték szerinti felbontás létezése

**T** **A szinguláris értékek létezése és egyértelműsége:** Minden  $r$ -rangú komplex  $\mathbf{A}$  mátrixnak létezik  $r$  (pozitív) 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, és unitéren 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




# Szinguláris érték

---

Geometriai interpretáció

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 nyújt/összenyom, 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:  $\mathbf{V}^T$  ort.  $\rightsquigarrow \mathbf{V}^T \mathbf{v}_i = \mathbf{e}_i$  ( $i = 1, 2, 3$ ).

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

A kép nem egy ellipsziszvonal, hanem ellipszistartomány.

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

$$\mathbf{A}_{2 \times 3} = \mathbf{U} \Sigma \mathbf{V}^T : \mathbf{x}_{3 \times 1} \mapsto \mathbf{U}_{2 \times 2} \Sigma_{2 \times 3} \mathbf{V}_{3 \times 3}^T \mathbf{x}_{3 \times 1}$$



- 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  $r < n$ .

# Szinguláris érték

---

Polárfelbontás, pszeudo inverz

- m  $re^{i\varphi}$ : egy nemnegatív nyújtási tényező ( $r$ ) és egy egységnyi abszolút értékű komplex szám ( $e^{i\varphi}$ , ami a komplex síkon  $\varphi$ -vel való forgatás) szorzata.
- D **Polárfelbontáson** egy négyzetes mátrixnak egy pozitív szemidefinit és egy ortogonális mátrix szorzatára való felbontását értjük.
- T Bármely komplex (valós) négyzetes  $\mathbf{A}$  mátrix előáll

$$\mathbf{A} = \mathbf{P}\mathbf{Q}$$

alakban, ahol  $\mathbf{P}$  pozitív szemidefinit önadjungált (szimmetrikus) mátrix,  $\mathbf{Q}$  pedig unitér (ortogonális). Ha  $\mathbf{A}$  invertálható, akkor  $\mathbf{P}$  pozitív definit, és a felbontás egyértelmű.

B  $\mathbf{A} = \mathbf{U}\Sigma\mathbf{V}^H = \mathbf{U}\Sigma\mathbf{U}^H\mathbf{U}\mathbf{V}^H = (\mathbf{U}\Sigma\mathbf{U}^H)(\mathbf{U}\mathbf{V}^H)$ , ahonnan  $\mathbf{P} = \mathbf{U}\Sigma\mathbf{U}^H$ ,  
 $\mathbf{Q} = \mathbf{U}\mathbf{V}^H$ .

$\mathbf{P}$  önadjungált, hisz  $(\mathbf{U}\Sigma\mathbf{U}^H)^H = \mathbf{U}\Sigma^H\mathbf{U}^H = \mathbf{U}\Sigma\mathbf{U}^H$ .

$\mathbf{A}$   $\mathbf{P}$  pozitív szemidefinit, hisz hasonló a pozitív szemidefinit  $\Sigma$  mátrixhoz (ha  $\mathbf{A}$  invertálható, akkor  $\Sigma$  pozitív definit)

$\mathbf{Q}$  unitér (ortogonális), hisz két unitér (ortogonális) mátrix szorzata.

$\mathbf{A}$   $\mathbf{P}$  egyértelmű (nem csak akkor, ha pozitív definit), ugyanis

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

azaz  $\mathbf{P} = \sqrt{\mathbf{A}\mathbf{A}^H}$ , 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.

- analógia a determinánsoknál is:  $\det \mathbf{P} = r$ ,  $\det \mathbf{Q} = e^{i\varphi}$  (hisz  $\mathbf{Q}$  unitér),  $\det \mathbf{A} = re^{i\varphi}$ .
- Fordított sorrend: azonos unitér (ortogonális) mátrixszal:

$$\mathbf{A} = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^H = \mathbf{U}\mathbf{V}^H\mathbf{V}\mathbf{\Sigma}\mathbf{V}^H = (\mathbf{U}\mathbf{V}^H)(\mathbf{V}\mathbf{\Sigma}\mathbf{V}^H) = \mathbf{Q}\hat{\mathbf{P}},$$

- Valós polárfelbontás geometriai jelentése: minden mátrixleképezés két olyan leképezés kompozíciója, amelyekből az egyik forgatja vagy forgatva tükrözi a teret ( $\mathbf{Q}$ ), a másik pedig egy ortonormált bázis tengelyei mentén nyújtja/összenyomja a teret minden tengelyirányban egy-egy nemnegatív tényezővel.



P Polárfelbontásait számítsuk ki

$$\mathbf{A} = \begin{bmatrix} 0 & -2 & 2 \\ -2 & 3 & -2 \\ 4 & -2 & 0 \end{bmatrix}$$

B  $\mathbf{P} = \mathbf{U}\Sigma\mathbf{U}^T$ ,  $\mathbf{Q} = \mathbf{U}\mathbf{V}^T$ ,  $\hat{\mathbf{P}} = \mathbf{V}\Sigma\mathbf{V}^H$

$$\begin{aligned} \mathbf{A} = \mathbf{P}\mathbf{Q} &= \begin{bmatrix} 2 & -2 & 0 \\ -2 & 3 & -2 \\ 0 & -2 & 4 \end{bmatrix} \begin{bmatrix} -4/9 & -8/9 & 1/9 \\ -4/9 & 1/9 & -8/9 \\ 7/9 & -4/9 & -4/9 \end{bmatrix} \\ &= \mathbf{Q}\hat{\mathbf{P}} = \begin{bmatrix} -4/9 & -8/9 & 1/9 \\ -4/9 & 1/9 & -8/9 \\ 7/9 & -4/9 & -4/9 \end{bmatrix} \begin{bmatrix} 4 & -2 & 0 \\ -2 & 3 & -2 \\ 0 & -2 & 2 \end{bmatrix}. \end{aligned}$$

$$\mathbf{A} = \begin{bmatrix} 2 & -2 & 0 \\ -2 & 3 & -2 \\ 0 & -2 & 4 \end{bmatrix} \begin{bmatrix} 0 & 0 & 1 \\ 0 & 1 & 0 \\ 1 & 0 & 0 \end{bmatrix} = \begin{bmatrix} 0 & 0 & 1 \\ 0 & 1 & 0 \\ 1 & 0 & 0 \end{bmatrix} \begin{bmatrix} 2 & -2 & 0 \\ -2 & 3 & -2 \\ 0 & -2 & 4 \end{bmatrix}.$$

T SVD:  $\mathbf{A} = \mathbf{U}_1 \Sigma_1 \mathbf{V}_1^T$ , illetve  $\mathbf{A} = \mathbf{U} \Sigma \mathbf{V}^T$ . Ekkor

$$\mathbf{A}^+ = \mathbf{V}_1 \Sigma_1^{-1} \mathbf{U}_1^T = \mathbf{V} \Sigma^+ \mathbf{U}^T.$$

B  $\mathbf{U}_1$  teljes oszloprangú,  $\Sigma_1 \mathbf{V}_1^T$  teljes sorrangú, így

$$\begin{aligned} \mathbf{A}^+ &= (\Sigma_1 \mathbf{V}_1^T)^T (\Sigma_1 \mathbf{V}_1^T (\Sigma_1 \mathbf{V}_1^T)^T)^{-1} (\mathbf{U}_1^T \mathbf{U}_1)^{-1} \mathbf{U}_1^T = \mathbf{V}_1 \Sigma_1 \Sigma_1^{-2} \mathbf{U}_1^T \\ &= \mathbf{V}_1 \Sigma_1^{-1} \mathbf{U}_1^T. \end{aligned}$$

Ebből

$$\mathbf{V} \Sigma^+ \mathbf{U}^T = \begin{bmatrix} \mathbf{V}_1 & \mathbf{V}_2 \end{bmatrix} \begin{bmatrix} \Sigma_1^{-1} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} \end{bmatrix} \begin{bmatrix} \mathbf{U}_1^T \\ \mathbf{U}_2^T \end{bmatrix} = \mathbf{V}_1 \Sigma_1^{-1} \mathbf{U}_1^T.$$

Norma

---

# Norma

---

Euklideszi vektornorma és  $p$ -norma

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  
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


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




$$p = 1$$




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



$$p = 2$$



$$p = 3$$




$$p = \infty$$



$$p = 1$$



$$p = 2$$



$$p = \infty$$



# Norma

---

A norma általános fogalma

Á Az előző normák alaptulajdonságai:

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

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

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

m  $\|x\| = \|-x\|$  bármely  $\|\cdot\|$  normára igaz, hisz

$$\|-x\| = |-1| \|x\| = \|x\|.$$

m háromszögegyenlőtlenség másik alakja:

$$\|z - x\| \geq \left| \|z\| - \|x\| \right|$$

m A háromszögegyenlőtlenség  $p$ -normánál:

**Minkowski-egyenlőtlenség:**  $\|\mathbf{x} + \mathbf{y}\|_p \leq \|\mathbf{x}\|_p + \|\mathbf{y}\|_p$ .

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

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

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 a következő is

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

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

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

m Minden norma folytonos függvény.

# Norma

---

Vektornormák ekvivalenciája

- 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 Legyen  $\mathbb{K} = \mathbb{R}$  vagy  $\mathbb{K} = \mathbb{C}$ . A  $\mathbb{K}^n$  téren értelmezett **bármely két norma ekvivalens**.
- m Ez **csak véges dimenziós terekben** igaz, itt tehát a konvergenciakérdésekhez bármelyik norma jó.

# Mátrixnorma

---

# Mátrixnorma

---

Vektornorma mátrixokon

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:

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



# Mátrixnorma

---

A mátrixnorma általános fogalma

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

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

a vektornorma által **indukált mátrixnorma**.

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

Ha lineáris leképezésre értelmezzük, **operátornormáról** beszélünk.

m Normák ekvivalenciája  $\rightsquigarrow$  az egységömb korlátos és zárt bármely normában  $\rightsquigarrow \mathbf{x} \mapsto \mathbf{Ax}$  függvénynek van maximuma és minimuma

m a definíció ekvivalens alakjai

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

# Mátrixnorma

---

Az 1-, 2- és  $\infty$ -norma mátrixokra

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

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

$$\|\mathbf{A}\|_\infty = \max_i \sum_{j=1}^m |a_{ij}| = \text{legnagyobb abszolút sorösszeg}, \quad (2)$$

$$\|\mathbf{A}\|_2 = \|\mathbf{A}^H\|_2 = \max_{\|\mathbf{x}\|_2=1} \max_{\|\mathbf{y}\|_2=1} |\mathbf{y}^H \mathbf{A} \mathbf{x}| = \sigma_1, \quad (3)$$

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

$$\|\mathbf{A}^{-1}\|_2 = \max_{\|\mathbf{x}\|_2=1} \frac{1}{\|\mathbf{A} \mathbf{x}\|_2} = \frac{1}{\min_{\|\mathbf{x}\|_2=1} \|\mathbf{A} \mathbf{x}\|_2} = \frac{1}{\sigma_n}, \quad (4)$$

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

m a legkisebb pontosan akkor pozitív, ha  $\mathbf{A}$  invertálható

m Az 1-, a  $\infty$ - és a 2-normára szokásos másik elnevezés:

oszlopnorma, sornorma és spektrálnorma.

# Alkalmazások

---

# Alkalmazások

---


## Információtömörítés

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 legfölbbebb  $k$ -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.





# Alkalmazások

---

Mögöttes tartalom analízise

**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

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

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

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