



BUDAPESTI MŰSZAKI  
MATEMATIKA  
ÉS GAZDASÁGTUDOMÁNYI  
INTÉZET  
EGYETEM



## Bevezetés az algebraba 2

BMETE91AM37



## Vektor- és mátrixnorma

H607 – 2017-05-08



## Wetttl Ferenc

ALGEBRA TANSZÉK

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

Á  $\infty$ -norma = maximum norma, azaz

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


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

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


# Egység sugarú körök




$$p = 1$$




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



$$p = 2$$



$$p = 3$$



$$p = \infty$$


# Egységsugarú gömbök



$$p = 1$$



$$p = 2$$



$$p = \infty$$

# Norma

---

A norma általános fogalma



# A norma definíciója

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  $\forall \mathbf{x}, \mathbf{y} \in \mathbb{R}^n$  ( $\in \mathbb{C}^n$ ) vektorra és  $\forall c \in \mathbb{R}$  ( $\in \mathbb{C}$ ) skalárra

- $f(\mathbf{x}) \geq 0$ , és  $f(\mathbf{x}) = 0 \iff \mathbf{x} = \mathbf{0}$ ,
- $f(c\mathbf{x}) = |c|f(\mathbf{x})$ ,
- $f(\mathbf{x} + \mathbf{y}) \leq f(\mathbf{x}) + f(\mathbf{y})$ .

# Néhány tulajdonság

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

$$\|-\mathbf{x}\| = |-1| \|\mathbf{x}\| = \|\mathbf{x}\|.$$

m háromszögegyenlőtlenség másik alakja:  $\|\mathbf{z} - \mathbf{x}\| \geq \left| \|\mathbf{z}\| - \|\mathbf{x}\| \right|$

m **Minkowski-egyenlőtlenség** a háromszögegyenlőtlenség  $p$ -normára:

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

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

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

Á 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.

Á Minden norma folytonos függvény.

B háromszög-egyenlőtlenségből

# Norma

---

## Vektornormák ekvivalenciája

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

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

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  $\mathbb{R}^n$  ( $\mathbb{C}^n$ ) téren értelmezett bármely két norma ekvivalens.

m A biz. ötlete: elég az  $\|\cdot\|_1$ -normával való ekvivalenciát bizonyítani, azaz hogy  $\exists c, d \forall \mathbf{x}: c \|\mathbf{x}\|_a \leq \|\mathbf{x}\|_1 \leq d \|\mathbf{x}\|_a$ . A bal  $\leq$  a háromszögegyenlőtlenségből, a jobb a Bolzano – Weierstrass-tételből adódik. Csak véges dimenziós terekben igaz a tétel, itt tehát a konvergenciakérdésekhez bármelyik norma jó.

## Egyenlő távolságra lévő pontok

**F** Igazoljuk, hogy  $\mathbb{R}^n$ -ben az euklideszi metrikában mérve legföljebb  $n + 1$  olyan pont van, melyek páronkénti távolsága azonos.

**M** Van  $n + 1$  ilyen pont:  $\mathbf{e}_1, \mathbf{e}_2, \dots, \mathbf{e}_{n+1} \in \mathbb{R}^{n+1}$  közül bármely kettő távolsága  $\|\mathbf{e}_i - \mathbf{e}_j\| = \sqrt{2}$ , másrészt e vektorok végpontjai benne vannak az  $x_1 + x_2 + \dots + x_{n+1} = 1$  hipersíkban, ami  $n$ -dimenziós.

- **Nincs több:** Tfh  $\mathbf{v}_0, \mathbf{v}_1, \dots, \mathbf{v}_k \in \mathbb{R}^n$  és  $\|\mathbf{v}_i - \mathbf{v}_j\|$  azonos minden  $i \neq j$ -re. Feltehető, hogy  $\mathbf{v}_0 = \mathbf{0}$  (különben az egyik vektort kivonjuk mindegyikből), és hogy minden távolság  $\sqrt{2}$  (különben minden vektort egy megfelelő skalárral szorzunk).
- Ekkor minden  $i > 0$ -ra  $\mathbf{v}_i \cdot \mathbf{v}_i = 2$ ,  $i \neq j, j > 0$ -ra  $\mathbf{v}_i \cdot \mathbf{v}_j = 1$ , ui.

$$2 = \|\mathbf{v}_i - \mathbf{v}_j\|^2 = (\mathbf{v}_i - \mathbf{v}_j) \cdot (\mathbf{v}_i - \mathbf{v}_j) = \|\mathbf{v}_i\|^2 + \|\mathbf{v}_j\|^2 - 2\mathbf{v}_i \cdot \mathbf{v}_j = 4 - 2\mathbf{v}_i \cdot \mathbf{v}_j.$$

- Tekintsük az  $\mathbf{A} = [\mathbf{v}_1 | \mathbf{v}_2 | \dots | \mathbf{v}_k]_{n \times k}$  mátrixot. Ekkor

$$\mathbf{A}^T \mathbf{A} = \begin{bmatrix} 2 & 1 & \dots & 1 \\ 1 & 2 & \dots & 1 \\ \vdots & \vdots & \ddots & \vdots \\ 1 & 1 & \dots & 2 \end{bmatrix}_{k \times k}$$

- $\mathbf{A}^T \mathbf{A}$  invertálható, ugyanis

$$\begin{aligned} |\mathbf{A}^T \mathbf{A}| &= \begin{vmatrix} 2 & 1 & \dots & 1 \\ 1 & 2 & \dots & 1 \\ \vdots & \vdots & \ddots & \vdots \\ 1 & 1 & \dots & 2 \end{vmatrix} = \begin{vmatrix} k+1 & k+1 & \dots & k+1 \\ 1 & 2 & \dots & 1 \\ \vdots & \vdots & \ddots & \vdots \\ 1 & 1 & \dots & 2 \end{vmatrix} \\ &= (k+1) \begin{vmatrix} 1 & 1 & \dots & 1 \\ 1 & 2 & \dots & 1 \\ \vdots & \vdots & \ddots & \vdots \\ 1 & 1 & \dots & 2 \end{vmatrix} = (k+1) \begin{vmatrix} 1 & 1 & \dots & 1 \\ 0 & 1 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 1 \end{vmatrix} = k+1 \neq 0. \end{aligned}$$

- $\mathbf{A}^T \mathbf{A}$  invertálható  $\rightsquigarrow r(\mathbf{A}) = r(\mathbf{A}^T \mathbf{A}) = k \rightsquigarrow k \leq n \rightsquigarrow k+1 \leq n+1$ .

$$F \quad |A| = \begin{vmatrix} a & b & \dots & b \\ b & a & \dots & b \\ \vdots & \vdots & \ddots & \vdots \\ b & b & \dots & a \end{vmatrix} = ?$$

$$M \quad A = bJ + (a - b)I = p(J), \text{ ahol } p(x) = bx + a - b.$$

$$J \sim \begin{bmatrix} 0 & 0 & \dots & 0 \\ 0 & 0 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & n \end{bmatrix} \rightsquigarrow A = p(J) \sim b \begin{bmatrix} 0 & 0 & \dots & 0 \\ 0 & 0 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & n \end{bmatrix} + (a - b)I =$$

$$\begin{bmatrix} a - b & 0 & \dots & 0 \\ 0 & a - b & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & a - b + nb \end{bmatrix} \rightsquigarrow |A| = (a - b)^{n-1}(a - b + nb)$$

F Adjunk meg  $\mathbb{R}^n$ -ben

(a)  $2n$  pontot, amelyek az összegmetrikára és

(b)  $2^n$  pontot, amelyek a maximummetrikára

nézve páronként egyenlő távolságra vannak egymástól.

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

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

(2)  $\|c\mathbf{A}\| = |c| \|\mathbf{A}\|$ ,

(3)  $\|\mathbf{A} + \mathbf{B}\| \leq \|\mathbf{A}\| + \|\mathbf{B}\|$ ,

(4)  $\|\mathbf{AC}\| \leq \|\mathbf{A}\| \|\mathbf{C}\|$ .

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

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

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

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

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

m A normák ekvivalenciájából  $\rightsquigarrow$  bármely normában az egységgömb korlátos és zárt  $\rightsquigarrow$  a  $x \mapsto \mathbf{Ax}$  függvénynek van maximuma és minimuma

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

Á A Frobenius-norma mátrixnorma

B (1), (2), (3) igaz, mert  $\|\cdot\|_F$  a  $\mathbb{K}^{n \times n}$ -ben =  $\|\cdot\|_2$  a  $\mathbb{K}^{n^2}$ -ben.

$$(4) \text{ korábban biz.: } \|\mathbf{Ax}\|_2 \leq \|\mathbf{A}\|_F \|\mathbf{x}\|_2 \rightsquigarrow \|\mathbf{AB}\|_F^2 = \|\mathbf{A}[\mathbf{b}_1 | \dots | \mathbf{b}_n]\|_F^2 = \|\mathbf{Ab}_1 | \dots | \mathbf{Ab}_n\|_F^2 = \sum_{i=1}^n \|\mathbf{Ab}_i\|_2^2 \leq \|\mathbf{A}\|_F^2 \sum \|\mathbf{b}_i\|_2^2 = \|\mathbf{A}\|_F^2 \|\mathbf{B}\|_F^2$$

Á Az indukált norma mátrixnorma.

B (1):  $\mathbf{A} \neq \mathbf{0} \rightsquigarrow \exists \mathbf{x} \neq \mathbf{0}: \mathbf{Ax} \neq \mathbf{0} \rightsquigarrow \frac{\|\mathbf{Ax}\|}{\|\mathbf{x}\|} > 0$

- (2):  $\max\{\|c\mathbf{Ax}\| : \|\mathbf{x}\| = 1\} = \max\{|c| \|\mathbf{Ax}\| : \|\mathbf{x}\| = 1\} = |c| \max\{\|\mathbf{Ax}\| : \|\mathbf{x}\| = 1\}$

- (3):  $\forall \|\mathbf{x}\| = 1: \|(\mathbf{A} + \mathbf{B})\mathbf{x}\| = \|\mathbf{Ax} + \mathbf{Bx}\| \leq \|\mathbf{Ax}\| + \|\mathbf{Bx}\| \leq \|\mathbf{A}\| + \|\mathbf{B}\|$

- (4):  $\forall \|\mathbf{x}\| = 1: \|(\mathbf{AB})\mathbf{x}\| = \|\mathbf{A}(\mathbf{Bx})\| \leq \|\mathbf{A}\| \|\mathbf{Bx}\| \leq \|\mathbf{A}\| \|\mathbf{B}\| \|\mathbf{x}\| = \|\mathbf{A}\| \|\mathbf{B}\|$

# Mátrixnorma

---

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

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

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

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

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

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

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

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.

B  $p = 1$ : ha  $\|\mathbf{x}\|_1 = 1$ , akkor

$$\begin{aligned}\|\mathbf{Ax}\|_1 &= \sum_{i=1}^m \left| \sum_{j=1}^n a_{ij}x_j \right| \leq \sum_{i=1}^m \sum_{j=1}^n |a_{ij}||x_j| = \sum_{j=1}^n |x_j| \sum_{i=1}^m |a_{ij}| \\ &\leq \left( \sum_{j=1}^n |x_j| \right) \max_j \sum_{i=1}^m |a_{ij}| = \max_j \sum_{i=1}^m |a_{ij}|\end{aligned}$$

E max elérhető, ha a  $k$ -adik oszl.össz. a max  $\|\mathbf{Ae}_k\|_1 = \max_j \sum_{i=1}^m |a_{ij}|$

-  $p = \infty$ : ha  $\|\mathbf{x}\|_\infty = 1$ , akkor

$$\|\mathbf{Ax}\|_\infty = \max_i \left| \sum_{j=1}^n a_{ij}x_j \right| \leq \max_i \sum_{j=1}^n |a_{ij}||x_j| \leq \max_i \sum_{j=1}^n |a_{ij}|.$$

Ez a maximum el is érhető: ha a  $k$ -adik sor a max, akkor az

$$\mathbf{x} = \left( \frac{\overline{a_{k1}}}{|a_{k1}|}, \frac{\overline{a_{k2}}}{|a_{k2}|}, \dots, \frac{\overline{a_{kn}}}{|a_{kn}|} \right)$$

vektorra  $\|\mathbf{x}\|_\infty = 1$  és  $\|\mathbf{Ax}\|_\infty = \max_i \sum_{j=1}^n |a_{ij}|$ .



- $p = 2$ : A CBS-egyenlőtlenség szerint  $|\mathbf{y}^H \mathbf{Ax}| \leq \|\mathbf{y}\|_2 \|\mathbf{Ax}\|_2$ , így

$$\max_{\|\mathbf{x}\|_2=1} \max_{\|\mathbf{y}\|_2=1} |\mathbf{y}^H \mathbf{Ax}| \leq \max_{\|\mathbf{x}\|_2=1} \|\mathbf{Ax}\|_2 = \|\mathbf{A}\|_2.$$

Legyen  $\mathbf{x}_0$  az a vektor, melyben  $\|\mathbf{Ax}\|_2$  a max

$$\|\mathbf{Ax}_0\|_2 = \max_{\|\mathbf{x}\|_2=1} \|\mathbf{Ax}\|_2 = \|\mathbf{A}\|_2, \quad \mathbf{y}_0 = \frac{\mathbf{Ax}_0}{\|\mathbf{Ax}_0\|_2} = \frac{\mathbf{Ax}_0}{\|\mathbf{A}\|_2}.$$

$$\mathbf{y}_0^H \mathbf{Ax}_0 = \frac{\mathbf{x}_0^H \mathbf{A}^H \mathbf{Ax}_0}{\|\mathbf{A}\|_2} = \frac{\|\mathbf{Ax}_0\|_2^2}{\|\mathbf{A}\|_2} = \frac{\|\mathbf{A}\|_2^2}{\|\mathbf{A}\|_2} = \|\mathbf{A}\|_2.$$

- Az  $\|\mathbf{A}\|_2 = \sigma_1$  igazolásához a következő maximumot keressük:

$$\|\mathbf{A}\|_2^2 = \max_{\mathbf{x} \neq \mathbf{0}} \frac{\|\mathbf{Ax}\|_2^2}{\|\mathbf{x}\|_2^2} = \max_{\mathbf{x} \neq \mathbf{0}} \frac{\mathbf{x}^H \mathbf{A}^H \mathbf{Ax}}{\mathbf{x}^H \mathbf{x}}.$$

Legyenek  $\mathbf{v}_1, \dots, \mathbf{v}_n$  a jobb szinguláris vektorok, ekkor bármely  $\mathbf{x} = \sum_j c_j \mathbf{v}_j \neq \mathbf{0}$  vektorra

$$\lambda_1 = \frac{\mathbf{v}_1^H \mathbf{A}^H \mathbf{A} \mathbf{v}_1}{\mathbf{v}_1^H \mathbf{v}_1}, \quad \lambda_1 - \frac{\mathbf{x}^H \mathbf{A}^H \mathbf{Ax}}{\mathbf{x}^H \mathbf{x}} = \lambda_1 - \frac{\sum_j \lambda_j c_j^2}{\sum_j c_j^2} = \frac{\sum_j (\lambda_1 - \lambda_j) c_j^2}{\sum_j c_j^2} \geq 0,$$

tehát  $\|\mathbf{A}\|_2^2 = \lambda_1$ , azaz  $\|\mathbf{A}\|_2 = \sqrt{\lambda_1} = \sigma_1$ .

- $$\frac{1}{\min_{\|\mathbf{x}\|_2=1} \|\mathbf{Ax}\|_2} = \max_{\|\mathbf{x}\|_2=1} \frac{1}{\|\mathbf{Ax}\|_2} = \max_{\mathbf{y} \neq \mathbf{0}} \frac{1}{\left\| \mathbf{A} \frac{\mathbf{A}^{-1} \mathbf{y}}{\|\mathbf{A}^{-1} \mathbf{y}\|_2} \right\|_2} = \max_{\mathbf{y} \neq \mathbf{0}} \frac{\|\mathbf{A}^{-1} \mathbf{y}\|_2}{\|\mathbf{y}\|_2}$$

$$= \left\| \mathbf{A}^{-1} \right\|_2.$$

- $\mathbf{A}^{-1}$  szinguláris értékei az  $\mathbf{A}$  szinguláris értékeinek reciprokai  $\rightsquigarrow$   $\mathbf{A}^{-1}$  legnagyobb sz.ért. az  $\mathbf{A}$  legkisebb sz.értékének reciproka.

- F A Frobenius-norma nem indukált norma.
- Ötlet:  $\mathbf{A} = \mathbf{I}$
- F Minden önadjungált  $\mathbf{A}$  mátrixra  $\|\mathbf{A}\|_1 = \|\mathbf{A}\|_\infty$
- F Minden normális  $\mathbf{A}$  mátrixra  $\|\mathbf{A}\|_2 = \rho(\mathbf{A})$
- F Minden unitér  $\mathbf{A}$  mátrixra  $\|\mathbf{A}\|_F = \sqrt{n}$ ,  $\|\mathbf{A}\|_2 = 1$ ,  
 $1 \leq \|\mathbf{A}\|_1, \|\mathbf{A}\|_\infty \leq \sqrt{n}$

# Alkalmazások

---

# Eckart–Young-tétel

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 legföljebb  $k$ -rangú közelítése, azaz

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

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

B 2-normára:  $r(\mathbf{B}) \leq k$ , így  $\dim \mathcal{N}(\mathbf{B}) \geq n - k$ .

Legyen  $\mathcal{V} = \text{span}(\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_{k+1})$  a  $k + 1$  legnagyobb szing.ért.hez tartozó jobb szinguláris vektorok által kifeszített altér.

Ha  $k \geq r$ , akkor kész vagyunk,  $\mathbf{A}$  legjobb közelítése  $\mathbf{A}$  és  $\sigma_{k+1} = 0$ .

Feltehető  $r > k \rightsquigarrow \dim \mathcal{N}(\mathbf{B}) + \dim \mathcal{V} \geq (n - k) + (k + 1) > n \rightsquigarrow \mathcal{N}(\mathbf{B}) \cap \mathcal{V} \neq \emptyset$

$\mathbf{w} \in \mathcal{N}(\mathbf{B}) \cap \mathcal{V}$ ,  $\|\mathbf{w}\|_2 = 1$ . Ekkor

$$\begin{aligned} \|\mathbf{A} - \mathbf{B}\|_2^2 &\geq \|(\mathbf{A} - \mathbf{B})\mathbf{w}\|_2^2 = \|\mathbf{A}\mathbf{w}\|_2^2 \\ &= \sum_{i=1}^{k+1} \sigma_i^2 |\mathbf{v}_i^T \mathbf{w}|^2 \geq \sigma_{k+1}^2 \sum_{i=1}^{k+1} |\mathbf{v}_i^T \mathbf{w}|^2 = \sigma_{k+1}^2 \end{aligned}$$

Másrészt  $\|\mathbf{A} - \mathbf{A}_k\|_2 = \sigma_{k+1}$ , így  $\|\mathbf{A} - \mathbf{B}\|_2 \geq \|\mathbf{A} - \mathbf{A}_k\|_2$ .