



BUDAPESTI MŰSZAKI
MATEMATIKA
ÉS GAZDASÁGTUDOMÁNYI
INTÉZET
EGYETEM



Bevezetés az algebra 2

BMETE91AM37



Vektor- és mátrixnorma

H607 - 2018-05-09



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 ∞ -norma, azaz $\|\mathbf{x}\|_\infty = \lim_{p \rightarrow \infty} \|\mathbf{x}\|_p$.

m 1-norma = rácsnorma = Manhattan-norma

Á ∞ -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



$$p = 1$$



$$p = 2$$



$$p = \infty$$

P Számítsuk ki az alábbi vektorok megadott normáit!

1. $\mathbf{x} = (\sqrt{3} - i, 6i, 3)$, $\mathbf{y} = (0.1, -0.2, -0.2)$, $p = 1, 2, \infty$;
2. $(1, 2, 2)$, $(2, 3, 6)$, $(1, 4, 8)$, $(4, 4, 7)$, $p = 2$;
3. $(i, 2, \sqrt{2} - \sqrt{2}i, -4i)$, $p = 1, 2, \infty$;
4. $(3, 4, 5)$, $(11, 12, 13, 14)$, $p = 3$;
5. $\|(95800, 217519, 414560)\|_4$, $\|(27, 84, 110, 133)\|_5$.

M

1. $\|\mathbf{x}\|_1 = 11$, $\|\mathbf{x}\|_2 = 7$, $\|\mathbf{x}\|_\infty = 6$, $\|\mathbf{y}\|_1 = 0.5$, $\|\mathbf{y}\|_2 = 0.3$,
 $\|\mathbf{x}\|_\infty = 0.2$.
2. Pitagorászi számnégyesek: a normák 3, 7, 9, 9.
3. 9, 5, 4;
4. 6, 20;
5. e két példa a $p = 4$ és $p = 5$ értékre a legkisebb olyan $p - 1$ -dimenziós pozitív egész vektor, melynek p -normája egész: $\|(95800, 217519, 414560)\|_4 = 422481$,
 $\|(27, 84, 110, 133)\|_5 = 144$. Euler még azt sejtette, hogy ilyen nincs.

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 ∞ -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 ∞ -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 σ_n az \mathbf{A} legkisebb (pozitív) szinguláris értéke.

m Az 1-, a ∞ - 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

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

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.

P Számítsuk ki a Frobenius-, 1-, 2- és ∞ -normát!

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

M $\|\mathbf{A}\|_F = 5, \|\mathbf{A}\|_1 = 6, \|\mathbf{A}\|_2 = 5, \|\mathbf{A}\|_\infty = 6$

$\|\mathbf{B}\|_F = 5, \|\mathbf{B}\|_1 = 7, \|\mathbf{B}\|_2 = 5, \|\mathbf{B}\|_\infty = 4$

$\|\mathbf{C}\|_F = \sqrt{13}, \|\mathbf{C}\|_1 = 4, \|\mathbf{C}\|_2 = 3, \|\mathbf{C}\|_\infty = 4$

P Számítsuk ki a Frobenius-, 1-, 2- és ∞ -normát!

$$\mathbf{A} = \begin{bmatrix} 0 & 1 & 0 \\ 4 & 0 & 0 \\ 0 & 0 & 8 \end{bmatrix}, \quad \mathbf{B} = \begin{bmatrix} 2 & 2 & -1 \\ -1 & 2 & 2 \\ 2 & -1 & 2 \end{bmatrix}, \quad \mathbf{C} = \begin{bmatrix} 2 & 2 & 1 \\ 1 & 2 & 2 \\ 2 & 1 & 2 \end{bmatrix}.$$

M $\|\mathbf{A}\|_F = 9, \|\mathbf{A}\|_1 = 8, \|\mathbf{A}\|_2 = 8, \|\mathbf{A}\|_\infty = 8.$

$\|\mathbf{B}\|_F = 3\sqrt{3}, \|\mathbf{B}\|_1 = 5, \|\mathbf{B}\|_2 = 3, \|\mathbf{B}\|_\infty = 5.$

$\|\mathbf{C}\|_F = 3\sqrt{3}, \|\mathbf{C}\|_1 = 5, \|\mathbf{C}\|_2 = 5, \|\mathbf{C}\|_\infty = 5.$

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 unitér \mathbf{A} mátrixra $\|\mathbf{A}\|_F = \sqrt{n}$, $\|\mathbf{A}\|_2 = 1$,
 $1 \leq \|\mathbf{A}\|_1, \|\mathbf{A}\|_\infty \leq \sqrt{n}$

- Számtani közép \leq négyzetes közép

F Minden normális \mathbf{A} mátrixra $\|\mathbf{A}\|_2 = \rho(\mathbf{A})$

F Igazoljuk, hogy tetszőleges mátrixnormára

$$\rho(\mathbf{A}) \leq \|\mathbf{A}\|,$$

ahol $\rho(\mathbf{A})$ az \mathbf{A} spektrálsugara.

- Ötlet: $L!$ (λ, \mathbf{x}) saját pár, vizsgáljuk az $\|\mathbf{A}\mathbf{x}\mathbf{x}^H\|$ mátrixnormát!

Alkalmazások

Eckart–Young-tétel

T Kis rangú approximáció tétele – Eckart–Young-tétel \mathbf{A} r -rangú, k -adik szinguláris értéke σ_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 $r > k \rightsquigarrow \dim \mathcal{N}(\mathbf{B}) + \dim \mathcal{V} \geq (n - k) + (k + 1) > n \rightsquigarrow \mathcal{N}(\mathbf{B}) \cap \mathcal{V} \neq \{\mathbf{0}\}$

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

P Adjunk 2- illetve Frobenius-normában legjobb 1-rangú közelítést az $\mathbf{A} = \begin{bmatrix} -1 & 2 \\ 2 & 2 \end{bmatrix}$ mátrixra! 1-normában is ez van hozzá a legközelebb?

M $\chi_{\mathbf{A}}(x) = x^2 - x - 6$, saját párok $(3, (1, 2)), (-2, (-2, 1)) \rightsquigarrow$

$$\text{SVD: } \mathbf{A} = \frac{1}{\sqrt{5}} \begin{bmatrix} 1 & 2 \\ 2 & -1 \end{bmatrix} \begin{bmatrix} 3 & 0 \\ 0 & 2 \end{bmatrix} \frac{1}{\sqrt{5}} \begin{bmatrix} 1 & 2 \\ -2 & 1 \end{bmatrix} \rightsquigarrow$$

legjobb közelítés:

$$\mathbf{B} = \frac{1}{\sqrt{5}} \begin{bmatrix} 1 & 2 \\ 2 & -1 \end{bmatrix} \begin{bmatrix} 3 & 0 \\ 0 & 0 \end{bmatrix} \frac{1}{\sqrt{5}} \begin{bmatrix} 1 & 2 \\ -2 & 1 \end{bmatrix} = \frac{1}{5} \begin{bmatrix} 3 & 6 \\ 6 & 12 \end{bmatrix}$$

az eltérés: $\|\mathbf{A} - \mathbf{B}\|_F = \|\mathbf{A} - \mathbf{B}\|_2 = \sigma_2 = 2$

- másrészt $\|\mathbf{A} - \mathbf{B}\|_1 = \left\| \begin{bmatrix} -\frac{8}{5} & \frac{4}{5} \\ \frac{4}{5} & -\frac{2}{5} \end{bmatrix} \right\|_1 = \frac{12}{5}$

- 1-normában van jobb közelítés, pl.

$$\left\| \mathbf{A} - \begin{bmatrix} \frac{3}{5} & 1 \\ \frac{3}{2} & \frac{5}{2} \end{bmatrix} \right\|_1 = \left\| \begin{bmatrix} -\frac{8}{5} & 1 \\ \frac{1}{2} & -\frac{1}{2} \end{bmatrix} \right\|_1 = \frac{21}{10}$$