

Bevezetés az algebra 2 – Vektor- és mátrixnorma

Wetl Ferenc
Algebra Tanszék



2016. április 29.

1 Norma

- Euklideszi vektornorma és p -norma
- A norma általános fogalma
- Vektornormák ekvivalenciája

2 Mátrixnorma

- Vektornorma mátrixokon
- A mátrixnorma általános fogalma
- Az 1-, 2- és ∞ -norma mátrixokra

3 Alkalmazások

1 Norma

- Euklideszi vektornorma és p -norma
- A norma általános fogalma
- Vektornormák ekvivalenciája

2 Mátrixnorma

- Vektornorma mátrixokon
- A mátrixnorma általános fogalma
- Az 1-, 2- és ∞ -norma mátrixokra

3 Alkalmazások

1 Norma

- Euklideszi vektornorma és p -norma
- A norma általános fogalma
- Vektornormák ekvivalenciája

2 Mátrixnorma

- Vektornorma mátrixokon
- A mátrixnorma általános fogalma
- Az 1-, 2- és ∞ -norma mátrixokra

3 Alkalmazások

1 Norma

- Euklideszi vektornorma és p -norma
- A norma általános fogalma
- Vektornormák ekvivalenciája

2 Mátrixnorma

- Vektornorma mátrixokon
- A mátrixnorma általános fogalma
- Az 1-, 2- és ∞ -norma mátrixokra

3 Alkalmazások

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

maximum norma = ∞ -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


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




$$p = 1$$




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



$$p = 2$$



$$p = 3$$




$$p = \infty$$



$$p = 1$$



$$p = 2$$



$$p = \infty$$

1 Norma

- Euklideszi vektornorma és p -norma
- A norma általános fogalma
- Vektornormák ekvivalenciája

2 Mátrixnorma

- Vektornorma mátrixokon
- A mátrixnorma általános fogalma
- Az 1-, 2- és ∞ -norma mátrixokra

3 Alkalmazások

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 **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

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

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

m Minden norma folytonos függvény.

1 Norma

- Euklideszi vektornorma és p -norma
- A norma általános fogalma
- Vektornormák ekvivalenciája

2 Mátrixnorma

- Vektornorma mátrixokon
- A mátrixnorma általános fogalma
- Az 1-, 2- és ∞ -norma mátrixokra

3 Alkalmazások

- 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{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.

1 Norma

- Euklideszi vektornorma és p -norma
- A norma általános fogalma
- Vektornormák ekvivalenciája

2 Mátrixnorma

- Vektornorma mátrixokon
- A mátrixnorma általános fogalma
- Az 1-, 2- és ∞ -norma mátrixokra

3 Alkalmazások

1 Norma

- Euklideszi vektornorma és p -norma
- A norma általános fogalma
- Vektornormák ekvivalenciája

2 Mátrixnorma

- Vektornorma mátrixokon
- A mátrixnorma általános fogalma
- Az 1-, 2- és ∞ -norma mátrixokra

3 Alkalmazások

1 Norma

- Euklideszi vektornorma és p -norma
- A norma általános fogalma
- Vektornormák ekvivalenciája

2 Mátrixnorma

- Vektornorma mátrixokon
- A mátrixnorma általános fogalma
- Az 1-, 2- és ∞ -norma mátrixokra

3 Alkalmazások

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 $\|\mathbf{Ax}\|_2 \leq \|\mathbf{A}\|_F \|\mathbf{x}\|_2$.

B Cauchy–Bunyakovszkij–Schwarz-egyenlőtlenségből:

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

1 Norma

- Euklideszi vektornorma és p -norma
- A norma általános fogalma
- Vektornormák ekvivalenciája

2 Mátrixnorma

- Vektornorma mátrixokon
- A mátrixnorma általános fogalma
- Az 1-, 2- és ∞ -norma mátrixokra

3 Alkalmazások

- D** $\|\cdot\| : \mathbb{K}^{n \times n} \rightarrow \mathbb{R}$ **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 ekvivalens alakjai

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

1 Norma

- Euklideszi vektornorma és p -norma
- A norma általános fogalma
- Vektornormák ekvivalenciája

2 Mátrixnorma

- Vektornorma mátrixokon
- A mátrixnorma általános fogalma
- Az 1-, 2- és ∞ -norma mátrixokra

3 Alkalmazások

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 $\rho = 1$: 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 k -adik oszlopössz. a max: $\|\mathbf{Ae}_k\|_1 = \max_j \sum_{i=1}^m |a_{ij}|$.

■ $\rho = \infty$: 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:

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

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


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

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

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

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

\mathbf{A}^{-1} szinguláris értékei az \mathbf{A} szinguláris értékeinek reciprokai \rightsquigarrow

\mathbf{A}^{-1} legnagyobb szing.ért. az \mathbf{A} legkisebb szing.értékének reciprokaként 

1 Norma

- Euklideszi vektornorma és p -norma
- A norma általános fogalma
- Vektornormák ekvivalenciája

2 Mátrixnorma

- Vektornorma mátrixokon
- A mátrixnorma általános fogalma
- Az 1-, 2- és ∞ -norma mátrixokra

3 Alkalmazások

1 Norma

- Euklideszi vektornorma és p -norma
- A norma általános fogalma
- Vektornormák ekvivalenciája

2 Mátrixnorma

- Vektornorma mátrixokon
- A mátrixnorma általános fogalma
- Az 1-, 2- és ∞ -norma mátrixokra

3 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 legfőlőbb 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 $\|\mathbf{A} - \mathbf{B}\|_2 \geq \|\mathbf{A} - \mathbf{A}_k\|_2$.