

# Közelítő szimbolikus számítások

## Normák, Sajátértékek

SZTE-TTIK, Számítógépes Optimalizálás Tanszék



Az  $\mathbf{x}$  vektor hosszát a geometriában már értelmeztük, mint a komponensek négyzetösszegének négyzetgyökét. Most ezt a fogalmat általánosítjuk.

# Definíció

A  $\|\cdot\| : \mathbb{R}^n \rightarrow \mathbb{R}$  leképezést *vektornormának* mondjuk, ha tetszőleges  $\mathbf{x}, \mathbf{y} \in \mathbb{R}^n$  vektorokra és tetszőleges  $\alpha \in \mathbb{R}$  skalárra teljesíti a következő három tulajdonságot:

1.  $\|\mathbf{x}\| > 0$ , ha  $\mathbf{x} \neq \mathbf{0}$  ( $\mathbf{x}$  nem zérusvektor)
2.  $\|\alpha\mathbf{x}\| = |\alpha| \cdot \|\mathbf{x}\|$  (a konstans szorzó kihozható a normából)
3.  $\|\mathbf{x} + \mathbf{y}\| \leq \|\mathbf{x}\| + \|\mathbf{y}\|$  (a háromszög-egyenlőtlenség)

**Megjegyzés.** Hasonlóan értelmezhető *komplex* vektorokra a vektornorma fogalma, csak ekkor a feltételeknek tetszőleges  $\mathbf{x}, \mathbf{y} \in \mathbb{C}^n$  komplex vektorokra és tetszőleges  $\alpha \in \mathbb{C}$  komplex skalárra kell teljesülni.

# p-normák

Tetszőleges  $p \geq 1$ -re belátható, hogy az

$$\|\mathbf{x}\|_p = \sqrt[p]{\sum_{1 \leq i \leq n} |x_i|^p}$$

képlet vektornormát határoz meg. Leggyakrabban használt esetei:

# p-normák

- ▶  $p = 1$  (egyenes norma):

$$\|\mathbf{x}\|_1 = \sum_{1 \leq i \leq n} |x_i|$$

- ▶  $p = 2$  (kettes vagy euklideszi norma):

$$\|\mathbf{x}\|_2 = \sqrt{\sum_{1 \leq i \leq n} |x_i|^2}$$

- ▶  $p = \infty$  (végtelen norma):

$$\|\mathbf{x}\|_\infty = \max_{1 \leq i \leq n} |x_i|$$



# Intuíció

Már korábban is előfordult, hogy a mátrixokat egy számmal jellemeztük, és ez alapján következtettünk tulajdonságaikra, például mátrixok determinánsa  $\rightarrow$  létezik-e inverz.

Most a mátrixokhoz fogunk egy újabb számszerű jellemzést megadni, sőt nem is egyet, hanem mindjárt egy egész családot. Ezek lesznek a mátrixnormák.

# Definíció

$\mathbf{A} \|\cdot\| : \mathbb{R}^{n \times n} \rightarrow \mathbb{R}$  leképezést *mátrixnormának* mondjuk, ha tetszőleges  $\mathbf{A}, \mathbf{B} \in \mathbb{R}^{n \times n}$  mátrixokra és tetszőleges  $\alpha \in \mathbb{R}$  skalárra teljesíti a következő négy tulajdonságot:

1.  $\|\mathbf{A}\| > 0$ , ha  $\mathbf{A} \neq \mathbf{O}$  ( $\mathbf{A}$  nem zérusmátrix)
2.  $\|\alpha\mathbf{A}\| = |\alpha| \cdot \|\mathbf{A}\|$  (a konstans szorzó kihozható a normából)
3.  $\|\mathbf{A} + \mathbf{B}\| \leq \|\mathbf{A}\| + \|\mathbf{B}\|$  (a háromszög-egyenlőtlenség)
4.  $\|\mathbf{AB}\| \leq \|\mathbf{A}\| \cdot \|\mathbf{B}\|$

**Megjegyzés.** Hasonlóan értelmezhető *komplex* mátrixokra a mátrixnorma fogalma, csak ekkor a feltételeknek tetszőleges  $\mathbf{A}, \mathbf{B} \in \mathbb{C}^{n \times n}$  komplex mátrixokra és tetszőleges  $\alpha \in \mathbb{C}$  komplex skalárra kell teljesülni.



## Példák mátrixnormákra

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

Néhány gyakran használt mátrixnorma definíciója és a megfelelő Octave függvény hívása:

- ▶ 1-es norma (oszlopnorma):  $\|\mathbf{A}\|_1 = \max_j \sum_{i=1}^n |a_{ij}|$

$$A = \begin{array}{cc|c} 1 & 2 & \\ \hline 3 & -4 & \\ \hline 4 & 6 & \end{array}$$

$$\text{norm}(A, 1)$$

- ▶ végtelen norma (sornorma):  $\|\mathbf{A}\|_\infty = \max_i \sum_{j=1}^n |a_{ij}|$

$$A = \begin{array}{cc|c} \hline 1 & 2 & 3 \\ \hline 3 & -4 & 7 \\ \hline \end{array}$$

$$\text{norm}(A, \text{inf})$$

- ▶ Frobenius norma:  $\|\mathbf{A}\|_F = \sqrt{\sum_{i=1}^n \sum_{j=1}^n |a_{ij}|^2}$

$$\text{norm}(A, \text{'fro'})$$



# Sajátérték definíció

**Def.:** Legyen  $\mathbf{A}$  egy négyzetes mátrix. Ha a  $\lambda$  számra és az  $\mathbf{x} \neq \mathbf{0}$  vektorra igaz, hogy

$$\mathbf{Ax} = \lambda \mathbf{x}$$

akkor  $\lambda$  az  $\mathbf{A}$  mátrix sajátértéke,  $\mathbf{x}$  pedig a  $\lambda$  sajátértékhez tartozó sajátvektora.

Megjegyzés. Itt (még valós  $\mathbf{A}$  mátrix esetén is!) megengedjük, hogy  $\lambda$  és/vagy  $\mathbf{x}$  komplex legyen.

## Geometriai értelmezés

- ▶ A mátrixok használhatók az  $n$  dimenziós tér bizonyos geometriai transzformációinak leírására is.
- ▶ A tér egy pontjának az origóból induló, az adott pontban végződő helyvektor felel meg. A transzformációt az adott vektor valamely mátrixszal való balról szorzása végzi el.
- ▶ Pl.: Az alábbi  $\mathbf{A}$  mátrix által indukált transzformáció (tükrözés az  $x$  tengelyre):

$$\mathbf{A} = \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix} \text{ és } \mathbf{v} = [2; 1] \text{ esetén:}$$

$$\mathbf{A} : \quad \mathbf{v} \mapsto \mathbf{A} * \mathbf{v} = \mathbf{v}' = [2, -1]$$

- ▶ Az  $\mathbf{A}$  mátrix (transzformáció) sajátvektorai azok a vektorok, amelyeket a transzformáció nem forgat el, csak megnyújt. A nyújtás mértéke a sajátvektorhoz tartozó sajátérték.

## Példa a sajátértékre, sajátvektorra

Legyen  $\mathbf{A} = \begin{bmatrix} 1 & 1 \\ 0 & 2 \end{bmatrix}$

Egy sajátvektor:  $\mathbf{x}_1 = \begin{bmatrix} 1 \\ 0 \end{bmatrix}$ , a hozzá tartozó sajátérték:  $\lambda_1 = 1$

Egy másik sajátvektor:  $\mathbf{x}_2 = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$ , itt a sajátérték:  $\lambda_2 = 2$

# Sajátérték kiszámítása

Hogyan határozhatók meg a sajátértékek és a sajátvektorok?

- ▶  $\mathbf{Ax} = \lambda\mathbf{x} \iff (\mathbf{A} - \lambda\mathbf{I})\mathbf{x} = \mathbf{0}$
- ▶ Megfigyelés: a második homogén lineáris egyenletrendszernek csak akkor van nem triviális  $\mathbf{x} \neq \mathbf{0}$  megoldása, ha  $\det(\mathbf{A} - \lambda\mathbf{I}) = 0$
- ▶ Ha ugyanis az  $\mathbf{A}_\lambda = \mathbf{A} - \lambda\mathbf{I}$  determinánsa nem 0, akkor az  $\mathbf{A}_\lambda : \mathbf{x} \mapsto \mathbf{A}_\lambda\mathbf{x}$  leképezés kölcsönösen egyértelmű, és a baloldalon csak az  $\mathbf{x} = \mathbf{0}$  esetén kaphatunk  $\mathbf{0}$  vektort.

# Karakterisztikus polinom

- ▶ Tehát ha  $\lambda$  sajátérték, akkor  $\det(\mathbf{A} - \lambda\mathbf{I}) = 0$
- ▶ Ez a determináns a  $\lambda$  határozatlan polinomja.
- ▶ Legyen

$$\mathbf{A} = \begin{bmatrix} 1 & 1 \\ 0 & 2 \end{bmatrix},$$

ekkor

$$\det(\mathbf{A} - \lambda\mathbf{I}) = \begin{vmatrix} 1 - \lambda & 1 \\ 0 & 2 - \lambda \end{vmatrix} = (1 - \lambda)(2 - \lambda) = 2 - 3\lambda + \lambda^2$$

Ezt nevezzük az  $\mathbf{A}$  mátrix *karakterisztikus polinomjának*.

- ▶ A karakterisztikus polinom gyökei (zérushelyei) a sajátértékek.

# Észrevételek:

## Tulajdonságok:

- ▶ A mátrixnak több sajátértéke lehet (pontosabban ha  $\mathbf{A}$   $n \times n$ -es mátrix, akkor  $n$  darab, hiszen az  $n$ -ed fokú karakterisztikus polinomjának – multiplicitással számolva – pontosan  $n$  gyöke van)
- ▶ Egy sajátértékhez végtelen sok sajátvektor tartozik (az összes megfelelő irányba mutató)
- ▶ Diagonális mátrixok sajátértékei a megfelelő diagonális

elemek. Ha például  $\mathbf{D} = \begin{bmatrix} d_{11} & 0 & 0 \\ 0 & d_{22} & 0 \\ 0 & 0 & d_{33} \end{bmatrix}$ , akkor

$$\det(\mathbf{D} - \lambda \mathbf{I}) = (d_{11} - \lambda)(d_{22} - \lambda)(d_{33} - \lambda).$$

Sajátvektorokként vehetők például az adott irányokba mutató egységvektorok.

# Definíciók

- ▶ A sajátértékek halmaza a *spektrum*. Jele  $\lambda(\mathbf{A})$ .

Ha például  $\mathbf{A} = \begin{bmatrix} 2 & 0 & 0 \\ 0 & -4 & 0 \\ 0 & 0 & 3 \end{bmatrix}$ , akkor  $\lambda(\mathbf{A})$  a  $\{2, -4, 3\}$

halmaz.

- ▶ A sajátértékek abszolút értékének maximuma a *spektrálsugár*.  $\rho(\mathbf{A}) = \max\{|\lambda| : \lambda \in \lambda(\mathbf{A})\}$   
A példában  $\rho(\mathbf{A}) = 4$ .

# A sajátérték korlátai

- ▶  $\rho(\mathbf{A}) \leq \|\mathbf{A}\|$ ,  
azaz a spektrálsugár mindig kisebb egyenlő, mint a mátrix bármely normája
- ▶ Gersgorin körök: Az  $\mathbf{A}$  mátrix minden sajátértéke benne van a

$$K_i = \left\{ z \in \mathbb{C} : |z - a_{ii}| \leq \sum_{k=1, k \neq i}^n |a_{ik}| \right\}$$

körök egyesítésében.



# Gersgorin magyarázat

- ▶ minden sorhoz egy kör tartozik
- ▶ a körök középpontja nálunk az x tengelyen van, mivel valós mátrixokkal foglalkozunk
- ▶ a körök sugara pedig a főátlón kívüli elemek abszolútértékösszege

Példa:  $\mathbf{A} = \begin{bmatrix} 1 & 1 & -1 \\ 2 & -2 & 0 \\ 1 & 0 & 5 \end{bmatrix}$

- ▶ Első sorhoz tartozó kör: 1 középpont és 2 sugár
- ▶ Második sor: -2 középpont 2 sugár
- ▶ Harmadik sor: 5 középpont 1 sugár

# Octave függvények a sajátértékek meghatározására

Legyen  $\mathbf{A}$  tetszőleges  $n \times n$  dimenziós mátrix. Ekkor

▶  $\mathbf{D} = \text{eig}(\mathbf{A})$

Az  $n$  dimenziós  $\mathbf{D}$  oszlopvektor elemei a sajátértékek.

▶  $[\mathbf{V}, \mathbf{D}] = \text{eig}(\mathbf{A})$

Az  $n \times n$  dimenziós  $\mathbf{V}$  mátrix oszlopai a normalizált sajátvektorok, a  $\mathbf{D}$  diagonális mátrix főátlóbeli elemei pedig a megfelelő sajátértékek.

▶  $\mathbf{D} = \text{eigs}(\mathbf{A}, k)$  (alapértelmezés:  $k = 6$ )

A  $k$  dimenziós  $\mathbf{D}$  oszlopvektor a  $k$  maximális abszolút értékű sajátértéket tartalmazza.

▶  $[\mathbf{V}, \mathbf{D}] = \text{eigs}(\mathbf{A}, k)$

Az  $n \times k$  dimenziós  $\mathbf{V}$  mátrix oszlopai a normalizált sajátvektorok, a  $k \times k$  dimenziós  $\mathbf{D}$  diagonális mátrix főátlójában pedig a  $k$  maximális abszolút értékű sajátérték

# Hatványmódszer

- ▶ Föltételezzük, hogy az  $\mathbf{A}$  mátrix sajátértékeire  $|\lambda_1| > |\lambda_i|$ ,  $2 \leq i \leq n$  teljesül.
- ▶ Közelítsük a legnagyobb abszolút értékű  $\lambda_1$  sajátértéket
- ▶ és egy hozzá tartozó  $\mathbf{x}_1$  sajátvektort.
- ▶ Ez iterációs módszer: *közelítő* megoldást kapunk  $\lambda_1$ -re és  $\mathbf{x}_1$ -re.
- ▶ Kell egy *megfelelő*  $\mathbf{x}^{(0)}$  kezdővektor.

Az iteráció képlete ( $\mathbf{x}^{(0)}$ -ból indulva):

$$\mathbf{y}^{(k)} = \mathbf{A}\mathbf{x}^{(k)}$$

$$\mathbf{x}^{(k+1)} = \frac{\mathbf{y}^{(k)}}{\|\mathbf{y}^{(k)}\|}$$

Itt  $\|\mathbf{y}^{(k)}\|$  az  $\mathbf{y}^{(k)}$  vektor normáját jelöli.

# Főkomponens analízis

## **Főkomponens analízis** (Principal Component Analysis - PCA):

- ▶ Nagy méretű, sok dimenziós adatok esetén szükség lehet a redundancia megszüntetésére, tömörebb tárolásra.
- ▶ Szükség lehet arra is, hogy megállapítsuk egy nagy adathalmazban, hogy mely paraméterek okozzák az adatok varianciájának nagy részét.
- ▶ Az adatok ábrázolásához azok átalakítására lehet szükség

Ezen feladatok egyik megoldási módszere a Főkomponens analízis, amely egy statisztikai eljárás, de a mesterséges intelligenciában, a felügyelet nélküli tanulásban is az egyik legalapvetőbb módszer.

## Példa a PCA-ra

- ▶ Tároljunk adatokat autókról. Mekkora a csúcssebességük, fogyasztásuk, hengerűrtartalmuk, milyen a színük, hány ajtósak stb. Az egyszerűség kedvéért legyen minden adat numerikus, és tegyük őket egy  $X$  mátrixba, melynek sorai felelnek meg az egyes autóknak, az oszlopok pedig a paramétereknek.
- ▶ A leghatékonyabb adatrepresentáció eléréséhez az  $X^*X$  mátrix (kovariancia mátrix) **sajátvektorainak** meghatározására van szükség. A sajátértékek aránya pedig megmondja, hogy mennyire hatásos a tömörítésünk.



# Gyakorló feladat

A mellékelt .mat fájlba Octave változókat mentettünk. Benne található egy változó (mátrix), amely emberek magasságát (cm) és tömegét tartalmazza (kg). Forrás: SOCR Data Dinov 020108 HeightsWeights  
Az A mátrix a nyers adat, ezt először centralizálni kell (kivonni minden dimenzióból az átlagot)

- ▶ Ábrázoljuk az adatpontokat (sorokat) a plot utasítás segítségével. Rajzoljuk ki a `data'*data` mátrix sajátvektorait ugyanezen az ábrán. Mit figyelhetünk meg?
- ▶ Tömörítsük az adatot egy dimenzióba! (Olvassunk utána, hogyan működik a PCA. A tömörítés a legnagyobb abszolútértékű sajátvektor irányára történő vetítéssel adható meg). Ábrázoljuk a megfelelő irányú egyenesre vetített pontokat!

# 1. Gyakorló feladat - 1 hint

Amennyiben jól sikerül a feladat, akkor ehhez hasonló képeket kell kapni (nem pont ugyanezeket):



## 2. Gyakorló feladat

- ▶ Implementáld a hatványmódszert egy olyan függvénnyel, amely 3x3-as mátrixokon működik és minden iterációban 3D-ben kirajzolja az aktuális  $x^k$  vektort. (3D-s plotokat a plot3 függvénnyel és a geometry csomaggal tudsz készíteni)