

# Szinguláris érték felbontás és függvényillesztés

Kormányos Andor

Komplex Rendszerek Fizikája Tanszék

2020. február 20.

# Szinguláris érték szerinti felbontás

## Singular value decomposition (SVD)

Tetszőleges  $M \times N$ -es ( $M \geq N$ )  $\mathbf{A}$  mátrix felírható a következő formában:

$$\mathbf{A} = \mathbf{U} \cdot \mathbf{W} \cdot \mathbf{V}^H$$

vagyis

$$\begin{pmatrix} \mathbf{A} \end{pmatrix} = \begin{pmatrix} \mathbf{U} \end{pmatrix} \cdot \begin{pmatrix} w_1 & & \\ & \dots & \\ & & w_N \end{pmatrix} \cdot \begin{pmatrix} \mathbf{V}^H \end{pmatrix}$$

ahol

- $\mathbf{U}$   $M \times N$ -es,  $\mathbf{V}$   $N \times N$ -es unitér mátrixok:  $\mathbf{U}^H \cdot \mathbf{U} = \mathbf{1}$   
( $\mathbf{U}^H = (\mathbf{U}^T)^*$ ),  $\mathbf{V}^H \cdot \mathbf{V} = \mathbf{1}$ . Mivel  $\mathbf{V}^H$  négyzetes, ezért  $\mathbf{V} \cdot \mathbf{V}^H = \mathbf{1}$  is igaz.
- $\mathbf{W}$  diagonális mátrix és  $w_i \geq 0$  valós számok.

# Szinguláris érték szerinti felbontás

## Singular value decomposition (SVD)

Tetszőleges  $M \times N$ -es ( $M \geq N$ )  $\mathbf{A}$  mátrix felírható a következő formában:

$$\mathbf{A} = \mathbf{U} \cdot \mathbf{W} \cdot \mathbf{V}^H$$

vagyis

$$\begin{pmatrix} \mathbf{A} \end{pmatrix} = \begin{pmatrix} \mathbf{U} \end{pmatrix} \cdot \begin{pmatrix} w_1 & & \\ & \dots & \\ & & w_N \end{pmatrix} \cdot \begin{pmatrix} \mathbf{V}^H \end{pmatrix}$$

ahol

- $\mathbf{U}$   $M \times N$ -es,  $\mathbf{V}$   $N \times N$ -es unitér mátrixok:  $\mathbf{U}^H \cdot \mathbf{U} = \mathbf{1}$   
( $\mathbf{U}^H = (\mathbf{U}^T)^*$ ),  $\mathbf{V}^H \cdot \mathbf{V} = \mathbf{1}$ . Mivel  $\mathbf{V}^H$  négyzetes, ezért  $\mathbf{V} \cdot \mathbf{V}^H = \mathbf{1}$  is igaz.
- $\mathbf{W}$  diagonális mátrix és  $w_i \geq 0$  valós számok.

Az SVD számolására kifejlesztett eljárás numerikusan nagyon stabil, függetlenül attól, hogy az  $\mathbf{A}$  mátrix esetleg mennyire szinguláris

# Szinguláris érték szerinti felbontás

## Fontos fogalmak:

i) Egy mátrix *kondicionáltsága* a legnagyobb és a legkisebb  $w_j$  hányadosa. Az  $\mathbf{A}$  mátrix *szinguláris*, ha ez a hányados végtelen, i.e., egy (vagy több)  $w_j = 0$ .

# Szinguláris érték szerinti felbontás

## Fontos fogalmak:

- i) Egy mátrix *kondicionáltsága* a legnagyobb és a legkisebb  $w_i$  hányadosa. Az  $\mathbf{A}$  mátrix *szinguláris*, ha ez a hányados végtelen, i.e., egy (vagy több)  $w_j = 0$ .
- ii) mátrix *mag tere* (*nullspace*) és *kép tere* (*range*). Tekintsük a következő lineáris egyenletrendszert:

$$\mathbf{A} \cdot \mathbf{x} = \mathbf{b}$$

Ez egy lineáris leképezés az  $\mathbf{x}$  vektortérről a  $\mathbf{b}$  vektortérre.

# Szinguláris érték szerinti felbontás

## Fontos fogalmak:

i) Egy mátrix *kondicionáltsága* a legnagyobb és a legkisebb  $w_i$  hányadosa. Az  $\mathbf{A}$  mátrix *szinguláris*, ha ez a hányados végtelen, i.e., egy (vagy több)  $w_j = 0$ .

ii) mátrix *mag tere* (*nullspace*) és *kép tere* (*range*). Tekintsük a következő lineáris egyenletrendszert:

$$\mathbf{A} \cdot \mathbf{x} = \mathbf{b}$$

Ez egy lineáris leképezés az  $\mathbf{x}$  vektortérről a  $\mathbf{b}$  vektortérre.

iii) Ha  $\mathbf{A}$  szinguláris, akkor az  $\mathbf{x}$  egy alterében levő vektorokra (a *magtér*) teljesül:  $\mathbf{A} \cdot \mathbf{x}' = 0$ .

# Szinguláris érték szerinti felbontás

## Fontos fogalmak:

i) Egy mátrix *kondicionáltsága* a legnagyobb és a legkisebb  $w_i$  hányadosa. Az  $\mathbf{A}$  mátrix *szinguláris*, ha ez a hányados végtelen, i.e., egy (vagy több)  $w_j = 0$ .

ii) mátrix *mag tere* (*nullspace*) és *kép tere* (*range*). Tekintsük a következő lineáris egyenletrendszert:

$$\mathbf{A} \cdot \mathbf{x} = \mathbf{b}$$

Ez egy lineáris leképezés az  $\mathbf{x}$  vektortérről a  $\mathbf{b}$  vektortérre.

iii) Ha  $\mathbf{A}$  szinguláris, akkor az  $\mathbf{x}$  egy alterében levő vektorokra (a *magtér*) teljesül:  $\mathbf{A} \cdot \mathbf{x}' = 0$ .

iv) A  $\mathbf{b}$  vektortér egy része “elérhető” az  $\mathbf{A}$  lineáris leképezés segítségével, vagyis vannak olyan  $\mathbf{x}$  vektorok, amelyek ide képződnek le: ez az  $\mathbf{A}$  *képtere* (*range*). Ennek a térnek a dimenziója az  $\mathbf{A}$  *rank*-je.

# Szinguláris érték szerinti felbontás

## Fontos fogalmak:

i) Egy mátrix *kondicionáltsága* a legnagyobb és a legkisebb  $w_i$  hányadosa. Az  $\mathbf{A}$  mátrix *szinguláris*, ha ez a hányados végtelen, i.e., egy (vagy több)  $w_j = 0$ .

ii) mátrix *mag tere* (*nullspace*) és *kép tere* (*range*). Tekintsük a következő lineáris egyenletrendszert:

$$\mathbf{A} \cdot \mathbf{x} = \mathbf{b}$$

Ez egy lineáris leképezés az  $\mathbf{x}$  vektortérről a  $\mathbf{b}$  vektortérre.

iii) Ha  $\mathbf{A}$  szinguláris, akkor az  $\mathbf{x}$  egy alterében levő vektorokra (a *magtér*) teljesül:  $\mathbf{A} \cdot \mathbf{x}' = 0$ .

iv) A  $\mathbf{b}$  vektortér egy része “elérhető” az  $\mathbf{A}$  lineáris leképezés segítségével, vagyis vannak olyan  $\mathbf{x}$  vektorok, amelyek ide képződnek le: ez az  $\mathbf{A}$  *képtere* (*range*). Ennek a térnek a dimenziója az  $\mathbf{A}$  *rank*-je.

v) Ha  $\mathbf{A}$  nem szinguláris, akkor  $rank = N$ , egyébként  $rank < N$ .



# Szinguláris érték szerinti felbontás

Az SVD tulajdonképpen egy ortonormált bázist ad az  $\mathbf{A}$  magterére és képterére:

- az  $\mathbf{U}$  mátrix azon oszlopai, amelyeknek megfelelő  $w_i$  értékek nem nullák, bázisvektornak használhatóak a képtérben
- a  $\mathbf{V}$  mátrix azon oszlopai, melyeknek megfelelő  $w_i$  értékek nullák, bázisvektornak használhatóak a magtérben

# Szinguláris érték szerinti felbontás

Az SVD tulajdonképpen egy ortonormált bázist ad az  $\mathbf{A}$  magterére és képterére:

- az  $\mathbf{U}$  mátrix azon oszlopai, amelyeknek megfelelő  $w_i$  értékek nem nullák, bázisvektornak használhatóak a képtérben
- a  $\mathbf{V}$  mátrix azon oszlopai, melyeknek megfelelő  $w_i$  értékek nullák, bázisvektornak használhatóak a magtérben

Tekintsük újra az egyenletrendszert

$$\mathbf{A} \cdot \mathbf{x} = \mathbf{b}$$

# Szinguláris érték szerinti felbontás

Az SVD tulajdonképpen egy ortonormált bázist ad az  $\mathbf{A}$  magterére és képterére:

- az  $\mathbf{U}$  mátrix azon oszlopai, amelyeknek megfelelő  $w_i$  értékek nem nullák, bázisvektornak használhatóak a képtérben
- a  $\mathbf{V}$  mátrix azon oszlopai, melyeknek megfelelő  $w_i$  értékek nullák, bázisvektornak használhatóak a magtérben

Tekintsük újra az egyenletrendszert

$$\mathbf{A} \cdot \mathbf{x} = \mathbf{b}$$

- Ha  $\mathbf{A}$  nem szinguláris, akkor a megoldás elvileg  $\mathbf{x} = \mathbf{V}[\text{diag}(1/w_i)]\mathbf{U}^H\mathbf{b}$
- Nem szokták a Gauss elimináció helyett alkalmazni, mert lassabb

# Szinguláris érték szerinti felbontás

Tekintsük újra az egyenletrendszert

$$\mathbf{A} \cdot \mathbf{x} = \mathbf{b}$$

- Ha  $\mathbf{A}$  szinguláris, akkor az a kérdés, hogy  $\mathbf{b}$  benne van-e az  $\mathbf{A}$  képterében. Ha igen, akkor létezik  $\mathbf{x}$  megoldásvektor, csak nem egyértelmű: bármely vektor, amely a magtérben van (melyet a  $\mathbf{V}$  oszlopai feszítenek ki) hozzáadható tetszőleges lineárkombinációban az  $\mathbf{x}$ -hez
- ezen megoldások közül választhatjuk pl azt, amelyre teljesül, hogy  $|\mathbf{x}|^2$  minimális. Hogyan kapható meg ez a partikuláris megoldás?
- ha  $w_j = 0$ , akkor az  $\mathbf{x} = \mathbf{V}[\text{diag}(1/w_j)]\mathbf{U}^H\mathbf{b}$ -ben  $1/w_j$  helyett a megfelelő átlós elemet írd át 0-ra

# Szinguláris érték szerinti felbontás

Tekintsük újra az egyenletrendszert

$$\mathbf{A} \cdot \mathbf{x} = \mathbf{b}$$

Ha  $\mathbf{b}$  nincs benne az  $\mathbf{A}$  képterében, akkor az egyenletrendszernek nincs megoldása.

# Szinguláris érték szerinti felbontás

Tekintsük újra az egyenletrendszert

$$\mathbf{A} \cdot \mathbf{x} = \mathbf{b}$$

Ha  $\mathbf{b}$  nincs benne az  $\mathbf{A}$  képterében, akkor az egyenletrendszernek nincs megoldása.

Ekkor a  $\mathbf{x} = \mathbf{V}[\text{diag}(1/w_j)]\mathbf{U}^H\mathbf{b}$  “megoldásra” ( $1/w_j$  helyett a megfelelő átlós elem 0-ra cserélve) igaz az, hogy ez minimalizálja a  $|\mathbf{Ax} - \mathbf{b}|$  mennyiséget a legkisebb négyzetek (vagyis  $\chi^2$ ) értelemben.

# Szinguláris érték szerinti felbontás

Tekintsük újra az egyenletrendszert

$$\mathbf{A} \cdot \mathbf{x} = \mathbf{b}$$

Ha  $\mathbf{b}$  nincs benne az  $\mathbf{A}$  képterében, akkor az egyenletrendszernek nincs megoldása.

Ekkor a  $\mathbf{x} = \mathbf{V}[\text{diag}(1/w_j)]\mathbf{U}^H\mathbf{b}$  "megoldásra" ( $1/w_j$  helyett a megfelelő átlós elem 0-ra cserélve) igaz az, hogy ez minimalizálja a  $|\mathbf{Ax} - \mathbf{b}|$  mennyiséget a legkisebb négyzetek (vagyis  $\chi^2$ ) értelemben.

Bizonyítás: Numerical Recipies, Eq(2.6.10)

# SVD és lineáris függvényillesztés

- Az SVD-t többféle problémában lehet alkalmazni
- Most: lineáris függvényillesztés
- Később: főkomponens analízis

**Probléma:** a normálegyenletek együtthatómátrixa rosszul kondicionált, ezért az egyenletek megoldásakor (közel) 0 pivot elemmel találkozunk.



# SVD és lineáris függvényillesztés

- Az SVD-t többféle problémában lehet alkalmazni
- Most: lineáris függvényillesztés
- Később: főkomponens analízis

**Probléma:** a normálegyenletek együtthatómátrixa rosszul kondicionált, ezért az egyenletek megoldásakor (közel) 0 pivot elemmel találkozunk.

Az  $\mathbf{X}$  tervmátrix és a mért értékeket tartalmazó  $\mathbf{b}$  vektor segítségével a legkisebb négyzetek módszere átfogalmazható:

keressük azt az  $\mathbf{a}$  vektort, amelyre  $\chi^2 = |\mathbf{X} \cdot \mathbf{a} - \mathbf{b}|^2$  minimális

# SVD és lineáris függvényillesztés

- Az SVD-t többféle problémában lehet alkalmazni
- Most: lineáris függvényillesztés
- Később: főkomponens analízis

**Probléma:** a normálegyenletek együtthatómátrixa rosszul kondicionált, ezért az egyenletek megoldásakor (közel) 0 pivot elemmel találkozunk.

Az  $\mathbf{X}$  tervmátrix és a mért értékeket tartalmazó  $\mathbf{b}$  vektor segítségével a legkisebb négyzetek módszere átfogalmazható:

keressük azt az  $\mathbf{a}$  vektort, amelyre  $\chi^2 = |\mathbf{X} \cdot \mathbf{a} - \mathbf{b}|^2$  minimális

Egzakt megoldás:  $\mathbf{a} = \mathbf{V}[\text{diag}(1/w_j)]\mathbf{U}^T\mathbf{b}$  ( $\mathbf{U}$  most valós mátrix)

# SVD és lineáris függvényillesztés

Egzakt megoldás:  $\mathbf{a} = \mathbf{V}[\text{diag}(1/w_j)]\mathbf{U}^T \mathbf{b}$

Ha valamely  $w_j \approx 0$  akkor helyettesítés:  $(1/w_j) \rightarrow 0$

# SVD és lineáris függvényillesztés

Egzakt megoldás:  $\mathbf{a} = \mathbf{V}[\text{diag}(1/w_j)]\mathbf{U}^T \mathbf{b}$

Ha valamely  $w_j \approx 0$  akkor helyettesítés:  $(1/w_j) \rightarrow 0$

Bizonyítás nélkül:

$$\text{Cov}(\mathbf{a}_j, \mathbf{a}_k) = \mathbf{V}\mathbf{W}^{-1}[\mathbf{V}\mathbf{W}^{-1}]^T = \tilde{\mathbf{V}}\tilde{\mathbf{V}}^T$$

A diagonális elemek adják meg a  $\sigma^2(\mathbf{a}_j)$  varianciákat