

# *Numerička analiza*

## *25. predavanje*

Saša Singer

`singer@math.hr`

`web.math.hr/~singer`

PMF – Matematički odjel, Zagreb

# Sadržaj predavanja

- Dekompozicija singularnih vrijednosti (SVD):
  - Osnovna svojstva.
  - Primjena SVD-a na metodu najmanjih kvadrata.
  - Računanje SVD-a.
    - Bidijagonalni QR algoritam.
    - Jacobijev algoritam.
    - Diferencijalni qd algoritam.

# Dekompozicija singularnih vrijednosti (SVD)

# Osnovni teorem

Jedna od najkorisnijih dekompozicija

- i s **teoretske** strane (za dokazivanje činjenica)
- i s **praktične** strane,

je **dekompozicija singularnih vrijednosti** (engl. singular value decomposition) ili, skraćeno, **SVD**.

Sljedeći teorem pokazuje da za **svaku** matricu **postoji** njezina dekompozicija singularnih vrijednosti.

# Osnovni teorem

**Teorem.** Neka je  $A$  proizvoljna matrica tipa  $m \times n$ , uz  $m \geq n$ .  
 $A$  se može dekomponirati kao

$$A = \hat{U} \begin{bmatrix} \Sigma \\ 0 \end{bmatrix} V^* = U \Sigma V^*,$$

gdje je  $\Sigma = \text{diag}(\sigma_1, \dots, \sigma_n)$ , uz  $\sigma_1 \geq \dots \geq \sigma_n \geq 0$ ,  
 $\hat{U} = [U, U_0]$  je **unitarna matrica** reda  $m$ , a  $V$  je **unitarna matrica** reda  $n$ .

Stupce matrice

•  $U$  (oznaka  $u_i$ ) zovemo **lijevi singularni vektori**,

•  $V$  (oznaka  $v_i$ ) zovemo **desni singularni vektori**,

a dijagonalne elemente  $\sigma_i$  matrice  $\Sigma$  **singularne vrijednosti**.

## Osnovni teorem — komentari

Nadalje, ako je

- $m < n$ , dekompozicija singularnih vrijednosti definira se za matricu  $A^*$ ;
- $A$  realna,  $U$  i  $V$  su, također, realne.

Ako o matrici  $A$  razmišljamo kao zapisu operatora koji preslikava vektor  $x \in \mathbb{R}^n$  u vektor  $y = Ax \in \mathbb{R}^m$ , onda

- možemo izabrati ortogonalni koordinatni sustav u  $\mathbb{R}^n$  (osi su mu jedinični vektori stupci u  $V$ ),
- i drugi ortogonalni koordinatni sustav u  $\mathbb{R}^m$  (osi su mu jedinični vektori stupci u  $U$ ),

takve da je zapis tog operatora u tom paru baza dijagonalna matrica  $\Sigma$  (s nenegativnom dijagonalom).

## Dokaz teorema

**Dokaz.** Dokaz se provodi **indukcijom** po  $m$  i  $n$ .

Iz pretpostavke o postojanju **SVD**-a za  $(m - 1) \times (n - 1)$  matrice, dokazat ćemo postojanje **SVD**-a i za  $m \times n$  matrice.

Dodatno, pretpostavljamo da je  $A \neq 0$ . U protivnom je  $\Sigma = 0$ , a  $U$  i  $V$  su **proizvoljne** unitarne matrice, tj. tvrdnja vrijedi.

**Baza indukcije** je za  $n = 1$ , jer je  $m \geq n$ . Napišimo tu **jednostupčanu** matricu  $A$  u obliku

$$A = U\Sigma V^*,$$

gdje je

$$U = \frac{A}{\|A\|_2}, \quad \Sigma = \|A\|_2, \quad V = 1,$$

pa tvrdnja vrijedi za  $n = 1$  i bilo koji  $m \geq 1$ .

## Dokaz teorema

Za **korak indukcije**, izaberemo vektor  $v$ , takav da je  $\|v\|_2 = 1$  i na njemu se baš dostiže **maksimum 2-norme** za  $A$ , tj. vrijedi

$$\|A\|_2 = \max_{\|x\|_2=1} \|Ax\|_2 = \|Av\|_2.$$

Definiramo jedinični vektor

$$u = \frac{Av}{\|Av\|_2}.$$

Vektore  $u$  i  $v$  **dopunimo** matricama  $\tilde{U}$ , odnosno  $\tilde{V}$ , tako da

$$U_0 = [u, \tilde{U}], \quad V_0 = [v, \tilde{V}]$$

budu **unitarne** matrice reda  $m$ , odnosno  $n$ .



## Dokaz teorema

Sada možemo pisati

$$U_0^* A V_0 = \begin{bmatrix} u^* \\ \tilde{U}^* \end{bmatrix} A [v, \tilde{V}] = \begin{bmatrix} u^* A v & u^* A \tilde{V} \\ \tilde{U}^* A v & \tilde{U}^* A \tilde{V} \end{bmatrix}.$$

Po definiciji vektora  $u$  i  $v$ , vrijedi

$$u^* A v = \frac{v^* A^* A v}{\|A v\|_2} = \frac{\|A v\|_2^2}{\|A v\|_2} = \|A v\|_2 = \|A\|_2 := \sigma.$$

Zbog **ortogonalnosti** stupaca **unitarne** matrice  $U_0$ , svi stupci matrice  $\tilde{U}$  su **okomiti** na vektor  $u$ , pa je  $\tilde{U}^* u = 0$ . Onda je i

$$\tilde{U}^* A v = \tilde{U}^* u \|A v\|_2 = 0.$$

## Dokaz teorema

Tvrdimo i da je  $u^* A \tilde{V} = 0$ . Ako označimo s  $A_1 = U_0^* A V_0$ ,  $w^* = u^* A \tilde{V}$ ,  $B = \tilde{U}^* A \tilde{V}$ , onda je

$$A_1 = U_0^* A V_0 = \begin{bmatrix} \sigma & w^* \\ 0 & B \end{bmatrix}.$$

Zbog **unitarne invarijantnosti** 2-norme je

$$\sigma = \|A\|_2 = \|U_0^* A V_0\|_2 = \|A_1\|_2.$$

S druge strane, za proizvoljni vektor  $z \neq 0$  vrijedi

$$\|A_1\|_2 = \max_{x \neq 0} \frac{\|A_1 x\|_2}{\|x\|_2} \geq \frac{\|A_1 z\|_2}{\|z\|_2},$$

## Dokaz teorema

odnosno,  $\|A_1\|_2 \|z\|_2 \geq \|A_1 z\|_2$ . Izaberimo

$$z = \begin{bmatrix} \sigma \\ w \end{bmatrix}.$$

Onda je

$$\begin{aligned} \|A_1\|_2^2 \|z\|_2^2 &= \|A_1\|_2^2 (\sigma^2 + \|w\|_2^2) \geq \|A_1 z\|_2^2 = \left\| A_1 \begin{bmatrix} \sigma \\ w \end{bmatrix} \right\|_2^2 \\ &= \left\| \begin{bmatrix} \sigma & w^* \\ 0 & B \end{bmatrix} \begin{bmatrix} \sigma \\ w \end{bmatrix} \right\|_2^2 = (\sigma^2 + w^* w)^2 + \|Bw\|_2^2 \\ &\geq (\sigma^2 + \|w\|_2^2)^2, \end{aligned}$$

## Dokaz teorema

pa vidimo da je

$$\|A_1\|_2^2(\sigma^2 + \|w\|_2^2) \geq (\sigma^2 + \|w\|_2^2)^2.$$

Dijeljenjem s  $(\sigma^2 + \|w\|_2^2)$  dobivamo

$$\sigma^2 = \|A\|_2^2 = \|A_1\|_2^2 \geq \sigma^2 + \|w\|_2^2,$$

što je moguće **samo** za  $w = 0$ .

Drugim riječima, vrijedi

$$U_0^* A V_0 = \begin{bmatrix} \sigma & 0 \\ 0 & B \end{bmatrix}.$$

## Dokaz teorema

Sada možemo iskoristiti **pretpostavku indukcije** na matricu  $B$ , da  $B$  ima **SVD**

$$B = U_1 \Sigma_1 V_1^*,$$

pa dobivamo

$$U_0^* A V_0 = \begin{bmatrix} \sigma & 0 \\ 0 & U_1 \Sigma_1 V_1^* \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & U_1 \end{bmatrix} \begin{bmatrix} \sigma & 0 \\ 0 & \Sigma_1 \end{bmatrix} \begin{bmatrix} 1 & 0 \\ 0 & V_1 \end{bmatrix}^*,$$

odakle odmah slijedi tvrdnja, jer **unitarne** matrice čine multiplikativnu **grupu**.

Ako želimo biti potpuno precizni, treba još **silazno** poredati singularne vrijednosti. To se postiže primjenom matrica **permutacije**, koje su, također, **unitarne**. ■

## Svojstva SVD-a

Dokažimo još i neka svojstva **SVD**-a.

Neka je  $A = U\Sigma V^T$  dekompozicija singularnih vrijednosti (SVD) **realne** matrice  $A$  tipa  $m \times n$ , uz  $m \geq n$ .

**Tvrdnja 1.** Ako je  $A$  **simetrična** matrica reda  $n$  sa svojstvenim vrijednostima  $\lambda_i$  i ortonormalnim svojstvenim vektorima  $u_i$ , tj. ako je **svojstvena dekompozicija** za  $A$  oblika

$$A = U\Lambda U^T, \quad \Lambda = \text{diag}(\lambda_1, \dots, \lambda_n), \quad U = [u_1, \dots, u_n],$$

onda **SVD** matrice  $A$  ima oblik

$$A = U\Sigma V^T,$$

gdje je  $\sigma_i = |\lambda_i|$  i  $v_i = \text{sign}(\lambda_i)u_i$ , uz dogovor da je  $\text{sign}(0) = 1$ .

## Svojstva SVD-a

**Dokaz.** Očito, da bismo dobili **singularne** vrijednosti matrice  $A$ , moramo samo izvući **predznake** svojstvenih vrijednosti. ■

**Tvrdnja 2.** Svojstvene vrijednosti simetrične matrice  $A^T A$  su  $\sigma_i^2$ . Desni singularni vektori  $v_i$  su pripadni svojstveni vektori.

**Dokaz.** Vrijedi

$$A^T A = V \Sigma^T U^T U \Sigma V^T = V \Sigma^2 V^T,$$

i to je svojstvena dekompozicija od  $A^T A$ . ■

## Svojstva SVD-a

Tvrđnja 3. Svojstvene vrijednosti matrice  $AA^T$  su:

- $\sigma_i^2$
- i još  $m - n$  njih, koje su jednake **nula**.

Svojstveni vektori matrice  $AA^T$  su:

- **lijevi** singularni vektori  $u_i$ , za svojstvene vrijednosti  $\sigma_i^2$ ;
- za preostalih  $m - n$  svojstvenih vrijednosti jednakih **nula**, kao svojstvene vektore možemo uzeti **bilo kojih**  $m - n$  vektora koji s prethodnima čine **ortogonalnu** matricu (dopuna do ortonormirane baze).



## Svojstva SVD-a

Dokaz. Uzmemo puni SVD od  $A$ , s kvadratnom matricom  $\hat{U}$ :

$$\begin{aligned} AA^T &= \hat{U} \begin{bmatrix} \Sigma \\ 0 \end{bmatrix} V^T V [\Sigma^T, 0] \hat{U}^T = \hat{U} \begin{bmatrix} \Sigma^2 & 0 \\ 0 & 0 \end{bmatrix} \hat{U}^T \\ &= [U, U_0] \begin{bmatrix} \Sigma^2 & 0 \\ 0 & 0 \end{bmatrix} [U, U_0]^T, \end{aligned}$$

što je svojstvena dekompozicija od  $AA^T$ . ■

## Svojstva SVD-a

Tvrdnja 4. Neka je  $A$  kvadratna matrica reda  $n$ , i neka je  $A = U\Sigma V^T$  dekompozicija singularnih vrijednosti od  $A$ , uz

$$\Sigma = \text{diag}(\sigma_1, \dots, \sigma_n), \quad U = [u_1, \dots, u_n], \quad V = [v_1, \dots, v_n].$$

Neka je

$$H = \begin{bmatrix} 0 & A^T \\ A & 0 \end{bmatrix}.$$

Svojstvene vrijednosti od  $H$  su  $\pm\sigma_i$ , a pripadni svojstveni vektori su

$$\frac{1}{\sqrt{2}} \begin{bmatrix} v_i \\ \pm u_i \end{bmatrix}.$$

## Svojstva SVD-a

**Dokaz.** Uvrstimo **SVD** od  $A$  u formulu za  $H$ . Onda je

$$\begin{aligned} H &= \begin{bmatrix} 0 & A^T \\ A & 0 \end{bmatrix} = \begin{bmatrix} 0 & V\Sigma U^T \\ U\Sigma V^T & 0 \end{bmatrix} \\ &= \begin{bmatrix} 0 & V \\ U & 0 \end{bmatrix} \begin{bmatrix} 0 & \Sigma \\ \Sigma & 0 \end{bmatrix} \begin{bmatrix} 0 & U^T \\ V^T & 0 \end{bmatrix}. \end{aligned}$$

Lako se provjerava da je matrica

$$Q = \frac{1}{\sqrt{2}} \begin{bmatrix} I & I \\ -I & I \end{bmatrix}$$

ortogonalna ...

## Svojstva SVD-a

... i da vrijedi

$$Q \begin{bmatrix} 0 & \Sigma \\ \Sigma & 0 \end{bmatrix} Q^T = \begin{bmatrix} \Sigma & 0 \\ 0 & -\Sigma \end{bmatrix}.$$

Konačno, zaključujemo da je

$$\begin{aligned} H &= \begin{bmatrix} 0 & V \\ U & 0 \end{bmatrix} Q^T Q \begin{bmatrix} 0 & \Sigma \\ \Sigma & 0 \end{bmatrix} Q^T Q \begin{bmatrix} 0 & U^T \\ V^T & 0 \end{bmatrix} \\ &= \frac{1}{\sqrt{2}} \begin{bmatrix} V & V \\ U & -U \end{bmatrix} \begin{bmatrix} \Sigma & 0 \\ 0 & -\Sigma \end{bmatrix} \left( \frac{1}{\sqrt{2}} \begin{bmatrix} V & V \\ U & -U \end{bmatrix} \right)^T, \end{aligned}$$

što je **svojstvena** dekompozicija od  $H$ . ■

# SVD — rješenje problema najmanjih kvadrata

Tvrđnja 5. Ako  $A$  ima **puni rang**, onda je rješenje problema najmanjih kvadrata

$$\min_x \|Ax - b\|_2$$

jednako  $x = V\Sigma^{-1}U^Tb$ , tj. dobiva se

• primjenom “invertiranog” **skraćenog SVD**-a od  $A$  na  $b$ .

**Dokaz.** Vrijedi

$$\|Ax - b\|_2^2 = \|U\Sigma V^T x - b\|_2^2.$$

Budući da je  $A$  **punog ranga**, to je i  $\Sigma$ .

# SVD — rješenje problema najmanjih kvadrata

Zbog **unitarne** invarijantnosti 2-norme, vrijedi

$$\begin{aligned}\|U\Sigma V^T x - b\|_2^2 &= \|\hat{U}^T (U\Sigma V^T x - b)\|_2^2 \\ &= \left\| \begin{bmatrix} U^T \\ U_0^T \end{bmatrix} (U\Sigma V^T x - b) \right\|_2^2 = \left\| \begin{bmatrix} \Sigma V^T x - U^T b \\ -U_0^T b \end{bmatrix} \right\|_2^2 \\ &= \|\Sigma V^T x - U^T b\|_2^2 + \|U_0^T b\|_2^2.\end{aligned}$$

Taj izraz je **minimalan** ako je **prvi** član jednak 0, tj. ako je

$$x = V\Sigma^{-1}U^T b.$$

Pripadna **vrijednost** minimuma je  $\min_x \|Ax - b\|_2 = \|U_0^T b\|_2$ . ■

## SVD — norme i broj uvjetovanosti matrice

**Tvrđnja 6.** Neka je  $A$  kvadratna matrica reda  $n$  i pretpostavimo da je  $A$  nesingularna. Ako je  $\sigma_1$  najveća, a  $\sigma_n$  najmanja singularna vrijednost od  $A$ , onda je

$$\|A\|_2 = \sigma_1, \quad \|A^{-1}\|_2^{-1} = \sigma_n, \quad \kappa_2(A) = \|A\|_2 \|A^{-1}\|_2 = \frac{\sigma_1}{\sigma_n}.$$

**Dokaz.** Zbog unitarne invarijantnosti 2-norme, vrijedi

$$\|A\|_2 = \|U^T A V\|_2 = \|\Sigma\|_2 = \sigma_1,$$

$$\|A^{-1}\|_2 = \|U^T A^{-1} V\|_2 = \|\Sigma^{-1}\|_2 = \sigma_n^{-1},$$

odakle odmah slijedi i formula za  $\kappa_2(A)$ . ■

## SVD — nul-potprostor i slika matrice

Tvrđnja 7. Pretpostavimo da za singularne vrijednosti matrice  $A$  vrijedi

$$\sigma_1 \geq \dots \geq \sigma_r > \sigma_{r+1} = \dots = \sigma_n = 0.$$

Tada (i samo tada) je  $\text{rang}(A) = r$ .

- **Nul-potprostor** od  $A$ , tj. potprostor svih vektora  $v$  za koje je  $Av = 0$ , je potprostor razapet sa **stupcima**  $v_{r+1}, \dots, v_n$  matrice  $V$ .
- **Slika** operatora  $A$ , tj. potprostor svih vektora oblika  $Aw$ , za sve  $w$ , razapet je **stupcima**  $u_1, \dots, u_r$  od  $U$ .

**Dokaz.** Napišimo **SVD** od  $A$  korištenjem kvadratnih matrica  $\hat{U}$  i  $V$ . Budući da su obje **ortogonalne**, one su **nesingularne**, pa je  $\text{rang}(A) = \text{rang}(\Sigma) = r$ .



## SVD — nul-potprostor i slika matrice

Vektor  $v$  je u nul-potprostoru od  $A$ , ako i samo ako je  $V^T v$  u nul-potprostoru od

$$\hat{U}^T AV = \begin{bmatrix} \Sigma \\ 0 \end{bmatrix} := \tilde{\Sigma},$$

jer je  $Av = 0$ , ako i samo ako je  $\hat{U}^T AV(V^T v) = 0$ .

- Nul-potprostor matrice  $\tilde{\Sigma}$  je razapet stupcima  $(r + 1)$  do  $n$  jedinične matrice  $I_n$ ,
- pa je nul-potprostor od  $A$  razapet sa stupcima  $(r + 1)$  do  $n$  matrice  $V$ .

Sličan argument vrijedi i za drugi dio dokaza. ■

## SVD — slika jedinične sfere

Tvrdnja 8. Neka je  $S^{n-1}$  jedinična sfera u  $\mathbb{R}^n$ ,

$$S^{n-1} = \{x \in \mathbb{R}^n \mid \|x\|_2 = 1\}.$$

Neka je  $A \cdot S^{n-1}$  slika od  $S^{n-1}$ , kad se jedinična sfera preslika operatorom  $A$ ,

$$A \cdot S^{n-1} = \{Ax \mid x \in \mathbb{R}^n, \|x\|_2 = 1\}.$$

Ta slika  $A \cdot S^{n-1}$  je

- elipsoid sa središtem u ishodištu od  $\mathbb{R}^m$
- i glavnim osima  $\sigma_i u_i$ , za  $i = 1, \dots, m$ .

## SVD — nul-potprostor i slika matrice

**Dokaz.** Pretpostavimo da je  $A$  kvadratna i nesingularna.

- Matrica  $V^T$  je **ortogonalna**, pa ona preslikava **jedinične** vektore u druge **jedinične** vektore, tj.  $V^T S^{n-1} = S^{n-1}$ .
- Budući da je  $v \in S^{n-1}$ , ako i samo ako je  $\|v\|_2 = 1$ , onda je  $w \in \Sigma S^{n-1}$ , ako i samo ako je  $\|\Sigma^{-1}w\|_2 = 1$ , ili

$$\sum_{i=1}^n \left( \frac{w_i}{\sigma_i} \right)^2 = 1.$$

Time je definiran **elipsoid** s glavnim osima  $\sigma_i e_i$ . Množenjem  $w = \Sigma v$  matricom  $U$ , elipsoid se **rotira** oko ishodišta, tako da se  $e_i$  preslika u  $u_i$ . **Dobiveni** elipsoid ima **glavne osi**  $\sigma_i u_i$ .

Argument vrijedi i za  $m \geq n$ , i kad je  $\text{rang}(A) = r \leq n$ . ■

# SVD — aproksimacija matricom nižeg ranga

**Tvrđnja 9.** Zapišimo matrice  $U$  i  $V$  iz SVD-a od  $A$  u stupčanom obliku  $U = [u_1, \dots, u_n]$  i  $V = [v_1, \dots, v_n]$ . Matricu  $A$  možemo zapisati i kao zbroj matrica ranga 1 (tipa  $m \times n$ )

$$A = U\Sigma V^T = \sum_{i=1}^n \sigma_i u_i v_i^T.$$

Matricu  $A_k$ , istog tipa kao i  $A$ , ranga  $\text{rang}(A_k) \leq k < n$ , koja je po 2-normi najbliža matrici  $A$ , možemo zapisati kao

$$A_k = U\Sigma_k V^T = \sum_{i=1}^k \sigma_i u_i v_i^T,$$

pri čemu je  $\Sigma_k = \text{diag}(\sigma_1, \dots, \sigma_k, 0, \dots, 0)$ .

# SVD — aproksimacija matricom nižeg ranga

Pritom je

$$\|A - A_k\|_2 = \sigma_{k+1}$$

**najmanja** udaljenost između  $A$  i **svih** matrica ranga **najviše**  $k$ .

**Dokaz.** Prema konstrukciji, matrica  $A_k$  ima rang **najviše**  $k$  (zbog  $\sigma_k \geq 0$ ) i vrijedi

$$\begin{aligned}\|A - A_k\|_2 &= \left\| \sum_{i=k+1}^n \sigma_i u_i v_i^T \right\|_2 \\ &= \|U \operatorname{diag}(0, \dots, 0, \sigma_{k+1}, \dots, \sigma_n) V^T\|_2 = \sigma_{k+1}.\end{aligned}$$

Ostaje pokazati da je to i **najbliža** matrica ranga **najviše**  $k$  matrici  $A$ .

# SVD — aproksimacija matricom nižeg ranga

Neka je  $B$  bilo koja matrica istog tipa  $m \times n$ , za koju vrijedi  $\text{rang}(B) \leq k$ .

- Njezin nul-potprostor ima dimenziju barem  $n - k$ .
- Potprostor razapet vektorima  $v_1, \dots, v_{k+1}$  ima dimenziju  $k + 1$ , pa sigurno postoji netrivialni vektor koji se nalazi u njegovom presjeku s nul-potprostorom od  $B$ .

Neka je  $h$  pripadni jedinični vektor koji se nalazi u presjeku ta dva potprostora. Onda je  $Bh = 0$  i vrijedi

$$\begin{aligned}\|A - B\|_2 &\geq \|(A - B)h\|_2 = \|Ah\|_2 = \|U\Sigma V^T h\|_2 \\ &= \|\Sigma V^T h\|_2 \geq \sigma_{k+1} \|V^T h\|_2 = \sigma_{k+1}.\end{aligned}$$

Zadnja nejednakost je posljedica pretpostavke da je  $h$  linearna kombinacija vektora  $v_1, \dots, v_{k+1}$ . ■

# Metoda najmanjih kvadrata i generalizirani inverz matrice

# Generalizirani inverz

Jedna od primjena **SVD**-a je u metodi najmanjih kvadrata i kad  $A$  nema puni stupčani rang.

- Rješenja su istog oblika kao i prije (samo ih je više),

$$x = V \Sigma^{-1} U^T b,$$

jedino treba znati “invertirati” singularnu matricu  $\Sigma$ .

- Takav inverz zove se generalizirani inverz i označava se sa  $\Sigma^+$ , ili  $\Sigma^\dagger$ .

Generalizirani inverz poopćava pojam inverza

- na pravokutne matrice
- i na matrice koje nisu punog ranga.



## Generalizirani inverz — definicije

Postoje **tri** ekvivalentne definicije **generaliziranog** inverza, koji se katkad zove i **Moore–Penroseov** inverz.

**Funkcijska definicija.** Neka je  $A \in \mathbb{C}^{m \times n}$  i neka je linearna transformacija  $\tilde{A}^+ : \mathbb{C}^m \rightarrow \mathbb{C}^n$  definirana s

$$\tilde{A}^+ x = \begin{cases} 0, & \text{ako je } x \in \mathcal{R}(A)^\perp \\ (\tilde{A} |_{\mathcal{R}(A^*)})^{-1} x, & \text{ako je } x \in \mathcal{R}(A). \end{cases}$$

Matrica linearne transformacije  $\tilde{A}^+$ , u oznaci  $A^+$ , zove se **generalizirani** inverz matrice  $A$ .

## Generalizirani inverz — definicije

Mooreova definicija (1935.). Ako je  $A \in \mathbb{C}^{m \times n}$ , njezin generalizirani inverz je **jedinstvena** matrica  $A^+$ , takva da je

$$AA^+ = P_{\mathcal{R}(A)} \quad \text{i} \quad A^+A = P_{\mathcal{R}(A^+)},$$

pri čemu je s  $P_X$  označen **projektor** na potprostor  $X$ .

Penroseova definicija (1955.). Ako je  $A \in \mathbb{C}^{m \times n}$ , njezin generalizirani inverz je **jedinstvena** matrica  $A^+$ , takva da je

$$\begin{aligned} AA^+A &= A, & A^+AA^+ &= A^+, \\ (AA^+)^* &= AA^+, & (A^+A)^* &= A^+A. \end{aligned}$$

U sva tri slučaja, **jedinstvenost** se lako dokazuje.

## Generalizirani inverz dijagonalne matrice

Nije teško pokazati da je za dijagonalnu matricu  $\Sigma$ ,

$$\Sigma = \begin{bmatrix} \Sigma_1 & 0 \\ 0 & 0 \end{bmatrix},$$

pri čemu je  $\Sigma_1$  regularna, njezin generalizirani inverz jednak

$$\Sigma^+ = \begin{bmatrix} \Sigma_1^{-1} & 0 \\ 0 & 0 \end{bmatrix}.$$

## Problem najmanjih kvadrata

**Teorem.** Za matricu  $A$  ranga  $r < n$ , rješenje  $x$  koje minimizira  $\|Ax - b\|_2$  može se karakterizirati na sljedeći način.

Neka je  $A = U\Sigma V^T$  dekompozicija singularnih vrijednosti matrice  $A$ , i neka je

$$A = U\Sigma V^T = [U_1, U_2] \begin{bmatrix} \Sigma_1 & 0 \\ 0 & 0 \end{bmatrix} [V_1, V_2]^T = U_1 \Sigma_1 V_1^T,$$

gdje je  $\Sigma_1$  nesingularna, reda  $r$ , a matrice  $U_1$  i  $V_1$  imaju  $r$  stupaca. Neka je

$$\sigma := \sigma_{\min}(\Sigma_1),$$

najmanja ne-nula singularna vrijednost od  $A$ .

# Problem najmanjih kvadrata

Tada se **sva** rješenja problema najmanjih kvadrata mogu napisati u formi

$$x = V_1 \Sigma_1^{-1} U_1^T b + V_2 z,$$

gdje je  $z$  proizvoljni vektor.

Rješenje  $x$  koje ima minimalnu 2-normu je **ono** za koje je  $z = 0$ , tj.

$$x = V_1 \Sigma_1^{-1} U_1^T b.$$

Dodatno, za **normu tog** rješenja vrijedi ocjena

$$\|x\|_2 \leq \frac{\|b\|_2}{\sigma}.$$

## Problem najmanjih kvadrata

**Dokaz.** Nadopunimo matricu  $[U_1, U_2]$  stupcima matrice  $U_3$  do **ortogonalne** matrice reda  $m$ , i označimo tu matricu s  $\hat{U}$ . Zbog **unitarne invarijantnosti 2-norme**, dobivamo

$$\begin{aligned}\|Ax - b\|_2^2 &= \|\hat{U}^T(Ax - b)\|_2^2 \\ &= \left\| \begin{bmatrix} U_1^T \\ U_2^T \\ U_3^T \end{bmatrix} (U_1 \Sigma_1 V_1^T x - b) \right\|_2^2 = \left\| \begin{bmatrix} \Sigma_1 V_1^T x - U_1^T b \\ -U_2^T b \\ -U_3^T b \end{bmatrix} \right\|_2^2 \\ &= \|\Sigma_1 V_1^T x - U_1^T b\|_2^2 + \|U_2^T b\|_2^2 + \|U_3^T b\|_2^2.\end{aligned}$$

Ovaj izraz je **minimiziran** kad je **prva** od **tri** norme u posljednjem redu jednaka **0**, tj. ako je  $\Sigma_1 V_1^T x = U_1^T b$ .

## Problem najmanjih kvadrata

Drugačije napisano, mora biti

$$x = V_1 \Sigma_1^{-1} U_1^T b.$$

Stupci matrica  $V_1$  i  $V_2$  su međusobno ortogonalni, pa je

$$V_1^T V_2 z = 0,$$

za sve vektore  $z$ . Zato  $x$  ostaje rješenje problema najmanjih kvadrata i kad mu dodamo  $V_2 z$ , za bilo koji  $z$ , tj. ako je

$$x = V_1 \Sigma_1^{-1} U_1^T b + V_2 z.$$

To su, ujedno, i sva rješenja, jer stupci matrice  $V_2$  razapinju nul-potprostor  $\mathcal{N}(A)$ .

# Problem najmanjih kvadrata

Zbog ortogonalnosti, vrijedi i

$$\|x\|_2^2 = \|V_1 \Sigma_1^{-1} U_1^T b\|_2^2 + \|V_2 z\|_2^2,$$

a to je minimalno za  $z = 0$ . Na kraju, za to minimalno rješenje vrijedi ocjena

$$\|x\|_2 = \|V_1 \Sigma_1^{-1} U_1^T b\|_2 = \|\Sigma_1^{-1} U_1^T b\|_2 \leq \frac{\|U_1^T b\|_2}{\sigma} = \frac{\|b\|_2}{\sigma}.$$

Primjerom se lako pokazuje da je ova ocjena dostižna. ■

Rješenje problema najmanjih kvadrata korištenjem SVD-a je najstabilnije. Za  $m \gg n$ , trajanje je približno jednako trajanju rješenja QR faktorizacijom.



# Računanje SVD-a

## Veza simetričnog svojstvenog problema i SVD-a

Tvrdnje 2, 3 i 4 iz svojstava SVD-a daju vezu svojstvenog problema i SVD-a, koja se koristi za njegovo računanje.

Ideja. Ako je  $G$  faktor matrice  $A$ , tj.

$$A = GG^T, \quad \text{ili} \quad A = G^T G, \quad \text{ili (rjeđe)} \quad A = \begin{bmatrix} 0 & G^T \\ G & 0 \end{bmatrix},$$

onda, za nalaženje SVD-a od  $G$ , implicitno primjenjujemo algoritam za simetrični svojstveni problem za  $A$ .

Implicitno znači da sve računamo kao da smo formirali matricu  $A$ . Međutim, umjesto na  $A$ , transformacije primjenjujemo na  $G$  (ili  $G^T$ ).

## Bidijagonalni QR

Standardna priprema za simetrični QR algoritam je tridijagonalizacija.

Za SVD algoritam to je bidijagonalizacija.

Ideja. Matricu  $G$  svodimo na gornju bidijagonalnu formu,

• svi elementi izvan glavne i prve gornje dijagonale su 0, tako da nađemo ortogonalne matrice  $U_1$  i  $V_1$ , takve da bude

$$G = U_1 B V_1^T,$$

gdje je  $B$  gornja bidijagonalna matrica.

# Bidijagonalni QR

Standardni algoritam bidijagonalizacije vrlo nalíči na QR faktorizaciju:

- prvi stupac od  $G$  svedemo na  $ce_1$ ;
- prvi redak od transformiranog  $G$  svedemo na samo 2 elementa (da ne pokvarimo sređeni prvi stupac);
- ...

Postoji i moderniji, točniji algoritam bidijagonalizacije.

Nakon bidijagonalizacije,

- provodimo implicitni QR algoritam na matrici  $B$ , tj. na jednoj od trodijagonalnih matrica  $BB^T$  ili  $B^T B$ .

# Jacobijev algoritam

Jacobijev algoritam provodimo na punoj matrici  $G$ , koja, recimo, neka ima više redaka, nego stupaca.

Da bismo skratili algoritam, prvo napravimo QR faktorizaciju matrice  $G$ ,

$$G = QR.$$

Zatim radimo implicitne transformacije,

• ili na  $R^T R$ , ili na  $RR^T$ .

Pohvalna karakteristika algoritma:

- jedne singularne vektore mora akumulirati,
- a drugi se jednostavno pročitaju na kraju algoritma.

# Jacobijev algoritam

Recimo da smo izabrali rad na  $R^T R$ .

- Na početku su **desni** singularni vektori jednaki  $I$ .
- U matrici **desnih** singularnih vektora **skupljamo** sve transformacije kojima smo dijagonalizirali  $R^T R$ .

Na kraju algoritma, kad  $R^T R$  postane **dijagonalna**,

- stupci matrice  $R$  su **ortogonalni**, ali **nisu** normirani.
- **Norme** stupaca matrice  $R$  su **singularne vrijednosti**, a **sami ortonormirani** stupci od  $R$  su **lijevi** singularni vektori za  $R$ .
- **Lijevi** singularni vektori za  $G$  su, onda, **lijevi** singularni vektori od  $R$ , **slijeva** pomnoženi s  $Q$ .

## Diferencijalni qd algoritam

Niz faktorizacija Choleskog za zadanu simetričnu, pozitivno definitnu matricu  $T_1 := T$  definiran je ovako:

$$\begin{aligned} T_1 &= &= G_1^T G_1 \\ T_2 &= G_1 G_1^T &= G_2^T G_2 \\ &\vdots &\vdots \\ T_{2k} &= G_{2k-1} G_{2k-1}^T &= G_{2k}^T G_{2k} \\ T_{2k+1} &= G_{2k} G_{2k}^T &= G_{2k+1}^T G_{2k+1} \\ &\vdots &\vdots \end{aligned}$$

Sljedeća matrica dobiva se okretanjem faktora prethodne matrice.

# Diferencijalni qd algoritam

Prethodni niz transformacija može se računati i **implicitno**,

• nizom običnih QR faktorizacija,

• na **transponiranom faktoru** prethodne matrice,

ako je zadan **prvi** “faktor”  $G_1 := G$ :

$$G_1^T = Q_2 G_2, \quad Q_2^T Q_2 = I$$

$$G_2^T = Q_3 G_3, \quad Q_3^T Q_3 = I$$

⋮

⋮

$$G_{2k}^T = Q_{2k+1} G_{2k+1}, \quad Q_{2k+1}^T Q_{2k+1} = I$$

$$G_{2k+1}^T = Q_{2k+2} G_{2k+2}, \quad Q_{2k+2}^T Q_{2k+2} = I$$

⋮

⋮



## Diferencijalni qd algoritam

Za prethodni algoritam može se pokazati da **konvergira** prema **singularnim vrijednostima** matrice  $G$ .

- Algoritam je **efikasniji** ako se provodi na **bidijagonalnim** matricama  $B = G$ .
- Pripadne **QR faktorizacije** treba raditi **rotacijama** (efikasnije, mijenjaju se samo **2** retka).

Neka su (oznake):

- $a_i$  — dijagonalni elementi od  $B$ ,
- $b_i$  — vandijagonalni elementi od  $B$ .

U **QR faktorizaciji** javljaju se **norme** stupaca, tj.

- korijeni** sume kvadrata elemenata  $a_i$  i  $b_i$ .

# Diferencijalni qd algoritam

Da bismo se riješili računanja korijena,

- formule za elemente  $a_i$  i  $b_i$  se jednostavno kvadriraju,
- nazovu novim imenima  $q_i = a_i^2$  i  $e_i = b_i^2$ ,
- i dobili smo diferencijalni qd algoritam.

Algoritmu se mogu dodati pomaci.

# Zaključak

Navedeni algoritmi:

- bidijagonalni QR bez pomaka,
- Jacobijev algoritam,
- i diferencijalni qd algoritam s pomacima,

imaju jedno bitno svojstvo:

- računaju singularne vrijednosti s visokom relativnom točnošću,
- kad god to matrice dopuštaju!