

Numerička analiza

12. predavanje

Autor: Sanja Singer
Predavač: Nela Bosner

nela@math.hr

web.math.hr/~nela/nad.html

PMF – Matematički odjel, Zagreb

Sadržaj predavanja

- Dekompozicija singularnih vrijednosti (SVD):
 - Osnovna svojstva.
 - Veza singularnih i svojstvenih vrijednosti.
 - Praktična svojstva SVD-a
- Računanje SVD-a:
 - Bidijagonalni QR algoritam.
 - Jacobijev algoritam.
 - Diferencijalni qd algoritam.
- Primjena SVD-a:
 - Problem najmanjih kvadrata.
 - Generalizirani inverz.

Dekompozicija singularnih vrijednosti (SVD)

Što je SVD?

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 $\sigma_1 \geq \dots \geq \sigma_n \geq 0$,

$\hat{U} = [U, U_\perp]$ 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 σ_i matrice Σ **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 Σ (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 (nastavak)

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 (nastavak)

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

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

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 (nastavak)

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 (nastavak)

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 (nastavak)

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 (nastavak)

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**. ■

Veza singularnih i svojstvenih vrijednosti

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 $m \geq n$.

Tvrđnja 1. Ako je A **simetrična** matrica reda n sa svojstvenim vrijednostima λ_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 $\text{sign}(0) = 1$.

Veza singularnih i svojstvenih vrijednosti (nast.)

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 σ_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 $A^T A$. ■

Veza singularnih i svojstvenih vrijednosti (nast.)

Tvrđnja 3. Svojstvene vrijednosti matrice AA^T su:

- σ_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 σ_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).

Veza singularnih i svojstvenih vrijednosti (nast.)

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

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

što je svojstvena dekompozicija od AA^T . ■

Veza singularnih i svojstvenih vrijednosti (nast.)

Tvrđnja 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

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

Veza singularnih i svojstvenih vrijednosti (nast.)

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...

Veza singularnih i svojstvenih vrijednosti (nast.)

... 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 — norme i broj uvjetovanosti matrice

Tvrđnja 6. Neka je A kvadratna matrica reda n i pretpostavimo da je A regularna. Ako je σ_1 najveća, a σ_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 — jezgra i slika matrice

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

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

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

- **Jezgra** 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 **regularne**, pa je $\text{rang}(A) = \text{rang}(\Sigma) = r$.

SVD — jezgra i slika matrice (nastavak)

Vektor v je u jezgri od A , ako i samo ako je $V^T v$ u jezgri od

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

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

- Jezgra matrice $\tilde{\Sigma}$ je razapeta stupcima $(r + 1)$ do n jedinične matrice I_n ,
- pa je jezgra od A razapeta 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 — slika jedinične sfere (nastavak)

Dokaz. Pretpostavimo da je A kvadratna i regularna.

- 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 $\text{rang}(B) \leq k$.

- Njezina jezgra 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 jezgrom od B .

Neka je h pripadni jedinični vektor koji se nalazi u presjeku ta dva potprostora. Onda je $Bh = 0$, $h = V_{k+1}g$ gdje je $V_{k+1} = [v_1, \dots, v_{k+1}]$, i vrijedi

$$\begin{aligned}\|A - B\|_2 &\geq \|(A - B)h\|_2 = \|Ah\|_2 = \|U\Sigma V^T h\|_2 \\ &= \|\Sigma V^T h\|_2 = \|\Sigma V^T V_{k+1}g\|_2 = \left\| \Sigma \begin{bmatrix} I_{k+1} \\ 0 \end{bmatrix} g \right\|_2\end{aligned}$$

SVD — aproksimacija matricom nižeg ranga

$$\|A - B\|_2 = \left\| \begin{bmatrix} \text{diag}(\sigma_1, \dots, \sigma_{k+1}) \\ 0 \end{bmatrix} g \right\|_2 \geq \sigma_{k+1} \|g\|_2 = \sigma_{k+1}.$$

Zadnja nejednakost je posljedica pretpostavke da je h linearna kombinacija vektora v_1, \dots, v_{k+1} i činjenice da je $\|g\|_2 = \|V_{k+1}g\|_2 = \|h\|_2 = 1$. ■

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 (nastavak)

Primjer bidijagonalizacije



Bidijagonalni QR (nastavak)

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);
- ...

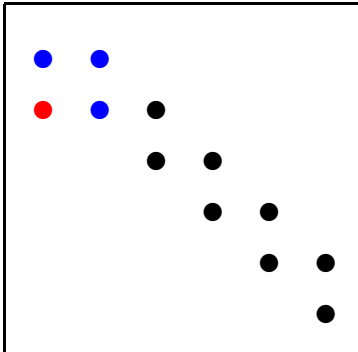
Postoji i moderniji, točniji algoritam bidijagonalizacije.

Nakon bidijagonalizacije,

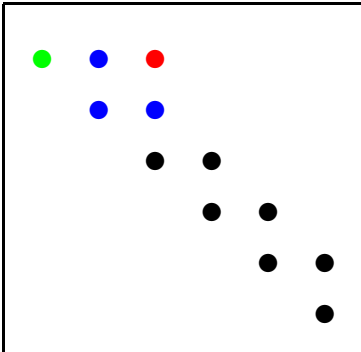
- provodimo implicitni QR algoritam na matrici B , tj. na jednoj od tridijagonalnih matrica BB^T ili $B^T B$.

Bidijagonalni QR (nastavak)

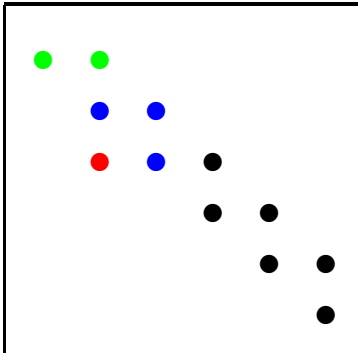
Primjer implicitnog QR algoritma

$$B_{k,1} \leftarrow B_k V_1 =$$


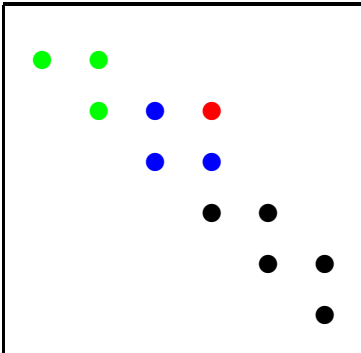
A square matrix diagram with a lower triangular part of black dots. The top-left corner has four colored dots: two blue dots in the first row, and one red dot in the second row followed by one blue dot in the second column.

$$B_{k,2} \leftarrow U_1^T B_{k,1} =$$


A square matrix diagram with a lower triangular part of black dots. The top-left corner has four colored dots: one green dot in the first row, one blue dot in the second row, one blue dot in the second column, and one red dot in the third row.

$$B_{k,3} \leftarrow B_{k,2} V_2 =$$



A square matrix diagram with a lower triangular part of black dots. The top-left corner has four colored dots: two green dots in the first row, one blue dot in the second row, one blue dot in the second column, and one red dot in the third row.

$$B_{k,4} \leftarrow U_2^T B_{k,3} =$$



A square matrix diagram with a lower triangular part of black dots. The top-left corner has four colored dots: two green dots in the first row, one green dot in the second row, one blue dot in the second column, and one blue dot in the third row.

Bidijagonalni QR (nastavak)


$$B_{k,5} \leftarrow B_{k,4} V_3 =$$




$$B_{k,6} \leftarrow U_3^T B_{k,5} =$$



$$B_{k,7} \leftarrow B_{k,6} V_4 =$$




$$B_{k,8} \leftarrow U_4^T B_{k,7} =$$




Bidijagonalni QR (nastavak)

$$B_{k,9} \leftarrow B_{k,8} V_5 =$$



$$B_{k,10} \leftarrow U_5^T B_{k,9} =$$



$$= B_{k+1}$$

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 (nastavak)

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 (nastavak)

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

- nizom običnih QR faktorizacija,
- na **transponiranom faktoru** prethodne matrice,

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

$$\begin{array}{ll} G_1^T = Q_2 G_2, & Q_2^T Q_2 = I \\ G_2^T = Q_3 G_3, & Q_3^T Q_3 = I \\ \vdots & \vdots \\ G_{2k}^T = Q_{2k+1} G_{2k+1}, & Q_{2k+1}^T Q_{2k+1} = I \\ G_{2k+1}^T = Q_{2k+2} G_{2k+2}, & Q_{2k+2}^T Q_{2k+2} = I \\ \vdots & \vdots \end{array}$$

Diferencijalni qd algoritam (nastavak)

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).

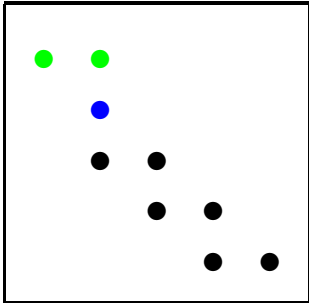
Neka su (oznake):

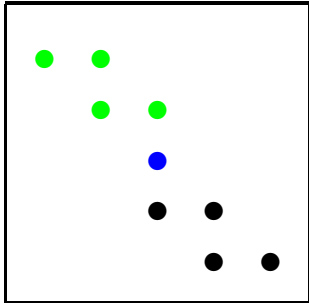
- a_i — dijagonalni elementi od B ,
- b_i — vandijagonalni elementi od B .

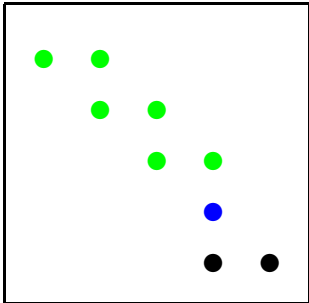
U **QR faktorizaciji** javljaju se **norme** stupaca, tj.

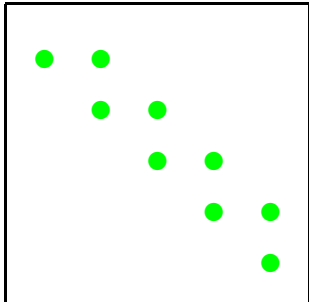
- **korijeni** sume kvadrata elemenata a_i i b_i .

Diferencijalni qd algoritam (nastavak)

$$B_{k,1}^T \leftarrow G_1^T B_k^T =$$


$$B_{k,2}^T \leftarrow G_2^T B_{k,1}^T =$$


$$B_{k,3}^T \leftarrow G_3^T B_{k,2}^T =$$


$$B_{k,4}^T \leftarrow G_4^T B_{k,3}^T =$$


$$= B_{k+1}$$

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!

Metoda najmanjih kvadrata i generalizirani inverz matrice

Primjena SVD-a

SVD ima široku primjenu:

- računanje inverza regularne kvadratne matrice
- računanje generaliziranog inverza pravokutne matrice
- računanje uvjetovanosti matrice
- rješavanje ortogonalnog Procrustes problema
- nalaženje presjeka jezgara dvaju linearnih operatora
- nalaženje kuteva između dva potprostora
- nalaženje presjeka potprostora
- rješavanje linearnog problema najmanjih kvadrata
- rješavanje linearnog problema totalnih najmanjih kvadrata

Primjena SVD-a (nastavak)

- rješavanje integralnih jednažbi (geofizika)
- procesiranje slika
- modeliranje prometa na internetu
- genetika (obrnuti inženjering genske mreže)

Problem najmanjih kvadrata — puni rang

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 Σ .

Problem najmanjih kvadrata — puni rang (n.)

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

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

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

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

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

Drugi način — puni rang

Napomena. Ponovo možemo na lakši način doći do prethodnog zaključka, ako znamo da su rješenja **problema minimizacije**

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

jednaka rješenju **sustava normalnih jednažbi**

$$A^T Ax = A^T b.$$

Ako je $A^T A$ **regularna**, što je ekvivalentno tome da A ima **puni** stupčani rang, onda problem najmanjih kvadrata ima **jedinstveno** rješenje

$$x = (A^T A)^{-1} A^T b.$$

Drugi način — puni rang (nastavak)

Napravimo skraćeni SVD matrice A

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

Uvrštavanjem u rješenje x izlazi

$$\begin{aligned}x &= (A^T A)^{-1} A^T b = (V\Sigma^2 V^T)^{-1} V\Sigma U^T b \\ &= V\Sigma^{-2} V^T V\Sigma U^T b = V\Sigma^{-2} \Sigma U^T b \\ &= V\Sigma^{-1} U^T b.\end{aligned}$$

Problem najmanjih kvadrata — defektni rang

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 Σ_1 regularna, 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 — defektni rang

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 — defektni rang

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

$$\|Ax - b\|_2^2 = \|\hat{U}^T(Ax - b)\|_2^2$$

$$= \left\| \begin{bmatrix} U_1^T \\ U_2^T \\ U_3^T \end{bmatrix} (U_1 \Sigma_1 V_1^T x - b) \right\|_2^2 = \left\| \begin{bmatrix} \Sigma_1 V_1^T x - U_1^T b \\ -U_2^T b \\ -U_3^T b \end{bmatrix} \right\|_2^2$$

$$= \|\Sigma_1 V_1^T x - U_1^T b\|_2^2 + \|U_2^T b\|_2^2 + \|U_3^T b\|_2^2.$$

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 — defektni rang

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 jezgru $\mathcal{N}(A)$.

Problem najmanjih kvadrata — defektni rang

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.

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**),

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

jedino treba znati “invertirati” **singularnu** matricu Σ .

- Takav inverz zove se **generalizirani** inverz i označava se sa Σ^+ , ili Σ^\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 $A \in \mathbb{C}^{m \times n}$ ($\tilde{A} : \mathbb{C}^n \rightarrow \mathbb{C}^m$) 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 (nastavak)

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 Σ ,

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

pri čemu je Σ_1 regularna, njezin generalizirani inverz jednak

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

Generalizirani inverz općenite matrice

Neka je za matricu A ranga $r \leq n$, $A = U\Sigma V^T$ 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 Σ_1 regularna, reda r , a matrice U_1 i V_1 imaju r stupaca. Tada je

$$A^+ = V\Sigma^+ U^T = [V_1, V_2] \begin{bmatrix} \Sigma_1^{-1} & 0 \\ 0 & 0 \end{bmatrix} [U_1, U_2]^T = V_1 \Sigma_1^{-1} U_1^T$$

upravo generalizirani inverz od A .