

## 12. Računanje singularnega razcepa

Bor Plestenjak

NLA

18. maj 2010

Za matriko  $A \in \mathbb{R}^{m \times n}$  bi radi izračunali singularni razcep  $A = U\Sigma V^T$ .

Ker velja

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

dobimo preprosto idejo:

Za matriko  $A \in \mathbb{R}^{m \times n}$  bi radi izračunali singularni razcep  $A = U\Sigma V^T$ .

Ker velja

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

dobimo preprosto idejo:

- 1) izračunamo  $A^T A$ ,

Za matriko  $A \in \mathbb{R}^{m \times n}$  bi radi izračunali singularni razcep  $A = U\Sigma V^T$ .

Ker velja

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

dobimo preprosto idejo:

- 1) izračunamo  $A^T A$ ,
- 2) rešimo lastni problem  $A^T A = V \Lambda V^T$ , odtod dobimo  $V$ ,

Za matriko  $A \in \mathbb{R}^{m \times n}$  bi radi izračunali singularni razcep  $A = U\Sigma V^T$ .

Ker velja

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

dobimo preprosto idejo:

- 1) izračunamo  $A^T A$ ,
- 2) rešimo lastni problem  $A^T A = V \Lambda V^T$ , odtod dobimo  $V$ ,
- 3) za  $\Sigma$  vzamemo  $m \times n$  matriko, ki ima v zgornjem bloku kvadratni koren  $\Lambda$ ,

Za matriko  $A \in \mathbb{R}^{m \times n}$  bi radi izračunali singularni razcep  $A = U\Sigma V^T$ .

Ker velja

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

dobimo preprosto idejo:

- 1) izračunamo  $A^T A$ ,
- 2) rešimo lastni problem  $A^T A = V \Lambda V^T$ , odtod dobimo  $V$ ,
- 3) za  $\Sigma$  vzamemo  $m \times n$  matriko, ki ima v zgornjem bloku kvadratni koren  $\Lambda$ ,
- 4) rešimo sistem  $U \Sigma = AV$  za matriko  $U$ .

# Računanje preko $A^T A$ ni numerično stabilno

Če vzamemo  $A = \begin{bmatrix} 1 & 1 \\ 0 & 10^{-8} \end{bmatrix}$ , potem je  $A^T A = \begin{bmatrix} 1 & 1 \\ 1 & 1 + 10^{-16} \end{bmatrix}$ , kar se v dvojni natančnosti zaokroži v  $\begin{bmatrix} 1 & 1 \\ 1 & 1 \end{bmatrix}$ .

# Računanje preko $A^T A$ ni numerično stabilno

Če vzamemo  $A = \begin{bmatrix} 1 & 1 \\ 0 & 10^{-8} \end{bmatrix}$ , potem je  $A^T A = \begin{bmatrix} 1 & 1 \\ 1 & 1 + 10^{-16} \end{bmatrix}$ , kar se v dvojni natančnosti zaokroži v  $\begin{bmatrix} 1 & 1 \\ 1 & 1 \end{bmatrix}$ . Numerično izračunani singularni vrednosti sta

$$\begin{aligned}\hat{\sigma}_1 &= \sqrt{2} \\ \hat{\sigma}_2 &= 0,\end{aligned}$$

točni pa

$$\begin{aligned}\sigma_1 &= \sqrt{2} - 2.22 \cdot 10^{-16} \\ \sigma_2 &= 7.07 \cdot 10^{-9}.\end{aligned}$$

Pri majhnih singularnih vrednostih lahko torej pride do velike relativne napake.



# Računanje preko $A^T A$ ni numerično stabilno

Če vzamemo  $A = \begin{bmatrix} 1 & 1 \\ 0 & 10^{-8} \end{bmatrix}$ , potem je  $A^T A = \begin{bmatrix} 1 & 1 \\ 1 & 1 + 10^{-16} \end{bmatrix}$ , kar se v dvojni natančnosti zaokroži v  $\begin{bmatrix} 1 & 1 \\ 1 & 1 \end{bmatrix}$ . Numerično izračunani singularni vrednosti sta

$$\begin{aligned}\hat{\sigma}_1 &= \sqrt{2} \\ \hat{\sigma}_2 &= 0,\end{aligned}$$

točni pa

$$\begin{aligned}\sigma_1 &= \sqrt{2} - 2.22 \cdot 10^{-16} \\ \sigma_2 &= 7.07 \cdot 10^{-9}.\end{aligned}$$

Pri majhnih singularnih vrednostih lahko torej pride do velike relativne napake.

Računanje preko **eksplicitno izračunane** matrike  $A^T A$  ni numerično stabilno.

# Povezave z lastnimi vrednostmi

Vemo, da so lastne vrednosti  $A^T A$  enake  $\sigma_1^2, \dots, \sigma_n^2$ .

## Lema

Naj bo  $A$  matrika  $m \times n$ ,  $m \geq n$ , s singularnimi vrednostmi in vektorji  $Av_i = \sigma_i u_i$ ,  $i = 1, \dots, n$ . Lastne vrednosti matrike

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

so  $\pm\sigma_i$  in  $m - n$  ničel, ustrezní lastni vektorji pa so  $\frac{1}{\sqrt{2}} \begin{bmatrix} v_i \\ \pm u_i \end{bmatrix}$  za  $i = 1, \dots, n$  in

$\begin{bmatrix} 0 \\ u_k \end{bmatrix}$  za  $k = n + 1, \dots, m$ .

# Posplošitev minimaks izreka in teorija motenj

Iz povezav med singularnim razcepom  $A$  in lastnim razcepom  $A^T A$  oz.  $\begin{bmatrix} 0 & A^T \\ A & 0 \end{bmatrix}$  sledijo naslednje lastnosti.

## Izrek

Naj bo  $A$  realna matrika  $m \times n$ , kjer je  $m \geq n$ . Za  $k = 1, \dots, n$  velja

$$\sigma_k = \max_{\substack{\dim(S)=k \\ \dim(T)=k}} \min_{\substack{0 \neq x \in S \\ 0 \neq y \in T}} \frac{y^T A x}{\|x\|_2 \|y\|_2} = \max_{\dim(S)=k} \min_{0 \neq x \in S} \frac{\|Ax\|_2}{\|x\|_2}.$$

## Posledica

Za singularne vrednosti  $A + E$  za  $k = 1, \dots, n$  velja

$$|\sigma_k(A + E) - \sigma_k(A)| \leq \|E\|_2.$$

# Računanje preko $A^T A$ ni obratno stabilno

Od obratno stabilnega algoritma za singularne vrednosti  $A$  pričakujemo, da bo za izračunane približke veljalo  $\tilde{\sigma}_k = \sigma_k(A + E)$ , kjer je  $\|E\| = \mathcal{O}(u\|A\|)$ , saj potem sledi  $|\tilde{\sigma}_k - \sigma_k| = \mathcal{O}(u\|A\|)$ .

# Računanje preko $A^T A$ ni obratno stabilno

Od obratno stabilnega algoritma za singularne vrednosti  $A$  pričakujemo, da bo za izračunane približke veljalo  $\tilde{\sigma}_k = \sigma_k(A + E)$ , kjer je  $\|E\| = \mathcal{O}(u\|A\|)$ , saj potem sledi  $|\tilde{\sigma}_k - \sigma_k| = \mathcal{O}(u\|A\|)$ .

Če računamo preko  $A^T A$  z obratno stabilnim algoritmom za računanje lastnih vrednosti simetrične matrike, potem velja

$$|\tilde{\sigma}_k^2 - \sigma_k^2| = \mathcal{O}(u\|A^T A\|) = \mathcal{O}(u\|A\|^2).$$

# Računanje preko $A^T A$ ni obratno stabilno

Od obratno stabilnega algoritma za singularne vrednosti  $A$  pričakujemo, da bo za izračunane približke veljalo  $\tilde{\sigma}_k = \sigma_k(A + E)$ , kjer je  $\|E\| = \mathcal{O}(u\|A\|)$ , saj potem sledi  $|\tilde{\sigma}_k - \sigma_k| = \mathcal{O}(u\|A\|)$ .

Če računamo preko  $A^T A$  z obratno stabilnim algoritmom za računanje lastnih vrednosti simetrične matrike, potem velja

$$|\tilde{\sigma}_k^2 - \sigma_k^2| = \mathcal{O}(u\|A^T A\|) = \mathcal{O}(u\|A\|^2).$$

Po korenjenju dobimo

$$|\tilde{\sigma}_k - \sigma_k| = \mathcal{O}\left(u\|A\|^2 \frac{1}{\sigma_k}\right).$$

# Računanje preko $A^T A$ ni obratno stabilno

Od obratno stabilnega algoritma za singularne vrednosti  $A$  pričakujemo, da bo za izračunane približke veljalo  $\tilde{\sigma}_k = \sigma_k(A + E)$ , kjer je  $\|E\| = \mathcal{O}(u\|A\|)$ , saj potem sledi  $|\tilde{\sigma}_k - \sigma_k| = \mathcal{O}(u\|A\|)$ .

Če računamo preko  $A^T A$  z obratno stabilnim algoritmom za računanje lastnih vrednosti simetrične matrike, potem velja

$$|\tilde{\sigma}_k^2 - \sigma_k^2| = \mathcal{O}(u\|A^T A\|) = \mathcal{O}(u\|A\|^2).$$

Po korenjenju dobimo

$$|\tilde{\sigma}_k - \sigma_k| = \mathcal{O}\left(u\|A\|^2 \frac{1}{\sigma_k}\right).$$

Za večje singularne vrednosti je to v redu, za manjše pa ne. Tako lahko pri  $\sigma_n$  pričakujemo napako velikosti  $\mathcal{O}(u\|A\|\kappa_2(A))$ .

# Redukcija na bidiagonalno obliko

Pri računanju SVD za  $A$  (razen pri Jacobijevi metodi) matriko najprej reduciramo na bidiagonalno obliko. Postopek je:

- 1) poišči ortogonalni matriki  $U_1, V_1$ , da bo  $A = U_1 B V_1^T$  in  $B$  bidiagonalna,
- 2) izračunaj SVD za  $B$ :  $B = U_2 \Sigma V_2^T$ ,
- 3) SVD razcep za  $A$  je  $A = (U_1 U_2) \Sigma (V_1 V_2)^T$ .



# Redukcija na bidiagonalno obliko

Pri računanju SVD za  $A$  (razen pri Jacobijevi metodi) matriko najprej reduciramo na bidiagonalno obliko. Postopek je:

- 1) poišči ortogonalni matriki  $U_1, V_1$ , da bo  $A = U_1 B V_1^T$  in  $B$  bidiagonalna,
- 2) izračunaj SVD za  $B$ :  $B = U_2 \Sigma V_2^T$ ,
- 3) SVD razcep za  $A$  je  $A = (U_1 U_2) \Sigma (V_1 V_2)^T$ .

Redukcijo na bidiagonalno obliko izvedemo s Householderjevimi zrcaljenji:

$$A = \begin{bmatrix} \times & \times & \times & \times \\ \times & \times & \times & \times \\ \times & \times & \times & \times \\ \times & \times & \times & \times \\ \times & \times & \times & \times \\ \times & \times & \times & \times \end{bmatrix}$$

# Redukcija na bidiagonalno obliko

Pri računanju SVD za  $A$  (razen pri Jacobijevi metodi) matriko najprej reduciramo na bidiagonalno obliko. Postopek je:

- 1) poišči ortogonalni matriki  $U_1, V_1$ , da bo  $A = U_1 B V_1^T$  in  $B$  bidiagonalna,
- 2) izračunaj SVD za  $B$ :  $B = U_2 \Sigma V_2^T$ ,
- 3) SVD razcep za  $A$  je  $A = (U_1 U_2) \Sigma (V_1 V_2)^T$ .

Redukcijo na bidiagonalno obliko izvedemo s Householderjevimi zrcaljenji:

$$P_1 A = \begin{bmatrix} \times & \times & \times & \times \\ 0 & \times & \times & \times \\ 0 & \times & \times & \times \\ 0 & \times & \times & \times \\ 0 & \times & \times & \times \\ 0 & \times & \times & \times \end{bmatrix}$$

# Redukcija na bidiagonalno obliko

Pri računanju SVD za  $A$  (razen pri Jacobijevi metodi) matriko najprej reduciramo na bidiagonalno obliko. Postopek je:

- 1) poišči ortogonalni matriki  $U_1, V_1$ , da bo  $A = U_1 B V_1^T$  in  $B$  bidiagonalna,
- 2) izračunaj SVD za  $B$ :  $B = U_2 \Sigma V_2^T$ ,
- 3) SVD razcep za  $A$  je  $A = (U_1 U_2) \Sigma (V_1 V_2)^T$ .

Redukcijo na bidiagonalno obliko izvedemo s Householderjevimi zrcaljenji:

$$P_1 A \tilde{P}_1 = \begin{bmatrix} \times & \times & 0 & 0 \\ 0 & \times & \times & \times \\ 0 & \times & \times & \times \\ 0 & \times & \times & \times \\ 0 & \times & \times & \times \\ 0 & \times & \times & \times \end{bmatrix}$$

# Redukcija na bidiagonalno obliko

Pri računanju SVD za  $A$  (razen pri Jacobijevi metodi) matriko najprej reduciramo na bidiagonalno obliko. Postopek je:

- 1) poišči ortogonalni matriki  $U_1, V_1$ , da bo  $A = U_1 B V_1^T$  in  $B$  bidiagonalna,
- 2) izračunaj SVD za  $B$ :  $B = U_2 \Sigma V_2^T$ ,
- 3) SVD razcep za  $A$  je  $A = (U_1 U_2) \Sigma (V_1 V_2)^T$ .

Redukcijo na bidiagonalno obliko izvedemo s Householderjevimi zrcaljenji:

$$P_2 P_1 A \tilde{P}_1 = \begin{bmatrix} \times & \times & 0 & 0 \\ 0 & \times & \times & \times \\ 0 & 0 & \times & \times \\ 0 & 0 & \times & \times \\ 0 & 0 & \times & \times \\ 0 & 0 & \times & \times \end{bmatrix}$$

# Redukcija na bidiagonalno obliko

Pri računanju SVD za  $A$  (razen pri Jacobijevi metodi) matriko najprej reduciramo na bidiagonalno obliko. Postopek je:

- 1) poišči ortogonalni matriki  $U_1, V_1$ , da bo  $A = U_1 B V_1^T$  in  $B$  bidiagonalna,
- 2) izračunaj SVD za  $B$ :  $B = U_2 \Sigma V_2^T$ ,
- 3) SVD razcep za  $A$  je  $A = (U_1 U_2) \Sigma (V_1 V_2)^T$ .

Redukcijo na bidiagonalno obliko izvedemo s Householderjevimi zrcaljenji:

$$P_2 P_1 A \tilde{P}_1 \tilde{P}_1 = \begin{bmatrix} \times & \times & 0 & 0 \\ 0 & \times & \times & 0 \\ 0 & 0 & \times & \times \\ 0 & 0 & \times & \times \\ 0 & 0 & \times & \times \\ 0 & 0 & \times & \times \end{bmatrix}$$

# Redukcija na bidiagonalno obliko

Pri računanju SVD za  $A$  (razen pri Jacobijevi metodi) matriko najprej reduciramo na bidiagonalno obliko. Postopek je:

- 1) poišči ortogonalni matriki  $U_1, V_1$ , da bo  $A = U_1 B V_1^T$  in  $B$  bidiagonalna,
- 2) izračunaj SVD za  $B$ :  $B = U_2 \Sigma V_2^T$ ,
- 3) SVD razcep za  $A$  je  $A = (U_1 U_2) \Sigma (V_1 V_2)^T$ .

Redukcijo na bidiagonalno obliko izvedemo s Householderjevimi zrcaljenji:

$$P_3 P_2 P_1 A \tilde{P}_1 \tilde{P}_1 = \begin{bmatrix} \times & \times & 0 & 0 \\ 0 & \times & \times & 0 \\ 0 & 0 & \times & \times \\ 0 & 0 & 0 & \times \\ 0 & 0 & 0 & \times \\ 0 & 0 & 0 & \times \end{bmatrix}$$

# Redukcija na bidiagonalno obliko

Pri računanju SVD za  $A$  (razen pri Jacobijevi metodi) matriko najprej reduciramo na bidiagonalno obliko. Postopek je:

- 1) poišči ortogonalni matriki  $U_1, V_1$ , da bo  $A = U_1 B V_1^T$  in  $B$  bidiagonalna,
- 2) izračunaj SVD za  $B$ :  $B = U_2 \Sigma V_2^T$ ,
- 3) SVD razcep za  $A$  je  $A = (U_1 U_2) \Sigma (V_1 V_2)^T$ .

Redukcijo na bidiagonalno obliko izvedemo s Householderjevimi zrcaljenji:

$$P_4 P_3 P_2 P_1 A \tilde{P}_1 \tilde{P}_1 = \begin{bmatrix} \times & \times & 0 & 0 \\ 0 & \times & \times & 0 \\ 0 & 0 & \times & \times \\ 0 & 0 & 0 & \times \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix}$$

# Redukcija na bidiagonalno obliko

Pri računanju SVD za  $A$  (razen pri Jacobijevi metodi) matriko najprej reduciramo na bidiagonalno obliko. Postopek je:

- 1) poišči ortogonalni matriki  $U_1, V_1$ , da bo  $A = U_1 B V_1^T$  in  $B$  bidiagonalna,
- 2) izračunaj SVD za  $B$ :  $B = U_2 \Sigma V_2^T$ ,
- 3) SVD razcep za  $A$  je  $A = (U_1 U_2) \Sigma (V_1 V_2)^T$ .

Redukcijo na bidiagonalno obliko izvedemo s Householderjevimi zrcaljenji:

$$P_4 P_3 P_2 P_1 A \tilde{P}_1 \tilde{P}_1 = \begin{bmatrix} \times & \times & 0 & 0 \\ 0 & \times & \times & 0 \\ 0 & 0 & \times & \times \\ 0 & 0 & 0 & \times \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix} = B$$



# Redukcija na bidiagonalno obliko

Pri računanju SVD za  $A$  (razen pri Jacobijevi metodi) matriko najprej reduciramo na bidiagonalno obliko. Postopek je:

- 1) poišči ortogonalni matriki  $U_1, V_1$ , da bo  $A = U_1 B V_1^T$  in  $B$  bidiagonalna,
- 2) izračunaj SVD za  $B$ :  $B = U_2 \Sigma V_2^T$ ,
- 3) SVD razcep za  $A$  je  $A = (U_1 U_2) \Sigma (V_1 V_2)^T$ .

Redukcijo na bidiagonalno obliko izvedemo s Householderjevimi zrcaljenji:

$$P_4 P_3 P_2 P_1 A \tilde{P}_1 \tilde{P}_1 = \begin{bmatrix} \times & \times & 0 & 0 \\ 0 & \times & \times & 0 \\ 0 & 0 & \times & \times \\ 0 & 0 & 0 & \times \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix} = B$$

V nadaljevanju potrebujemo le zgornji kvadratni del matrike  $B$ , zato lahko predpostavimo, da je  $B$  kvadratna.

# Ekonomična redukcija

Za redukcijo s Householderjevimi zrcaljenji potrebujemo  $8mn^2 - 8n^3/3$  operacij.

Če je  $m \gg n$ , se splača najprej narediti QR razcep matrike  $A$ , kjer dobimo  $m \times m$  ortogonalno matriko  $Q$  in  $n \times n$  zgornjo trikotno matriko  $R_1$ , da je

$$Q^T A = \begin{bmatrix} R_1 \\ 0 \end{bmatrix},$$

Sedaj bidiagonaliziramo  $R_1$ , da dobimo

$$U_R^T R_1 V = B_1,$$

kjer je  $B_1$  bidiagonalna  $n \times n$  matrika. Na koncu dobimo

$$\begin{bmatrix} U_R^T & 0 \\ 0 & I \end{bmatrix} Q^T A V = \begin{bmatrix} B_1 \\ 0 \end{bmatrix} = B.$$

Za to redukcijo potrebujemo  $4mn^2 + 4n^3$  operacij, torej je cenejša, če je  $m \geq 5n/3$ .

# Prevedba na tridiagonalni simetrični lastni problem

Naj bo

$$B = \begin{bmatrix} a_1 & b_1 & & & \\ & \ddots & \ddots & & \\ & & a_{n-1} & b_{n-1} & \\ & & & & a_n \end{bmatrix}.$$

Potem je

$$B^T B = \begin{bmatrix} a_1^2 & a_1 b_1 & & & \\ a_1 b_1 & a_2^2 + b_1^2 & \ddots & & \\ & \ddots & \ddots & \ddots & \\ & & \ddots & \ddots & a_{n-1} b_{n-1} \\ & & & a_{n-1} b_{n-1} & a_n^2 + b_{n-1}^2 \end{bmatrix}$$

simetrična tridiagonalna matrika. Podobno velja za  $BB^T$ .

# Prevedba na tridiagonalni simetrični lastni problem

Naj bo

$$B = \begin{bmatrix} a_1 & b_1 & & & \\ & \ddots & \ddots & & \\ & & \ddots & \ddots & \\ & & & \ddots & b_{n-1} \\ & & & & a_n \end{bmatrix}, \quad C = \begin{bmatrix} 0 & B^T \\ B & 0 \end{bmatrix}.$$

Če vzamemo permutacijsko matriko

$$P = [e_1 \quad e_{n+1} \quad e_2 \quad e_{n+2} \quad \cdots \quad e_n \quad e_{2n}],$$

ki predstavlja t.i. **perfektno mešanje**, potem ima  $P^T C P$  obliko

$$\begin{bmatrix} 0 & a_1 & & & & & & & & & \\ a_1 & 0 & b_1 & & & & & & & & \\ & b_1 & 0 & a_2 & & & & & & & \\ & & a_2 & 0 & \ddots & & & & & & \\ & & & \ddots & \ddots & \ddots & & & & & \\ & & & & \ddots & \ddots & b_{n-1} & & & & \\ & & & & & b_{n-1} & 0 & a_n & & & \\ & & & & & & a_n & 0 & & & \end{bmatrix}.$$

$$P^T \begin{bmatrix} 0 & B^T \\ B & 0 \end{bmatrix} P = \begin{bmatrix} 0 & a_1 & & & & & & & \\ a_1 & 0 & b_1 & & & & & & \\ & b_1 & 0 & \ddots & & & & & \\ & & \ddots & \ddots & b_{n-1} & & & & \\ & & & & b_{n-1} & 0 & a_n & & \\ & & & & & a_n & 0 & & \end{bmatrix} .$$

V primeru, ko je  $a_i = 0$  ali  $b_i = 0$ , lahko naredimo deflacijo, zato lahko predpostavimo, da so vsi diagonalni in bidiagonalni elementi neničelni.

## Posledica

Če za matriko  $B$  velja  $a_i \neq 0$  za  $i = 1, \dots, n$  in  $b_i \neq 0$  za  $i = 1, \dots, n - 1$ , potem ima  $B$  same enostavne singularne vrednosti.

Naj bo

$$B = \begin{bmatrix} a_1 & b_1 & & & \\ & \ddots & \ddots & & \\ & & \ddots & \ddots & \\ & & & \ddots & b_{n-1} \\ & & & & a_n \end{bmatrix}.$$

Mislimo si, da računamo implicitno QR iteracijo z Wilkinsonovimi premiki za  $B^T B$ , a  $B^T B$  nikoli ne izračunamo eksplicitno.

Naj bo

$$B = \begin{bmatrix} a_1 & b_1 & & & \\ & \ddots & \ddots & & \\ & & \ddots & \ddots & \\ & & & \ddots & b_{n-1} \\ & & & & a_n \end{bmatrix}.$$

Mislimo si, da računamo implicitno QR iteracijo z Wilkinsonovimi premiki za  $B^T B$ , a  $B^T B$  nikoli ne izračunamo eksplicitno.

Za Wilkinsonov premik potrebujemo lastne vrednosti desne spodnje  $2 \times 2$  podmatrike  $B^T B$

$$\begin{bmatrix} a_{n-1}^2 + b_{n-2}^2 & a_{n-1}b_{n-1} \\ a_{n-1}b_{n-1} & a_n^2 + b_{n-1}^2 \end{bmatrix},$$

za premik  $\sigma^2$  pa vzamemo tisto lastno vrednost, ki je bližja  $a_n^2 + b_{n-1}^2$ .

# Premikanje grbe

Določimo Givensovo rotacijo  $R = \begin{bmatrix} c & -s \\ s & c \end{bmatrix}$ , da bo (glede na prvi stolpec  $B^T B$ )  
 $R \begin{bmatrix} a_1^2 - \sigma^2 \\ a_1 b_2 \end{bmatrix} = \begin{bmatrix} \times \\ 0 \end{bmatrix}$  in vzamemo  $R'_{12} = \begin{bmatrix} R & 0 \\ 0 & I \end{bmatrix}$ .



# Premikanje grbe

Določimo Givensovo rotacijo  $R = \begin{bmatrix} c & -s \\ s & c \end{bmatrix}$ , da bo (glede na prvi stolpec  $B^T B$ )  
 $R \begin{bmatrix} a_1^2 - \sigma^2 \\ a_1 b_2 \end{bmatrix} = \begin{bmatrix} \times \\ 0 \end{bmatrix}$  in vzamemo  $R'_{12} = \begin{bmatrix} R & 0 \\ 0 & I \end{bmatrix}$ .

Poglejmo zgled premikanja grbe na primeru matrike  $5 \times 5$ .

$$B = \begin{bmatrix} \times & \times & & & \\ & \times & \times & & \\ & & \times & \times & \\ & & & \times & \times \\ & & & & \times \end{bmatrix} .$$

# Premikanje grbe

Določimo Givensovo rotacijo  $R = \begin{bmatrix} c & -s \\ s & c \end{bmatrix}$ , da bo (glede na prvi stolpec  $B^T B$ )  
 $R \begin{bmatrix} a_1^2 - \sigma^2 \\ a_1 b_2 \end{bmatrix} = \begin{bmatrix} \times \\ 0 \end{bmatrix}$  in vzamemo  $R'_{12} = \begin{bmatrix} R & 0 \\ 0 & I \end{bmatrix}$ .

Poglejmo zgled premikanja grbe na primeru matrike  $5 \times 5$ .

$$BR'_{12} = \begin{bmatrix} \times & \times & & & \\ + & \times & \times & & \\ & & \times & \times & \\ & & & \times & \times \\ & & & & \times \end{bmatrix} .$$

# Premikanje grbe

Določimo Givensovo rotacijo  $R = \begin{bmatrix} c & -s \\ s & c \end{bmatrix}$ , da bo (glede na prvi stolpec  $B^T B$ )  
 $R \begin{bmatrix} a_1^2 - \sigma^2 \\ a_1 b_2 \end{bmatrix} = \begin{bmatrix} \times \\ 0 \end{bmatrix}$  in vzamemo  $R'_{12} = \begin{bmatrix} R & 0 \\ 0 & I \end{bmatrix}$ .

Poglejmo zgled premikanja grbe na primeru matrike  $5 \times 5$ .

$$R_{12} B R'_{12} = \begin{bmatrix} \times & \times & + & & \\ & \times & \times & & \\ & & \times & \times & \\ & & & \times & \times \\ & & & & \times \end{bmatrix} .$$

# Premikanje grbe

Določimo Givensovo rotacijo  $R = \begin{bmatrix} c & -s \\ s & c \end{bmatrix}$ , da bo (glede na prvi stolpec  $B^T B$ )  
 $R \begin{bmatrix} a_1^2 - \sigma^2 \\ a_1 b_2 \end{bmatrix} = \begin{bmatrix} \times \\ 0 \end{bmatrix}$  in vzamemo  $R'_{12} = \begin{bmatrix} R & 0 \\ 0 & I \end{bmatrix}$ .

Poglejmo zgled premikanja grbe na primeru matrike  $5 \times 5$ .

$$R_{12} B R'_{12} R'_{23} = \begin{bmatrix} \times & \times & & & \\ & \times & \times & & \\ & + & \times & \times & \\ & & & \times & \times \\ & & & & \times \end{bmatrix} .$$

# Premikanje grbe

Določimo Givensovo rotacijo  $R = \begin{bmatrix} c & -s \\ s & c \end{bmatrix}$ , da bo (glede na prvi stolpec  $B^T B$ )  
 $R \begin{bmatrix} a_1^2 - \sigma^2 \\ a_1 b_2 \end{bmatrix} = \begin{bmatrix} \times \\ 0 \end{bmatrix}$  in vzamemo  $R'_{12} = \begin{bmatrix} R & 0 \\ 0 & I \end{bmatrix}$ .

Poglejmo zgled premikanja grbe na primeru matrike  $5 \times 5$ .

$$R_{23} R_{12} B R'_{12} R'_{23} = \begin{bmatrix} \times & \times & & & \\ & \times & \times & + & \\ & & \times & \times & \\ & & & \times & \times \\ & & & & \times \end{bmatrix} .$$

# Premikanje grbe

Določimo Givensovo rotacijo  $R = \begin{bmatrix} c & -s \\ s & c \end{bmatrix}$ , da bo (glede na prvi stolpec  $B^T B$ )  
 $R \begin{bmatrix} a_1^2 - \sigma^2 \\ a_1 b_2 \end{bmatrix} = \begin{bmatrix} \times \\ 0 \end{bmatrix}$  in vzamemo  $R'_{12} = \begin{bmatrix} R & 0 \\ 0 & I \end{bmatrix}$ .

Poglejmo zgled premikanja grbe na primeru matrike  $5 \times 5$ .

$$R_{23} R_{12} B R'_{12} R'_{23} R'_{34} = \begin{bmatrix} \times & \times & & & \\ & \times & \times & & \\ & & \times & \times & \\ & & + & \times & \times \\ & & & & \times \end{bmatrix} .$$

# Premikanje grbe

Določimo Givensovo rotacijo  $R = \begin{bmatrix} c & -s \\ s & c \end{bmatrix}$ , da bo (glede na prvi stolpec  $B^T B$ )  
 $R \begin{bmatrix} a_1^2 - \sigma^2 \\ a_1 b_2 \end{bmatrix} = \begin{bmatrix} \times \\ 0 \end{bmatrix}$  in vzamemo  $R'_{12} = \begin{bmatrix} R & 0 \\ 0 & I \end{bmatrix}$ .

Poglejmo zgled premikanja grbe na primeru matrike  $5 \times 5$ .

$$R_{34} R_{23} R_{12} B R'_{12} R'_{23} R'_{34} = \begin{bmatrix} \times & \times & & & \\ & \times & \times & & \\ & & \times & \times & + \\ & & & \times & \times \\ & & & & \times \end{bmatrix} .$$

# Premikanje grbe

Določimo Givensovo rotacijo  $R = \begin{bmatrix} c & -s \\ s & c \end{bmatrix}$ , da bo (glede na prvi stolpec  $B^T B$ )  
 $R \begin{bmatrix} a_1^2 - \sigma^2 \\ a_1 b_2 \end{bmatrix} = \begin{bmatrix} \times \\ 0 \end{bmatrix}$  in vzamemo  $R'_{12} = \begin{bmatrix} R & 0 \\ 0 & I \end{bmatrix}$ .

Poglejmo zgled premikanja grbe na primeru matrike  $5 \times 5$ .

$$R_{34} R_{23} R_{12} B R'_{12} R'_{23} R'_{34} R'_{45} = \begin{bmatrix} \times & \times & & & \\ & \times & \times & & \\ & & \times & \times & \\ & & & \times & \times \\ & & & + & \times \end{bmatrix} .$$



# Premikanje grbe

Določimo Givensovo rotacijo  $R = \begin{bmatrix} c & -s \\ s & c \end{bmatrix}$ , da bo (glede na prvi stolpec  $B^T B$ )  
 $R \begin{bmatrix} a_1^2 - \sigma^2 \\ a_1 b_2 \end{bmatrix} = \begin{bmatrix} \times \\ 0 \end{bmatrix}$  in vzamemo  $R'_{12} = \begin{bmatrix} R & 0 \\ 0 & I \end{bmatrix}$ .

Poglejmo zgled premikanja grbe na primeru matrike  $5 \times 5$ .

$$R_{45} R_{34} R_{23} R_{12} B R'_{12} R'_{23} R'_{34} R'_{45} = \begin{bmatrix} \times & \times & & & \\ & \times & \times & & \\ & & \times & \times & \\ & & & \times & \times \\ & & & & \times \end{bmatrix} = \tilde{B}.$$

# Premikanje grbe

Določimo Givensovo rotacijo  $R = \begin{bmatrix} c & -s \\ s & c \end{bmatrix}$ , da bo (glede na prvi stolpec  $B^T B$ )  
 $R \begin{bmatrix} a_1^2 - \sigma^2 \\ a_1 b_2 \end{bmatrix} = \begin{bmatrix} \times \\ 0 \end{bmatrix}$  in vzamemo  $R'_{12} = \begin{bmatrix} R & 0 \\ 0 & I \end{bmatrix}$ .

Poglejmo zgled premikanja grbe na primeru matrike  $5 \times 5$ .

$$R_{45} R_{34} R_{23} R_{12} B R'_{12} R'_{23} R'_{34} R'_{45} = \begin{bmatrix} \times & \times & & & \\ & \times & \times & & \\ & & \times & \times & \\ & & & \times & \times \\ & & & & \times \end{bmatrix} = \tilde{B}.$$

Za en korak enostranske  $QR$  iteracije porabimo  $30n + \mathcal{O}(1)$  osnovnih operacij in  $2n$  kvadratnih korenov.

Kriterija za deflacijo sta  $|b_i| \leq \epsilon(|a_i| + |a_{i+1}|)$  in  $|a_i| \leq \epsilon \|B\|$ .

## LR algoritem ( $T$ simetrična pozitivno definitna)

$$T_0 = T$$

$i = 0, 1, 2, \dots:$

$$T_i = V_i^T V_i \text{ (razcep Choleskega)}$$

$$T_{i+1} = V_i V_i^T$$

## LR algoritem ( $T$ simetrična pozitivno definitna)

$$T_0 = T$$

$$i = 0, 1, 2, \dots:$$

$$T_i = V_i^T V_i \text{ (razcep Choleskega)}$$

$$T_{i+1} = V_i V_i^T$$

$T_i$  konvergira proti diagonalni matriki lastnih vrednosti matrike  $T$ . Matriki  $T_i$  in  $T_{i+1}$  sta podobni, saj velja

$$T_{i+1} = V_i V_i^T = V_i V_i^T V_i V_i^{-1} = V_i T_i V_i^{-1}.$$

Če je  $T$  tridiagonalna, se tridiagonalnost med algoritmom ohranja.

## LR algoritem ( $T$ simetrična pozitivno definitna)

$$T_0 = T$$

$$i = 0, 1, 2, \dots:$$

$$T_i = V_i^T V_i \text{ (razcep Choleskega)}$$

$$T_{i+1} = V_i V_i^T$$

$T_i$  konvergira proti diagonalni matriki lastnih vrednosti matrike  $T$ . Matriki  $T_i$  in  $T_{i+1}$  sta podobni, saj velja

$$T_{i+1} = V_i V_i^T = V_i V_i^T V_i V_i^{-1} = V_i T_i V_i^{-1}.$$

Če je  $T$  tridiagonalna, se tridiagonalnost med algoritmom ohranja.

Stabilnost in konvergenco zagotavlja naslednji izrek.

## Lema

*Dva koraka LR algoritma ustrezata enemu koraku QR algoritma brez premikov.*

Namesto enega koraka QR metode lahko naredimo dva koraka LR metode. Konvergenco pospešimo s premiki, paziti pa moramo na pozitivno definitnost.

## LR algoritem s premiki

$$T_0 = T$$

$i = 0, 1, 2, \dots$ :

izberi premik  $\tau_i^2 > 0$ , tako da je  $\tau_i^2 \leq \lambda_n(T)$

$$T_i - \tau_i^2 I = V_i^T V_i \quad (\text{razcep Choleskega})$$

$$T_{i+1} = V_i V_i^T + \tau_i^2 I$$

Matriki  $T_{i+1}$  in  $T_i$  sta podobni, saj velja

$$T_{i+1} = V_i V_i^T + \tau_i^2 I = V_i^{-T} V_i^T (V_i V_i^T + \tau_i^2 I) = V_i^{-T} T_i V_i^T.$$

Namesto enega koraka QR metode lahko naredimo dva koraka LR metode. Konvergenco pospešimo s premiki, paziti pa moramo na pozitivno definitnost.

## LR algoritem s premiki

$$T_0 = T$$

$i = 0, 1, 2, \dots$ :

izberi premik  $\tau_i^2 > 0$ , tako da je  $\tau_i^2 \leq \lambda_n(T)$

$$T_i - \tau_i^2 I = V_i^T V_i \quad (\text{razcep Choleskega})$$

$$T_{i+1} = V_i V_i^T + \tau_i^2 I$$

Matriki  $T_{i+1}$  in  $T_i$  sta podobni, saj velja

$$T_{i+1} = V_i V_i^T + \tau_i^2 I = V_i^{-T} V_i^T (V_i V_i^T + \tau_i^2 I) = V_i^{-T} T_i V_i^T.$$

Pri **dqds metodi** delamo LR metodo s premiki za  $B^T B$  a te matrike ne računamo eksplicitno. Iz bidiagonalne matrike  $B_i$  dobimo bidiagonalno  $B_{i+1}$ , pri tem pa velja, da če bi naredili LR s premikom za  $B_i^T B_i$ , bi dobili  $B_{i+1}^T B_{i+1}$ .

# Osnovna ideja dqds metode

$$B_i = \begin{bmatrix} a_1 & b_1 & & & \\ & \ddots & \ddots & & \\ & & & a_{n-1} & b_{n-1} \\ & & & & a_n \end{bmatrix} \quad \text{in} \quad B_{i+1} = \begin{bmatrix} \tilde{a}_1 & \tilde{b}_1 & & & \\ & \ddots & \ddots & & \\ & & & \tilde{a}_{n-1} & \tilde{b}_{n-1} \\ & & & & \tilde{a}_n \end{bmatrix}.$$

S primerjavo  $T_i = B_i^T B_i + \tau_i^2 I$  in  $T_{i+1} = B_{i+1}^T B_{i+1} + \tau_{i+1}^2 I = B_i B_i^T + \tau_i^2 I$  pridemo do osnovnega algoritma, kjer je  $\delta = \tau_{i+1}^2 - \tau_i^2 \geq 0$  in privzamemo  $b_0 = \tilde{b}_0 = 0$ .

## Osnovni algoritem

$$\begin{aligned} k &= 1, \dots, n-1 \\ \tilde{a}_k^2 &= a_k^2 + b_k^2 - \tilde{b}_{k-1}^2 - \delta \\ \tilde{b}_k^2 &= a_{k+1}^2 b_k^2 / \tilde{a}_k^2 \\ \tilde{a}_n^2 &= a_n^2 - \tilde{b}_{n-1}^2 - \delta \end{aligned}$$



## Osnovni algoritem

$$\begin{aligned}k &= 1, \dots, n-1 \\ \tilde{a}_k^2 &= a_k^2 + b_k^2 - \tilde{b}_{k-1}^2 - \delta \\ \tilde{b}_k^2 &= a_{k+1}^2 b_k^2 / \tilde{a}_k^2 \\ \tilde{a}_n^2 &= a_n^2 - \tilde{b}_{n-1}^2 - \delta\end{aligned}$$

Ves čas lahko računamo s kvadrati in korenimo le na koncu. Če označimo  $c_k = a_k^2$  in  $d_k = b_k^2$ , dobimo novo različico algoritma:

## qds algoritem

$$\begin{aligned}k &= 1, \dots, n-1 \\ \tilde{c}_k &= c_k + d_k - \tilde{d}_{k-1} - \delta \\ \tilde{d}_k &= c_{k+1} d_k / \tilde{c}_k \\ \tilde{c}_n &= c_n - \tilde{d}_{n-1} - \delta\end{aligned}$$

Novi algoritem porabi le  $5n + \mathcal{O}(1)$  operacij za en korak.

# Končni dqds algoritem

qds

$$k = 1, \dots, n-1$$

$$\tilde{c}_k = c_k + d_k - \tilde{d}_{k-1} - \delta$$

$$\tilde{d}_k = c_{k+1} d_k / \tilde{c}_k$$

$$\tilde{c}_n = c_n - \tilde{d}_{n-1} - \delta$$

dqds

$$g = c_1 - \delta$$

$$k = 1, \dots, n-1$$

$$\tilde{c}_k = g + d_k$$

$$t = c_{k+1} / \tilde{c}_k$$

$$\tilde{d}_k = d_k \cdot t$$

$$g = g \cdot t - \delta$$

$$\tilde{c}_n = g$$

Če definiramo  $g_k = c_k - \tilde{d}_{k-1} - \delta$ , potem velja

$$g_k = c_k - \frac{c_k d_{k-1}}{\tilde{c}_{k-1}} - \delta = c_k \frac{\tilde{c}_{k-1} - d_{k-1}}{\tilde{c}_{k-1}} - \delta = c_k \frac{c_{k-1} - \tilde{d}_{k-2} - \delta}{\tilde{c}_{k-1}} - \delta = \frac{c_k}{\tilde{c}_{k-1}} g_{k-1} - \delta.$$

Nov algoritem ima eno množenje namesto seštevanja. Izkaže se, da nam ravno to zagotavlja visoko obratno stabilnost.

## Izrek

Če je  $B$  bidiagonalna nesingularna matrika s singularnimi vrednostmi  $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_n > 0$ , potem za izračunane singularne vrednosti  $\tilde{\sigma}_1 \geq \dots \geq \tilde{\sigma}_n > 0$  po dqds algoritmu velja (če ne uporabljamo premikov)

$$\frac{|\tilde{\sigma}_i - \sigma_i|}{\sigma_i} \leq (10n - 5)u + O(u^2).$$