

## 2.3 Lanczos

Če je  $A$  simetrična, za generiranje ON baze za  $\mathcal{K}_k(A, r_0)$  uporabimo Lanczosevo metodo.

$$\begin{aligned}v_1 &= r_0 / \|r_0\|, \beta_0 = 0, v_0 = 0 \\j &= 1, 2, \dots, k \\z &= Av_j - \beta_{j-1}v_{j-1} \\ \alpha_j &= v_j^T z \\z &= z - \alpha_j v_j \\ \beta_j &= \|z\| \\ \text{če je } \beta_j &= 0, \text{ prekini računanje} \\v_{j+1} &= z / \beta_j\end{aligned}$$

Dobimo

$$AV_k = V_k T_k + \beta_k v_{k+1} e_k^T,$$

kjer je

$$T_k = \begin{bmatrix} \alpha_1 & \beta_1 & & & \\ \beta_1 & \alpha_2 & \cdots & & \\ & \cdots & \cdots & & \\ & & & \beta_{k-1} & \\ & & & & \alpha_k \end{bmatrix}.$$

Za reševanje sistema  $Ax = b$  uporabimo *Lanczosevo metodo za linearni sistem*.

$$\begin{aligned}r_0 &= b - Ax_0 \\ \text{Lanczos}(A, r_0, k) &\implies AV_k = V_k T_k + \beta_k v_{k+1} e_k^T \\ y_k &= T_k^{-1} \|r_0\| e_1 \\ x_k &= x_0 + V_k y_k\end{aligned}$$

Za ostanek velja  $\|r_k\| = \beta_k |e_k^T y_k|$ .

## D-Lanczos

Podobno kot pri DIOM lahko preko LU razcepa matrike  $T_k$  pridemo do rekurzivnih formul za vektorje  $x_k$  in se tako izognemo temu, da bi morali na koncu za izračun  $x_k = x_0 + V_k y_k$  poznati vse stolpce matrike  $V_k$ .

Ker je  $T_k$  tridiagonalna, ima  $LU$  razcep obliko  $T_k = L_k U_k$ , kjer je

$$T_k = \begin{bmatrix} \alpha_1 & \beta_1 & & & \\ \beta_1 & \alpha_2 & \cdots & & \\ & \cdots & \cdots & \beta_{k-1} & \\ & & \beta_{k-1} & \alpha_k & \end{bmatrix} = \begin{bmatrix} 1 & & & & \\ \lambda_2 & 1 & & & \\ & \cdots & \cdots & & \\ & & \lambda_k & 1 & \end{bmatrix} \begin{bmatrix} \eta_1 & \beta_1 & & & \\ & \eta_2 & \cdots & & \\ & & \cdots & \beta_{k-1} & \\ & & & & \eta_k \end{bmatrix}.$$

Za rešitev  $x_k$  velja  $x_k = x_0 + V_k T_k^{-1} \|r_0\| e_1 = x_0 + V_k U_k^{-1} L_k^{-1} \|r_0\| e_1$ .

Če definiramo  $P_k = V_k U_k^{-1}$  in  $z_k = L_k^{-1} \|r_0\| e_1$ , dobimo  $x_k = x_0 + P_k z_k$ .

Iz  $P_k U_k = V_k$  sledi  $\beta_{k-1} p_{k-1} + \eta_k p_k = v_k$  oziroma  $p_k = \frac{1}{\eta_k} (v_k - \beta_{k-1} p_{k-1})$ .

Vektor  $z_k$  je oblike  $z_k = \begin{bmatrix} z_{k-1} \\ \zeta_k \end{bmatrix}$ , kjer je  $\zeta_k = -\lambda_k \zeta_{k-1}$ .

Ker je  $x_{k-1} = x_0 + P_{k-1} z_{k-1}$  dobimo  $x_k = x_{k-1} + \zeta_k p_k$ .

## D-Lanczos

$$v_1 = r_0 / \|r_0\|, \beta_0 = 0, v_0 = 0$$

$$j = 1, 2, \dots, k$$

$$z = Av_j - \beta_{j-1}v_{j-1}$$

$$\alpha_j = v_j^T z$$

$$z = z - \alpha_j v_j$$

$$\beta_j = \|z\|$$

$$\lambda_j = \beta_{j-1} / \eta_{j-1}, \text{ (na začetku } \lambda_1 = 0)$$

$$\eta_j = \alpha_j - \beta_{j-1} \lambda_j, \text{ če je } \eta_j = 0, \text{ končaj}$$

$$\zeta_j = -\lambda_j \zeta_{j-1} \text{ (na začetku } \zeta_1 = \|r_0\|)$$

$$p_j = (1/\eta_j) (v_j - \beta_{j-1} p_{j-1})$$

$$x_j = x_{j-1} + \zeta_j p_j.$$

če je  $\beta_j = 0$ , prekini računanje

$$v_{j+1} = z / \beta_j$$

Za ostanek  $r_k$ , ki ga dobimo pri uporabi D-Lanczosa, velja

$$\|r_k\| = \beta_k |e_k^T y_k| = \beta_k \frac{|\zeta_k|}{|\eta_k|}.$$

Če LU razcep brez pivotiranja ne obstaja, se algoritem kritično zaustavi pri  $\eta_j = 0$ . Temu se izognemo z varianto, ki uporablja LU razcep z delnim pivotiranjem ali pa QR razcep.

## Konjugirane smeri

**Izrek 1.** Za vektorje, dobljene pri D-Lanczosu, velja:

a) Vektorji  $r_0, r_1, \dots, r_k$  so paroma pravokotni.

b) Smeri  $p_i$  so  $A$ -konjugirane. Velja  $\langle Ap_i, p_j \rangle = 0$  za  $i \neq j$ .

Dokaz: a) Iz zveze  $r_k = -\beta_k e_k^T y_k v_{k+1}$  sledi da sta vektorja  $r_k$  in  $v_{k+1}$  kolinearna. Zato so vektorji  $r_0, r_1, \dots, r_k$  paroma pravokotni (saj to velja za vektorje  $v_1, \dots, v_{k+1}$ ).

b)  $P_k = V_k U_k^{-1}$ . Velja  $P_k^T A P_k = U_k^{-T} V_k^T A V_k U_k^{-1} = U_k^{-1} T_k U_k^{-1} = U_k^{-T} L_k$ .

Matrika  $U_k^{-T} L_k$  je simetrična spodnje trikotna, torej diagonalna, in  $p_j^T A p_i = 0$  za  $i \neq j$ .

Te zveze nam omogočajo, da za simetrične pozitivno definitne matrike pridemo do rekurzij brez eksplicitnega računanja matrik  $T_k$  in  $V_k$ . Pozitivna definitnost nam zagotavlja, da obstaja LU razcep brez pivotiranja.

Tako pridemo do *konjugiranih gradientov*.

## Konjugirani gradienti

Iz D-Lanczosa lahko razberemo:

- 1) Vektorja  $r_{j-1}$  in  $v_j$  sta kolinearna.
- 2) Vektor  $p_j$  dobimo tako, da  $r_{j-1}$  prištejemo vektor v smeri  $p_{j-1}$ .
- 3) Vektor  $x_j$  dobimo tako, da  $x_{j-1}$  prištejemo vektor v smeri  $p_j$ .

Ker dolžina nove smeri  $p_j$  ni pomembna, velja

$$p_j = r_{j-1} + \beta_{j-1}p_{j-1}$$

$$x_j = x_{j-1} + \alpha_j p_j$$

$$r_j = r_{j-1} - \alpha_j A p_j$$

za primerne skalarje  $\alpha_j$ ,  $\beta_j$  (niso enaki kot pri Lanczosu). Skalarje določimo tako, da velja

- a) Vektorji  $r_0, r_1, \dots, r_k$  so paroma pravokotni.
- b) Smeri  $p_i$  so  $A$ -konjugirane oziroma  $\langle A p_i, p_j \rangle = 0$  za  $i \neq j$ .

Dobimo

$$\alpha_j = \frac{r_{j-1}^T r_{j-1}}{p_j^T A p_j}, \quad \beta_{j-1} = \frac{r_{j-1}^T r_{j-1}}{r_{j-2}^T r_{j-2}}.$$

## CG algoritem

$$r_0 = b - Ax_0, \quad p_1 = r_0$$

$$j = 1, 2, \dots, k$$

$$\alpha_j = \frac{\|r_{j-1}\|^2}{p_j^T A p_j}$$

$$x_j = x_{j-1} + \alpha_j p_j$$

$$r_j = r_{j-1} - \alpha_j A p_j$$

$$\beta_j = \frac{\|r_j\|^2}{\|r_{j-1}\|^2}$$

$$p_{j+1} = r_j + \beta_j p_j$$

**Izrek 2.** Pri  $z = x_j$  je dosežen minimum  $\|x - z\|_A$  po  $z \in x_0 + \mathcal{K}_j(A, r_0)$ .

**Lema 1.** Če je  $A$  s.p.d., potem  $f(x) := \frac{1}{2}x^T A x - x^T b$  doseže minimum pri  $x = A^{-1}b$ .

**Lema 2.** Naj bo  $A$  s.p.d. Potem je ekvivalentno

- 1) minimizirati  $f(x) = \frac{1}{2}x^T A x - x^T b$ ,
- 2) minimizirati  $\|b - Ax_k\|_{A^{-1}}$ ,
- 3) minimizirati  $\|\hat{x} - x_k\|_A$ .

## Konvergenca CG

Če je  $d_i = x - x_i$ , potem iščemo tak polinom  $P_k$  stopnje  $k$ , da bo  $\|d_k\|_A = \|P_k(A)d_0\|_A$  minimalno, pri čemer je  $P_k$  polinom stopnje  $k$  in velja  $P_k(0) = 1$ .

Velja namreč  $x - x_k = x - x_0 - Q_{k-1}(A)r_0$  za nek polinom  $Q_{k-1}$  stopnje  $k - 1$ . Ker je  $r_0 = A(x - x_0)$ , dobimo

$$d_k = x - x_k = (I - Aq_{k-1}(A))d_0 = P_k(A)d_0,$$

kjer je  $P_k$  polinom stopnje  $k$ , za katerega velja  $P_k(0) = 1$ .

**Izrek 3.** Če metoda CG ne skonvergira do  $k$ -tega koraka ( $r_j \neq 0$  za  $j < k$ ), potem velja  $d_k = P_k(A)d_0$ , kjer  $P_k$  minimizira  $\|P_k(A)d_0\|_A$ . Velja

$$\frac{\|d_k\|_A}{\|d_0\|_A} = \min_{\substack{P_k \text{ stopnje } k \\ P_k(0)=1}} \frac{\|P_k(A)d_0\|_A}{\|d_0\|_A} \leq \min_{\substack{P_k \text{ stopnje } k \\ P_k(0)=1}} \max_{\lambda \in \sigma(A)} |P_k(\lambda)|.$$

**Posledica 1.** Če ima s.p.d. matrika  $A$  le  $k$  različnih lastnih vrednosti, potem metoda CG skonvergira v največ  $k$  korakih.

# Polinomi Čebiševa

Polinomi Čebiševa so definirani z rekurzivno zvezo

$$\begin{aligned}T_0(x) &= 1, \\T_1(x) &= x, \\T_{m+1}(x) &= 2xT_m(x) - T_{m-1}(x) \quad \text{za } m > 1.\end{aligned}$$

Zanje velja:

- a)  $T_m(1) = 1$ .
- b)  $T_m(x) = 2^{m-1}x^m + \mathcal{O}(x^{m-1})$ .
- c)  $T_m(x) = \begin{cases} \cos(m \arccos x), & |x| \leq 1, \\ \cosh(m \operatorname{arccosh} x), & |x| \geq 1. \end{cases}$
- č)  $|T_m(x)| \leq 1$  za  $|x| \leq 1$ .
- d) Izmed vseh polinomov stopnje  $m$  z vodilnim koeficientom  $2^{m-1}$  ima  $T_m$  najmanjšo  $\infty$ -normo na  $[-1, 1]$ .
- e)  $T_m(x) = \frac{1}{2} \left[ \left( x + \sqrt{x^2 - 1} \right)^m + \left( x + \sqrt{x^2 - 1} \right)^{-m} \right]$  za  $|x| \geq 1$ .
- f)  $T_m(1 + \epsilon) \geq 1 + m^2\epsilon$  za  $\epsilon > 0$ .



## Ocena za konvergenco CG

**Izrek 4.** Za približek  $x_j \in x_0 + \mathcal{K}_j(A, r_0)$ , dobljen z metodo CG, velja ocena

$$\|x - x_j\|_A \leq \frac{1}{\left| T_j \left( \frac{\lambda_{\max}(A) + \lambda_{\min}(A)}{\lambda_{\max}(A) - \lambda_{\min}(A)} \right) \right|} \|x - x_0\|_A.$$

**Posledica 2.** Za približek  $x_j \in x_0 + \mathcal{K}_j(A, r_0)$ , dobljen z metodo CG, velja ocena

$$\|x - x_j\|_A \leq 2 \left( \frac{\sqrt{\kappa} - 1}{\sqrt{\kappa} + 1} \right)^j \|x - x_0\|_A,$$

kjer je

$$\kappa = \frac{\lambda_{\max}(A)}{\lambda_{\min}(A)}$$

spektralna občutljivost matrike  $A$ .

## Študij konvergence CG

$$r_0 = b - Ax_0, \quad p_1 = r_0$$

$$j = 1, 2, \dots, k$$

$$\alpha_j = \frac{\|r_{j-1}\|^2}{p_j^T A p_j}$$

$$x_j = x_{j-1} + \alpha_j p_j$$

$$r_j = r_{j-1} - \alpha_j A p_j$$

$$\beta_j = \frac{\|r_j\|^2}{\|r_{j-1}\|^2}$$

$$p_{j+1} = r_j + \beta_j p_j$$

Izkaže se, da je dovolj obravnavati le diagonalne matrike  $A$ .

Namreč, če je  $Q$  ortogonalna matrika in  $\tilde{A} = Q^T A Q$ ,  $\tilde{x} = Q^T x$ ,  $\tilde{b} = Q^T b$  in vzamemo  $\tilde{x}_0 = Q^T x_0$ , potem CG na sistemu  $Ax = b$  z začetnim približkom  $x_0$  vrne iste konstante  $\alpha_j$  in  $\beta_j$  kot CG na sistemu  $\tilde{A}\tilde{x} = \tilde{b}$  z začetnim približkom  $\tilde{x}_0$ . Za ustrezna ostanka velja  $\|\tilde{r}_j\| = \|r_j\|$ .