

Numerička analiza

7. predavanje

Autor: Nela Bosner
Predavač: Nela Bosner

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

PMF – Matematički odjel, Zagreb

Sadržaj predavanja

- Rješavanje linearnih sustava: iteracije iz Krylovljevih potprostora:
 - Aproksimacije iz Krylovljevih potprostora i prekondicioniranje.
- Metoda konjugiranih gradijenata (CG):
 - Metoda najbržeg silaska i njena konvergencija.
 - Metoda konjugiranih smjerova i njena konvergencija.
 - Metoda konjugiranih gradijenata (CG) i njena konvergencija.
 - Prekondicionirana metoda konjugiranih gradijenata
 - Numerička stabilnost metode konjugiranih gradijenata

Sadržaj predavanja (nastavak)

- GMRES metoda:
 - Arnoldijeva metoda
 - Izvod GMRES metode
 - Svojstva GMRES metode i njena konvergencija
- Primjeri konvergencije metoda:
 - Primjer konvergencije CG metode.
 - Primjer konvergencije GMRES metode.

Rješavanje linearnih sustava: iteracije iz Krylovljevih potprostora

Krylovljevi potprostori

Prisjetimo se najprije rezultata iz linearne algebre, koji tvrdi da:

- svaka matrica poništava svoj karakteristični i minimalni polinom.

Za $A \in \mathbb{C}^{n \times n}$ i $b \in \mathbb{C}^n$, to možemo zapisati na sljedeći način

$$p_A(A) = a_0I + a_1A + \cdots + a_{n-1}A^{n-1} + a_nA^n = 0,$$

gdje je $p_A(\lambda) = \det(A - \lambda I) = \sum_{i=0}^n a_i \lambda^i$ karakteristični polinom matrice A .

- Slično možemo napisati da je $\mu_A(A) = 0$, gdje je $\mu_A(\lambda)$ minimalni polinom stupnja manjeg ili jednakog n .

Krylovljevi potprostori (nastavak)

- Linearni sustavi najčešće se rješavaju kada je **matrica** sustava **regularna**, jer je tada rješenje jedinstveno.
- U tom slučaju **nula ne može biti korijen** karakterističnog polinoma, pa je $a_0 \neq 0$.
- Odavde jednostavnim računom možemo dobiti da vrijedi

$$\begin{aligned} & -\frac{1}{a_0}(a_1I + \cdots + a_{n-1}A^{n-2} + a_nA^{n-1}) \cdot A \\ & = A \cdot \left(-\frac{1}{a_0}\right) (a_1I + \cdots + a_{n-1}A^{n-2} + a_nA^{n-1}) = I, \end{aligned}$$

to jest,

$$A^{-1} = -\frac{1}{a_0}(a_1I + \cdots + a_{n-1}A^{n-2} + a_nA^{n-1}).$$

Krylovljevi potprostori (nastavak)

- Budući da **rješenje** sustava $Ax = b$ možemo zapisati kao $x = A^{-1}b$, uz uvažavanje prethodnog zapisa za A^{-1} možemo zaključiti da je

$$x = -\frac{a_1}{a_0}b - \dots - \frac{a_{n-1}}{a_0}A^{n-2}b - \frac{a_n}{a_0}A^{n-1}b,$$

odnosno

$$x \in \text{span}\{b, Ab, \dots, A^{n-1}b\} = \mathcal{K}_n(A, b).$$

- Prostor koji se pojavljuje na desnoj strani zovemo **Krylovljevim prostorom** matrice A i inicijalnog vektora b .
- Upravo odavde dobivamo ideju za **metode** rješavanja sustava linearnih jednačbi koje bi se temeljile na **aproksimacijama iz Krylovljevih potprostora**.

Aproksimacije iz Krylovljevih potprostora

- Naime kako je vektor b jedini vektor direktno vezan za problem rješavanja sutava $Ax = b$, čini nam se prirodno **uzeti** neki **multipl** od b kao **početnu** aproksimaciju rješenja, tj.

$$x_0 \in \text{span}\{b\}.$$

- Nakon toga računamo produkt Ab i zahtijevamo da nam je **sljedeća** aproksimacija jednaka nekoj **linearnoj** kombinaciji od b i Ab , tj.

$$x_1 \in \text{span}\{b, Ab\}.$$

- Taj se proces **nastavlja**, tako da nam aproksimacija u k -tom koraku zadovoljava

$$x_k \in \text{span}\{b, Ab, \dots, A^k b\}, \quad k = 1, 2, \dots$$

Aproksimacije iz Krylovljevih potprostora (nast.)

- Metoda, naravno, mora odrediti **kriterij** po kojem **biramo vektore** iz pojedinih **Krylovljevih potprostora** u svakom koraku,
- Prije svega promotrimo jednu vrlo jednostavnu činjenicu. Ako je x_k **aproksimacija** rješenja u k -tom koraku neke iterativne metode za rješavanje linearnih sustava, i ako u $(k + 1)$ -om koraku uzmemo

$$x_{k+1} = x_k + A^{-1}(b - Ax_k),$$

tada je $x_{k+1} = A^{-1}b$ **rješenje sustava**.

- Budući da je računanje vektora $A^{-1}(b - Ax_k)$ **ekvivalentno** problemu **rješavanja polaznog sustava**, **korekciju** vektora x_k radit ćemo pomoću neke njegove **aproksimacije**.

Aproksimacije iz Krylovljevih potprostora (nast.)

- Ta aproksimacija mora
 - se lakše računati i
 - mora nas držati unutar Krylovljevih potprostora.
- Zato, najprije pretpostavimo da polazimo od iteracije jednostavnog oblika

$$x_{k+1} = x_k + \alpha_k(b - Ax_k),$$

gdje je α_k parametar koji određuje točku na pravcu koji

- prolazi kroz točku x_k i
 - pruža se u smjeru vektora $r_k = b - Ax_k$.
- Tada je

$$x_1 = x_0 + \alpha_0 r_0 \in x_0 + \text{span}\{r_0\},$$

$$x_2 = x_0 + \alpha_0 r_0 + \alpha_1 (r_0 - \alpha_0 A r_0) \in x_0 + \text{span}\{r_0, A r_0\},$$
$$\vdots$$

Aproksimacije iz Krylovljevih potprostora (nast.)

- Na temelju iteracije lako se vidi da je za $k = 0, 1, 2, \dots$

$$x_k \in x_0 + \text{span} \{r_0, Ar_0, A^2r_0, \dots, A^{k-1}r_0\} = x_0 + \mathcal{K}_k(A, r_0),$$

$$r_k \in r_0 + \text{span} \{Ar_0, A^2r_0, A^3r_0, \dots, A^k r_0\} = r_0 + A\mathcal{K}_k(A, r_0),$$

pri čemu je $r_k = b - Ax_k$ rezidual k -te iteracije, a sa $e_k = A^{-1}r_k = A^{-1}b - x_k$ označavamo grešku.

- Prostor koji se pojavljuje kod definiranja iteracije je također Krylovljev potprostor, ali određen matricom A i vektorom r_0 , koji ne mora biti jednak vektoru b .
- Primijetimo da je za $x_0 = 0, r_0 = b$, pa je $x_k \in \mathcal{K}_k(A, b)$.

Aproksimacije iz Krylovljevih potprostora (nast.)

- Međutim, ako prema uvodnom razmatranju napišemo da je $A^{-1} = q_{k-1}(A)$, gdje je $q_{k-1}(\lambda)$ polinom stupnja $(k-1)$ za neki $k \leq n$, tada
 - za bilo koji r_0 ,
 - u prostoru $x_0 + \mathcal{K}_k(A, r_0)$ možemo naći vektor oblika $x_0 + q_{k-1}(A)r_0 = x_0 + A^{-1}r_0 = A^{-1}b$ koji je rješenje linearnog sustava $Ax = b$.
- Općenito, iteracija iterativne metode bit će oblika

$$x_k = x_{k-1} + z_{k-1}, \quad \text{ili} \quad x_k = x_0 + w_k$$

pri čemu će z_{k-1} i w_{k-1} biti birani tako da $x_k \in x_0 + \mathcal{K}_k(A, r_0)$ i da zadovoljava neki uvjet optimalnosti, najčešće vezan uz normu reziduala ili neku normu greške.

Prekondicioniranje

- Kao što ćemo kasnije vidjeti, sve metode ovakvog oblika **konvergiraju vrlo brzo** ukoliko je matrica sustava A **blizu identiteti**. (Jasno za iteracije oblika $x_{k+1} = x_k + \alpha_k(b - Ax_k)$.)

- Naravno, to se događa vrlo rijetko, ali mi **možemo** cijeli sustav $Ax = b$ **zamijeniti** sa **modificiranim** sustavom

$$M^{-1}Ax = M^{-1}b \quad \text{ili} \quad AM^{-1}y = b, \quad x = M^{-1}y,$$

čija bi matrica bila **bliža identiteti** od matrice A .

- Ovdje se radi o **lijevom** odnosno **desnom** **prekondicioniranju**.

Prekondicioniranje (nastavak)

- Ako je M hermitska i pozitivno definitna matrica, tada možemo izvesti **simetrično prekondicioniranje** i riješiti modificirani linearni sustav

$$L^{-1}AL^{-*}y = L^{-1}b, \quad x = L^{-*}y,$$

pri čemu je $M = LL^*$.

- Matrica L može biti
 - hermitski drugi korijen od M ,
 - ili donje trokutasti faktor Choleskog od M ,
 - ili bilo koja druga matrica koja zadovoljava $M = LL^*$.

U svakom slučaju bitno je samo to da je **računanje** $M^{-1}z$ za bilo koji vektor z **jednostavnije** (odnosno da je **jednostavnije riješiti** sustav sa matricom sustava M).

Prekondicioniranje (nastavak)

● Dakle, ako **matricu prekondicioniranja** M možemo izabrati tako

● da se **linearni sustav** sa matricom sustava M može **jednostavno riješiti**

● i da $M^{-1}A$ ili AM^{-1} ili $L^{-1}AL^{-*}$ **aproksimiraju identitetu**,

tada **primjenom iterativne metode** na **prekondicionirane sustave** možemo dobiti još **bolju** tehniku za računanje rješenja sustava.

● Pravi smisao tvrdnje da “**prekondicionirana matrica aproksimira identitetu**”, ovisi o **iterativnoj metodi** koju smo koristili, i o **njenim svojstvima**.

Metoda konjugiranih gradijenata (CG)

Metoda najbržeg silaska

- To je iterativna metode iz Krylovljevih potprostora, za rješavanje sustava $Ax = b$, $A \in \mathbb{R}^{n \times n}$, $b, x \in \mathbb{R}^n$, pri čemu je matrica sustava A simetrična pozitivno definitna:
 - $A^T = A$
 - $y^T Ay > 0$ za svaki $y \in \mathbb{R}^n$, $y \neq 0$
- Ideja odabira parametra α_k u k -toj iteraciji metode $x_{k+1} = x_k + \alpha_k r_k$ je ta da se minimizira neka norma greške $e_{k+1} = e_k - \alpha_k r_k$.
- Problem je što nam je greška jednako tako nepoznata kao i samo rješenje, pa norma $\| \cdot \|_2$ ne dolazi u obzir.
- Ono što možemo izračunati je rezidual $r_{k+1} = Ae_{k+1} = r_k - \alpha_k Ar_k$.

Metoda najbržeg silaska (nastavak)

- Za **simetričnu pozitivno definitnu** matricu A ima smisla definirati **A -normu** $\|\cdot\|_A$

$$\|v\|_A = \sqrt{\langle v, v \rangle_A} = \sqrt{v^T A v}.$$

- Uvjerite se da je $\|\cdot\|_A$ zaista **norma** na \mathbb{R}^n !
- **Definirajmo** sada funkciju $f : \mathbb{R} \rightarrow \mathbb{R}$ kao

$$\begin{aligned} f(\alpha_k) &= e_{k+1}^T A e_{k+1} \\ &= \alpha_k^2 r_k^T A r_k - 2\alpha_k r_k^T A e_k + e_k^T A e_k \\ &= \alpha_k^2 r_k^T A r_k - 2\alpha_k r_k^T r_k + e_k^T A e_k. \end{aligned}$$

- Traženje **minimuma funkcije** $f(\alpha_k)$ je **ekvivalentno** traženju **minimuma** $\|e_{k+1}\|_A$.

Metoda najbržeg silaska (nastavak)

- Funkcija $f(\alpha_k)$ je kvadratna funkcija po varijabli α_k , i parametar uz α_k^2 je $r_k^T A r_k \geq 0$, što znači da funkcija poprima minimum u tjemenu, koje je jedina nultočka derivacije funkcije f' .

$$0 = f'(\alpha_k) = 2\alpha_k r_k^T A r_k - 2r_k^T r_k,$$

odakle slijedi da se minimalna A -norma greške e_{k+1} postiže za

$$\alpha_k = \frac{r_k^T r_k}{r_k^T A r_k}.$$

- Zbog ovakvog odabira parametra α_k vrijedi da je r_{k+1} okomit na r_k , tj.

$$r_k^T r_{k+1} = r_k^T r_k - \alpha_k r_k^T A r_k = r_k^T r_k - \frac{r_k^T r_k}{r_k^T A r_k} r_k^T A r_k = 0.$$

Metoda najbržeg silaska (nastavak)

- Važno je još primijetiti, da tako dugo dok **nismo našli egzaktno rješenje** ($r_k \neq 0$), α_k je **strogo veći od nule**.
- Zbog **okomitosti** r_{k+1} i r_k slijedi

$$\begin{aligned}\|e_k\|_A^2 &= e_{k+1}^T A e_{k+1} + 2\alpha_k r_k^T A e_{k+1} + \alpha_k^2 r_k^T A r_k \\ &= \|e_{k+1}\|_A^2 + \alpha_k^2 \|r_k\|_A^2 > \|e_{k+1}\|_A^2,\end{aligned}$$

odakle se vidi da se **A -norma greške smanjuje** u svakom koraku.

- Ova metoda, zbog načina odabira parametra, zove se **metoda najbržeg silaska**.

Algoritam metode najbržeg silaska

Algoritam (Metoda najbržeg silaska).

x_0 zadan; $k = 0$;

$r_0 = b - Ax_0$;

dok nije zadovoljen kriterij zaustavljanja radi {

$$\alpha_k = \frac{r_k^T r_k}{r_k^T A r_k};$$

$$x_{k+1} = x_k + \alpha_k r_k;$$

$$r_{k+1} = r_k - \alpha_k A r_k;$$

$$k = k + 1;$$

}

Konvergenција metode najbržeg silaska

- Iz iteracije možemo dobiti **rekurziju** za e_k (već smo ju vidjeli), koja glasi

$$e_{k+1} = e_k - \alpha_k r_k = e_k - \alpha_k A e_k = (I - \alpha_k A) e_k,$$

koju na drugačiji način možemo zapisati kao

$$e_{k+1} = p_1(A) e_k,$$

pri čemu je p_1 **polinom** prvog stupnja, takav da je $p_1(\lambda) = 1 - \alpha_k \lambda$.

- Prema gore navedenom, za grešku e_{k+1} onda vrijedi

$$\|e_{k+1}\|_A = \min_{p_1 \in \mathbb{P}_1, p_1(0)=1} \|p(A)e_k\|_A,$$

gdje se **minimum** uzima po **svim polinomima** p prvog stupnja, za koje je $p(0) = 1$, odnosno koji su oblika $p(\lambda) = 1 - \alpha \lambda$. — to nam je i bio **uvjet** za izbor α_k

Konvergenција metode najbržeg silaska (nast.)

- Za nastavak analize trebat će nam još sljedeće **svojstvo** A -norme za proizvoljni vektor u :

$$\begin{aligned}\|u\|_A &= (u^T A u)^{1/2} = (u^T A^{1/2} A^{1/2} u)^{1/2} \\ &= ((A^{1/2} u)^T A^{1/2} u)^{1/2} = \|A^{1/2} u\|_2.\end{aligned}$$

- Vidjet ćemo da **simetričnu** matricu A možemo dijagonalizirati ortogonalnom matricom: $A = U \Lambda U^T$, $\Lambda = \text{diag}(\lambda_1, \dots, \lambda_n)$, gdje je $U^T U = U U^T = I$, i $\lambda_i \in \mathbb{R}$ za $i = 1, \dots, n$ su realne svojstvene vrijednosti.
- Za **simetričnu pozitivno definitnu matricu** još vrijedi da su $\lambda_i > 0$ za $i = 1, \dots, n$, tj. **sve svojstvene vrijednosti su pozitivne**.

Konvergenција metode najbržeg silaska (nast.)

- Tada možemo definirati $A^{1/2}$ simetrični kvadratni korijen matrice A , oblika $A^{1/2} = U\Lambda^{1/2}U^T$, koji komutira sa A i bilo kojim polinomom od A .
- Zato vrijedi

$$\begin{aligned}\|e_{k+1}\|_A &= \min_{p_1 \in \mathbb{P}_1, p_1(0)=1} \|A^{1/2}p_1(A)e_k\|_2 \\ &= \min_{p_1 \in \mathbb{P}_1, p_1(0)=1} \|Up_1(\Lambda)U^T A^{1/2}e_k\|_2 \\ &\leq \min_{p_1 \in \mathbb{P}_1, p_1(0)=1} \|p_1(\Lambda)\|_2 \|e_k\|_A \\ &= \min_{p_1 \in \mathbb{P}_1, p_1(0)=1} \max_{j=1, \dots, n} |p_1(\lambda_j)| \|e_k\|_A.\end{aligned}$$

Konvergenција metode najbržeg silaska (nast.)

- Može se pokazati da se taj **minimum postiže** za polinom

$$p_1(\lambda) = 1 - \frac{2}{\lambda_{min} + \lambda_{max}} \lambda$$

i iznosi

$$|p_1(\lambda_{min})| = |p_1(\lambda_{max})| = \frac{\lambda_{max} - \lambda_{min}}{\lambda_{max} + \lambda_{min}} = \frac{\kappa_2(A) - 1}{\kappa_2(A) + 1} < 1,$$

pri čemu je λ_{min} **minimalna**, a λ_{max} **maksimalna** **svojstvena vrijednost** matrice A , te $\kappa_2(A) = \lambda_{max}/\lambda_{min}$ **uvjetovanost** matrice A .

Konvergenција metode najbržeg silaska (nast.)

- Dakle dobivamo rezultat

$$\|e_{k+1}\|_A \leq \left(\frac{\kappa(A) - 1}{\kappa(A) + 1} \right) \|e_k\|_A,$$


i kao konačni oblik

$$\|e_k\|_A \leq \left(\frac{\kappa(A) - 1}{\kappa(A) + 1} \right)^k \|e_0\|_A.$$

- Iz njega možemo zaključiti da za loše uvjetovane matrice možemo imati sporu konvergenciju jer je u tom slučaju $\frac{\kappa(A)-1}{\kappa(A)+1} \approx 1$.
- Ova metoda često dosta sporo konvergira, jer radi korake u smjeru kojim je neki raniji korak već prošao.

Konvergenција metode najbržeg silaska (nast.)

Iteracije metode najbržeg silaska za $A \in \mathbb{R}^{3 \times 3}$.



Metoda konjugiranih smjerova

- Da bi se **izbjegla spora konvergencija** metode najbržeg **silaska**, unaprijed odabiremo skup **A -ortogonalnih** vektora, odnosno **smjerove traganja** d_0, d_1, \dots, d_{n-1} .
- Dva vektora d_i i d_j su **A -ortogonalna** ili **konjugirana** ako vrijedi da je

$$\langle d_i, d_j \rangle_A = d_j^T A d_i = 0.$$

- Lagano se može provjeriti da su **A -ortogonalni** vektori **linearno nezavisni**.
- Znači u svakom koraku bираmo točku

$$x_{k+1} = x_k + \alpha_k d_k$$

s **minimalnom A -normom** greške.

Metoda konjugiranih smjerova (nastavak)

- Dakle, u svakom smjeru d_k napraviti ćemo **točno jedan korak**, takav da ćemo **poništiti komponentu** vektora greške e_k u smjeru Ad_k .
- Nakon n koraka bit ćemo **gotovi!**
- U $(k + 1)$ -om koraku e_{k+1} je **jednak početnoj grešci** kojoj su **odstranjene** sve **komponente u smjerovima** Ad_0, \dots, Ad_k , odnosno
- e_{k+1} je **A -ortogonalan** na d_0, \dots, d_k .
- **A -ortogonalnost** između e_{k+1} i d_k je **ekvivalentna** nalaženju točke **minimuma** duž **smjera traganja** d_k , kao i u metodi **najbržeg silaska**.

Metoda konjugiranih smjerova (nastavak)

- Ponovo ćemo **derivirati** po α_k funkciju

$$g(\alpha_k) = e_{k+1}^T A e_{k+1}$$

i izjednačiti je s nulom, samo što je u tom slučaju r_{k+1} **okomit** na d_k .

- Ako opet uvrstimo da je $r_{k+1} = r_k - \alpha_k A d_k$ i $e_{k+1} = e_k - \alpha_k d_k$

$$g(\alpha_k) = \alpha_k^2 d_k^T A d_k - 2\alpha_k d_k^T A e_k + e_k^T A e_k,$$

slijedi da je

$$g'(\alpha_k) = 2\alpha_k d_k^T A d_k - 2d_k^T r_k$$

Metoda konjugiranih smjerova (nastavak)

odakle ćemo izjednačavanjem s nulom dobit izraz za α_k

$$\alpha_k = \frac{d_k^T r_k}{d_k^T A d_k}.$$

- Ovako dobivena metoda naziva se **metoda konjugiranih smjerova**.
- Da je e_{k+1} A -ortogonalan na d_0, \dots, d_k , može se sad dokazati **matematičkom indukcijom**:
 - $d_0^T A e_1 = d_0^T A e_0 - \alpha_0 d_0^T A d_0 = d_0^T r_0 - \frac{d_0^T r_0}{d_0^T A d_0} d_0^T A d_0 = 0$
iz definicije parametra α_0
 - Ako **pretpostavimo** da je $d_i^T A e_k = 0$ za $i = 0, \dots, k - 1$, tada imamo

Metoda konjugiranih smjerova (nastavak)

$$d_k^T A e_{k+1} = d_k^T A e_k - \alpha_k d_k^T A d_k = d_k^T r_k - \frac{d_k^T r_k}{d_k^T A d_k} d_k^T A d_k = 0$$

$$d_i^T A e_{k+1} = d_i^T A e_k - \alpha_k d_i^T A d_k = 0, \quad i = 0, \dots, k-1$$

iz definicije parametra α_k , pretpostavke indukcije i A -ortogonalnosti vektora d_i .

Algoritam metode konjugiranih smjerova

Algoritam (Metoda konjugiranih smjerova).

x_0 zadan;

A -ortogonalni vektori d_0, d_1, \dots, d_{n-1} zadani;

$k = 0$;

$r_0 = b - Ax_0$;

dok nije zadovoljen kriterij zaustavljanja radi {

$$\alpha_k = \frac{d_k^T r_k}{d_k^T A d_k};$$

$$x_{k+1} = x_k + \alpha_k d_k;$$

$$r_{k+1} = r_k - \alpha_k A d_k;$$

$$k = k + 1;$$

}

Svojstva metode konjugiranih smjerova

Teorem. Za metodu konjugiranih smjerova vrijede sljedeća svojstva:

$$d_j^T A d_i = 0 \quad (i \neq j)$$

$$d_j^T r_i = d_j^T A e_i = 0 \quad (j < i)$$

$$d_i^T r_0 = d_i^T r_1 = \dots = d_i^T r_i.$$

Skalar α_i može se zato napisati kao

$$\alpha_k = \frac{d_k^T r_0}{d_k^T A d_k}.$$

Dokaz. Prve dvije tvrdnje smo već pokazali, a **treća** slijedi iz svojstva **A-ortogonalnosti** vektora d_i :

Svojstva metode konjugiranih smjerova (nast.)

$$\begin{aligned}d_i^T r_i &= d_i^T r_{i-1} - \alpha_{i-1} d_i^T A d_{i-1} \\ &= d_i^T r_{i-1} = d_i^T r_{i-2} - \alpha_{i-2} d_i^T A d_{i-2} = d_i^T r_{i-2} \\ &= \dots = d_i^T r_0\end{aligned}$$



Posljedica formule za α_k iz ovog **Teorema** je ta da se aproksimacije x_1, x_2, \dots od x mogu izračunati bez računanja reziduala r_1, r_2, \dots . Ovisne su samo o početnom rezidualu r_0 .

Konvergenција metode konjugiranih smjerova

Teorem. Metoda konjugiranih smjerova je m -koračna metoda ($m \leq n$), u smislu da je u m -tom koraku aproksimacija x_m jednaka rješenju $x = A^{-1}b$.

Dokaz. Neka je m najmanji cijeli broj takav da se $e_0 = x - x_0$ nalazi u $\text{span}\{d_0, \dots, d_{m-1}\}$. Očito je $m \leq n$, budući da su vektori d_0, d_1, \dots linearno nezavisni, pa ih maksimalno može biti n . Zatim, izaberimo skalare a_0, \dots, a_{m-1} takve da je

$$e_0 = a_0 d_0 + \dots + a_{m-1} d_{m-1}.$$

Odavde slijedi

$$x = x_0 + a_0 d_0 + \dots + a_{m-1} d_{m-1}.$$

Konvergenција metode konjugiranih smjerova

Nadalje,

$$r_0 = b - Ax_0 = A(x - x_0) = a_0Ad_0 + \cdots + a_{m-1}Ad_{m-1}.$$

Koristeći se činjenicom da su **smjerovi traženja** d_i međusobno **konjugirani** i jednakošću za α_k iz prethodnog **Teorema**, računanjem skalarnog produkta $d_i^T r_0$ dobivamo

$$d_i^T r_0 = a_i d_i^T Ad_i$$

odnosno

$$a_i = \frac{d_i^T r_0}{d_i^T Ad_i} = \alpha_i.$$

Konvergencija metode konjugiranih smjerova

Budući da je, primjenom indukcije na iteraciju za x_k

$$x_m = x_0 + \alpha_0 d_0 + \cdots + \alpha_{m-1} d_{m-1},$$

možemo zaključiti da tvrdnja $x = x_m$ vrijedi. ■

Metoda konjugiranih gradijenata [CG]

- Preostaje nam još **pronaći** odgovarajuće vektore d_0, d_1, \dots, d_{n-1} .
- Skup A -ortogonalnih smjerova $\{d_i\}$ možemo dobiti primjenom **Gramm–Schmidtove** metode A -ortogonalizacije na niz **linearno nezavisnih** vektora u_0, \dots, u_{n-1} sa skalarnim produktom $\langle \cdot, \cdot \rangle_A$.
- Dakle, A -ortogonalne vektore možemo dobiti kao

$$d_k = u_k + \sum_{i=0}^{k-1} \beta_{ki} d_i,$$

pri čemu su koeficijenti oblika

$$\beta_{ki} = -\frac{d_i^T A u_k}{d_i^T A d_i}.$$

Metoda konjugiranih gradijenata [CG] (nast.)

- **Konkretan** odabir vektora u_0, \dots, u_{n-1} vodi nas do metode konjugiranih gradijenata (CG).
- Metoda konjugiranih gradijenata (CG) je, zapravo, **metoda konjugiranih smjerova** za $u_i = r_i$.
- Činjenica da su vektori r_i dobiveni **metodom konjugiranih smjerova** **linearno nezavisni**, može se provjeriti uz pomoć **prethodnih teorema**.
- Ponovo vrijedi

$$\text{span}\{d_0, d_1, \dots, d_{k-1}\} = \text{span}\{r_0, r_1, \dots, r_{k-1}\},$$

i budući da je r_k **ortogonalan** na **prethodne smjerove** **traganja** vrijedi

$$r_i^T r_j = 0, \quad i \neq j.$$

Metoda konjugiranih gradijenata [CG] (nast.)

- Promatramo sljedeći skalarni produkt

$$r_{i+1}^T r_k = r_i^T r_k - \alpha_i d_i^T A r_k,$$

- odakle vrijedi

$$d_i^T A r_k = \frac{1}{\alpha_i} (r_i^T r_k - r_{i+1}^T r_k).$$

Za $i < k - 1$ lijeva strana ove jednakosti je jednaka 0, pa su $\beta_{ki} = 0$ za $i = 0, 1, \dots, k - 2$, a za $\beta_k = \beta_{k,k-1}$ zbog izraza za α_{k-1} i prethodnih teorema vrijedi

$$\begin{aligned} \beta_k &= - \frac{d_{k-1}^T A r_k}{d_{k-1}^T A d_{k-1}} = \frac{r_k^T r_k}{\alpha_{k-1} d_{k-1}^T A d_{k-1}} \\ &= \frac{r_k^T r_k}{d_{k-1}^T r_{k-1}} = \frac{r_k^T r_k}{r_{k-1}^T r_{k-1}} \end{aligned}$$

Metoda konjugiranih gradijenata [CG] (nast.)

- Također, zbog **istih teorema** možemo i α_k napisati u ljepšem obliku

$$\alpha_k = \frac{r_k^T r_k}{d_k^T A d_k},$$

odakle se vidi, da ukoliko **nismo našli egzaktno rješenje** u k -tom koraku, α_k je **pozitivan**.

- Ovime smo u potpunosti definirali **metodu konjugiranih gradijenata**.

Algoritam metode konjugiranih gradijenata

Algoritam (Metoda konjugiranih gradijenata).

x_0 zadan;

$k = 0$;

$d_0 = r_0 = b - Ax_0$;

dok nije zadovoljen kriterij zaustavljanja radi {

$$\alpha_k = \frac{r_k^T r_k}{d_k^T A d_k};$$

$$x_{k+1} = x_k + \alpha_k d_k;$$

$$r_{k+1} = r_k - \alpha_k A d_k;$$

$$\beta_{k+1} = \frac{r_{k+1}^T r_{k+1}}{r_k^T r_k};$$

$$d_{k+1} = r_{k+1} + \beta_{k+1} d_k;$$

$$k = k + 1;$$

}

Svojstva metode konjugiranih gradijenata

- Za primjenu metode konjugiranih gradijenata ne trebamo pristupati pojedinim elementima matrice.
- Dovoljno je znati djelovanje matrice na vektor $A \cdot y$ — često se zadaje kao funkcija od y .

Konvergenција metode konjugiranih gradijenata

Teorem. Greška e_k dobivena u k -tom koraku metode konjugiranih gradijenata ima **najmanju** A -normu na prostoru

$$e_0 + \text{span}\{Ae_0, A^2e_0, \dots, A^k e_0\}.$$

Dokaz. Ako gledamo kako su definirani vektori e_k i d_k u ovoj metodi, tada možemo **zaključiti** sljedeće: $d_0 = r_0 = Ae_0$, pa je

$$e_1 = e_0 - \alpha_0 r_0 = e_0 - \alpha_0 Ae_0 \in e_0 + \text{span}\{Ae_0\}.$$

Pretpostavimo da vrijedi da je $e_k \in \text{span}\{e_0, Ae_0, \dots, A^k e_0\}$ i $d_{k-1} \in \text{span}\{Ae_0, A^2e_0, \dots, A^k e_0\}$, tada za e_{k+1} imamo

$$e_{k+1} = e_k - \alpha_k d_k = e_k - \alpha_k \beta_k d_{k-1} - \alpha_k Ae_k \in \text{span}\{e_0, \dots, A^{k+1} e_0\}.$$

Konvergenција metode konjugiranih gradijenata

Matematičkom indukcijom možemo zaključiti da je koeficijent uz e_0 uvijek jednak 1, odnosno

$$e_{k+1} \in e_0 + \text{span}\{Ae_0, A^2e_0, \dots, A^{k+1}e_0\}$$

i zbog $d_k = Ae_k + \beta_k d_{k-1}$

$$d_k \in \text{span}\{Ae_0, A^2e_0, \dots, A^{k+1}e_0\}.$$

Oдавде slijedi da je

• $\text{span}\{d_0, d_1, \dots, d_k\} = \text{span}\{Ae_0, \dots, A^{k+1}e_0\},$

• a kako je e_{k+1} A -ortogonalan na $\text{span}\{d_0, d_1, \dots, d_k\},$

onda slijedi da je e_{k+1} vektor u prostoru

$e_0 + \text{span}\{Ae_0, A^2e_0, \dots, A^{k+1}e_0\}$ sa najmanjom A -normom.

Konvergenција metode konjugiranih gradijenata

Za $k = n - 1$ zbog **linearne nezavisnosti** vektora $\{d_0, \dots, d_{n-1}\}$ slijedi da je $e_n = 0$. ■


Dakle, metoda konjugiranih gradijenata **konvergira** u najviše n koraka.

Teorem. U **svakom koraku** metode konjugiranih gradijenata, duljina (2-norma) vektora greške $e_k = x - x_k$ se **reducira**, pri čemu je $A^{-1}b = x = x_m$, za neki $m \leq n$.

Dokaz. Tehnički! ■

Konvergencija metode konjugiranih gradijenata

Iteracije metode konjugiranih gradijenata za $A \in \mathbb{R}^{3 \times 3}$.



Konvergenција metode konjugiranih gradijenata

Sada nas zanima **kolika** je točno A -norma greške u svakom koraku metode konjugiranih gradijenata.

- Zbog relacije $e_k \in e_0 + \text{span}\{Ae_0, A^2e_0, \dots, A^k e_0\}$, greška u k -tom koraku metode ima oblik

$$e_k = e_0 + \sum_{i=1}^k \psi_i A^i e_0 = \left(I + \sum_{i=1}^k \psi_i A^i \right) e_0.$$

Koeficijenti ψ_i su u **linearnoj vezi** sa koeficijentima α_i i β_i , a metoda konjugiranih gradijenata bira ψ_j takve da oni **minimiziraju** $\|e_k\|_A$.

- Tada, izraz za grešku možemo izraziti kao

$$e_k = p_k(A)e_0,$$

gdje je p_k **polinom k -tog stupnja** kod kojeg zahtijevamo da je $p_k(0) = 1$.

Konvergencija metode konjugiranih gradijenata

Kako je matrica A simetrična i pozitivno definitna, tada matricu možemo zapisati kao produkt matrica $A = U\Lambda U^T$, pri čemu su

- za $\Lambda = \text{diag}(\lambda_1, \dots, \lambda_n)$, $\lambda_1, \dots, \lambda_n$ svojstvene vrijednosti od A i
- $U^T U = U U^T = I$ je ortogonalna.
- $A^{1/2}$ je simetrični drugi korijen od A i vrijedi $A^{1/2} = U\Lambda^{1/2}U^T$, pa komutira sa A .

Zbog toga slijedi

$$\begin{aligned}\|e_k\|_A &= \min_{p_k \in \mathbb{P}_k, p_k(0)=1} \|p_k(A)e_0\|_A \\ &= \min_{p_k \in \mathbb{P}_k, p_k(0)=1} \|A^{1/2}p_k(A)e_0\|_2\end{aligned}$$

Konvergenција metode konjugiranih gradijenata

$$\begin{aligned}\|e_k\|_A &= \min_{p_k \in \mathbb{P}_k, p_k(0)=1} \|U p_k(\Lambda) U^T A^{1/2} e_0\|_2 \\ &\leq \min_{p_k \in \mathbb{P}_k, p_k(0)=1} \|p_k(\Lambda)\|_2 \|e_0\|_A \\ &= \min_{p_k \in \mathbb{P}_k, p_k(0)=1} \max_{i=1, \dots, n} |p_k(\lambda_i)| \|e_0\|_A.\end{aligned}$$

- Općenito, polinom n -tog stupnja može biti jednoznačno određen ako je zadan na $n + 1$ točaka.
- Ako uzmemo da je $p_n(0) = 1$ i da u svim svojstvenim vrijednostima od A (njih n) p_n poprima vrijednost 0, tada je to polinom koji minimizira gornju ogradu, pri čemu je onda e_n jednak nuli.

Konvergenција metode konjugiranih gradijenata

- U **egzaktnoj aritmetici** broj iteracija k koje su potrebne da se **izračuna egzaktno rješenje** je manji ili jednak **broju različitih svojstvenih vrijednosti**, jer možemo naći polinom stupnja k koji je
 - u 0 jednak 1, i
 - u svim različitim svojstvenim vrijednostima jednak 0.
- Za **takav polinom** je $\max_{i=1,\dots,n} |p_k(\lambda_i)| = 0$, pa iz **prethodne ocjene** slijedi da je $e_k = 0$.
- Time se vidi da je **metoda konjugiranih gradijenata brža** ako A ima

višestrukih svojstvenih vrijednosti.

Konvergenција metode konjugiranih gradijenata

- Sve svojstvene vrijednosti od A smještene su u segmentu $[\lambda_{min}, \lambda_{max}]$, pri čemu je $\lambda_{min} > 0$ najmanja, a $\lambda_{max} > 0$ najveća svojstvena vrijednost.
- Budući da je ograda na A -normu greške manja ili jednaka minimizaciji pa maksimizaciji po cijelom intervalu $[\lambda_{min}, \lambda_{max}]$, jednostavniji pristup je minimizacija po tom segmentu nego po konačnom broju točaka.
- Polinomi s kojima se to postiže bazirani su na Čebiševljevim polinomima.
- Čebiševljev polinom stupnja k je

$$T_k(\omega) = \frac{1}{2} \left[(\omega + \sqrt{\omega^2 - 1})^k + (\omega - \sqrt{\omega^2 - 1})^k \right]$$

$$T_k(\omega) = \cos(k \arccos(\omega)), \quad \omega \in [-1, 1].$$

Konvergenција metode konjugiranih gradijenata

- Čebiševljevi polinomi imaju sljedeća svojstva:

$$|T_k(\omega)| \leq 1, \quad \omega \in [-1, 1],$$

rapidno osciliraju između -1 i 1 , odnosno

$$T_k \left(\cos \left(\frac{i\pi}{k} \right) \right) = (-1)^i, \quad i = 0, 1, \dots, k,$$

i k nultočaka polinoma T_k moraju se nalaziti između $k + 1$ ekstrema od T_k u segmentu $[-1, 1]$.

- Najbitnije mu je svojstvo to da između svih normiranih polinoma stupnja k ($a_k = 1$) polinom $2^{1-k}T^k$ ima najmanju ∞ -normu na intervalu $[-1, 1]$, koja iznosi 2^{1-k} .

Konvergenција metode konjugiranih gradijenata

- U ovom slučaju, **polinom** k -tog stupnja koji
 - ima **vrijednost 1** u ishodištu, i
 - ima **minimalnu ∞ -normu** na $[\lambda_{min}, \lambda_{max}]$je dan sa

$$p_k(\lambda) = \frac{T_k \left(\frac{\lambda_{max} + \lambda_{min} - 2\lambda}{\lambda_{max} - \lambda_{min}} \right)}{T_k \left(\frac{\lambda_{max} + \lambda_{min}}{\lambda_{max} - \lambda_{min}} \right)}.$$

- Argument **brojnika** je takav da segment $[\lambda_{min}, \lambda_{max}]$ **prebacuje** u segment $[-1, 1]$.
- Slijedi da za $z \in [\lambda_{min}, \lambda_{max}]$ **apsolutna vrijednost brojnika** je **ograničena** sa 1.
- **Nazivnik** je određen tako da **zadovolji svojstvo** $p_k(0) = 1$.

Konvergenција metode konjugiranih gradijenata

• Znači, imamo sljedeće

$$\|e_k\|_A \leq T_k \left(\frac{\lambda_{max} + \lambda_{min}}{\lambda_{max} - \lambda_{min}} \right)^{-1} \|e_0\|_A = T_k \left(\frac{\kappa(A) + 1}{\kappa(A) - 1} \right)^{-1} \|e_0\|_A,$$

i nakon što izračunamo vrijednost Čebiševljevog polinoma, dobivamo

$$\|e_k\|_A \leq 2 \left[\left(\frac{\sqrt{\kappa(A)} + 1}{\sqrt{\kappa(A)} - 1} \right)^k + \left(\frac{\sqrt{\kappa(A)} - 1}{\sqrt{\kappa(A)} + 1} \right)^k \right]^{-1} \|e_0\|_A$$

Konvergencija metode konjugiranih gradijenata

odnosno

$$\|e_k\|_A \leq 2 \left(\frac{\sqrt{\kappa(A)} - 1}{\sqrt{\kappa(A)} + 1} \right)^k \|e_0\|_A.$$

pri čemu je $\kappa(A) = \lambda_{max}/\lambda_{min}$ broj **uvjetovanosti** matrice A .

- 📍 Ovo je **slabija ograda** od rezultata sa **višestrukim svojstvenim vrijednostima!**
- 📍 **Loša konvergencija** se ostvaruje za **loše uvjetovane matrice**.

Prekondicionirana metode konjugiranih grad.

- Kada rješavamo **simetrični sustav**, želimo da se to svojstvo **zadrži** i nakon **prekondicioniranja**.
- Zato bираmo **matricu prekondicioniranja** M koja je **simetrična** i **pozitivno definitna**.
- Ako matricu M **faktoriziramo** kao $M = LL^T$, tada algoritam **možemo primijeniti** na sustav

$$L^{-1}AL^{-T}\bar{x} = L^{-1}b,$$

koji i dalje ostaje **simetrični**, a **svojstvene vrijednosti** matrice $L^{-1}AL^{-T}$ su **iste** kao i kod $M^{-1}A$.

- Matricu M također bираmo i uz **kriterij** da $L^{-1}AL^{-T}$ ima
 - što sabitije svojstvene vrijednosti, i
 - što manju uvjetovanost.

Prekondicionirana metode konjugiranih grad.

- Ako sada **označimo** sve veličine vezane uz **prekondicionirani sustav** sa $\bar{\cdot}$, a veličine vezane uz **početni sustav** $Ax = b$ sa **standardnim oznakama**, tada uz pomoć relacija

$$x_k = L^{-T} \bar{x}_k, \quad r_k = L \bar{r}_k, \quad d_k = L^{-T} \bar{d}_k,$$

metodu konjugiranih gradijenata primijenjenu na **prekondicionirani sustav** možemo transformirati u **algoritam**, koji **ne ovisi o faktorizaciji** matrice prekondicioniranja M .

Algoritam prekondicionirane metode konj. grad.

Algoritam (Prekondicionirana metoda konj. grad.).

x_0 zadan;

$k = 0$;

$r_0 = b - Ax_0$;

riješiti $Mp_0 = r_0$; $d_0 = p_0$;

dok nije zadovoljen kriterij zaustavljanja radi {

$$\alpha_k = \frac{r_k^T p_k}{d_k^T A d_k};$$

$$x_{k+1} = x_k + \alpha_k d_k;$$

$$r_{k+1} = r_k - \alpha_k A d_k;$$

riješiti $Mp_{k+1} = r_{k+1}$;

$$\beta_{k+1} = \frac{r_{k+1}^T p_{k+1}}{r_k^T p_k};$$

$$d_{k+1} = p_{k+1} + \beta_{k+1} d_k;$$

$$k = k + 1;$$

}

Numerička stabilnost metode konj. grad.

Teorem. Razlika između pravog reziduala $b - A\hat{x}_k$, za izračunatu aproksimaciju \hat{x}_k , i izračunatog vektora \hat{r}_k zadovoljava nejednakost

$$\frac{\|b - A\hat{x}_k - \hat{r}_k\|_2}{\|A\|_2 \|x\|_2} \leq \leq (u + \mathcal{O}(u^2)) \left[k + 1 + (1 + c + k(10 + 2c)) \left(2 + \frac{\|x_0\|_2}{\|x\|_2} \right) \right],$$

gdje je $c = \sqrt{n}\gamma_n$.

Napomena. Promotrimo sada što se događa kada je algoritam blizu konvergencije,

- budući da u većini slučajeva možemo očekivati da \hat{r}_k teži k 0 kada $k \rightarrow \infty$.

Numerička stabilnost metode konj. grad.

- Jednom kada se \hat{r}_k **reducira** ispod određenog stupnja, kada je **vrlo mali**, aproksimacija rješenja \hat{x}_{k+1} ostaje približno **nepromijenjena** u odnosu na prethodnu iteraciju.
- To je zbog toga što je **norma izraza**, koji **mijenja** vrijednost aproksimacije \hat{x}_k u \hat{x}_{k+1} , u bliskoj **vezi** sa veličinom vektora \hat{r}_k , kao što se može vidjeti iz

$$\alpha_k \hat{d}_k = A^{-1}(\hat{r}_k - \hat{r}_{k+1} + \eta_{k+1}), \quad \eta_{k+1} \text{ je greška zaokruživanja.}$$

- Iz ovoga slijedi da kada vektori \hat{r}_k , a prema tome i $\alpha_k \hat{d}_{k-1}$, **konvergiraju ka nuli**, i kada su iteracije algoritma prošle točku u kojoj $\|A^{-1}\hat{r}_k\|_2$ **dostiže** $\mathcal{O}(u)\|\hat{x}_k\|_2$, pravi rezidual $b - A\hat{x}_k$ **neće ovisiti** o k , kao što pretpostavlja ocjena **Teorema**, već će ostati skoro **konstantan**.

Numerička stabilnost metode konj. grad.

- Na žalost, **svojstvo ortogonalnosti reziduala**, koje se koristi za dobivanje **redukcije euklidske norme greške** može se u potpunosti **izgubiti** u **aritmetici konačne preciznosti**.
- Međutim, može se napraviti analogna analiza i u tom slučaju, što nam omogućava **sličan zaključak** i za **aritmetiku konačne preciznosti**.

GMRES metoda

GMRES metoda

- GMRES metoda (Generalized minimal residual algorithm) ili generalizirani algoritam minimalnog reziduala koristi modificirani Gram–Schmidtov postupak kako bi konstruirao ortonormiranu bazu za niz Krylovljevih potprostora

$$\mathcal{K}_k(A, r_0) = \text{span}\{r_0, Ar_0, \dots, A^{k-1}r_0\}.$$

- Kada se modificirani Gram–Schmidtov postupak primijeni na ovakav prostor tada govorimo o Arnoldijevoj metodi.

Algoritam Arnoldijeve metode

Algoritam (Arnoldijeva metoda).

q_1 sa $\|q_1\|_2 = 1$ zadan;
za $j = 1$ do $n - 1$ radi {
 $\tilde{q}_{j+1} = Aq_j$;
 za $i = 1$ do j radi {
 $h_{ij} = q_i^T \tilde{q}_{j+1}$;
 $\tilde{q}_{j+1} := \tilde{q}_{j+1} - h_{ij}q_i$;
 }
 $h_{j+1,j} = \|\tilde{q}_{j+1}\|_2$;
 $q_{j+1} = \frac{\tilde{q}_{j+1}}{h_{j+1,j}}$;
}

Arnoldijeva metoda

- Ako je Q_k $n \times k$ matrica čije stupce čine vektori ortonormirane baze q_1, \dots, q_k , tada se Arnoldijeva iteracija može napisati u matičnom obliku

$$AQ_k = Q_k H_k + h_{k+1,k} q_{k+1} \xi_k^T = Q_{k+1} H_{k+1,k}.$$

- Ovdje je H_k $k \times k$ gornja Hessenbergova matrica kojoj je (i, j) -ti element jednak $h_{i,j}$ za $j = 1, \dots, k$, $i = 1, \dots, \min\{j + 1, k\}$, a svi ostali elementi su jednaki 0.
- Vektor ξ_k je k -ti jedinični vektor $[0 \ \dots \ 0 \ 1]^T$.
- $(k + 1) \times k$ matrica $H_{k+1,k}$ je matrica kojoj je gornji $k \times k$ blok jednak H_k , a zadnji redak jednak nuli, osim na poziciji $(k + 1, k)$, na kojoj je element jednak $h_{k+1,k}$.

Arnoldijeva metoda (nastavak)

$$Q_k = [q_1 \quad q_2 \quad \cdots \quad q_k]$$

$$H_{k+1,k} = \left[\begin{array}{cccccc} h_{11} & h_{12} & h_{13} & \cdots & \cdots & h_{1k} \\ h_{21} & h_{22} & h_{23} & \cdots & \cdots & h_{2k} \\ 0 & h_{32} & h_{33} & \cdots & \cdots & h_{3k} \\ 0 & 0 & h_{43} & \ddots & & \vdots \\ \vdots & \vdots & & \ddots & \ddots & \vdots \\ 0 & 0 & \cdots & 0 & h_{k,k-1} & h_{kk} \\ \hline 0 & 0 & \cdots & 0 & 0 & h_{k+1,k} \end{array} \right] \left. \vphantom{\begin{array}{cccccc} h_{11} & h_{12} & h_{13} & \cdots & \cdots & h_{1k} \\ h_{21} & h_{22} & h_{23} & \cdots & \cdots & h_{2k} \\ 0 & h_{32} & h_{33} & \cdots & \cdots & h_{3k} \\ 0 & 0 & h_{43} & \ddots & & \vdots \\ \vdots & \vdots & & \ddots & \ddots & \vdots \\ 0 & 0 & \cdots & 0 & h_{k,k-1} & h_{kk} \end{array}} \right\} H_k$$

Arnoldijeva metoda (nastavak)

- **Rekurzivna definicija** za matricu Q_{k+1} može se u **matričnom obliku** napisati kao

$$[q_1 \quad AQ_k] = Q_{k+1}R_{k+1},$$

pri čemu je R_{k+1} $(k+1) \times (k+1)$ **gornje trokutasta** matrica

$$R_{k+1} = [\xi_1 \quad H_{k+1,k}],$$

a $\xi_1 = [1, 0, \dots, 0]^T$.

- Prema tome **Arnoldijev algoritam** od prvog do $(k+1)$ -og koraka možemo smatrati **rekurzivnom QR faktorizacijom** matrice $[q_1 \quad AQ_k]$.

GMRES metoda (nastavak)

- U GMRES metodi, aproksimacija rješenja u k -tom koraku tada ima oblik

$$x_k = x_0 + Q_k y_k$$

za neki k -dimenzionalni vektor y_k , tj.

- x_k se dobiva tako da se početnoj aproksimaciji x_0 doda neki vektor iz Krylovljevog potprostora.
- Sada tražimo aproksimaciju za koju $r_k = r_0 - AQ_k y_k$ ima minimalnu euklidsku normu, i za nju vektor y_k mora biti rješenje problema najmanjih kvadrata

$$\min_{y \in \mathbb{R}^k} \|r_0 - AQ_k y\|_2 = \min_{y \in \mathbb{R}^k} \|r_0 - Q_{k+1} H_{k+1,k} y\|_2$$

$$= \min_{y \in \mathbb{R}^k} \|Q_{k+1}(\beta \xi_1 - H_{k+1,k} y)\|_2 = \min_{y \in \mathbb{R}^k} \|\beta \xi_1 - H_{k+1,k} y\|_2,$$

GMRES metoda (nastavak)

gdje je $\beta = \|r_0\|_2$, ξ_1 prvi jedinični $(k + 1)$ -dimenzionalni vektor $[1 \ 0 \ \dots \ 0]^T$.

- Druga jednakost je ostvarena uz korištenje činjenice da je $Q_{k+1}\xi_1 = q_1$ prvi vektor ortonormirane baze koji je jednak $q_1 = r_0/\beta$.

Glavni koraci GMRES algoritma su sljedeći:

- Dana je početna iteracija x_0 , izračunaj $r_0 = b - Ax_0$ i $q_1 = r_0/\|r_0\|_2$.
- Za $k=1,2,\dots$
 - Izračunaj q_{k+1} i h_{ik} , $i = 1, \dots, k + 1$ pomoću Arnoldijevog algoritma.
 - Nađi $x_k = x_0 + Q_k y_k$, gdje je y_k rješenje problema najmanjih kvadrata $\min_y \|\beta \xi_1 - H_{k+1,k} y\|_2$.

GMRES metoda (nastavak)

- Kao što ćemo vidjeti **standardna metoda** za rješavanje problema najmanjih kvadrata sa matricom **punog ranga** je **QR faktorizacija** $(k + 1) \times k$ matrice $H_{k+1,k}$.
- U jednom od sljedećih **teorema** uvjerit ćemo se da je $H_{k+1,k}$ **punog ranga** za
 - **regularnu** matricu A , i
 - u slučaju kada x_k još **nije rješenje** sustava. $H_{k+1,k}$ se svodi na produkt
 - $(k + 1) \times (k + 1)$ **ortogonalne** matrice $G^{(k)T}$ i
 - $(k + 1) \times k$ **gornje trokutaste** matrice $R^{(k)}$.
- **Gornji** $k \times k$ blok matrice $R^{(k)}$ je **gornje trokutasti**, a **zadnji redak** je jednak **nul-vektoru**.

GMRES metoda (nastavak)

$$H_{k+1,k} = G^{(k)T} R^{(k)} = G^{(k)T} \begin{bmatrix} R_{k \times k}^{(k)} \\ 0 \end{bmatrix}$$

- Ta QR faktorizacija može se ostvariti upotrebom **Givensovih rotacija** jer imamo samo **jedan netrivialan element** ispod dijagonale.
- Budući da je

$$\begin{aligned} \|\beta \xi_1 - H_{k+1,k} y\|_2 &= \|G^{(k)T} (\beta G^{(k)} \xi_1 - R^{(k)} y)\|_2 \\ &= \|\beta G^{(k)} \xi_1 - R^{(k)} y\|_2, \end{aligned}$$

i da je $(k + 1)$ -a koordinata vektora $R^{(k)} y$ **jednaka nuli**, rješenje y_k se tada može dobiti **rješavanjem gornje trokutastog sustava**

GMRES metoda (nastavak)

$$R_{k \times k}^{(k)} y = \beta (G^{(k)} \xi_1)_{k \times 1},$$

gdje je $R_{k \times k}^{(k)}$ gornji $k \times k$ blok od $R^{(k)}$, a $(G^{(k)} \xi_1)_{k \times 1}$ je dio od k gornjih elemenata prvog stupca od $G^{(k)}$.

- Važno je primijetiti da je u tom slučaju **apsolutna vrijednost** zadnjeg elementa $(k + 1)$ -dimenzionalnog vektora $\beta G^{(k)} \xi_1$ jednaka **euklidskoj normi reziduala** u k -tom koraku GMRES metode jer

$$\|b - Ax_k\|_2 = \|\beta G^{(k)} \xi_1 - R^{(k)} y_k\|_2,$$

a $\beta G^{(k)} \xi_1 - R^{(k)} y_k$ je **jednak nuli** u svim komponentama osim u zadnjoj, $(k + 1)$ -oj, koja je **jednaka** zadnjem elementu od $\beta G^{(k)} \xi_1$.

GMRES metoda (nastavak)

Promotrimo sada samu QR faktorizaciju matrice $H_{k+1,k}$.

- Ako nam je dana QR faktorizacija matrice $H_{k,k-1}$, tada želimo izračunati QR faktorizaciju sljedeće matrice $H_{k+1,k}$ sa što manje utrošenog posla.
- Da bismo to postigli najprije označimo sa G_i **Givensov** **rotaciju** koja rotira ravninu razapetu sa jediničnim vektorima ξ_i i ξ_{i+1} za kut θ_i :

$$G_i = \begin{bmatrix} I & & & \\ & c_i & s_i & \\ & -s_i & c_i & \\ & & & I \end{bmatrix},$$

gdje je $c_i = \cos(\theta_i)$ i $s_i = \sin(\theta_i)$.

GMRES metoda (nastavak)

- Dimenzija matrice G_i kao i dimenzija drugog identičnog bloka ovisi o kontekstu u kojem se koristi.
- Pretpostavimo da su rotacije G_i , $i = 1, \dots, k$ prethodno bile upotrebljene na matrici $H_{k,k-1}$ tako da je

$$(G_{k-1}G_{k-2} \cdots G_1)H_{k,k-1} = R^{(k-1)} = \begin{bmatrix} x & x & \cdots & x \\ & x & \cdots & x \\ & & \ddots & \vdots \\ & & & x \\ 0 & 0 & \cdots & 0 \end{bmatrix},$$

gdje x -evi označavaju netrivialne elemente.

GMRES metoda (nastavak)

- Tada je

$$G^{(k-1)} = G_{k-1}G_{k-2} \cdots G_1.$$

- Da bismo dobili matricu $R^{(k)}$, prvo trebamo **izmnožiti** zadnji stupac od $H_{k+1,k}$ sa **prethodnim rotacijama**, jer se prvih $k - 1$ stupaca te matrice **poklapa** sa $\begin{bmatrix} H_{k,k-1} \\ 0 \end{bmatrix}$.
- **Trokutasti faktor** matrice u k -tom koraku je zbog toga **jednak trokutastom faktoru** matrice iz $(k - 1)$ -og koraka, samo kojemu je također **dodan još jedan stupac**, pa zato je **dovoljno obraditi** samo novi, k -ti stupac matrice $H_{k+1,k}$.

GMRES metoda (nastavak)

- Time dobivamo

$$(G_{k-1}G_{k-2}\cdots G_1)H_{k+1,k} = \begin{bmatrix} x & x & \dots & x & x \\ & x & \dots & x & x \\ & & \ddots & \vdots & \vdots \\ & & & x & x \\ 0 & 0 & \dots & 0 & d \\ 0 & 0 & \dots & 0 & h \end{bmatrix},$$

čiji je $(k+1, k)$ -i element h upravo $h_{k+1,k}$ budući da na taj element **ne utječu prethodne rotacije**.

- Sljedeća rotacija G_k se bira tako da **eliminira taj element**, odnosno da vrijedi

$$-s_k d + c_k h = 0,$$

GMRES metoda (nastavak)

a to možemo postići ako stavimo da je

$$c_k = \frac{|d|}{\sqrt{d^2 + h^2}}, \quad s_k = \frac{c_k h}{d}, \quad \text{za } d \neq 0, h \neq 0,$$

$$c_k = 0, \quad s_k = 1, \quad \text{za } d = 0,$$

$$(c_k = 1, \quad s_k = 0, \quad \text{za } h = 0).$$

- Primijetimo da ako je $h = 0$, tada je **egzaktno rješenje** linearnog sustava **dostignuto** u k -tom koraku.
- Naime, u tom slučaju je $G_k = I$, pa je zadnja $(k + 1)$ -a komponenta vektora $\beta G^{(k)} \xi_1$ **ostala nepromijenjena**, odnosno jednaka **nuli**.

GMRES metoda (nastavak)

- Budući da je apsolutna vrijednost te zadnje komponente **jednaka** euklidskoj normi reziduala u tom koraku GMRES metode, zaključujemo da je $r_k = 0$.
- Prema tome, ako **egzaktno rješenje** još **nije izračunato**, tada je $h \neq 0$, i k -ti dijagonalni element od $R^{(k)}$ je **različit od nule**.
 - Za $d \neq 0$ taj dijagonalni element je **jednak**

$$c_k d + s_k h = \frac{d}{|d|} \sqrt{d^2 + h^2},$$

- dok za $d = 0$ on je **jednak** h .

Algoritam GMRES metode

Algoritam (GMRES metoda).

x_0 zadan;

$k = 0$;

$r_0 = b - Ax_0$; $\beta = \|r_0\|_2$; $q_1 = \frac{r_0}{\beta}$;

$\ell = [1, 0, \dots, 0]^T$;

dok nije zadovoljen kriterij zaustavljanja radi {
 $k = k + 1$;

Izračunaj q_{k+1} i $H(i, k) = h_{ik}$ za $i = 0, \dots, k + 1$,
koristeći Arnoldijev algoritam.

Primijeni G_0, \dots, G_{k-1} na zadnji stupac od H :
za $i = 1$ do $k - 1$ radi {

$$\left[\begin{array}{c} H(i, k) \\ H(i + 1, k) \end{array} \right] = \left[\begin{array}{cc} c_i & s_i \\ -s_i & c_i \end{array} \right] \left[\begin{array}{c} H(i, k) \\ H(i + 1, k) \end{array} \right];$$

}

Algoritam GMRES metode (nastavak)

Izračunaj k -tu Givensovu rotaciju G_k kako bi se poništio $H(k+1, k)$:

$$c_k = \frac{|H(k, k)|}{\sqrt{H(k, k)^2 + H(k+1, k)^2}};$$

ako je $c_k \neq 0$ tada

$$s_k = c_k \frac{H(k+1, k)}{H(k, k)};$$

inače

$$s_k = 1;$$

Primijeni G_k na ℓ i na k -ti stupac od H :

$$\begin{bmatrix} \ell(k) \\ \ell(k+1) \end{bmatrix} = \begin{bmatrix} c_k & s_k \\ -s_k & c_k \end{bmatrix} \begin{bmatrix} \ell(k) \\ 0 \end{bmatrix};$$

Algoritam GMRES metode (nastavak)

$$\begin{aligned}H(k, k) &= c_k H(k, k) + s_k H(k + 1, k); \\H(k + 1, k) &= 0;\end{aligned}$$

}

ako je (ocjena norme reziduala $\beta|\ell(k + 1)|$
dovoljno mala) tada

Riješi gornje trokutasti sustav

$$H(1 : k, 1 : k)y_k = \beta\ell(1 : k).$$

$$x_k = x_0 + Q_k y_k;$$

}

Svojstva GMRES metode

- Potpun GMRES algoritam može biti nepraktičan zbog
 - velikog zahtjeva za memorijom i
 - brojem operacija,ako je broj iteracija koje su potrebne za rješavanje sustava velik.
- GMRES(j) algoritam se definira tako da restartamo GMRES svakih j koraka, koristeći zadnju iteraciju kao početnu za sljedeći GMRES ciklus.
- Poznati problem vezan uz GMRES sa restartom je taj što on može stagnirati.
- Naime može se dogoditi da pri restartanju ponovno pretražujemo smjerove koje smo već u prethodnom ciklusu pretraživali.

Svojstva GMRES metode (nastavak)

Teorem. Neka su G_i , $i = 1, \dots, k$ matrice rotacija koje su korištene za svođenje matrice $H_{k+1,k}$ na trokutasti oblik, te $R^{(k)} = G^{(k)} H_{k+1,k}$ i $g^{(k)} = \beta G^{(k)} \xi_1$ matrica i desna strana sustava dobivenog tokom rješavanja GMRES metodom.

Označimo sa $R_{k \times k}^{(k)}$ $k \times k$ gornje trokutastu matricu dobivenu iz $R^{(k)} = [R_{ij}^{(k)}]$ brisanjem zadnjeg retka, i sa $g_{k \times 1}^{(k)}$ k -dimenzionalan vektor dobiven iz $g^{(k)} = [g_i^{(k)}]$ brisanjem zadnje komponente. Tada,

- Rang od AQ_k je jednak rangu od $R_{k \times k}^{(k)}$. Posebno, ako je $R_{k,k}^{(k)} = 0$ tada A mora biti singularna.
- Vektor y_k koji minimizira $\|\beta \xi_1 - H_{k+1,k} y\|_2$ dan je sa

$$y_k = (R_{k \times k}^{(k)})^{-1} g_{k \times 1}^{(k)}.$$

Svojstva GMRES metode (nastavak)

- Rezidual u k -tom koraku zadovoljava

$$r_k = b - Ax_k = Q_{k+1}(\beta\xi_1 - H_{k+1,k}y_k) = Q_{k+1}G^{(k)T}(g_{k+1}^{(k)}\xi_{k+1})$$

i, kao rezultat

$$\|r_k\|_2 = \|b - Ax_k\|_2 = |g_{k+1}^{(k)}|.$$

Dokaz.

- Vrijedi

$$AQ_k = Q_{k+1}H_{k+1,k} = Q_{k+1}G^{(k)T}G^{(k)}H_{k+1,k} = Q_{k+1}G^{(k)T}R^{(k)}.$$

Budući da je $Q_{k+1}G^{(k)T}$ ortogonalna, rang od AQ_k je jednak rangu od $R^{(k)}$, koji je opet jednak rangu od $R_{k \times k}^{(k)}$, budući da se te dvije matrice razlikuju samo za zadnji nul-redak od $R^{(k)}$.

Svojstva GMRES metode (nastavak)

Ako je pak $R_{k,k}^{(k)} = 0$ tada je rang od $R_{k \times k}^{(k)}$ manji ili jednak $k - 1$, a kao rezultat je i rang od AQ_k manji ili jednak $k - 1$. Kako je Q_k punog ranga, to znači da je A singularna.

- To je već uglavnom pokazano kod izvoda metode. Ako smo krenuli od regularne matrice A tada je i $R_{k \times k}^{(k)}$ regularna, pa možemo iraćunati rješenje

$$y_k = (R_{k \times k}^{(k)})^{-1} g_{k \times 1}^{(k)}.$$

- Za bilo koji $x = x_0 + Q_k y$ vrijedi

$$\begin{aligned} b - Ax &= Q_{k+1}(\beta \xi_1 - H_{k+1,k} y) \\ &= Q_{k+1} G^{(k)T} G^{(k)} (\beta \xi_1 - H_{k+1,k} y) \\ &= Q_{k+1} G^{(k)T} (g^{(k)} - R^{(k)} y). \end{aligned}$$

Svojstva GMRES metode (nastavak)

Za normu tada vrijedi

$$\|b - Ax\|_2^2 = \|g^{(k)} - R^{(k)}y\|_2^2 = |g_{k+1}^{(k)}|^2 + \|g_{k \times 1}^{(k)} - R_{k \times k}^{(k)}y\|_2^2$$

pa se **minimum** upravo postiže za y_k kada je drugi član gornjeg izraza **jednak nuli**.



Svojstva GMRES metode (nastavak)

Napomena.

- Primijetimo da, kada vektor $\beta\xi_1$ izmnožimo redom sa G_1, G_2, \dots, G_{k-1} , zadnja $k + 1$ -a komponenta tako dobivenog vektora $g^{(k,k-1)}$ ostaje **nepromijenjena**, odnosno **jednaka nuli**.
- To znači da je on oblika

$$g^{(k,k-1)} = [g_1^{(k)} \quad g_2^{(k)} \quad \dots \quad g_{k-1}^{(k)} \quad g_k^{(k-1)} \quad 0]^T.$$

- U zadnjem koraku, kada taj vektor na kraju još **pomnožimo** i sa G_k , dobivamo da je

$$g^{(k)} = [g_1^{(k)} \quad g_2^{(k)} \quad \dots \quad g_{k-1}^{(k)} \quad c_k g_k^{(k-1)} \quad - s_k g_k^{(k-1)}],$$

Svojstva GMRES metode (nastavak)

odnosno dobivamo korisnu jednakost za $g_{k+1}^{(k)}$

$$g_{k+1}^{(k)} = -s_k g_k^{(k-1)}.$$

- Posebno, ako je $s_k = 0$ tada norma reziduala mora biti jednaka nuli, što znači da je egzaktno rješenje dostignuto u k -tom koraku.
- Iz Algoritma se vidi da je $s_k = 0$ samo ako je $h_{k+1,k} = 0$.
- S druge strane, jedini mogući slučaj kada k -ti korak algoritma neće biti izvediv, i kada će doći do prekida GMRES metode, je prekid Arnoldijevog algoritma kada je $\tilde{q}_{k+1} = 0$, odnosno $h_{k+1,k} = 0$.
- U tom slučaju se algoritam zaustavlja jer se sljedeći Arnoldijev vektor neće moći generirati zbog dijeljenja s nulom.

Svojstva GMRES metode (nastavak)

- Ali u tom je slučaju, kao što smo već vidjeli, rezidual je jednak nuli, pa smo dostigli egzaktno rješenje u tom koraku.
- Obrat je također istinit: ako se algoritam zaustavi u k -tom koraku sa $r_k = b - Ax_k = 0$, tada je $h_{k+1,k} = 0$.

Svojstva GMRES metode (nastavak)

Teorem. Neka je A regularna matrica. Tada se GMRES algoritam prekida u k -tom koraku ($h_{k+1,k} = 0$, $k \leq n$) ako i samo ako je aproksimacija x_k jednaka egzaktnom rješenju.

Dokaz. Nužnost smo već pokazali.

- Da bismo dokazali dovoljnost tvrdnje, pretpostavimo da je $r_k = 0$ i pri tome koristimo $g_{k+1}^{(k)} = -s_k g_k^{(k-1)}$.
- Budući da smo u k -tom koraku dostigli egzaktno rješenje, a ne u $(k-1)$ -tom, znači da je $g_k^{(k,k-1)} = g_k^{(k-1)}$ različito od nule, pa onda mora biti $s_k = 0$.
- Ponovo iz Algoritma vidimo da onda mora biti $h_{k+1,k} = 0$. ■

Konvergencija GMRES metode

GMRES algoritam primijenjen na **općeniti** linearni susutav daje u k -tom koraku rezidual koji zadovoljava, **slično** kao kod CG,

$$\|r_k\|_2 = \min_{p_k \in \mathbb{P}_k, p_k(0)=1} \|p_k(A)r_0\|_2,$$

gdje se **minimum** uzima po **svim polinomima** p_k stupnja k ili manje, uz svojstvo da je $p_k(0) = 1$.

Teorem. Neka je x_k **aproksimacija** rješenja ostvarena u k -tom koraku GMRES algoritma, i neka je $r_k = b - Ax_k$. Tada **postoji** $q_{k-1} \in \mathbb{P}_{k-1}$ takav da je x_k oblika

$$x_k = x_0 + q_{k-1}(A)r_0$$

i

$$\|r_k\|_2 = \min_{q_{k-1} \in \mathbb{P}_{k-1}} \|(I - Aq_{k-1}(A))r_0\|_2.$$

Konvergencija GMRES metode (nastavak)

Dokaz.

- Iz definicije metode u k -tom koraku bira se aproksimacija rješenja x_k takva da za

$\mathcal{K}_k(A, r_0) = \text{span}\{r_0, Ar_0, \dots, A^{k-1}r_0\}$ vrijedi

$$\|b - Ax_k\|_2 = \min_{x \in x_0 + \mathcal{K}_k(A, r_0)} \|b - Ax\|_2,$$

(znamo da je x_k oblika $x_k = x_0 + Q_k y_k$, pri čemu stupci od Q_k čine bazu Krylovljevog potprostora $\mathcal{K}_k(A, r_0)$).

- Kako je svaki $x \in x_0 + \mathcal{K}_k(A, r_0)$ oblika $x = x_0 + \sum_{j=0}^{k-1} \alpha_j A^j r_0$, tada možemo pisati

$$x = x_0 + q_{k-1}(A)r_0, \quad \text{za } q_{k-1} \in \mathbb{P}_{k-1}.$$

Konvergenција GMRES metode (nastavak)

U tom slučaju je

$$\begin{aligned}r &= b - Ax = b - Ax_0 - Aq_{k-1}(A)r_0 \\ &= (I - Aq_{k-1}(A))r_0 = p_k(A)r_0,\end{aligned}$$

za $p_k \in \mathbb{P}_k$, sa $p_k(0) = 1$.

Napomena. Za GMRES metodu ne postoji “lijepi” teorem o konvergenčiji za općenite matrice. Ipak, nešto se može reći za dijagonalizabilne matrice.

Konvergencija GMRES metode (nastavak)

Teorem. Pretpostavimo da je A dijagonalizabilna matrica i neka je $A = V\Lambda V^{-1}$ spektralna dekompozicija od A , gdje je $\Lambda = \text{diag}(\lambda_1, \dots, \lambda_n)$ dijagonalna matrica svojstvenih vrijednosti, a stupci regularne matrice V su svojstveni vektori od A . Definirajmo,

$$\epsilon_k = \min_{p_k \in \mathbb{P}_k, p_k(0)=1} \max_{i=1, \dots, n} |p_k(\lambda_i)|.$$

Tada, norma reziduala postignutog u k -tom koraku GMRES metode zadovoljava nejednakost

$$\|r_k\|_2 \leq \kappa(V) \epsilon_k \|r_0\|_2,$$

gdje je $\kappa(V) = \|V\|_2 \|V^{-1}\|_2$.

Konvergencija GMRES metode (nastavak)

Dokaz. Neka je p_k bilo koji polinom **stupnja** manjeg ili jednakog k , koji zadovoljava **uvjet** $p_k(0) = 1$, i neka je $x \in x_0 + \mathcal{K}_k(A, r_0)$ vektor za koji je $r = b - Ax = p_k(A)r_0$ iz $\mathcal{K}_{k+1}(A, r_0)$. Tada

$$\|b - Ax\|_2 = \|V p_k(\Lambda) V^{-1} r_0\|_2 \leq \|V\|_2 \|V^{-1}\|_2 \|p_k(\Lambda)\|_2 \|r_0\|_2.$$

Budući da je Λ **dijagonalna** matrica, vrijedi

$$\|p_k(\Lambda)\|_2 = \max_{i=1, \dots, n} \|p_k(\lambda_i)\|_2.$$

Kako x_k **minimizira** normu reziduala na $x_0 + \mathcal{K}_k(A, r_0)$, tada za **bilo koji polinom** p_k sa gornjim svojstvima vrijedi

$$\|b - Ax_k\|_2 \leq \|b - Ax\|_2 \leq \|V\|_2 \|V^{-1}\|_2 \|r_0\|_2 \max_{i=1, \dots, n} |p_k(\lambda_i)|.$$

Konvergenција GMRES metode (nastavak)

Sada možemo u gornjoj nejednakosti uzeti **polinom** p_k koji **minimizira** desnu stranu nejednakosti, to odgovara odabiru **odgovarajućeg** $x_{min} \in x_0 + \mathcal{K}_k(A, r_0)$. Time dobivamo željeni rezultat


$$\|b - Ax_k\|_2 \leq \|b - Ax_{min}\|_2 \leq \|V\|_2 \|V^{-1}\|_2 \|r_0\|_2 \epsilon_k.$$

Napomena.

- Promatrat ćemo one **matrice** kojima **spektar** možemo smjestiti u neki **pravilni geometrijski lik**, koji je po mogućnosti **udaljen od ishodišta** (ne sadrži ga).
- Najjednostavniji slučaj je kada **spektar** matrice A možemo smjestiti unutar **elipse** $\mathbf{E}(c, d, a)$ sa **centrom** u c , gdje je **udaljenost između fokusa** jednaka $2d$, a **veća poluos** je a .

Konvergenција GMRES metode (nastavak)

Elipsa $\mathbf{E}(c,d,a)$, koja ne sadrži ishodište.



Konvergenција GMRES metode (nastavak)

Korolar. Neka je A dijagonalizabilna matrica, to jest neka je $A = V\Lambda V^{-1}$ gdje je $\Lambda = \text{diag}(\lambda_1, \dots, \lambda_n)$ dijagonalna matrica svojstvenih vrijednosti. **Pretpostavimo** da su sve svojstvene vrijednosti od A smještene unutar ellipse $\mathbf{E}(c, d, a)$ u kojoj se **ne nalazi** ishodište. Tada norma reziduala, postignutog u k -tom koraku GMRES metode, zadovoljava nejednakost

$$\|r_k\|_2 \leq \kappa(V) \frac{T_k\left(\frac{a}{d}\right)}{\left|T_k\left(\frac{c}{d}\right)\right|} \|r_0\|_2,$$

gdje je T_k Čebiševljev polinom stupnja k .

Dokaz. Tehnički! ■

Konvergencija GMRES metode (nastavak)

Napomena.

- Budući da **uvjetovanost** $\kappa(V)$ matrice svojstvenih vektora V obično **nije poznata** i može biti **vrlo velika**, ocjena prethodnog **Korolara** ne mora biti precizna.
- Ona može biti **korisna** jedino ako znamo da je matrica A **normalna**, pa je tada $\kappa(V) = 1$.
- U tom slučaju dobili smo vrlo **primjenljivu ocjenu konvergencije** samo pomoću **analize distribucije svojstvenih vrijednosti**.
- U **normalnom** slučaju, kao i kod **simetričnih matrica**, problem **konvergencije GMRES** metode općenito svodi se na **problem teorije aproksimacija**: kako se dobro može **aproksimirati nula** na skupu **kompleksnih svojstvenih vrijednosti**, **koristeći polinome stupnja k** koji u **ishodištu** poprimaju vrijednost **1** (isto kao kod **CG**).

Konvergenција GMRES metode (nastavak)

- U ovom problemu može se dobro primijeniti informacija o tome da li su svojstvene vrijednosti dobro ili loše distribuirane u kompleksnoj ravnini.
- Svojstvene vrijednosti nakupljene u uskom području oko jedne točke c , daleke od ishodišta daju dobru distribuciju, budući da je vrijednost polinoma $(1 - z/c)^k$ mala u svim točkama kompleksne ravnine koje su bliske točki c (prethodni Korolar).
- Svojstvene vrijednosti koje su raspoređene svuda oko ishodišta su loše distribuirane, jer je nemoguće naći polinom (po principu maksimuma modula analitičke funkcije) čija je vrijednost u ishodištu jednaka 1, a u svakoj točki na nekoj zatvorenoj krivulji oko ishodišta, manja od 1.

Konvergencija GMRES metode (nastavak)

- Također polinom niskog stupnja ne može biti 1 u ishodištu, i malen po apsolutnoj vrijednosti u mnogim točkama distribuiranim svuda oko ishodišta.
- Općenito se, međutim, ponašanje GMRES metode ne može odrediti samo iz svojstava svojstvenih vrijednosti.
- Zapravo, bilo koja nerastuća krivulja može predstavljati graf normi reziduala po broju iteracija za GMRES metodu primijenjenu na nekom ne-normalnom problemu, štoviše, matrica problema može imati bilo koje svojstvene vrijednosti.

Konvergencija GMRES metode (nastavak)

Teorem. Neka je dan **nerastući niz** $f(0) \geq f(1) \geq \dots \geq f(n-1) > 0$ pozitivnih brojeva i **skup kompleksnih brojeva** različitih od nule $\{\lambda_1, \lambda_2, \dots, \lambda_n\}$, tada **postoji** matrica A sa **svojstvenim vrijednostima** $\lambda_1, \lambda_2, \dots, \lambda_n$ i desna strana sustava b sa $\|b\|_2 = f(0)$ takvi da reziduali r_k u **svakom koraku** GMRES algoritma primijenjenog na sustav $Ax = b$ sa $x_0 = 0$, **zadovoljavaju** $\|r_k\|_2 = f(k)$, $k = 1, 2, \dots, n-1$.

Dokaz. Pogledajte primjere! ■

Primjeri konvergencije metoda

Primjer konvergencija CG metode

- U ovom primjeru ćemo pokazati konvergenciju metode konjugiranih gradijenata primijenjenu na dva sustava.
- Matrice oba sustava A_1 i A_2 su simetrične pozitivno definitne 100×100 matrice, sa svojstvenim vrijednostima $\lambda(A_1) \in \{1, 4, 9, \dots, 10000\}$ i $\lambda(A_2) \in \{1, 100, 200, 300, 400, 500, 600, 700, 900, 10000\}$, pri čemu 1 i 10000 imaju kratnost 5, a ostale imaju kratnost 10.
- Dakle, A_1 ima 100 prilično različitih svojstvenih vrijednosti, dok ih A_2 ima 11.
- Matrice su
 - dobivene kao produkt $A_i = Q_i \Lambda_i Q_i^T$, $i = 1, 2$,
 - pri čemu su Λ_i dijagonalne matrice svojstvenih vrijednosti,

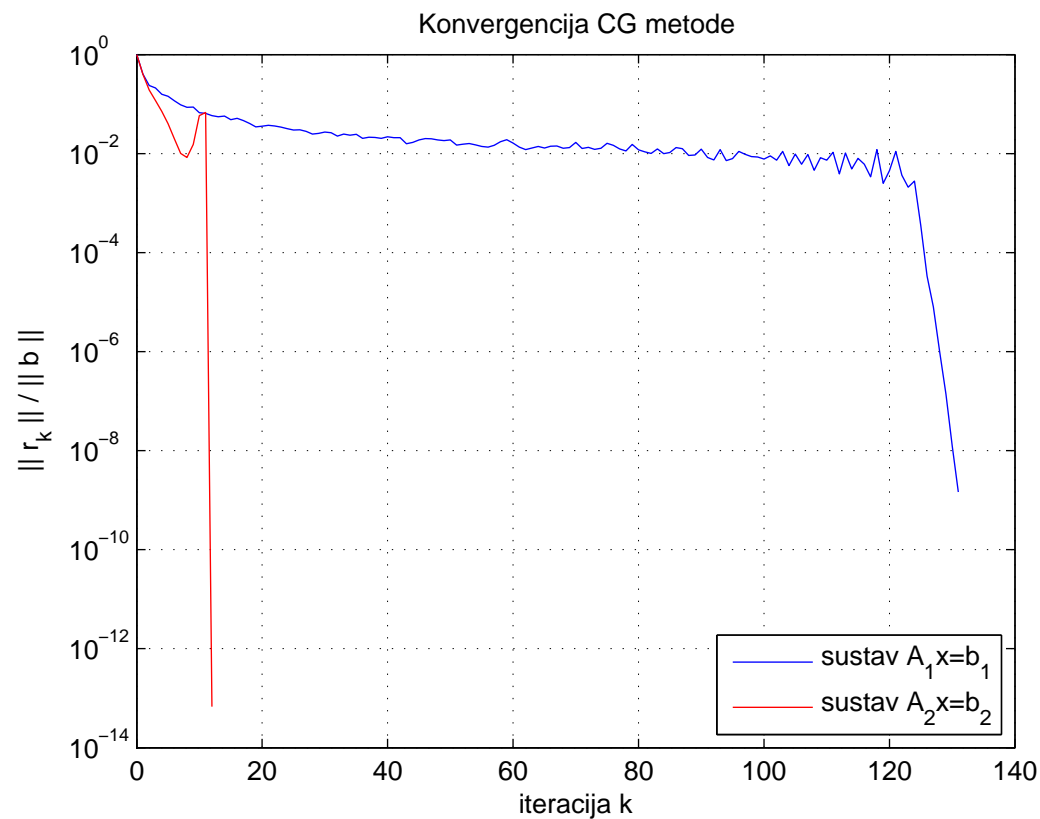
Primjer konvergencija CG metode (nastavak)

- a Q_i slučajne ortogonalne matrice.
- Uvjetovanost obaju matrica jednaka je $\kappa(A_i) = 10^4$.
- Desne strane sustava, b_i određene su tako da rješenje oba sustava bude jednako $x = [1 \ 1 \ \dots \ 1]^T$, odnosno da je $b_i = A_i \cdot x$.
- Za početnu iteraciju u oba slučaja uzet ćemo $x_0 = [0 \ 0 \ \dots \ 0]^T$.
- Iteracije se trebaju zaustaviti kada je relativna norma reziduala $\|r_k\|_2 / \|b\|_2$ manja od $tol = 10^{-8}$.

Pogledajte **MATLAB** program.

Primjer konvergencija CG metode (nastavak)

Konvergencija metode konjugiranih gradijenata za sustave $A_1x = b_1$ i $A_2x = b_2$:



Primjer konvergencija CG metode (nastavak)

- Prema teoriji prvi sustav treba konvergirati u 100 koraka, a drugi u 11. Odstupanja od toga dolaze zbog grešaka zaokruživanja.
- U praksi se iteracije uvijek zaustavljaju kada broj iteracija dostigne dimenziju matrice n .

Primjer konvergencija GMRES metode

Ovaj primjer ilustrira zadnji **Teorem** o **neovisnosti konvergencije GMRES** metode o **svojstvenim vrijedostima** ne-normalne matrice.

● Norme reziduala dobivene u nizu koraka **GMRES** metode su **nerastući niz**, budući da se **reziduali minimiziraju** po skupu **ekspandirajućih podprostora**.

● Postavlja se sljedeće pitanje: ako je dan **nerastući niz** pozitivnih realnih brojeva

$f(0) \geq f(1) \geq \dots \geq f(n-1) > 0$, i skup kompleksnih brojeva $\{\lambda_1, \dots, \lambda_n\} \subset \mathbb{C}$, različitih od nule, **da li tada postoje**

● $n \times n$ matrica A sa **svojstvenim vrijednostima**

$\lambda_1, \dots, \lambda_n$ i

● početni vektor r_0 sa $\|r_0\|_2 = f(0)$,

Primjer konvergencija GMRES metode (nast.)

takvi da kod primjene GMRES algoritma na linearni sustav $Ax = b$, sa početnim rezidualom r_0 , dobijemo aproksimacije x_k takve da je $\|r_k\|_2 = f(k)$, $k = 1, \dots, n - 1$?

- Odgovor na ovo pitanje je potvrđan.
- No, prije samog odgovora primijetimo da pretpostavka $f(n - 1) > 0$ znači da GMRES algoritam ne konvergira k egzaktom rješenju sve do zadnjeg, n -tog, koraka, kada su dimenzije potprostora $\mathcal{K}_n(A, r_0)$ i $A\mathcal{K}_n(A, r_0)$ jednake n .

Primjer konvergencija GMRES metode (nast.)

Započet ćemo najprije sa jednostavnom analizom nekih svojstava traženog rješenja.

- Budući da su reziduali generirani primjenom GMRES algoritma na linearni sustav $Ax = b$, sa početnom aproksimacijom x_0 , potpuno određeni matricom A i početnim rezidualom r_0 , bez smanjenja općenitosti možemo pretpostaviti da je početna aproksimacija x_0 jednaka nuli, i da je vektor desne strane sustava b zapravo početni rezidual.
- Pretpostavimo da A i b predstavljaju nepoznatu matricu i desnu stranu sustava.
- Neka je $\mathcal{W} = \{w_1, \dots, w_n\}$ ortonormirana baza Krylovljevog prostora reziduala $AK_n(A, b)$, takva da je $\text{span}\{w_1, \dots, w_j\} = AK_j(A, b)$, $j = 1, \dots, n$, i neka je $W = [w_1 \ \dots \ w_n]$.

Primjer konvergencija GMRES metode (nast.)

- Prema **Teoremu** o konvergenciji, **minimizacijsko** svojstvo reziduala možemo preformulirati u

$$\|r_k\|_2 = \min_{u \in AK_k(A, b)} \|b - u\|_2,$$

odakle se **vidi** da je $r_k \perp AK_k(A, b)$ za $k = 0, 1, \dots, n - 1$ (kao kod izvoda **CG** metode), pa je on oblika

$$r_k = \sum_{j=k+1}^n \langle b, w_j \rangle w_j,$$

r_n je nula, a $b = r_0$ se može raspisati kao

$$b = \sum_{j=1}^n \langle b, w_j \rangle w_j.$$

Primjer konvergencija GMRES metode (nast.)

- Iz prethodnoga se **vidi** da je

$$|\langle b, w_j \rangle| = \sqrt{\|r_{j-1}\|_2^2 - \|r_j\|_2^2}.$$

- Ako je zadan nerastući pozitivan niz $f(0) \geq f(1) \geq \dots \geq f(n-1) > 0$, **definirajmo** $f(n) = 0$ i nove vrijednosti $g(k)$ sa

$$g(k) = \sqrt{(f(k-1))^2 - (f(k))^2}, \quad k = 1, \dots, n.$$

- Uvjeti $\|b\|_2 = f(0)$, $\|r_k\|_2 = f(k)$, $k = 1, 2, \dots, n-1$ bit će tada **zadovoljeni** ako su **koordinate** od b u **bazi** \mathcal{W} određene sa

$$W^T b = [g(1) \ \dots \ g(n)]^T.$$

Primjer konvergencija GMRES metode (nast.)

- Zaista, u tom slučaju je

$$r_k = \sum_{j=k+1}^n \langle b, w_j \rangle w_j = \sum_{j=k+1}^n g(j) w_j, \text{ pa slijedi}$$

$$\|r_k\|_2^2 = \sum_{j=k+1}^n |g(j)|^2 = \sum_{j=k+1}^n [(f(j-1))^2 - (f(j))^2] = (f(k))^2.$$

- Neka je $\Lambda = \{\lambda_1, \lambda_2, \dots, \lambda_n\}$, $\lambda_j \neq 0$, $j = 1, 2, \dots, n$ skup točaka različitih od nule u kompleksnoj ravnini.
- Promotrimo normirani polinom

$$a(z) = z^n - \sum_{j=0}^{n-1} \alpha_j z^j = (z - \lambda_1)(z - \lambda_2) \cdots (z - \lambda_n).$$

- Zbog toga što su svi λ_j različiti od nule, slijedi $\alpha_0 \neq 0$.

Primjer konvergencija GMRES metode (nast.)

- Matricu A možemo smatrati **linearnim operatorom** na n -dimenzionalnim **Hilbertovim prostorom** \mathbb{R}^n .
- Taj operator označit ćemo sa \mathcal{A} , a njegova **reprezentacija** u **standardnoj bazi** $\mathcal{E} = \{\xi_1, \dots, \xi_n\}$, pri čemu je ξ_i i -ti **jedinični vektor**, daje traženu matricu A :

$$\mathcal{A}^{\mathcal{E}} = A.$$

- A je **jedinstveno određen djelovanjem** na bilo koji skup vektora baze.
- Neka je $\mathcal{V} = \{v_1, \dots, v_n\}$ **bilo koja ortonormirana baza** u \mathbb{R}^n , i neka je $V = [v_1 \ \dots \ v_n]$.
- Neka b zadovoljava

$$V^T b = [g(1) \ \dots \ g(n)]^T$$

Primjer konvergencija GMRES metode (nast.)

pri čemu

- ukoliko je dan b sa $\|b\|_2 = f(0)$, V može biti izabran,
- ili ako je V zadan, b može biti izabran.
- Budući da je $g(n) = f(n-1)$ različit od nule, skup vektora $\mathcal{B} = \{b, v_1, \dots, v_{n-1}\}$ je linearno nezavisan i također tvori bazu za \mathbb{R}^n .
- Neka je $B = [b \ v_1 \ \dots \ v_{n-1}]$.
- Tada je operator A jednostavno određen jednažbama

$$Ab = v_1,$$

$$Av_1 = v_2,$$

$$\vdots$$

Primjer konvergencija GMRES metode (nast.)

$$Av_{n-2} = v_{n-1},$$

$$Av_{n-1} = \alpha_0 b + \alpha_1 v_1 + \cdots + \alpha_{n-1} v_{n-1}.$$

iz svojstva $AK_n(A, r_0) = \mathcal{K}_n(A, r_0)$.

• U **matričnoj** reprezentaciji u **bazi** \mathcal{B} matrica

$$A^{\mathcal{B}} = \begin{bmatrix} 0 & \dots & 0 & \alpha_0 \\ 1 & \dots & 0 & \alpha_1 \\ & \ddots & \vdots & \vdots \\ & & 1 & \alpha_{n-1} \end{bmatrix}$$

tada **ima svojstvene vrijednosti** koje odgovaraju skupu Λ .
(Izračunajte karakteristični polinom!)

Primjer konvergencija GMRES metode (nast.)

• Radi se o matrici koju još nazivamo **pratilac polinoma**.

• Na kraju, matrica A je dana sa

$$A = \mathcal{A}^\varepsilon = B\mathcal{A}^\beta B^{-1}.$$

• Za naš konkretan primjer uzet ćemo:

• skup **svojstvenih vrijednosti**

$$\lambda(A) \in \{e^{\frac{2\pi i}{100}k} : k = 0, 1, \dots, 99\},$$

• niz vrijednosti $f(0) = 100, f(1) = 99,$

$$f(2) = 98, \dots, f(99) = 1, f(100) = 0.$$

• Izračunajmo **koeficijente** polinoma

$$a(z) = z^{100} - \sum_{i=0}^{99} \alpha_i z^i = (z - \lambda_1(A)) \cdots (z - \lambda_{100}(A)),$$

Primjer konvergencija GMRES metode (nast.)

u našem slučaju je $a(z) = z^{100} - 1$, odnosno

$$\alpha_0 = 1, \quad \alpha_1 = \alpha_2 = \cdots = \alpha_{99} = 0,$$

jer se radi o stotim korijenima jedinice.

Pogledajte **MATLAB** program.

Primjer konvergencija CG metode (nastavak)

Konvergencija GMRES metode za sustav $Ax = b$:

