



Prirodoslovno-matematički fakultet
Matematički odsjek
Sveučilište u Zagrebu

ITERATIVNE METODE

Vježbe 03 - Iterativne metode za linearne sustave

15. rujna 2021.

Sastavili: Nela Bosner, Zvonimir Bujanović



- 1 Osnovne iterativne metode
 - 1.1 Jacobijeva metoda
 - 1.2 Gauss-Seidelova metoda
 - 1.3 JOR (Jacobi Over-Relaxation)
 - 1.4 SOR (Successive Over-Relaxation)
- 2 Aproksimacije iz Krilovljevih potprostora
 - 2.1 Metoda najbržeg silaska
 - 2.2 Metoda konjugiranih smjerova
 - 2.3 Metoda konjugiranih gradijenata
 - 2.4 GMRES
- 3 Prekondicioniranje

OSNOVNE ITERATIVNE METODE

Nedostaci Gaussovih eliminacija:

- Prespore za matrice velikih dimenzija: $\mathcal{O}(n^3)$ za $A \in \mathbb{R}^{n \times n}$.
- Matrice u praksi su rijetko popunjene (*sparse*) i ne čuvaju se kao 2D-polje, već se spremaju samo elementi koji nisu jednaki 0. LU-faktorizacija uništava *strukturu nula* u *sparse* matricama.

Nedostaci Gaussovih eliminacija:

- Prespore za matrice velikih dimenzija: $\mathcal{O}(n^3)$ za $A \in \mathbb{R}^{n \times n}$.
- Matrice u praksi su rijetko popunjene (*sparse*) i ne čuvaju se kao 2D-polje, već se spremaju samo elementi koji nisu jednaki 0. LU-faktorizacija uništava *strukturu nula* u *sparse* matricama.

Zato takve sustave rješavamo iterativno:

Algoritam (Općenita iterativna metoda)

```
 $x^{(0)}$  zadan;  
 $k=0$ ;  
while ~uvjet_zaustavljanja  
     $k=k+1$ ;  
     $x^{(k)} = f(x^{(k-1)})$ ;  
end  
 $x \approx x^{(k)}$ 
```

Algoritam (Općenita iterativna metoda)

```
 $x^{(0)}$  zadan;  
 $k=0$ ;  
while ~uvjet_zaustavljanja  
     $k=k+1$ ;  
     $x^{(k)} = f(x^{(k-1)})$ ;  
end  
 $x \approx x^{(k)}$ 
```

Ciljevi:

- Efikasno računanje $x^{(k)}$ pomoću $x^{(k-1)}$ (jednostavna f)
- $x^{(k)} \xrightarrow{k} x$, gdje je $Ax = b$.

Općenita iterativna metoda

Proučavat ćemo metode oblika

$$x^{(k+1)} = R \cdot x^{(k)} + c, \quad k = 0, 1, 2, \dots$$

Ovdje: $R \in \mathbb{R}^{n \times n}$ je **matrica iteracije**, $c \in \mathbb{R}^n$.

Proučavat ćemo metode oblika

$$x^{(k+1)} = R \cdot x^{(k)} + c, \quad k = 0, 1, 2, \dots$$

Ovdje: $R \in \mathbb{R}^{n \times n}$ je **matrica iteracije**, $c \in \mathbb{R}^n$.

Tipičan način konstrukcije metode: $A = M - N$, M regularna.

$$\begin{aligned} Ax &= b \\ (M - N)x &= b \\ Mx &= Nx + b \\ x &= M^{-1}Nx + M^{-1}b \end{aligned}$$

Općenita iterativna metoda

Proučavat ćemo metode oblika

$$x^{(k+1)} = R \cdot x^{(k)} + c, \quad k = 0, 1, 2, \dots$$

Ovdje: $R \in \mathbb{R}^{n \times n}$ je **matrica iteracije**, $c \in \mathbb{R}^n$.

Tipičan način konstrukcije metode: $A = M - N$, M regularna.

$$\begin{aligned} Ax &= b \\ (M - N)x &= b \\ Mx &= Nx + b \\ x &= M^{-1}Nx + M^{-1}b \end{aligned}$$

Odavde dobivamo iterativnu metodu:

$$x^{(k+1)} = \underbrace{M^{-1}N}_R \cdot x^{(k)} + \underbrace{M^{-1}b}_c$$

Teorem

Neka je $A = M - N \in \mathbb{R}^{n \times n}$ regularna matrica i $b \in \mathbb{R}^n$. Niz iteracija $x^{(0)}, x^{(1)}, \dots, x^{(k)}, \dots$ definiran sa

$$x^{(k+1)} = M^{-1}N \cdot x^{(k)} + M^{-1}b$$

konvergira prema $x = A^{-1}b$ za *svaku* početnu iteraciju $x^{(0)}$ ako i samo ako je

- M regularna matrica,
- $\rho(M^{-1}N) < 1$ (spektralni radijus),

Tvrđnja teorema vrijedi i kada drugi uvjet zamijenimo sa

- $\|M^{-1}N\| < 1$ za neku konzistentnu matricnu normu $\|\cdot\|$.

Spektralni radijus: za $A \in \mathbb{C}^{n \times n}$ je

$$\rho(A) := \max\{|\lambda| : \lambda \in \Lambda(A)\}$$

Matrična norma $\|\cdot\|$ je konzistentna ako za sve $A, B \in \mathbb{C}^{n \times n}$ vrijedi:

$$\|AB\| \leq \|A\| \cdot \|B\|.$$

Na primjer: $\|\cdot\|_2$, $\|\cdot\|_1$, $\|\cdot\|_\infty$, $\|\cdot\|_F$.

Spektralni radijus: za $A \in \mathbb{C}^{n \times n}$ je

$$\rho(A) := \max\{|\lambda| : \lambda \in \Lambda(A)\}$$

Matrična norma $\|\cdot\|$ je konzistentna ako za sve $A, B \in \mathbb{C}^{n \times n}$ vrijedi:

$$\|AB\| \leq \|A\| \cdot \|B\|.$$

Na primjer: $\|\cdot\|_2$, $\|\cdot\|_1$, $\|\cdot\|_\infty$, $\|\cdot\|_F$.

Teorem

Za svaku konzistentnu normu $\|\cdot\|$ na $\mathbb{C}^{n \times n}$ i svaku matricu $A \in \mathbb{C}^{n \times n}$ vrijedi:

$$\rho(A) \leq \|A\|.$$

Spektralni radijus, konzistentne norme

Spektralni radijus: za $A \in \mathbb{C}^{n \times n}$ je

$$\rho(A) := \max\{|\lambda| : \lambda \in \Lambda(A)\}$$

Matrična norma $\|\cdot\|$ je konzistentna ako za sve $A, B \in \mathbb{C}^{n \times n}$ vrijedi:

$$\|AB\| \leq \|A\| \cdot \|B\|.$$

Na primjer: $\|\cdot\|_2, \|\cdot\|_1, \|\cdot\|_\infty, \|\cdot\|_F$.

Teorem

Za svaku konzistentnu normu $\|\cdot\|$ na $\mathbb{C}^{n \times n}$ i svaku matricu $A \in \mathbb{C}^{n \times n}$ vrijedi:

$$\rho(A) \leq \|A\|.$$

Za svaku $A \in \mathbb{C}^{n \times n}$ i svaki $\varepsilon > 0$ postoji konzistentna matrična norma $\|\cdot\|_{A,\varepsilon}$ takva da vrijedi:

$$\|A\|_{A,\varepsilon} \leq \rho(A) + \varepsilon.$$

Zadatak 1

Neka vrijede pretpostavke Teorema o konvergenciji iterativne metode za $R = M^{-1}N$. Odredite kriterij zaustavljanja, tj. broj iteracija k dovoljan da vrijedi

$$\|x^{(k)} - x\| < \varepsilon,$$

za zadanu točnost ε .

Neka vrijede pretpostavke Teorema o konvergenciji iterativne metode za $R = M^{-1}N$. Odredite kriterij zaustavljanja, tj. broj iteracija k dovoljan da vrijedi

$$\|x^{(k)} - x\| < \varepsilon,$$

za zadanu točnost ε .

Rješenje.

$$\frac{\|R\|^k}{1 - \|R\|} \cdot \|x^{(1)} - x^{(0)}\| < \varepsilon.$$

Zadatak 2

Dan je sustav $Ax = b$, gdje je

$$A = \begin{bmatrix} 5 & 0 & 0 & 0.1 & 0.1 \\ 5 & 5 & 0 & 0 & 0.1 \\ 0.1 & 0 & 5 & 0 & 0 \\ 0 & 0 & 0 & 5 & 0.1 \\ 0.1 & 0.1 & 5 & 0 & 5 \end{bmatrix}, \quad b = \begin{bmatrix} -9.7 \\ -14.8 \\ -0.2 \\ 5.2 \\ 9.7 \end{bmatrix}$$

Odredite rastav $A = M - N$ i pripadnom iterativnom metodom riješite sustav tako da greška u svakoj nepoznanici bude manja od 10^{-3} .

Rješenje. Stavimo

$$M = \begin{bmatrix} 5 & 0 & 0 & 0 & 0 \\ 5 & 5 & 0 & 0 & 0 \\ 0 & 0 & 5 & 0 & 0 \\ 0 & 0 & 0 & 5 & 0 \\ 0 & 0 & 5 & 0 & 5 \end{bmatrix}, \quad N = \begin{bmatrix} 0 & 0 & 0 & -0.1 & -0.1 \\ 0 & 0 & 0 & 0 & -0.1 \\ -0.1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & -0.1 \\ -0.1 & -0.1 & 0 & 0 & 0 \end{bmatrix}$$

Rješenje. Stavimo

$$M = \begin{bmatrix} 5 & 0 & 0 & 0 & 0 \\ 5 & 5 & 0 & 0 & 0 \\ 0 & 0 & 5 & 0 & 0 \\ 0 & 0 & 0 & 5 & 0 \\ 0 & 0 & 5 & 0 & 5 \end{bmatrix}, \quad N = \begin{bmatrix} 0 & 0 & 0 & -0.1 & -0.1 \\ 0 & 0 & 0 & 0 & -0.1 \\ -0.1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & -0.1 \\ -0.1 & -0.1 & 0 & 0 & 0 \end{bmatrix}$$

1 inv(M)

| | | | | |
|---------|--------|---------|--------|--------|
| 0.2000 | 0 | 0 | 0 | 0 |
| -0.2000 | 0.2000 | 0 | 0 | 0 |
| 0 | 0 | 0.2000 | 0 | 0 |
| 0 | 0 | 0 | 0.2000 | 0 |
| 0 | 0 | -0.2000 | 0 | 0.2000 |

Rješenje.

1 $R = M \setminus N$

| | | | | |
|---------|---------|---|---------|---------|
| 0 | 0 | 0 | -0.0200 | -0.0200 |
| 0 | 0 | 0 | 0.0200 | 0 |
| -0.0200 | 0 | 0 | 0 | 0 |
| 0 | 0 | 0 | 0 | -0.0200 |
| 0.0000 | -0.0200 | 0 | 0 | 0 |

Rješenje.

```
1 R = M \ N
```

| | | | | |
|---------|---------|---|---------|---------|
| 0 | 0 | 0 | -0.0200 | -0.0200 |
| 0 | 0 | 0 | 0.0200 | 0 |
| -0.0200 | 0 | 0 | 0 | 0 |
| 0 | 0 | 0 | 0 | -0.0200 |
| 0.0000 | -0.0200 | 0 | 0 | 0 |

Želimo $\|x^{(k)} - x\|_\infty < 10^{-3}$. Da li metoda konvergira?

```
1 norm( R, 'inf' )
```

```
0.0400
```

Dakle, metoda $x^{(k+1)} = Rx^{(k)} + c$ konvergira jer $\|R\|_\infty < 1$, uz $c = M \setminus b = [-1.94 \ -1.02 \ -0.04 \ 1.04 \ 1.98]'$.

Rješenje. Koliko iteracija je potrebno?

Stavimo $x^{(0)} = 0$; tada $x^{(1)} = c$ i $\|x^{(1)} - x^{(0)}\|_\infty = \|c\|_\infty = 1.98$.

Prethodni zadatak: dovoljno je osigurati

$$\begin{aligned}\frac{\|R\|_\infty^k}{1 - \|R\|_\infty} \|c\|_\infty &< 10^{-3} \\ \frac{(0.04)^k}{0.96} \cdot 1.98 &< 10^{-3} \\ (0.04)^k &< 4.85 \cdot 10^{-4} \\ k \log(0.04) &< \log(4.85 \cdot 10^{-4}) \\ k &> 2.3709\end{aligned}$$

Dakle, možemo uzeti $k = 3$.

Rješenje.

- 1 $x_0 = [0; 0; 0; 0; 0];$
- 2 $x_1 = R \cdot x_0 + c$
- 3 $x_2 = R \cdot x_1 + c$
- 4 $x_3 = R \cdot x_2 + c$

| $x_1 =$ | $x_2 =$ | $x_3 =$ |
|------------|------------|------------|
| -1.9400000 | -2.0004000 | -2.0000160 |
| -1.0200000 | -0.9992000 | -0.9999920 |
| -0.0400000 | -0.0012000 | 0.0000080 |
| 1.0400000 | 1.0004000 | 0.9999920 |
| 1.9800000 | 2.0004000 | 1.9999840 |

Rješenje.

- 1 $x_0 = [0; 0; 0; 0; 0];$
- 2 $x_1 = R \cdot x_0 + c$
- 3 $x_2 = R \cdot x_1 + c$
- 4 $x_3 = R \cdot x_2 + c$

| $x_1 =$ | $x_2 =$ | $x_3 =$ |
|------------|------------|------------|
| -1.9400000 | -2.0004000 | -2.0000160 |
| -1.0200000 | -0.9992000 | -0.9999920 |
| -0.0400000 | -0.0012000 | 0.0000080 |
| 1.0400000 | 1.0004000 | 0.9999920 |
| 1.9800000 | 2.0004000 | 1.9999840 |

Egzaktno rješenje je $x = [-2 \ -1 \ 0 \ 1 \ 2]'$.

Zaista, $\|x - x^{(3)}\| < 10^{-3}$.

Jacobijeva metoda

Rastavimo $A = D + L + U$.

D =dijagonala, L =donji trokut, U =gornji trokut od A .

Jacobi: $M_J = D$, $N_J = -L - U$, odnosno,

$$x^{(k+1)} = \underbrace{-D^{-1}(L + U)}_{R_J} \cdot x^{(k)} + \underbrace{D^{-1}b}_{c_J}.$$

Jacobijeva metoda

Rastavimo $A = D + L + U$.

D =dijagonala, L =donji trokut, U =gornji trokut od A .

Jacobi: $M_J = D$, $N_J = -L - U$, odnosno,

$$x^{(k+1)} = \underbrace{-D^{-1}(L + U)}_{R_J} \cdot x^{(k)} + \underbrace{D^{-1}b}_{c_J}.$$

Teorem

Ako je matrica sustava $A \in \mathbb{C}^{n \times n}$ *strogo dijagonalno dominantna*, tj. ako je

$$\sum_{\substack{j=1 \\ j \neq i}}^n |A_{ij}| < |A_{ii}|, \quad i = 1, 2, \dots, n,$$

onda Jacobijeva metoda konvergira za svaku početnu iteraciju.
(Tada je $\|R_J\|_\infty < 1$.)

Algoritam (Jacobi)

$x^{(0)}$ zadan.

for $k = 0, 1, 2, \dots$

for $i = 1, 2, \dots, n$

$$x_i^{(k+1)} = \frac{1}{A_{ii}} \left(b_i - \sum_{j=1}^{i-1} A_{ij}x_j^{(k)} - \sum_{j=i+1}^n A_{ij}x_j^{(k)} \right)$$

end

end

Iz i -te jednadžbe izrazimo x_i pomoću ostalih varijabli.

Za aproksimaciju $x_i^{(k+1)}$ koristimo vrijednosti preostalih x -eva iz k -tog koraka.

U implementaciji se koriste dva vektora za $x^{(k)}$.

Rastavimo $A = D + L + U$.

D =dijagonala, L =donji trokut, U =gornji trokut od A .

Gauss-Seidel: $M_{GS} = D + L$, $N_{GS} = -U$, odnosno,

$$x^{(k+1)} = \underbrace{-(D + L)^{-1}U}_{R_{GS}} \cdot x^{(k)} + \underbrace{(D + L)^{-1}b}_{c_{GS}}.$$

Gauss-Seidelova metoda

Rastavimo $A = D + L + U$.

D =dijagonala, L =donji trokut, U =gornji trokut od A .

Gauss-Seidel: $M_{GS} = D + L$, $N_{GS} = -U$, odnosno,

$$x^{(k+1)} = \underbrace{-(D + L)^{-1}U}_{R_{GS}} \cdot x^{(k)} + \underbrace{(D + L)^{-1}b}_{c_{GS}}.$$

Teorem

Ako je matrica sustava $A \in \mathbb{C}^{n \times n}$ *simetrična i pozitivno definitna*, onda Gauss-Seidelova metoda konvergira za svaku početnu iteraciju.

Ako je matrica sustava $A \in \mathbb{C}^{n \times n}$ *strogo dijagonalno dominantna*, onda Gauss-Seidelova metoda konvergira za svaku početnu iteraciju.

Algoritam (Gauss-Seidel)

$x^{(0)}$ zadan.

for $k = 0, 1, 2, \dots$

for $i = 1, 2, \dots, n$

$$x_i^{(k+1)} = \frac{1}{A_{ii}} \left(b_i - \sum_{j=1}^{i-1} A_{ij} x_j^{(k+1)} - \sum_{j=i+1}^n A_{ij} x_j^{(k)} \right)$$

end

end

Iz i -te jednadžbe izrazimo x_i pomoću ostalih varijabli.

Za aproksimaciju $x_i^{(k+1)}$ koristimo vrijednosti preostalih x -eva:

- iz $k + 1$ -vog koraka ako smo ih već ranije izračunali:

$$x_1^{(k+1)}, x_2^{(k+1)}, \dots, x_{i-1}^{(k+1)};$$

- iz k -tog koraka ako ih još nismo izračunali: $x_{i+1}^{(k)}, x_{i+2}^{(k)}, \dots, x_n^{(k)}$.

U implementaciji se koristi samo jedan vektor za $x^{(k)}$.

Zadatak 3

Napišite funkcije

$$\begin{aligned}x_k &= \text{Jacobi}(A, b, x_0, k_{\text{Max}}) \\x_k &= \text{GaussSeidel}(A, b, x_0, k_{\text{Max}})\end{aligned}$$

koje vraćaju aproksimaciju rješenja sustava $Ax = b$ nakon k_{Max} koraka Jacobijeve, odnosno Gauss-Seidelove metode s početnom iteracijom x_0 .

Pomoću ovih metoda riješite sustav $Ax = b$ uz

$$A = \begin{bmatrix} 10 & 1 & 0 & 1 \\ 1 & 10 & 1 & 0 \\ 0 & 1 & 10 & 1 \\ 1 & 0 & 1 & 10 \end{bmatrix}, \quad b = \begin{bmatrix} -8 \\ 0 \\ 12 \\ 20 \end{bmatrix}$$

tako da greška u svakoj koordinati ne prelazi 10^{-3} .

Rješenje. Jacobi:

$$R_J = -D^{-1}(L+U) = -\frac{1}{10} \begin{bmatrix} 0 & 1 & 0 & 1 \\ 1 & 0 & 1 & 0 \\ 0 & 1 & 0 & 1 \\ 1 & 0 & 1 & 0 \end{bmatrix}, \quad c_J = D^{-1}b = \begin{bmatrix} -0.8 \\ 0 \\ 1.2 \\ 2 \end{bmatrix}$$

Rješenje. Jacobi:

$$R_J = -D^{-1}(L+U) = -\frac{1}{10} \begin{bmatrix} 0 & 1 & 0 & 1 \\ 1 & 0 & 1 & 0 \\ 0 & 1 & 0 & 1 \\ 1 & 0 & 1 & 0 \end{bmatrix}, \quad c_J = D^{-1}b = \begin{bmatrix} -0.8 \\ 0 \\ 1.2 \\ 2 \end{bmatrix}$$

Metoda konvergira jer je $\rho(R_J) \leq \|R_J\|_\infty = 0.2 < 1$.

Rješenje. Jacobi:

$$R_J = -D^{-1}(L+U) = -\frac{1}{10} \begin{bmatrix} 0 & 1 & 0 & 1 \\ 1 & 0 & 1 & 0 \\ 0 & 1 & 0 & 1 \\ 1 & 0 & 1 & 0 \end{bmatrix}, \quad c_J = D^{-1}b = \begin{bmatrix} -0.8 \\ 0 \\ 1.2 \\ 2 \end{bmatrix}$$

Metoda konvergira jer je $\rho(R_J) \leq \|R_J\|_\infty = 0.2 < 1$.

Broj koraka (uz $x^{(0)} = 0$):

$$\|x^{(k)} - x\|_\infty \leq \frac{\|R_J\|_\infty^k}{1 - \|R_J\|_\infty} \cdot \|c_J\|_\infty < 10^{-3}$$

Slijedi $k > 4.8614$, tj. dovoljno je uzeti $k = 5$.

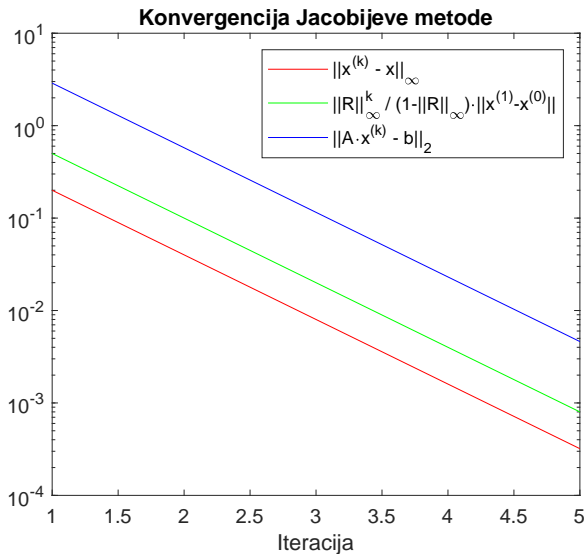
Rješenje. Jacobi:

$$x^{(1)} = \begin{bmatrix} -0.8 \\ 0 \\ 1.2 \\ 2.0 \end{bmatrix}, \quad x^{(2)} = \begin{bmatrix} -1 \\ -0.04 \\ 1.0 \\ 1.96 \end{bmatrix}, \quad x^{(3)} = \begin{bmatrix} -0.992 \\ 0 \\ 1.008 \\ 2.0 \end{bmatrix}$$

$$x^{(4)} = \begin{bmatrix} -1.0 \\ -0.0016 \\ 1.0 \\ 1.9984 \end{bmatrix}, \quad x^{(5)} = \begin{bmatrix} -0.99968 \\ 0 \\ 1.00032 \\ 2.0 \end{bmatrix}$$

Zadatak 3

Rješenje.



Rješenje. Gauss-Seidel:

$$R_{GS} = -(D + L)^{-1}U = \begin{bmatrix} 0 & -0.1 & 0 & -0.1 \\ 0 & 0.01 & -0.1 & 0.01 \\ 0 & -0.001 & 0.01 & -0.101 \\ 0 & 0.0101 & -0.001 & 0.0201 \end{bmatrix}$$

$$c_{GS} = (D + L)^{-1}b = \begin{bmatrix} -0.8 \\ 0.08 \\ 1.192 \\ 1.9608 \end{bmatrix}$$

Rješenje. Gauss-Seidel:

$$R_{GS} = -(D + L)^{-1}U = \begin{bmatrix} 0 & -0.1 & 0 & -0.1 \\ 0 & 0.01 & -0.1 & 0.01 \\ 0 & -0.001 & 0.01 & -0.101 \\ 0 & 0.0101 & -0.001 & 0.0201 \end{bmatrix}$$

$$c_{GS} = (D + L)^{-1}b = \begin{bmatrix} -0.8 \\ 0.08 \\ 1.192 \\ 1.9608 \end{bmatrix}$$

Metoda konvergira jer je $\rho(R_{GS}) \leq \|R_{GS}\|_{\infty} = 0.2 < 1$.

Rješenje. Gauss-Seidel:

$$R_{GS} = -(D + L)^{-1}U = \begin{bmatrix} 0 & -0.1 & 0 & -0.1 \\ 0 & 0.01 & -0.1 & 0.01 \\ 0 & -0.001 & 0.01 & -0.101 \\ 0 & 0.0101 & -0.001 & 0.0201 \end{bmatrix}$$

$$c_{GS} = (D + L)^{-1}b = \begin{bmatrix} -0.8 \\ 0.08 \\ 1.192 \\ 1.9608 \end{bmatrix}$$

Metoda konvergira jer je $\rho(R_{GS}) \leq \|R_{GS}\|_{\infty} = 0.2 < 1$.

Broj koraka (uz $x^{(0)} = 0$):

$$\|x^{(k)} - x\|_{\infty} \leq \frac{\|R_{GS}\|_{\infty}^k}{1 - \|R_{GS}\|_{\infty}} \cdot \|c_{GS}\|_{\infty} < 10^{-3}$$

Slijedi $k > 4.8491$, tj. dovoljno je uzeti $k = 5$.

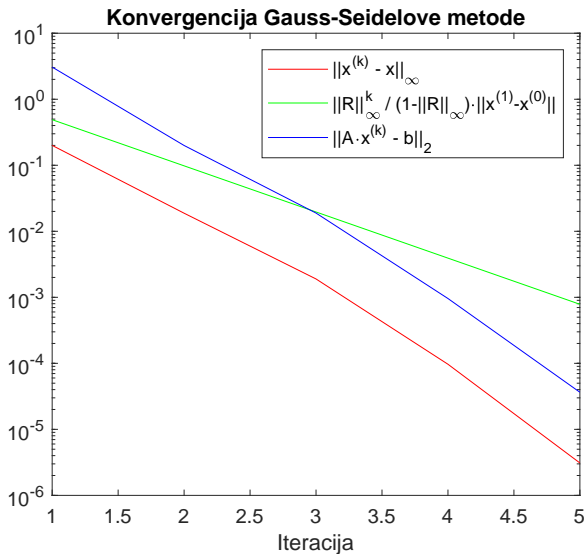
Rješenje. Gauss-Seidel:

$$x^{(1)} = \begin{bmatrix} -0.8 \\ 0.08 \\ 1.192 \\ 1.9608 \end{bmatrix}, \quad x^{(2)} = \begin{bmatrix} -1.00408 \\ -0.018792 \\ 1.005799 \\ 1.99982808 \end{bmatrix}, \quad x^{(3)} = \begin{bmatrix} -0.99810 \\ -0.0007695 \\ 1.00009414 \\ 1.9998009 \end{bmatrix}$$

$$x^{(4)} = \begin{bmatrix} -0.999903 \\ -0.00001910 \\ 1.0000218 \\ 1.9999881 \end{bmatrix}, \quad x^{(5)} = \begin{bmatrix} -0.999997 \\ -0.00000249 \\ 1.0000014 \\ 1.9999995 \end{bmatrix}$$

Zadatak 3

Rješenje.



Uz $\rho(R_J) \approx 1$, konvergencija Jacobijeve metode je spora.
 Uvodimo **parametar relaksacije** ω s ciljem da smanjimo spektralni radijus matrice iteracije i ubrzamo konvergenciju.

Rastavimo $A = (\frac{1}{\omega}D) + (\frac{\omega-1}{\omega}D + L + U)$.
 D =dijagonala, L =donji trokut, U =gornji trokut od A .

JOR(ω): $M_{JOR(\omega)} = \frac{1}{\omega}D$, $N_{JOR(\omega)} = \frac{1-\omega}{\omega}D - L - U$, odnosno,

$$\begin{aligned} x^{(k+1)} &= \underbrace{((1-\omega)I + \omega R_J)}_{R_{JOR(\omega)}} \cdot x^{(k)} + \underbrace{\omega D^{-1}b}_{C_{JOR(\omega)}} \\ &= (1-\omega)x^{(k)} + \omega x_J^{(k+1)}. \end{aligned}$$

JOR(1) = Jacobi.

Teorem

Ako *konvergira Jacobijeva metoda*, onda konvergira i JOR(ω) za svaki $\omega \in \langle 0, 1 \rangle$ i za svaku početnu iteraciju.

Neka je matrica sustava $A \in \mathbb{C}^{n \times n}$ *simetrična i pozitivno definitna*, te $\mu_1 \geq \mu_2 \geq \dots \geq \mu_n$ svojstvene vrijednosti od R_J . Ako je $\mu_j < 1$ za sve j , onda JOR(ω) konvergira za:

$$0 < \omega < \frac{2}{1 - \mu_n} \leq 2,$$

za svaku početnu iteraciju.

JOR(ω) ne konvergira za $\omega < 0$ ni za $\omega \geq 2$.

Algoritam (JOR(ω))

$x^{(0)}$ zadan.

for $k = 0, 1, 2, \dots$

for $i = 1, 2, \dots, n$

$$x_i^{(k+1)} = (1 - \omega)x_i^{(k)} + \frac{\omega}{A_{ii}} \left(b_i - \sum_{j=1}^{i-1} A_{ij}x_j^{(k)} - \sum_{j=i+1}^n A_{ij}x_j^{(k)} \right)$$

end

end

Iz i -te jednadžbe izrazimo x_i pomoću ostalih varijabli, napravimo težinsku sredinu s trenutnim rješenjem.

Za aproksimaciju $x_i^{(k+1)}$ koristimo vrijednosti preostalih x -eva iz k -tog koraka.

U implementaciji se koriste dva vektora za $x^{(k)}$.

Zadatak 4

Napišite funkciju $x_k = \text{JOR}(\omega, A, b, x_0, k_{\text{Max}})$ koja vraća aproksimaciju rješenja sustava $Ax = b$ nakon k_{Max} koraka JOR(ω) metode s početnom iteracijom x_0 .

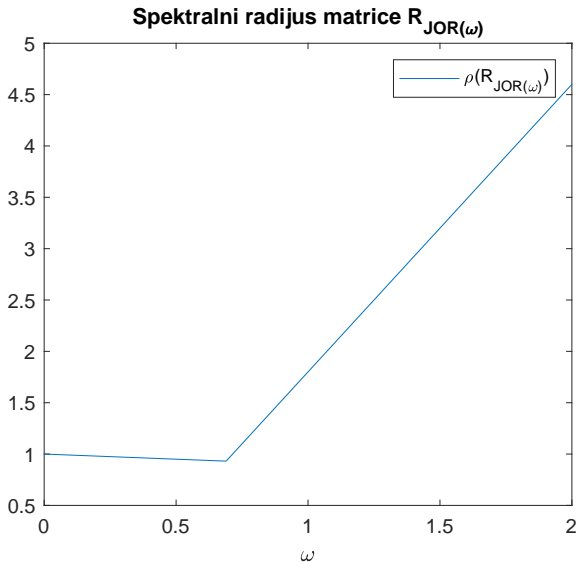
Odredite za koje $\omega \in \mathbb{R}$ metoda JOR(ω) konvergira ako je matrica sustava

$$A = \begin{bmatrix} 1 & 0.9 & 0.9 \\ 0.9 & 1 & 0.9 \\ 0.9 & 0.9 & 1 \end{bmatrix}.$$

Za koji ω je konvergencija najbrža?

Zadatak 4

Rješenje. Napravite ovaj graf uz samo 1 poziv funkcije `eig`!



Rješenje. Za $\omega = 0.689655$, $\mathbf{b}=[1;2;3]$, $\mathbf{x}_0=[0;0;0]$:

$$\mathbf{x}^{(1)} = \begin{bmatrix} 0.689655 \\ 1.37931 \\ 2.068965 \end{bmatrix}, \quad \mathbf{x}^{(2)} = \begin{bmatrix} -1.236622 \\ 0.0951254 \\ 1.426873 \end{bmatrix}, \quad \mathbf{x}^{(3)} = \begin{bmatrix} -0.638813 \\ 1.2907449 \\ 3.220302 \end{bmatrix}$$

$$\mathbf{x}^{(4)} = \begin{bmatrix} -2.308557 \\ 0.1775825 \\ 2.663722 \end{bmatrix}, \quad \mathbf{x}^{(5)} = \begin{bmatrix} -1.790362 \\ 1.2139745 \\ 4.218311 \end{bmatrix}, \quad \mathbf{x}^{(120)} = \begin{bmatrix} -9.283961 \\ 0.7141508 \\ 10.71226 \end{bmatrix}$$

Uz $\rho(R_{GS}) \approx 1$, konvergencija Gauss-Seidelove metode je spora.
 Uvodimo **parametar relaksacije** ω s ciljem da smanjimo spektralni radijus matrice iteracije i ubrzamo konvergenciju.

Rastavimo $A = (\frac{1}{\omega}D + L) + (\frac{\omega-1}{\omega}D + U)$.
 D =dijagonala, L =donji trokut, U =gornji trokut od A .

SOR(ω): $M_{SOR(\omega)} = \frac{1}{\omega}D + L$, $N_{SOR(\omega)} = \frac{1-\omega}{\omega}D - U$, odnosno,

$$x^{(k+1)} = \underbrace{(D + \omega L)^{-1}((1 - \omega)D - \omega U)}_{R_{SOR(\omega)}} \cdot x^{(k)} + \underbrace{\omega(D + \omega L)^{-1}b}_{c_{SOR(\omega)}}$$

$$\neq (1 - \omega)x^{(k)} + \omega x_{GS}^{(k+1)}.$$

$$\text{Ali, } x_i^{(k+1)} = (1 - \omega)x_i^{(k)} + \omega x_{i,GS}^{(k+1)}.$$

SOR(1) = Gauss-Seidel.

Teorem

Ako je matrica sustava $A \in \mathbb{C}^{n \times n}$ *simetrična i pozitivno definitna*, onda $SOR(\omega)$ konvergira za svaki $\omega \in \langle 0, 2 \rangle$.

$SOR(\omega)$ ne konvergira za $\omega < 0$ ni za $\omega \geq 2$.

Algoritam (SOR(ω))

$x^{(0)}$ zadan.

for $k = 0, 1, 2, \dots$

for $i = 1, 2, \dots, n$

$$x_i^{(k+1)} = (1 - \omega)x_i^{(k)} + \frac{\omega}{A_{ii}} \left(b_i - \sum_{j=1}^{i-1} A_{ij}x_j^{(k+1)} - \sum_{j=i+1}^n A_{ij}x_j^{(k)} \right)$$

end

end

Iz i -te jednadžbe izrazimo x_i pomoću ostalih varijabli, napravimo težinsku sredinu s trenutnim rješenjem.

Za aproksimaciju $x_i^{(k+1)}$ koristimo vrijednosti preostalih x -eva:

- iz $k + 1$ -vog koraka ako smo ih već ranije izračunali:

$$x_1^{(k+1)}, x_2^{(k+1)}, \dots, x_{i-1}^{(k+1)};$$

- iz k -tog koraka ako ih još nismo izračunali: $x_{i+1}^{(k)}, x_{i+2}^{(k)}, \dots, x_n^{(k)}$.

U implementaciji se koristi samo jedan vektor za $x^{(k)}$.

Zadatak 5

Napišite funkciju $x_k = \text{SOR}(w, A, b, x_0, k_{\text{Max}})$ koja vraća aproksimaciju rješenja sustava $Ax = b$ nakon k_{Max} koraka $\text{SOR}(w)$ metode s početnom iteracijom x_0 .

Grafički odredite za koje $w \in \mathbb{R}$ metoda $\text{SOR}(w)$ konvergira ako je matrica sustava


$$A = \begin{bmatrix} 16 & -4 & 8 & 12 \\ -4 & 4 & -7 & 3 \\ 8 & -7 & 78 & 32 \\ 12 & 3 & 32 & 113 \end{bmatrix}.$$

Grafički odredite w za kojeg je konvergencija najbrža.

Riješite sustav uz $b = [32; -4; 111; 160]$ za $w = 1$ i za optimalni w tako da bude $\|Ax^{(k)} - b\| < 10^{-5}$.

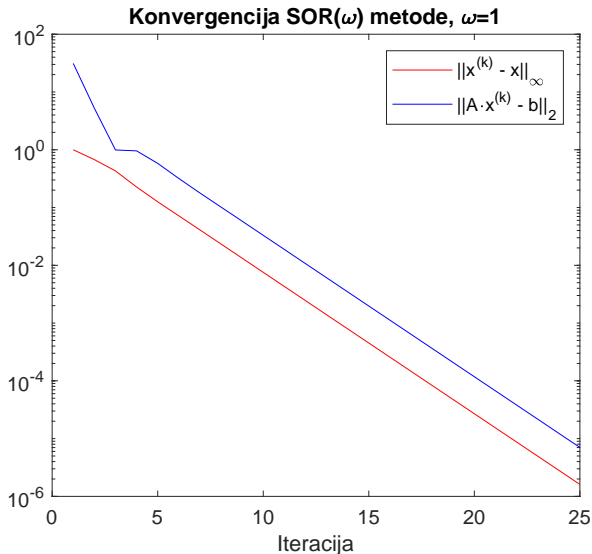
Zadatak 5

Rješenje.



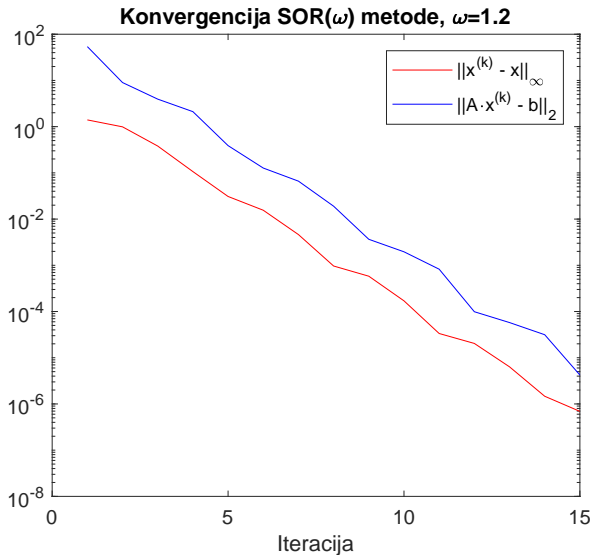
Zadatak 5

Rješenje. $\omega = 1 \Rightarrow 25$ iteracija



Zadatak 5

Rješenje. $\omega = 1.2 \Rightarrow 15$ iteracija



Rješenje. Za $\omega = 1.2$:

$$x^{(1)} = \begin{bmatrix} 2.4 \\ 1.68 \\ 1.593230 \\ 0.798335 \end{bmatrix}, \quad x^{(2)} = \begin{bmatrix} 0.749559 \\ 1.990753 \\ 1.118154 \\ 1.000531 \end{bmatrix}, \quad x^{(3)} = \begin{bmatrix} 1.275942 \\ 1.380626 \\ 0.983135 \\ 0.958333 \end{bmatrix}$$

$$x^{(4)} = \begin{bmatrix} 1.106617 \\ 1.053899 \\ 1.016567 \\ 0.987399 \end{bmatrix}, \quad x^{(5)} = \begin{bmatrix} 0.996246 \\ 1.030848 \\ 1.006674 \\ 0.999747 \end{bmatrix}, \quad x^{(15)} = \begin{bmatrix} 1.000000 \\ 1.000000 \\ 1.000000 \\ 0.999999 \end{bmatrix}$$

APROKSIMACIJE IZ KRILOVLJEVIH POTPROSTORA

Karakteristični polinom matrice $A \in \mathbb{C}^{n \times n}$:

$$\kappa_A(\xi) := \det(A - \xi I) = a_n \xi^n + a_{n-1} \xi^{n-1} + \dots + a_1 \xi + a_0$$

Karakteristični polinom matrice $A \in \mathbb{C}^{n \times n}$:

$$\kappa_A(\xi) := \det(A - \xi I) = a_n \xi^n + a_{n-1} \xi^{n-1} + \dots + a_1 \xi + a_0$$

Matrica poništava svoj karakteristični polinom:

$$\kappa_A(A) = a_n \cdot A^n + a_{n-1} \cdot A^{n-1} + \dots + a_1 \cdot A + a_0 I = 0$$

Inverz matrice kao polinom

Karakteristični polinom matrice $A \in \mathbb{C}^{n \times n}$:

$$\kappa_A(\xi) := \det(A - \xi I) = a_n \xi^n + a_{n-1} \xi^{n-1} + \dots + a_1 \xi + a_0$$

Matrica poništava svoj karakteristični polinom:

$$\kappa_A(A) = a_n \cdot A^n + a_{n-1} \cdot A^{n-1} + \dots + a_1 \cdot A + a_0 I = 0$$

Ako je A regularna, onda $a_0 \neq 0$ i

$$A^{-1} = -\frac{1}{a_0} (a_n \cdot A^{n-1} + a_{n-1} \cdot A^{n-2} + \dots + a_2 \cdot A + a_1 I)$$

Karakteristični polinom matrice $A \in \mathbb{C}^{n \times n}$:

$$\kappa_A(\xi) := \det(A - \xi I) = a_n \xi^n + a_{n-1} \xi^{n-1} + \dots + a_1 \xi + a_0$$

Matrica poništava svoj karakteristični polinom:

$$\kappa_A(A) = a_n \cdot A^n + a_{n-1} \cdot A^{n-1} + \dots + a_1 \cdot A + a_0 I = 0$$

Ako je A regularna, onda $a_0 \neq 0$ i

$$A^{-1} = -\frac{1}{a_0} (a_n \cdot A^{n-1} + a_{n-1} \cdot A^{n-2} + \dots + a_2 \cdot A + a_1 I)$$

Dakle, $A^{-1} = p(A)$, za neki **polinom** stupnja $n - 1$.

Ako je $Ax = b$, onda $x = A^{-1}b = p(A)b$.

Za vektor $v \in \mathbb{C}^n$ definiramo **Krilovljev potprostor**

$$\mathcal{K}_k(A, v) := \text{span}\{v, Av, A^2v, \dots, A^{k-1}v\}.$$

Dakle, ako je $Ax = b$, onda je $x \in \mathcal{K}_n(A, b)$.

Za vektor $v \in \mathbb{C}^n$ definiramo **Krilovljev potprostor**

$$\mathcal{K}_k(A, v) := \text{span}\{v, Av, A^2v, \dots, A^{k-1}v\}.$$

Dakle, ako je $Ax = b$, onda je $x \in \mathcal{K}_n(A, b)$.

Očekujemo da će već za $k \ll n$ u prostoru $\mathcal{K}_k(A, b)$ postojati **dobre aproksimacije** za x .

Za vektor $v \in \mathbb{C}^n$ definiramo **Krilovljev potprostor**

$$\mathcal{K}_k(A, v) := \text{span}\{v, Av, A^2v, \dots, A^{k-1}v\}.$$

Dakle, ako je $Ax = b$, onda je $x \in \mathcal{K}_n(A, b)$.

Očekujemo da će već za $k \ll n$ u prostoru $\mathcal{K}_k(A, b)$ postojati **dobre aproksimacije** za x .

Zašto Krilovljevi potprostori?

- Matrica sustava A je toliko velika ili je tako zadana da je jedina operacija koju možemo s njom izvesti oblika $v \mapsto Av$ (tzv. "matvec").

Brzinu konvergencije obično mjerimo u broju operacija $v \mapsto Av$.

Oznake:

- $x^{(k)}$ – k-ta iteracija
- $e^{(k)} = x - x^{(k)}$ – greška u k-tom koraku
- $r^{(k)} = b - Ax^{(k)}$ – rezidual u k-tom koraku

Uoči: $r^{(k)} = Ae^{(k)}$.

Oznake:

- $x^{(k)}$ – k-ta iteracija
- $e^{(k)} = x - x^{(k)}$ – greška u k-tom koraku
- $r^{(k)} = b - Ax^{(k)}$ – rezidual u k-tom koraku

Uoči: $r^{(k)} = Ae^{(k)}$.

Iteracije:

$$x^{(k+1)} = x^{(k)} + \alpha_k(b - Ax^{(k)}) = x^{(k)} + \alpha_k r^{(k)} = x^{(k)} + \alpha_k Ae^{(k)}$$

Vrijednost α_k ćemo odabrati tako da $x^{(k+1)}$ bude u nekom smislu optimalan.

Oznake:

- $x^{(k)}$ – k-ta iteracija
- $e^{(k)} = x - x^{(k)}$ – greška u k-tom koraku
- $r^{(k)} = b - Ax^{(k)}$ – rezidual u k-tom koraku

Uoči: $r^{(k)} = Ae^{(k)}$.

Iteracije:

$$x^{(k+1)} = x^{(k)} + \alpha_k(b - Ax^{(k)}) = x^{(k)} + \alpha_k r^{(k)} = x^{(k)} + \alpha_k Ae^{(k)}$$

Vrijednost α_k ćemo odabrati tako da $x^{(k+1)}$ bude u nekom smislu optimalan.

Uoči: $e^{(k+1)} = e^{(k)} - \alpha_k Ae^{(k)}$, $r^{(k+1)} = r^{(k)} - \alpha_k Ar^{(k)}$.

Uoči:

$$x^{(0)} = x - e^{(0)} \in x + \text{span}\{e^{(0)}\}$$

$$x^{(1)} = x^{(0)} + \alpha_0 A e^{(0)} = x - e^{(0)} + \alpha_0 A e^{(0)} \in x + \text{span}\{e^{(0)}, A e^{(0)}\}$$

$$\begin{aligned} x^{(2)} &= x^{(1)} + \alpha_1 A e^{(1)} = x^{(1)} + \alpha_1 A (e^{(0)} - \alpha_0 A e^{(0)}) \\ &\in x + \text{span}\{e^{(0)}, A e^{(0)}, A^2 e^{(0)}\} \end{aligned}$$

...

$$x^{(k)} \in x + \mathcal{K}_{k+1}(e^{(0)}, A)$$

Kako odabrati α_k ?

- $\|e^{(k+1)}\| \rightarrow \min$? Ali $e^{(k+1)} = x - x^{(k+1)}$, x nepoznat

Kako odabrati α_k ?

- $\|e^{(k+1)}\| \rightarrow \min$? Ali $e^{(k+1)} = x - x^{(k+1)}$, x nepoznat

Definiramo **A-normu** i **A-skalarni produkt**: za simetričnu, pozitivno definitnu A i vektor v je

$$\|v\|_A := \sqrt{v^T A v}, \quad \langle u, v \rangle_A := v^T A u$$

(DZ: Dokažite da su ovo zaista norma, odnosno skal. produkt.)

Kako odabrati α_k ?

- $\|e^{(k+1)}\| \rightarrow \min$? Ali $e^{(k+1)} = x - x^{(k+1)}$, x nepoznat

Definiramo **A-normu** i **A-skalarni produkt**: za simetričnu, pozitivno definitnu A i vektor v je

$$\|v\|_A := \sqrt{v^T A v}, \quad \langle u, v \rangle_A := v^T A u$$

(DZ: Dokažite da su ovo zaista norma, odnosno skal. produkt.)

Definirajmo $f(\alpha_k) := \|e^{(k+1)}\|_A$.

Cilj: naći α_k tako da $f(\alpha_k)$ minimalno.

$$\begin{aligned}f(\alpha_k) &= (e^{(k+1)})^\top A e^{(k+1)} \\&= (e^{(k+1)})^\top r^{(k+1)} \\&= (e^{(k)} - \alpha_k A e^{(k)})^\top (r^{(k)} - \alpha_k A r^{(k)}) \\&= (e^{(k)} - \alpha_k r^{(k)})^\top (r^{(k)} - \alpha_k A r^{(k)}) \\&= \alpha_k^2 \cdot (r^{(k)})^\top A r^{(k)} - 2\alpha_k (r^{(k)})^\top r^{(k)} + (e^{(k)})^\top A e^{(k)} \\&\rightarrow \min_{\alpha_k}\end{aligned}$$

$$\begin{aligned}f(\alpha_k) &= (e^{(k+1)})^T A e^{(k+1)} \\&= (e^{(k+1)})^T r^{(k+1)} \\&= (e^{(k)} - \alpha_k A e^{(k)})^T (r^{(k)} - \alpha_k A r^{(k)}) \\&= (e^{(k)} - \alpha_k r^{(k)})^T (r^{(k)} - \alpha_k A r^{(k)}) \\&= \alpha_k^2 \cdot (r^{(k)})^T A r^{(k)} - 2\alpha_k (r^{(k)})^T r^{(k)} + (e^{(k)})^T A e^{(k)} \\&\rightarrow \min_{\alpha_k}\end{aligned}$$

Uvjet optimalnosti:

$$0 = f'(\alpha_k) = 2\alpha_k (r^{(k)})^T A r^{(k)} - 2(r^{(k)})^T r^{(k)}$$

Slijedi:

$$\alpha_k = \frac{(r^{(k)})^T r^{(k)}}{(r^{(k)})^T A r^{(k)}}.$$

Algoritam (Metoda najbržeg silaska: A simetrična, poz. definitna)

$x^{(0)}$ zadan.

$$r^{(0)} = b - Ax^{(0)}$$

for $k = 0, 1, 2, \dots$

$$\alpha_k = \frac{(r^{(k)})^T r^{(k)}}{(r^{(k)})^T A r^{(k)}}$$

$$x^{(k+1)} = x^{(k)} + \alpha_k r^{(k)}$$

$$r^{(k+1)} = r^{(k)} - \alpha_k A r^{(k)}$$

end

Uoči:

$$(r^{(k)})^T r^{(k+1)} = (r^{(k)})^T r^{(k)} - \alpha_k (r^{(k)})^T A r^{(k)} = 0,$$

tj. rezidual $r^{(k+1)} = A e^{(k+1)}$ je okomit (pazi, ne A -okomit!) na $r^{(k)}$, pa je $e^{(k+1)}$ A -okomit na $r^{(k)}$.

Uoči:

$$(r^{(k)})^T r^{(k+1)} = (r^{(k)})^T r^{(k)} - \alpha_k (r^{(k)})^T A r^{(k)} = 0,$$

tj. rezidual $r^{(k+1)} = Ae^{(k+1)}$ je okomit (pazi, ne A -okomit!) na $r^{(k)}$, pa je $e^{(k+1)}$ A -okomit na $r^{(k)}$.

Zato možemo primjeniti A -Pitagorin poučak:

$$\|e^{(k)}\|_A^2 = \|e^{(k+1)} + \alpha_k r^{(k)}\|_A^2 = \|e^{(k+1)}\|_A^2 + \alpha_k^2 \|r^{(k)}\|_A^2 > \|e^{(k+1)}\|_A^2,$$

to jest, greška monotono pada.

(Ako je $r^{(k)} = 0$, onda je $x^{(k)}$ egzaktno rješenje od $Ax = b$.)

Teorem (konvergencija metode najbržeg silaska)

Neka je A simetrična, pozitivno definitna matrica, te neka je

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

Tada vrijedi:

$$\|e^{(k)}\|_A \leq \frac{\kappa - 1}{\kappa + 1} \cdot \|e^{(k-1)}\|_A,$$

odnosno,

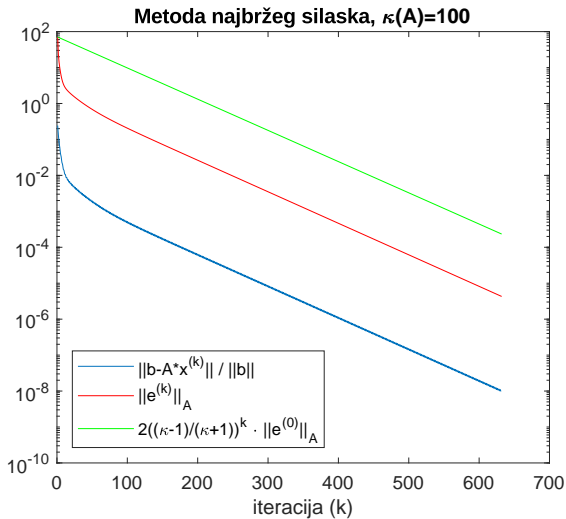
$$\|e^{(k)}\|_A \leq \left(\frac{\kappa - 1}{\kappa + 1}\right)^k \cdot \|e^{(0)}\|_A.$$

Napišite funkciju `x=najbrziSilazak(A,b,x0)` koja metodom najbržeg silaska računa aproksimaciju rješenja linearnog sustava $Ax = b$, uz početnu iteraciju x_0 . Iteracije zaustavite kada bude $\|r^{(k)}\| / \|b\| < 10^{-8}$.

Metodu testirajte za matricu $A = U\Lambda U^T$, pri čemu je U slučajna ortogonalna matrica, te $\Lambda = \text{diag}(1, 2, \dots, 100)$. Neka je $x_0 = 0$, te b takav da je vektor $x=[1; 1; \dots; 1]$ egzaktno rješenje sustava.

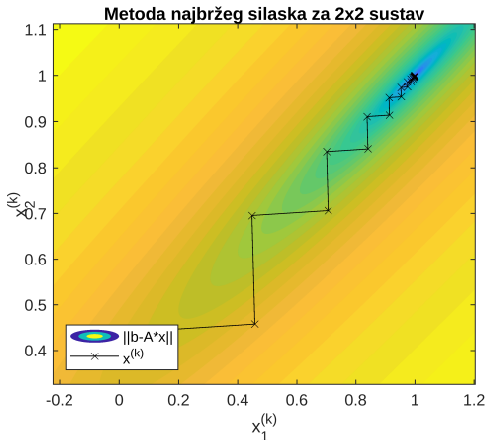
Usporedite $e^{(k)}$ s ocjenom iz Teorema o konvergenciji.

Rješenje.



Metoda konjugiranih smjerova

Metoda najbržeg silaska često radi korake u smjeru koji se već ranije pojavio (tj. $r^{(k)}$ se može ponavljati) → potencijalno spora konv.



Rješenje: unaprijed odaberemo skup **A-ortogonalnih** vektora $\{d_0, d_1, \dots, d_{n-1}\}$ i definiramo

$$x^{(k+1)} := x^{(k)} + \alpha_k d_k.$$

Uoči: $e^{(k+1)} = e^{(k)} - \alpha_k d_k$, $r^{(k+1)} = r^{(k)} - \alpha_k A d_k$.

Rješenje: unaprijed odaberemo skup **A-ortogonalnih** vektora $\{d_0, d_1, \dots, d_{n-1}\}$ i definiramo

$$x^{(k+1)} := x^{(k)} + \alpha_k d_k.$$

Uoči: $e^{(k+1)} = e^{(k)} - \alpha_k d_k$, $r^{(k+1)} = r^{(k)} - \alpha_k A d_k$.

Skalar α_k opet odaberemo tako da je $\|e^{(k+1)}\|_A$ minimalna, tj.

$$\alpha_k = \frac{d_k^T r^{(k)}}{d_k^T A d_k}.$$

Lako se vidi da $\langle e^{(k)}, d_0 \rangle_A = \langle e^{(k)}, d_1 \rangle_A = \dots = \langle e^{(k)}, d_{k-1} \rangle_A = 0$, te

$$e^{(k)} \in \text{span}\{d_k, d_{k+1}, \dots, d_{n-1}\}.$$

Preciznije, ako je

$$e^{(0)} = \xi_0 d_0 + \xi_1 d_1 + \dots + \xi_k d_k + \xi_{k+1} d_{k+1} + \dots + \xi_{n-1} d_{n-1},$$

onda je

$$e^{(k)} = \xi_k d_k + \xi_{k+1} d_{k+1} + \dots + \xi_{n-1} d_{n-1}.$$

Dakle, $e^{(n)} = 0$, tj. metoda (u egzaktnoj aritmetici) daje egzaktno rješenje u n koraka.

Algoritam (Metoda konjugiranih smjerova: A **simetrična, poz. definitna**)

$x^{(0)}$ *zadan.*

Odaberi d_0, d_1, \dots, d_{n-1} tako da budu A -ortogonalni.

$$r^{(0)} = b - Ax^{(0)}$$

for $k = 0, 1, 2, \dots$

$$\alpha_k = \frac{d_k^T r^{(k)}}{d_k^T A d_k}$$

$$x^{(k+1)} = x^{(k)} + \alpha_k d_k$$

$$r^{(k+1)} = r^{(k)} - \alpha_k A d_k$$

end

Neka svojstva:

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

$$d_j^T r^{(k)} = d_j^T A e^{(k)} = 0, \quad j < k$$

$$d_j^T r^{(0)} = d_j^T r^{(1)} = \dots = d_j^T r^{(j)}$$

$$\alpha_k = \frac{d_k^T r^{(0)}}{d_k^T A d_k}$$

Neka svojstva:

$$\begin{aligned}d_j^T A d_i &= 0, \quad i \neq j \\d_j^T r^{(k)} &= d_j^T A e^{(k)} = 0, \quad j < k \\d_j^T r^{(0)} &= d_j^T r^{(1)} = \dots = d_j^T r^{(j)} \\ \alpha_k &= \frac{d_k^T r^{(0)}}{d_k^T A d_k}\end{aligned}$$

Kako odabrati d_0, d_1, \dots, d_{n-1} ?

A-Gram-Schmidtovim postupkom na linearno nezavisne vektore

u_0, u_1, \dots, u_{n-1} :

$$d_k = u_k - \beta_0 d_0 - \beta_1 d_1 - \dots - \beta_{k-1} d_{k-1},$$

$$\beta_j = \frac{\langle u_k, d_j \rangle_A}{\langle d_j, d_j \rangle_A} = \frac{d_j^T A u_k}{d_j^T A d_j}.$$

Zadatak 7

Napišite funkciju $Q = \text{mgsA}(A, X)$ koja modificiranim A-Gram-Schmidovim postupkom redom A-ortogonalizira stupce matrice X i sprema ih kao stupce matrice Q .

Napišite funkciju $x = \text{konjugiraniSmjerovi}(A, b, x_0, D)$ koja metodom konjugiranih smjerova računa aproksimaciju rješenja linearnog sustava $Ax = b$, uz početnu iteraciju x_0 . Iteracije zaustavite kada bude $\|r^{(k)}\| / \|b\| < 10^{-8}$. Konjugirani smjerovi su stupci matrice D .

Metodu testirajte za matricu $A = U\Lambda U^T$, pri čemu je U slučajna ortogonalna matrica, te $\Lambda = \text{diag}(1, 2, \dots, 100)$. Neka je $x_0 = 0$, te b takav da je vektor $x = [1; 1; \dots; 1]$ egzaktno rješenje sustava.

Usporedite s metodom najbržeg silaska.

Metoda konjugiranih gradijenata (CG):

- metoda konjugiranih smjerova
- d_0, \dots, d_{n-1} dobivamo A-Gram-Schmidtovim postupkom na vektorima $r^{(0)}, r^{(1)}, \dots, r^{(n-1)}$.

Metoda konjugiranih gradijenata (CG):

- metoda konjugiranih smjerova
- d_0, \dots, d_{n-1} dobivamo A-Gram-Schmidtovim postupkom na vektorima $r^{(0)}, r^{(1)}, \dots, r^{(n-1)}$.

Pokazat ćemo:

$$d_k = r^{(k)} - \beta_{k-1}d_{k-1}, \quad \beta_{k-1} = \frac{-(r^{(k)})^T r^{(k)}}{(r^{(k-1)})^T r^{(k-1)}}$$

tj. $\beta_0 = \beta_1 = \dots = \beta_{k-2} = 0$ u A-Gram-Schmidtovom postupku

$$d_k = r^{(k)} - \beta_0 d_0 - \beta_1 d_1 - \dots - \beta_{k-1} d_{k-1}.$$

Svojstvo A-Gram-Schmidtovog postupka:

$$\text{span}\{d_0, d_1, \dots, d_{k-1}\} = \text{span}\{r^{(0)}, r^{(1)}, \dots, r^{(k-1)}\}.$$

Kako je CG metoda konjugiranih smjerova, vrijedi $d_j^T r^{(k)} = 0$, za $j < k$, pa onda i

$$(r^{(j)})^T r^{(k)} = 0, \quad i \neq j.$$

$$d_k = r^{(k)} - \beta_0 d_0 - \beta_1 d_1 - \dots - \beta_{k-1} d_{k-1},$$

$$\beta_j = \frac{d_j^T A r^{(k)}}{d_j^T A d_j}$$

Uoči: $(r^{(j+1)})^T r^{(k)} = (r^{(j)})^T r^{(k)} - \alpha_j d_j^T A r^{(k)}$, pa je

$$d_j^T A r^{(k)} = 0, \quad j < k - 1$$

$$d_{k-1}^T A r^{(k)} = \frac{-(r^{(k)})^T r^{(k)} + (r^{(k-1)})^T r^{(k)}}{\alpha_{k-1}} = \frac{-(r^{(k)})^T r^{(k)}}{\alpha_{k-1}} = \frac{-(r^{(k)})^T r^{(k)}}{\alpha_{k-1}},$$

Slijedi $\beta_j = 0$, za $j = 0, 1, \dots, k-2$, te

$$\beta_{k-1} = \frac{-(r^{(k)})^T r^{(k)}}{\alpha_{k-1} d_{k-1}^T A d_{k-1}} = \frac{-(r^{(k)})^T r^{(k)}}{d_{k-1}^T r^{(k-1)}} = \frac{-(r^{(k)})^T r^{(k)}}{(r^{(k-1)})^T r^{(k-1)}},$$

jer je $\alpha_{k-1} = \frac{d_{k-1}^T r^{(k-1)}}{d_{k-1}^T A d_{k-1}}$, te $d_{k-1} = r^{(k-1)} - \xi d_{k-2}$, a $d_{k-2}^T r^{(k-1)} = 0$.

Slično, zbog $d_k^T r^{(k)} = (r^{(k)})^T r^{(k)}$, možemo pisati

$$\alpha_k = \frac{d_k^T r^{(k)}}{d_k^T A d_k} = \frac{(r^{(k)})^T r^{(k)}}{d_k^T A d_k}.$$

Algoritam (Metoda konjugiranih gradijenata: A **simetrična, poz. def.**)

$x^{(0)}$ *zadan.*

$$d_0 = r^{(0)} = b - Ax^{(0)}$$

for $k = 0, 1, 2, \dots$

$$\alpha_k = \frac{(r^{(k)})^T r^{(k)}}{d_k^T A d_k}$$

$$x^{(k+1)} = x^{(k)} + \alpha_k d_k$$

$$r^{(k+1)} = r^{(k)} - \alpha_k A d_k$$

$$\beta_k = \frac{-(r^{(k+1)})^T r^{(k+1)}}{(r^{(k)})^T r^{(k)}}$$

$$d_{k+1} = r^{(k+1)} - \beta_k d_k$$

end

Može se pokazati da vektor $e^{(k)}$ ima najmanju A -normu od svih vektora iz mnogostrukosti

$$e^{(0)} + \text{span}\{Ae^{(0)}, A^2e^{(0)}, \dots, A^ke^{(0)}\}.$$

Metoda konjugiranih gradijenata – konvergencija

Može se pokazati da vektor $e^{(k)}$ ima najmanju A -normu od svih vektora iz mnogostrukosti

$$e^{(0)} + \text{span}\{Ae^{(0)}, A^2e^{(0)}, \dots, A^k e^{(0)}\}.$$

Možemo pisati:

$$e^{(k)} = e^{(0)} + \tau_1 Ae^{(0)} + \tau_2 A^2 e^{(0)} + \dots + \tau_k A^k e^{(0)} = \pi(A)e^{(0)},$$

za neki polinom $\pi \in \mathcal{P}_k$ stupnja k takav da je $\pi(0) = 1$.

Metoda konjugiranih gradijenata – konvergencija

Može se pokazati da vektor $e^{(k)}$ ima najmanju A -normu od svih vektora iz mnogostrukosti

$$e^{(0)} + \text{span}\{Ae^{(0)}, A^2e^{(0)}, \dots, A^ke^{(0)}\}.$$

Možemo pisati:

$$e^{(k)} = e^{(0)} + \tau_1 Ae^{(0)} + \tau_2 A^2e^{(0)} + \dots + \tau_k A^k e^{(0)} = \pi(A)e^{(0)},$$

za neki polinom $\pi \in \mathcal{P}_k$ stupnja k takav da je $\pi(0) = 1$.

Dakle, ako je $\hat{\pi}$ polinom za kojeg se postiže

$$\min_{\substack{\pi \in \mathcal{P}_k \\ \pi(0)=1}} \left\| \pi(A)e^{(0)} \right\|_A,$$

onda je $e^{(k)} = \hat{\pi}(A)e^{(0)}$.

Metoda konjugiranih gradijenata – konvergencija

Za poz.def. $A = U\Lambda U^T$ je $A^{1/2} = U\Lambda^{1/2}U^T$ i $\pi(A) = U\pi(\Lambda)U^T$, pa imamo:

$$\begin{aligned}\|e^{(k)}\|_A &= \min_{\substack{\pi \in \mathcal{P}_k \\ \pi(0)=1}} \|\pi(A)e^{(0)}\|_A \\ &= \min_{\substack{\pi \in \mathcal{P}_k \\ \pi(0)=1}} \sqrt{(e^{(0)})^T \pi(A)^T A \pi(A) e^{(0)}} \\ &= \min_{\substack{\pi \in \mathcal{P}_k \\ \pi(0)=1}} \sqrt{(e^{(0)})^T \pi(A)^T A^{1/2} A^{1/2} \pi(A) e^{(0)}} \\ &= \min_{\substack{\pi \in \mathcal{P}_k \\ \pi(0)=1}} \|A^{1/2} \pi(A) e^{(0)}\|_2 = \min_{\substack{\pi \in \mathcal{P}_k \\ \pi(0)=1}} \|\pi(A) A^{1/2} e^{(0)}\|_2 \\ &\leq \min_{\substack{\pi \in \mathcal{P}_k \\ \pi(0)=1}} \|\pi(A)\|_2 \cdot \|A^{1/2} e^{(0)}\|_2 \\ &= \min_{\substack{\pi \in \mathcal{P}_k \\ \pi(0)=1}} \|\pi(\Lambda)\|_2 \cdot \|e^{(0)}\|_A\end{aligned}$$

Vrijedi:

$$\min_{\substack{\pi \in \mathcal{P}_k \\ \pi(0)=1}} \|\pi(\Lambda)\|_2 = \min_{\substack{\pi \in \mathcal{P}_k \\ \pi(0)=1}} \max_{\lambda \in \Lambda(A)} |\pi(\lambda)|.$$

Ocjenu za $e^{(k)}$ dobivamo tako da za π uvrstimo neki konkretni polinom stupnja k za kojeg vrijedi $\pi(0) = 1$.

Uvrštavanjem Čebiševljevog polinoma za interval $[\lambda_{\min}(A), \lambda_{\max}(A)]$ dobivamo:

Teorem (konvergencija metode konjugiranih gradijenata)

Neka je A simetrična, pozitivno definitna matrica, te neka je $\kappa = \frac{\lambda_{\max}(A)}{\lambda_{\min}(A)}$. Tada:

$$\|e^{(k)}\|_A \leq 2 \left(\frac{\sqrt{\kappa} - 1}{\sqrt{\kappa} + 1} \right)^k \cdot \|e^{(0)}\|_A.$$

Zadatak 8

Napišite funkciju $x = \text{CG}(A, b, x_0)$ koja CG-metodom računa aproksimaciju rješenja linearnog sustava $Ax = b$, uz početnu iteraciju x_0 . Iteracije zaustavite kada bude $\|r^{(k)}\| / \|b\| < 10^{-8}$.


Metodu testirajte za matricu $A = U\Lambda U^T$, pri čemu je U slučajna ortogonalna matrica, te

- (a) $\Lambda = \text{diag}(1, 2^2, 3^2, \dots, 100^2)$.
- (b) $\Lambda = \text{diag}(1, 2, 3, \dots, 100)$.
- (c) $\Lambda = \text{diag}(1, 1, 3, 3, 5, 5, \dots, 97, 97, 99, 100)$.
- (d) $\Lambda = \text{diag}(\underbrace{1, \dots, 1}_{10}, \underbrace{20, \dots, 20}_{10}, \dots, 90, \underbrace{100, \dots, 100}_{10})$.


Neka je $x_0 = 0$, te b takav da je vektor $x = [1; 1; \dots; 1]$ egzaktno rješenje sustava.

Usporedite sa ocjenom iz teorema i objasnite dobivene rezultate!


Rješenje. (a)



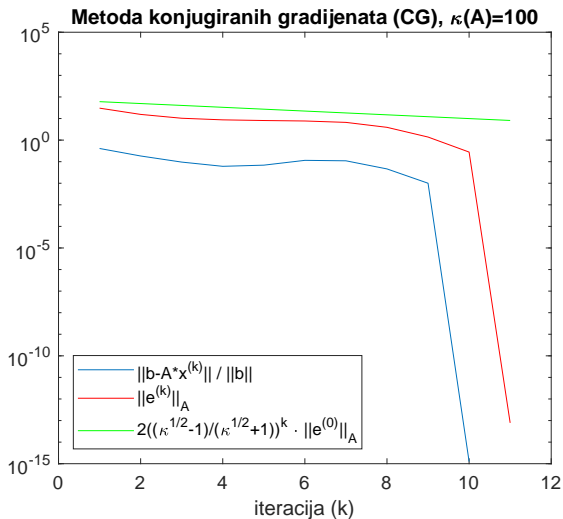
Rješenje. (b)



Rješenje. (c)



Rješenje. (d)



CG:

- simetrična, pozitivno definitna matrica sustava
- $x^{(k)} \in x^{(0)} + \mathcal{K}_k(A, r^{(0)})$
- $r^{(k)} = \min_{\substack{\pi \in \mathcal{P}_k \\ \pi(0)=1}} \|\pi(A)r^{(0)}\|_A$
- kratke rekurzivne formule za update $x^{(k)}, r^{(k)}$; ne treba baza za $\mathcal{K}_k(A, r^{(0)})$

CG:

- simetrična, pozitivno definitna matrica sustava
- $x^{(k)} \in x^{(0)} + \mathcal{K}_k(A, r^{(0)})$
- $r^{(k)} = \min_{\substack{\pi \in \mathcal{P}_k \\ \pi(0)=1}} \|\pi(A)r^{(0)}\|_A$
- kratke rekurzivne formule za update $x^{(k)}, r^{(k)}$; ne treba baza za $\mathcal{K}_k(A, r^{(0)})$

GMRES (Generalized Minimal RESidual):

- proizvoljna (regularna) matrica sustava
- $x^{(k)} \in x^{(0)} + \mathcal{K}_k(A, r^{(0)})$
- $r^{(k)} = \min_{\substack{\pi \in \mathcal{P}_k \\ \pi(0)=1}} \|\pi(A)r^{(0)}\|_2$
- složeniji izračun $x^{(k)}$; treba baza za $\mathcal{K}_k(A, r^{(0)})$

$[r^{(0)}, Ar^{(0)}, A^2r^{(0)}, \dots, A^{k-1}r^{(0)}]$ je loša baza za $\mathcal{K}_k(r^{(0)}, A)$.

$[r^{(0)}, Ar^{(0)}, A^2r^{(0)}, \dots, A^{k-1}r^{(0)}]$ je loša baza za $\mathcal{K}_k(r^{(0)}, A)$.

Ortonormirana baza je numerički stabilna:

- gradimo redom o-n baze za $\mathcal{K}_1 \leq \mathcal{K}_2 \leq \mathcal{K}_3 \dots$
- pretp. da smo dosad sagradili $V^{(k)} = [v_1 \ v_2 \ \dots \ v_k]$ – o-n bazu za \mathcal{K}_k t.d. je $\mathcal{K}_j = \text{span}\{v_1, \dots, v_j\}$, za sve $j \leq k$.

$[r^{(0)}, Ar^{(0)}, A^2r^{(0)}, \dots, A^{k-1}r^{(0)}]$ je loša baza za $\mathcal{K}_k(r^{(0)}, A)$.

Ortonormirana baza je numerički stabilna:

- gradimo redom o-n baze za $\mathcal{K}_1 \leq \mathcal{K}_2 \leq \mathcal{K}_3 \dots$
- pretp. da smo dosad sagradili $V^{(k)} = [v_1 \ v_2 \ \dots \ v_k]$ – o-n bazu za \mathcal{K}_k t.d. je $\mathcal{K}_j = \text{span}\{v_1, \dots, v_j\}$, za sve $j \leq k$.
- može se pokazati da je $\mathcal{K}_{k+1} = \text{span}\{V^{(k)}, Av_k\}$.

$[r^{(0)}, Ar^{(0)}, A^2r^{(0)}, \dots, A^{k-1}r^{(0)}]$ je loša baza za $\mathcal{K}_k(r^{(0)}, A)$.

Ortonormirana baza je numerički stabilna:

- gradimo redom o-n baze za $\mathcal{K}_1 \leq \mathcal{K}_2 \leq \mathcal{K}_3 \dots$
- pretp. da smo dosad sagradili $V^{(k)} = [v_1 \ v_2 \ \dots \ v_k]$ – o-n bazu za \mathcal{K}_k t.d. je $\mathcal{K}_j = \text{span}\{v_1, \dots, v_j\}$, za sve $j \leq k$.
- može se pokazati da je $\mathcal{K}_{k+1} = \text{span}\{V^{(k)}, Av_k\}$.
- Gram-Schmidtovim algoritmom ortogonaliziramo Av_k na $V^{(k)}$:

$$h_{k+1,k}v_{k+1} = Av_k - h_{1,k}v_1 - h_{2,k}v_2 - \dots - h_{k,k}v_k.$$

$[r^{(0)}, Ar^{(0)}, A^2r^{(0)}, \dots, A^{k-1}r^{(0)}]$ je loša baza za $\mathcal{K}_k(r^{(0)}, A)$.

Ortonormirana baza je numerički stabilna:

- gradimo redom o-n baze za $\mathcal{K}_1 \leq \mathcal{K}_2 \leq \mathcal{K}_3 \dots$
- pretp. da smo dosad sagradili $V^{(k)} = [v_1 \ v_2 \ \dots \ v_k]$ – o-n bazu za \mathcal{K}_k t.d. je $\mathcal{K}_j = \text{span}\{v_1, \dots, v_j\}$, za sve $j \leq k$.
- može se pokazati da je $\mathcal{K}_{k+1} = \text{span}\{V^{(k)}, Av_k\}$.
- Gram-Schmidtovim algoritmom ortogonaliziramo Av_k na $V^{(k)}$:

$$h_{k+1,k}v_{k+1} = Av_k - h_{1,k}v_1 - h_{2,k}v_2 - \dots - h_{k,k}v_k.$$

- stavimo $V^{(k+1)} = [V^{(k)} \ v_{k+1}]$.

Definiramo ovu gornje-Hessenbergovu matricu (reda $(k + 1) \times k$):

$$H^{(k+1)} = \begin{bmatrix} h_{1,1} & h_{1,2} & h_{1,3} & h_{1,4} & \dots & h_{1,k-1} & h_{1,k} \\ h_{2,1} & h_{2,2} & h_{2,3} & h_{2,4} & \dots & h_{2,k-1} & h_{2,k} \\ & h_{3,2} & h_{3,3} & h_{3,4} & \dots & h_{3,k-1} & h_{3,k} \\ & & h_{4,3} & h_{4,4} & \dots & h_{4,k-1} & h_{4,k} \\ & & & & \vdots & & \\ & & & & & h_{k,k-1} & h_{k,k} \\ & & & & & & h_{k+1,k} \end{bmatrix}$$

Tada: $AV^{(k)} = V^{(k+1)}H^{(k+1)}$, tj.

$$A[v_1 \ v_2 \ \dots \ v_k] = [v_1 \ v_2 \ \dots \ v_k \ v_{k+1}]H^{(k+1)}$$

j -ti stupac: Av_j je linearna kombinacija v_1, v_2, \dots, v_j .

Algoritam (**Arnoldijev algoritam** – ortonormirana baza za $\mathcal{K}_k(A, r^{(0)})$)

$$v_1 = r^{(0)} / \|r^{(0)}\|;$$

for $k = 1, 2, \dots$

$$z = Av_k;$$

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

$$h_{j,k} = v_j^\top z;$$

$$z = z - h_{j,k}v_j;$$

end

$$h_{k+1,k} = \|z\|;$$

if $(h_{k+1,k} == 0)$

break; // u tom slučaju je $\mathcal{K}_{k+1}(A, r^{(0)}) = \mathcal{K}_k(A, r^{(0)})$

$$v_{k+1} = z/h_{k+1,k};$$

end

Kada imamo bazu za $\mathcal{K}_k(A, r^{(0)})$:

- biramo $x^{(k)} \in x^{(0)} + \mathcal{K}_k(A, r^{(0)})$, tj. $x^{(k)} = x^{(0)} + V^{(k)}y$, za neko $y \in \mathbb{R}^k$.
- cilj: $\|r^{(k)}\| \rightarrow \min$.

Kada imamo bazu za $\mathcal{K}_k(A, r^{(0)})$:

- biramo $x^{(k)} \in x^{(0)} + \mathcal{K}_k(A, r^{(0)})$, tj. $x^{(k)} = x^{(0)} + V^{(k)}y$, za neko $y \in \mathbb{R}^k$.
- cilj: $\|r^{(k)}\| \rightarrow \min$.

$$\begin{aligned}
 \|r^{(k)}\| &= \|b - Ax^{(k)}\| = \|b - A(x^{(0)} + V^{(k)}y)\| \\
 &= \|r^{(0)} - AV^{(k)}y\| = \|r^{(0)} - V^{(k+1)}H^{(k+1)}y\| \\
 &= \left\| \|r^{(0)}\| \cdot V^{(k+1)}e_1 - V^{(k+1)}H^{(k+1)}y \right\| \\
 &= \left\| V^{(k+1)}(\|r^{(0)}\| e_1 - H^{(k+1)}y) \right\| \\
 &= \left\| \|r^{(0)}\| e_1 - H^{(k+1)}y \right\| = \min_y \left\| \|r^{(0)}\| e_1 - H^{(k+1)}y \right\|
 \end{aligned}$$

Algoritam (GMRES)

$$\beta = \|r^{(0)}\|;$$

for $k = 1, 2, \dots$

Izračunaj $V^{(k+1)}$ i $H^{(k+1)}$ (jedan korak Arnoldijevog algoritma);

Riješi problem najmanjih kvadrata $\min_y \|\beta e_1 - H^{(k+1)}y\|$;

$$x^{(k)} = x^{(0)} + V^{(k)}y;$$

if ($x^{(k)}$ dovoljno dobar)

break;

end

Algoritam (GMRES)

```

 $\beta = \|r^{(0)}\|;$ 
for  $k = 1, 2, \dots$ 
    Izračunaj  $V^{(k+1)}$  i  $H^{(k+1)}$  (jedan korak Arnoldijevog algoritma);
    Riješi problem najmanjih kvadrata  $\min_y \|\beta e_1 - H^{(k+1)}y\|;$ 
     $x^{(k)} = x^{(0)} + V^{(k)}y;$ 
    if ( $x^{(k)}$  dovoljno dobar)
        break;
end

```

- problem najmanjih kvadrata sa Hessenbergovog matricom se može riješiti puno efikasnije nego s proizvoljnom;
- moguće je i bez rješavanja problema najmanjih kvadrata izračunati $\|r^{(k)}\|$, pa $x^{(k)}$ računamo tek kad je $r^{(k)}$ dovoljno malen.

Pretp. A dijagonalizabilna, tj. $A = X\Lambda X^{-1}$.

$$\begin{aligned}
 \|r^{(k)}\| &= \min_{\substack{\pi \in \mathcal{P}_k \\ \pi(0)=1}} \|\pi(A)r^{(0)}\| \\
 &= \min_{\substack{\pi \in \mathcal{P}_k \\ \pi(0)=1}} \|X\pi(\Lambda)X^{-1}r^{(0)}\| \\
 &\leq \min_{\substack{\pi \in \mathcal{P}_k \\ \pi(0)=1}} \|X\| \cdot \|\pi(\Lambda)\| \cdot \|X^{-1}\| \cdot \|r^{(0)}\| \\
 &= \kappa_2(X) \cdot \|r^{(0)}\| \cdot \min_{\substack{\pi \in \mathcal{P}_k \\ \pi(0)=1}} \|\pi(\Lambda)\| \\
 &= \kappa_2(X) \cdot \|r^{(0)}\| \cdot \min_{\substack{\pi \in \mathcal{P}_k \\ \pi(0)=1}} \max_{\lambda \in \Lambda(A)} |\pi(\lambda)|.
 \end{aligned}$$

$\Lambda \subseteq \mathbb{C}$, optimalan π je teško pronaći/ocijeniti.

Teorem (Greenbaum, Pták, Strakoš)

Neka je zadan niz $a_0 \geq a_1 \geq \dots \geq a_{n-1} > 0$, te neka su $\lambda_1, \dots, \lambda_n$ proizvoljni kompleksni brojevi. Tada postoji matrica A čije su svojstvene vrijednosti $\lambda_1, \dots, \lambda_n$, te vektor b takvi da reziduali GMRES metode za sustav $Ax = b$ zadovoljavaju

$$\|r^{(k)}\| = a_k,$$

za sve $k = 0, 1, \dots, n - 1$.

Napišite funkciju $x = \text{GMRES}(A, b, x_0)$ koja GMRES-metodom računa aproksimaciju rješenja linearnog sustava $Ax = b$, uz početnu iteraciju x_0 . Iteracije zaustavite kada bude $\|r^{(k)}\| / \|r^{(0)}\| < 10^{-8}$.

Neka je $a_k = (12 - k/10)^2$, za $k = 0, 1, \dots, 99$. Pronađite matricu A reda 100 i vektor b takve da reziduali GMRES metode za sustav $Ax = b$ zadovoljavaju $\|r^{(k)}\| = a_k$. Testirajte funkciju **GMRES** na ovom sustavu.

Zadatak 9

Rješenje. Stavimo npr. $\lambda_j = \cos \frac{2\pi j}{100} + i \sin \frac{2\pi j}{100}, j = 1, \dots, 100$.

Zadatak 9

Rješenje. Stavimo npr. $\lambda_j = \cos \frac{2\pi j}{100} + i \sin \frac{2\pi j}{100}, j = 1, \dots, 100$.

Definiramo:

- $g_k = \sqrt{a_{k-1}^2 - a_k^2}, k = 1, 2, \dots, 100; (a_{100} = 0);$

Rješenje. Stavimo npr. $\lambda_j = \cos \frac{2\pi j}{100} + i \sin \frac{2\pi j}{100}, j = 1, \dots, 100$.

Definiramo:

- $g_k = \sqrt{a_{k-1}^2 - a_k^2}, k = 1, 2, \dots, 100; (a_{100} = 0);$
- $Q = [q_1 \ q_2 \ \dots, q_{100}]$ slučajna ortogonalna matrica;

Rješenje. Stavimo npr. $\lambda_j = \cos \frac{2\pi j}{100} + i \sin \frac{2\pi j}{100}, j = 1, \dots, 100$.

Definiramo:

- $g_k = \sqrt{a_{k-1}^2 - a_k^2}, k = 1, 2, \dots, 100; (a_{100} = 0);$
- $Q = [q_1 \ q_2 \ \dots, q_{100}]$ slučajna ortogonalna matrica;
- $b = g_1 q_1 + g_2 q_2 + \dots + g_{100} q_{100};$

Rješenje. Stavimo npr. $\lambda_j = \cos \frac{2\pi j}{100} + i \sin \frac{2\pi j}{100}, j = 1, \dots, 100$.

Definiramo:

- $g_k = \sqrt{a_{k-1}^2 - a_k^2}, k = 1, 2, \dots, 100; (a_{100} = 0);$
- $Q = [q_1 \ q_2 \ \dots \ q_{100}]$ slučajna ortogonalna matrica;
- $b = g_1 q_1 + g_2 q_2 + \dots + g_{100} q_{100};$
- $B = [b \ q_1 \ \dots \ q_{99}];$

Rješenje. Stavimo npr. $\lambda_j = \cos \frac{2\pi j}{100} + i \sin \frac{2\pi j}{100}, j = 1, \dots, 100$.

Definiramo:

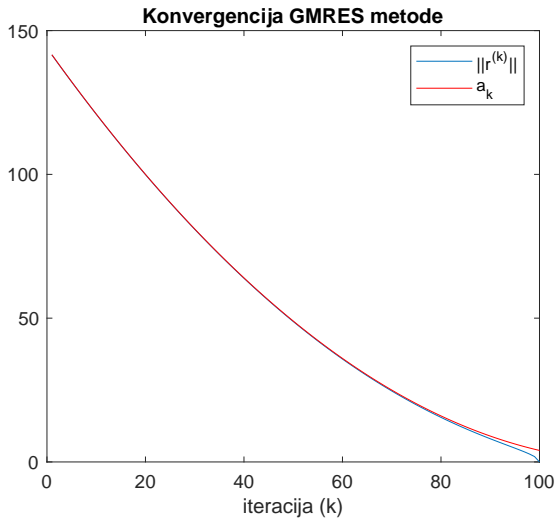
- $g_k = \sqrt{a_{k-1}^2 - a_k^2}, k = 1, 2, \dots, 100; (a_{100} = 0);$
- $Q = [q_1 \ q_2 \ \dots \ q_{100}]$ slučajna ortogonalna matrica;
- $b = g_1 q_1 + g_2 q_2 + \dots + g_{100} q_{100};$
- $B = [b \ q_1 \ \dots \ q_{99}];$
- $p(z) = z^{100} - \sum_{j=0}^{99} \alpha_j z^j = (z - \lambda_1)(z - \lambda_2) \dots (z - \lambda_n) = z^{100} - 1;$

Rješenje. Stavimo npr. $\lambda_j = \cos \frac{2\pi j}{100} + i \sin \frac{2\pi j}{100}, j = 1, \dots, 100$.

Definiramo:

- $g_k = \sqrt{a_{k-1}^2 - a_k^2}, k = 1, 2, \dots, 100; (a_{100} = 0);$
- $Q = [q_1 \ q_2 \ \dots \ q_{100}]$ slučajna ortogonalna matrica;
- $b = g_1 q_1 + g_2 q_2 + \dots + g_{100} q_{100};$
- $B = [b \ q_1 \ \dots \ q_{99}];$
- $p(z) = z^{100} - \sum_{j=0}^{99} \alpha_j z^j = (z - \lambda_1)(z - \lambda_2) \dots (z - \lambda_n) = z^{100} - 1;$
- $A = B \cdot \begin{bmatrix} 0 & \dots & 0 & \alpha_0 \\ 1 & \dots & 0 & \alpha_1 \\ & \ddots & \vdots & \vdots \\ & & 1 & \alpha_{99} \end{bmatrix} \cdot B^{-1}$

Rješenje.



PREKONDITIONIRANJE

Prekondicioniranje – modifikacija početnog sustava $Ax = b$ koja ubrzava metodu za rješavanje sustava.

Prekondicioniranje – modifikacija početnog sustava $Ax = b$ koja ubrzava metodu za rješavanje sustava.

Umjesto $Ax = b$, rješavamo $M^{-1}Ax = M^{-1}b$.

Kada iterativna metoda treba izračunati $z = M^{-1}Av$, to radimo ovako:

- (1) $t = Av$;
- (2) Riješi sustav $Mz = t$.

Prekondicioniranje – modifikacija početnog sustava $Ax = b$ koja ubrzava metodu za rješavanje sustava.

Umjesto $Ax = b$, rješavamo $M^{-1}Ax = M^{-1}b$.

Kada iterativna metoda treba izračunati $z = M^{-1}Av$, to radimo ovako:

- (1) $t = Av$;
- (2) Riješi sustav $Mz = t$.

Cilj – odabрати M tako da:

- $M \approx A$ u nekom smislu ($M^{-1}A \approx I$).
- Sustavi tipa $Mz = t$ se mogu jako brzo riješiti.
- CG, GMRES – npr. $\kappa(M^{-1}A) \ll \kappa(A)$ ili $\Lambda(M^{-1}A)$ koncentriran oko jedne točke.

Prekondicioniranje dijagonalnom matricom

$M =$ dijagonala matrice A .

Ako je A pozitivno definitna, onda možemo rješavati i

$$Ax = b \Rightarrow DADy = Db, \quad x = Dy,$$

gdje je D matrica iz ovog Teorema:

Teorem (Van der Sluis)

Neka je A pozitivno definitna matrica i

$D = \text{diag}(\sqrt{1/A_{1,1}}, \sqrt{1/A_{2,2}}, \dots, \sqrt{1/A_{n,n}})$. Tada:

$$\kappa(DAD) \leq n \cdot \min_{\Delta \in \mathcal{D}} \kappa(\Delta A \Delta),$$

gdje je \mathcal{D} skup svih dijagonalnih matrica sa pozitivnim elementima dijagonale.

Ako A simetrična, onda $M^{-1}A$ ne mora biti simetrična.

Ali, ako $M = LL^T$, onda

$$\begin{aligned}M^{-1}Ax &= M^{-1}b \\L^{-T}L^{-1}Ax &= L^{-T}L^{-1}b \\L^{-1}AL^{-T}y &= L^{-1}b,\end{aligned}$$

uz $x = L^{-T}y$. Sada je matrica sustava $L^{-1}AL^{-T}$ simetrična.

Uoči: matrice $M^{-1}A$ i $L^{-1}AL^{-T}$ su slične, pa su očuvana svojstva konvergencije koja ovise o spektru matrice sustava.

Prekondicioniranje pozitivno definitnih matrica

Kako dobiti $M = LL^T$?

Ako A pozitivno definitna – npr. **incomplete Cholesky**.

MATLAB: `R=cholinc(A, '0'); L=R'`;

Algoritam (incomplete Cholesky)

```
for  $i = 1, 2, \dots, n$   
   $L_{i,i} = \sqrt{A_{i,i} - \sum_{k=1}^{i-1} L_{i,k}^2}$   
  for  $j = i + 1, \dots, n$   
    if ( $A_{i,j} \neq 0$ )  
       $L_{j,i} = (A_{i,j} - \sum_{k=1}^{i-1} L_{i,k}L_{j,k})/L_{i,i}$   
    else  
       $L_{j,i} = 0$   
    end  
  end  
end
```

Uoči: struktura nula u matrici L je ista kao struktura nula u (donjem trokutu od) A !

Ponekad M je pozitivno definitna, ali nije zadana u formi $M = LL^T$.
Želimo verziju CG za sustav $L^{-1}AL^{-T}y = L^{-1}b$ koja ne koristi L već samo M .

Ponekad M je pozitivno definitna, ali nije zadana u formi $M = LL^T$. Želimo verziju CG za sustav $L^{-1}AL^{-T}y = L^{-1}b$ koja ne koristi L već samo M .

Neka CG za $L^{-1}AL^{-T}\tilde{x} = L^{-1}b$ koristi $\tilde{x}^{(k)}, \tilde{r}^{(k)}, \tilde{d}_k, \alpha_k, \beta_k$.

Uvedimo oznake:

$$\begin{aligned}x^{(k)} &= L^{-T}\tilde{x}^{(k)}, \\r^{(k)} &= L\tilde{r}^{(k)}, \\d_k &= L^{-T}\tilde{d}_k.\end{aligned}$$

Tada:

$$x^{(k+1)} = L^{-T}\tilde{x}^{(k+1)} = L^{-T}(\tilde{x}^{(k)} + \alpha_k\tilde{d}_k) = x^{(k)} + \alpha_k d_k$$

$$r^{(k+1)} = L\tilde{r}^{(k+1)} = L(\tilde{r}^{(k)} - \alpha_k L^{-1}AL^{-T}\tilde{d}_k) = r^{(k)} - \alpha_k Ad_k$$

$$\begin{aligned} d_{k+1} &= L^{-T}\tilde{d}_{k+1} = L^{-T}(\tilde{r}^{(k+1)} - \beta_k\tilde{d}_k) = L^{-T}L^{-1}r^{(k+1)} - \beta_k d_k \\ &= M^{-1}r^{(k+1)} - \beta_k d_k \end{aligned}$$

$$\alpha_k = \frac{(\tilde{r}^{(k)})^T \tilde{r}^{(k)}}{\tilde{d}_k^T (L^{-1}AL^{-T})\tilde{d}_k} = \frac{(r^{(k)})^T L^{-T}L^{-1}r^{(k)}}{d_k^T Ad_k} = \frac{(r^{(k)})^T M^{-1}r^{(k)}}{d_k^T Ad_k}$$

$$\beta_k = \frac{-(\tilde{r}^{(k+1)})^T \tilde{r}^{(k+1)}}{(\tilde{r}^{(k)})^T \tilde{r}^{(k)}} = \frac{-(r^{(k+1)})^T M^{-1}r^{(k+1)}}{(r^{(k)})^T M^{-1}r^{(k)}}$$

Algoritam (CG sa prekondicioniranjem: A, M **simetrične, poz. definitne**)

$x^{(0)}$ zadan;

$$r^{(0)} = b - Ax^{(0)};$$

Riješi sustav $Mp_0 = r^{(0)}$;

$$d_0 = p_0;$$

for $k = 0, 1, 2, \dots$

$$\alpha_k = \frac{(r^{(k)})^T p_k}{d_k^T A d_k};$$

$$x^{(k+1)} = x^{(k)} + \alpha_k d_k;$$

$$r^{(k+1)} = r^{(k)} - \alpha_k A d_k;$$

Riješi sustav $Mp_{k+1} = r^{(k+1)}$;

$$\beta_k = \frac{-(r^{(k+1)})^T p_{k+1}}{(r^{(k)})^T p_k};$$

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

end

Napišite funkciju `x=CG_precond(A,M,b,x0)` koja CG-metodom računa aproksimaciju rješenja linearnog sustava $Ax = b$, uz početnu iteraciju x_0 i matricu prekondicioniranja M . Iteracije zaustavite kada bude $\|b - Ax^{(k)}\| / \|b - Ax^{(0)}\| < 10^{-10}$.


Testirajte brzinu konvergencije:

- bez prekondicioniranja,
- uz prekondicioniranje dijagonalnom matricom,
- uz prekondicioniranje incomplete Cholesky faktorizacijom,

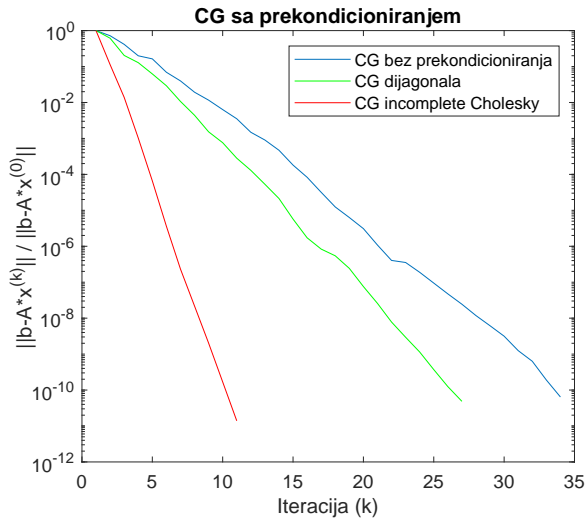
ako je matrica sustava $Ax = b$ Stieltjesova matrica iz datoteke `'stieltjes.mat'`. Neka je desna strana takva da je rješenje $x=[1 \ 1 \ \dots \ 1]'$.

Zadatak 10

Rješenje. `spy(A);`



Rješenje.



Rješenje.

Bez prekondicioniranja:

- $\kappa = 14.56273$
- Metoda konvergira u 33 iteracija.

Prekondicioniranje dijagonalnom matricom:

- $\kappa = 7.816230$
- Metoda konvergira u 26 iteracija.

Prekondicioniranje pomoću incomplete Cholesky faktorizacije:

- $\kappa = 1.502516$
- Metoda konvergira u 10 iteracija.