

Numerička analiza

6. predavanje

Autor: Nela Bosner
Predavač: Nela Bosner

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

PMF – Matematički odjel, Zagreb

Sadržaj predavanja

- Numerička analiza Gaussovih eliminacija:
 - Pomoćni rezultati za grešku unazad određenih izraza (supstitucija unaprijed i unazad).
 - Greška unazad po komponentama LR faktorizacije.
 - Greška unazad po komponentama Gaussovih eliminacija.
 - Greška unazad po normi Gaussovih eliminacija s parcijalnim pivotiranjem.
- Primjer nestabilnosti Gaussovih eliminacija s parcijalnim pivotiranjem:
- Rješavanje linearnih sustava: iterativne metode:
 - Uvod u iterativne metode.

Sadržaj predavanja (nastavak)

- Standardne iteracije, i nužan i dovoljan uvjet konvergencije iteracija.
- Jacobijeva metoda i njena konvergencija.
- Gauss-Seidelova metoda i njena konvergencija.
- JOR metoda i njena konvergencija.
- SOR metoda i njena konvergencija.
- Primjer konvergencije iterativnih metoda

Numerička analiza Gaussovih eliminacija

Pomoćni rezultati

Prvo ćemo započeti sa nekoliko pomoćnih rezultata.

Lema 1. Ako imamo $|\delta_i| \leq u$ (u je jedinična greška zaokruživanja) i $\rho_i = \pm 1$ za $i = 1, \dots, n$, pri čemu je $nu < 1$, tada vrijedi

$$\prod_{i=1}^n (1 + \delta_i)^{\rho_i} = 1 + \theta_n,$$

uz ocjenu

$$|\theta_n| \leq \frac{nu}{1 - nu} =: \gamma_n.$$

Dokaz. Dokaz se provodi matematičkom indukcijom.

Pomoćni rezultati (nastavak)

Baza indukcije: Za $n = 1$ vrijedi da je

• ako je $\rho_1 = 1$

$$\prod_{i=1}^1 (1 + \delta_i)^{\rho_i} = 1 + \delta_1, \quad |\delta_1| \leq u \leq \frac{u}{1 - u},$$

• ako je $\rho_1 = -1$

$$\prod_{i=1}^1 (1 + \delta_i)^{\rho_i} = \frac{1}{1 + \delta_1} = 1 + \theta_1,$$

odakle je

$$\theta_1 = \frac{1}{1 + \delta_1} - 1 = \frac{-\delta_1}{1 + \delta_1}, \quad |\theta_1| \leq \frac{u}{1 - u}.$$

Pomoćni rezultati (nastavak)

Korak indukcije: Pretpostavimo da tvrdnja leme **vrijedi** za $n - 1$.

• Ako je $\rho_n = 1$, tada

$$\prod_{i=1}^n (1 + \delta_i)^{\rho_i} = (1 + \theta_{n-1})(1 + \delta_n) = 1 + \theta_n,$$

odakle je

$$\theta_n = \delta_n + (1 + \delta_n)\theta_{n-1},$$

i vrijedi

$$|\theta_n| \leq u + (1 + u) \frac{(n-1)u}{1 - (n-1)u}$$

Pomoćni rezultati (nastavak)

$$\begin{aligned} |\theta_n| &= \frac{u(1 - (n-1)u) + (1+u)(n-1)u}{1 - (n-1)u} \\ &= \frac{nu}{1 - (n-1)u} \leq \frac{nu}{1 - nu} = \gamma_n. \end{aligned}$$

• Ako je $\rho_n = -1$, tada

$$\prod_{i=1}^n (1 + \delta_i)^{\rho_i} = \frac{1 + \theta_{n-1}}{1 + \delta_n} = 1 + \theta_n,$$

odakle je

$$\theta_n = \frac{\theta_{n-1} - \delta_n}{1 + \delta_n},$$

Pomoćni rezultati (nastavak)

i vrijedi

$$\begin{aligned} |\theta_n| &\leq \frac{\frac{(n-1)u}{1-(n-1)u} + u}{1-u} \\ &= \frac{(n-1)u + u - (n-1)u^2}{(1-u)(1-(n-1)u)} \\ &= \frac{nu - (n-1)u^2}{1-u - (n-1)u + (n-1)u^2} \leq \frac{nu}{1-nu} = \gamma_n. \end{aligned}$$



Pomoćni rezultati (nastavak)

Lema 2. Pretpostavimo da se $y = (c - \sum_{i=1}^{k-1} a_i b_i) / b_k$ računa u aritmetici pomičnog zareza na sljedeći način

$$s = c$$

za $i = 1, \dots, k - 1$

$$s = s - a_i b_i$$

kraj

$$y = s / b_k$$

Tada izračunati \hat{y} zadovoljava

$$b_k \hat{y} (1 + \theta_k) = c - \sum_{i=1}^{k-1} a_i b_i (1 + \theta_i),$$

gdje su $|\theta_i| \leq \gamma_i$.

Pomoćni rezultati (nastavak)

Dokaz. Analizirajmo prvo kako se računa

$\hat{s} = fl(c - \sum_{i=1}^{k-1} a_i b_i)$ korak po korak.

• Za $i = 1$ imamo

$$\begin{aligned}\hat{s}_1 &= fl(c - a_1 b_1) = (c - a_1 b_1(1 + \epsilon_1))(1 + \delta_1) \\ &= c(1 + \delta_1) - a_1 b_1(1 + \epsilon_1)(1 + \delta_1),\end{aligned}$$

gdje je $|\epsilon_1| \leq u$ greška množenja, a $|\delta_1| \leq u$ greška zbrajanja.

• Za $i = 2$ imamo

$$\begin{aligned}\hat{s}_2 &= fl(\hat{s}_1 - a_2 b_2) = (\hat{s}_1 - a_2 b_2(1 + \epsilon_2))(1 + \delta_2) \\ &= (c(1 + \delta_1) - a_1 b_1(1 + \epsilon_1)(1 + \delta_1) - a_2 b_2(1 + \epsilon_2))(1 + \delta_2)\end{aligned}$$

Pomoćni rezultati (nastavak)

$$\hat{s}_2 = c(1 + \delta_1)(1 + \delta_2) - a_1b_1(1 + \epsilon_1)(1 + \delta_1)(1 + \delta_2) - a_2b_2(1 + \epsilon_2)(1 + \delta_2),$$

gdje je $|\epsilon_2| \leq u$ greška množenja, a $|\delta_2| \leq u$ greška zbrajanja.

• ...i tako nastavimo dalje. Možemo zaključiti da je

$$\hat{s} = \hat{s}_{k-1} = c(1 + \delta_1) \cdots (1 + \delta_{k-1}) - \sum_{i=1}^{k-1} a_i b_i (1 + \epsilon_i)(1 + \delta_i) \cdots (1 + \delta_{k-1}),$$

gdje su $|\epsilon_i|, |\delta_i| \leq u$.

Pomoćni rezultati (nastavak)

- Preostaje nam još samo zadnje dijeljenje

$$\hat{y} = fl(\hat{s}/b_k) = \frac{\hat{s}(1 + \epsilon_k)}{b_k}, \quad |\epsilon_k| \leq u,$$

odakle slijedi dijeljenjem sa $(1 + \delta_1) \cdots (1 + \delta_{k-1})(1 + \epsilon_k)$

$$\begin{aligned} b_k \hat{y} & \frac{1}{(1 + \delta_1) \cdots (1 + \delta_{k-1})(1 + \epsilon_k)} \\ & = c - \sum_{i=1}^{k-1} a_i b_i \frac{1 + \epsilon_i}{(1 + \delta_1) \cdots (1 + \delta_{i-1})}. \end{aligned}$$

Rezultat slijedi primjenom **Leme 1**.



Pomoćni rezultati (nastavak)

Lema 3. Ako se $y = (c - \sum_{i=1}^{k-1} a_i b_i) / b_k$ računa u aritmetici pomičnog zareza bez obzira na poredak operacija, tada je

$$b_k \hat{y} (1 + \theta_k^{(0)}) = c - \sum_{i=1}^{k-1} a_i b_i (1 + \theta_k^{(i)}),$$

gdje su $|\theta_k^{(i)}| \leq \gamma_k$ za sve i . Ako je $b_k = 1$, u tom slučaju nema posljednjeg dijeljenja i vrijedi $|\theta_k^{(i)}| \leq \gamma_{k-1}$ za sve i .

Glavni rezultati

Pomoćni rezultat izražen u **Lemi 3** koristit ćemo za analizu **grešaka zaokruživanja** kod računanja **pojedinih elemenata** matrice **L** i **R** iz LR faktorizacije

- Analizirajmo prvo računanje elementa $r_{ij} = a_{ij}^{(i)}$, za $i \leq j$, matrice **R** u **egzaktnoj aritmetici**.

$$a_{ij}^{(1)} = a_{ij}$$

$$a_{ij}^{(2)} = a_{ij}^{(1)} - m_{i1}a_{1j}^{(1)} = a_{ij} - \ell_{i1}r_{1j}$$

$$a_{ij}^{(3)} = a_{ij}^{(2)} - m_{i2}a_{2j}^{(2)} = a_{ij} - \ell_{i1}r_{1j} - \ell_{i2}r_{2j}$$

⋮

$$r_{ij} = a_{ij}^{(i)} = a_{ij}^{(i-1)} - m_{i,i-1}a_{i-1,j}^{(i-1)}$$

$$= a_{ij} - \ell_{i1}r_{1j} - \cdots - \ell_{i,i-1}r_{i-1,j}$$

Glavni rezultati (nastavak)

- Za elemente **izračunate** matrice \hat{R} prema **Lemi 3** slijedi:

$$\hat{r}_{ij}(1 + \theta_i^{(i)}) = a_{ij} - \sum_{k=1}^{i-1} \hat{l}_{ik} \hat{r}_{kj}(1 + \theta_i^{(k)}),$$

pri čemu su $|\theta_i^{(k)}| \leq \gamma_{i-1} \leq \gamma_i$ za sve k .

- Analizirajmo sada računanje elementa $l_{ij} = m_{ij}$, za $i > j$, matrice L u **egzaktnoj aritmetici**. Koristit ćemo i prethodnu analizu za $a_{ij}^{(s)}$.

$$l_{ij} = m_{ij} = \frac{a_{ij}^{(j)}}{a_{jj}^{(j)}} = \frac{a_{ij} - l_{i1}r_{1j} - \cdots - l_{i,j-1}r_{j-1,j}}{r_{jj}}$$

Glavni rezultati (nastavak)

- Za elemente **izračunate** matrice \hat{L} prema **Lemi 3** slijedi:

$$\hat{\ell}_{ij} \hat{r}_{jj} (1 + \Theta_j^{(j)}) = a_{ij} - \sum_{k=1}^{j-1} \hat{\ell}_{ik} \hat{r}_{kj} (1 + \Theta_j^{(k)}),$$

pri čemu su $|\Theta_j^{(k)}| \leq \gamma_j$ za sve k .

- Ovi rezultati čine okosnicu **greške unazad** za LR faktorizaciju.

Glavni rezultati (nastavak)

Teorem 1. Ako se **Gaussove eliminacije** primijenjene na $A \in \mathbb{R}^{n \times n}$ izvedu do kraja, tada **izračunati LR faktori** $\hat{L}, \hat{R} \in \mathbb{R}^{n \times n}$ zadovoljavaju

$$\hat{L}\hat{R} = A + \Delta A, \quad |\Delta A| \leq \gamma_n |\hat{L}| |\hat{R}|.$$

Dokaz. Iz prethodne analize izračunatih elemenata \hat{r}_{ij} i \hat{l}_{ij} možemo zaključiti:

• za $i \leq j$, uz izjednačavanje $\hat{l}_{ii} = 1$, imamo

$$a_{ij} = \left(\sum_{k=1}^i \hat{l}_{ik} \hat{r}_{kj} \right) + \sum_{k=1}^i \hat{l}_{ik} \hat{r}_{kj} \theta_i^{(k)} = (\hat{L}\hat{R})_{ij} + \sum_{k=1}^i \hat{l}_{ik} \hat{r}_{kj} \theta_i^{(k)}$$

Glavni rezultati (nastavak)

za $i > j$ imamo

$$a_{ij} = \left(\sum_{k=1}^j \hat{\ell}_{ik} \hat{r}_{kj} \right) + \sum_{k=1}^j \hat{\ell}_{ik} \hat{r}_{kj} \Theta_j^{(k)} = (\hat{L}\hat{R})_{ij} + \sum_{k=1}^j \hat{\ell}_{ik} \hat{r}_{kj} \Theta_j^{(k)}$$

Dakle, za $\Delta A = A - \hat{L}\hat{R}$ vrijedi

$$|(\Delta A)_{ij}| = \begin{cases} \left| \sum_{k=1}^i \hat{\ell}_{ik} \hat{r}_{kj} \theta_i^{(k)} \right| \leq \gamma_i \sum_{k=1}^i |\hat{\ell}_{ik}| |\hat{r}_{kj}| \leq \gamma_n (|\hat{L}| |\hat{R}|)_{ij}, & \text{za } i \leq j \\ \left| \sum_{k=1}^j \hat{\ell}_{ik} \hat{r}_{kj} \Theta_j^{(k)} \right| \leq \gamma_j \sum_{k=1}^j |\hat{\ell}_{ik}| |\hat{r}_{kj}| \leq \gamma_n (|\hat{L}| |\hat{R}|)_{ij}, & \text{za } i > j \end{cases}$$



Glavni rezultati (nastavak)

Teorem 2. Neka je $A \in \mathbb{R}^{n \times n}$ i pretpostavimo da smo **Gaussovima eliminacijama** dobili **izračunate** LR faktore \hat{L} i \hat{R} , i **izračunato** rješenje \hat{x} sustava $Ax = b$. Tada je

$$(A + \Delta A)\hat{x} = b, \quad |\Delta A| \leq \gamma_{3n}|\hat{L}||\hat{R}|.$$

Dokaz. Prema **Teoremu 1** je

$$\hat{L}\hat{R} = A + \Delta A_1, \quad |\Delta A_1| \leq \gamma_n|\hat{L}||\hat{R}|.$$

Za **rješavanje trokutastih sustava** koristimo

$$Ly = b, \quad \text{supstitucija unaprijed,}$$

$$Rx = y, \quad \text{povratna supstitucija,}$$

Glavni rezultati (nastavak)

pri čemu se svaki element rješenja trokutastog sustava računa

$$y_i = b_i - \sum_{j=1}^{i-1} l_{ij} y_j, \quad (y_1 = b_1), \quad i = 2, \dots, n,$$

$$x_i = \frac{1}{r_{ii}} \left(y_i - \sum_{j=i+1}^n r_{ij} x_j \right), \quad \left(x_n = \frac{y_n}{r_{nn}} \right) \quad i = n-1, \dots, 1.$$

Prema **Lemi 3** za izračunate vrijednosti vrijedi

$$\hat{y}_i (1 + \theta_i^{(i)}) = b_i - \sum_{j=1}^{i-1} \hat{l}_{ij} \hat{y}_j (1 + \theta_i^{(j)}), \quad i=2, \dots, n,$$

$$\hat{r}_{ii} \hat{x}_i (1 + \Theta_{n-i+1}^{(i)}) = \hat{y}_i - \sum_{j=i+1}^n \hat{r}_{ij} \hat{x}_j (1 + \Theta_{n-i+1}^{(j)}), \quad i=n-1, \dots, 1,$$

Glavni rezultati (nastavak)

pri čemu je $\theta_i^{(j)} \leq \gamma_{i-1} \leq \gamma_i$, a $\Theta_{n-i+1}^{(j)} \leq \gamma_{n-i+1}$ za svaki j .
Zato **izračunata rješenja** \hat{y} i \hat{x} zadovoljavaju

$$\begin{aligned}(\hat{L} + \Delta L)\hat{y} &= b, & |\Delta L| &\leq \gamma_n |\hat{L}|, \\(\hat{R} + \Delta R)\hat{x} &= \hat{y}, & |\delta R| &\leq \gamma_n |\hat{U}|.\end{aligned}$$

jer su $(\Delta L)_{ij} = \hat{\ell}_{ij} \theta_i^{(j)}$ i $(\Delta R)_{ij} = \hat{r}_{ij} \Theta_{n-i+1}^{(j)}$. Prema tome dobivamo

$$\begin{aligned}b &= (\hat{L} + \Delta L)(\hat{R} + \Delta R)\hat{x} \\&= (A + \Delta A_1 + \hat{L}\Delta R + \Delta L\hat{R} + \Delta L\Delta R)\hat{x} \\&= (A + \Delta A)\hat{x},\end{aligned}$$

Glavni rezultati (nastavak)

gdje je

$$\begin{aligned} |\Delta A| &= |\Delta A_1 + \hat{L}\Delta R + \Delta L\hat{R} + \Delta L\Delta R| \\ &\leq |\Delta A_1| + |\hat{L}||\Delta R| + |\Delta L||\hat{R}| + |\Delta L||\Delta R| \\ &\leq (3\gamma_n + \gamma_n^2)|\hat{L}||\hat{R}|. \end{aligned}$$

Uz uvijet $nu < 1$ dobivamo konačnu ocjenu:

$$\begin{aligned} 3\gamma_n + \gamma_n^2 &= \frac{3nu}{1 - nu} + \frac{n^2u^2}{(1 - nu)^2} = \frac{3nu - 3n^2u^2 + n^2u^2}{(1 - nu)^2} \\ &= \frac{3nu - 2n^2u^2}{1 - 2nu + n^2u^2} \leq \frac{3nu}{1 - 2nu} \leq \gamma_{3n}. \end{aligned}$$



Interpretacija rezultata

Idealno, mi bi željeli dobiti rezultat oblika

$$|\Delta A| \leq \mathcal{O}(n)u|A|,$$

što predstavlja **perturbaciju elemenata matrice** A s malom **relativnom greškom**. Takva ograda greške **postoji** ako \hat{L} i \hat{R} zadovoljavaju

$$|\hat{L}||\hat{R}| = |\hat{L}\hat{R}|.$$

To vrijedi npr. za **nenegativne matrice** (po elementima). U tom slučaju imamo

$$|\hat{L}||\hat{R}| = |\hat{L}\hat{R}| = |A + \Delta A_1| \leq |A| + \gamma_n |\hat{L}||\hat{R}|,$$

odakle slijedi

Interpretacija rezultata (nastavak)

$$|\hat{L}||\hat{R}| \leq \frac{1}{1 - \gamma_n} |A|.$$

Ako to ubacimo u rezultat **Teorema 2** dobit ćemo

$$(A + \Delta A)\hat{x} = b, \quad |\Delta A| \leq \frac{\gamma_{3n}}{1 - \gamma_n} |A|, \quad (\hat{L}, \hat{R} > 0).$$

To znači da \hat{x} ima **malu relativnu grešku u nazad po komponentama**.

Jedna klasa matrica koja ima nenegativne LR faktore se definira na sljedeći način:

- Matrica $A \in \mathbb{R}^{n \times n}$ je **totalno pozitivna (nenegativna)** ako je **determinanta** svake njene **kvadratne podmatrice pozitivna (nenegativna)**.

Interpretacija rezultata (nastavak)

Jedna važna činjenica koja slijedi iz Teorema 1 i Teorema 2 je ta da je **stabilnost Gaussovih eliminacija** određena

- ne veličinom multiplikatora,
- već **veličinom elemenata matrice** $|\hat{L}||\hat{R}|$.

Ta matrica može imati male elemente kada su multiplikatori $\hat{\ell}_{ij}$ veliki, i obratno.

Za bolje razumijevanje stabilnosti Gaussovih eliminacija potrebno je gledati **ocjene po normi**.

- Za Gaussove eliminacije bez pivotiranja, omjer $\|\hat{L}\|\hat{R}\|/\|A\|$ može biti **proizvoljno velik**.
- Npr. za matricu $\begin{bmatrix} \epsilon & 1 \\ 1 & 1 \end{bmatrix}$ taj omjer je reda veličine ϵ^{-1} .

Interpretacija rezultata (nastavak)

- Ako se koristi **parcijalno pivotiranje**, tada je $|l_{ij}| \leq 1$ za sve $i \geq j$. Već smo prije spomenuli da je u tom slučaju

$$|r_{ij}| \leq 2^{i-1} \max_{k \leq i} |a_{kj}|,$$

pa prema tome za parcijalno pivotiranje L ima male elemente, a elementi od R su relativno ograničeni elementima od A .

Sada ponovo u igru ulazi **pivotni rast**:

$$\rho_n = \frac{\max_{i,j,k} |a_{ij}^{(k)}|}{\max_{i,j} |a_{ij}|}.$$

Ako ubacimo ogradu $|r_{ij}| = |a_{ij}^{(i)}| \leq \rho_n \max_{i,j} |a_{ij}|$ u rezultat **Teorema 2**, dobivamo sljedeći klasični teorem.

Glavni rezultati (nastavak)

Teorem 3. (Wilkinson). Neka je $A \in \mathbb{R}^{n \times n}$ i pretpostavimo da **Gaussove eliminacije s parcijalnim pivotiranjem** daju izračunato rješenje \hat{x} sustava $Ax = b$. Tada je

$$(A + \Delta A)\hat{x} = b, \quad \|\Delta A\|_\infty \leq n^2 \gamma_{3n} \rho_n \|A\|_\infty.$$

Dokaz. Računamo normu greške iz **Teorema 2**:

$$\begin{aligned} \|\Delta A\|_\infty &= \| |\Delta A| \|_\infty \leq \gamma_{3n} \| |\hat{L}| |\hat{R}| \|_\infty \\ &= \gamma_{3n} \max_{i=1, \dots, n} \sum_{j=1}^n (|\hat{L}| |\hat{R}|)_{ij} = \gamma_{3n} \max_{i=1, \dots, n} \sum_{j=1}^n \sum_{k=1}^{\min\{i, j\}} |\hat{\ell}_{ik}| |\hat{r}_{kj}| \\ &\leq \gamma_{3n} \max_{i=1, \dots, n} \sum_{j=1}^n \sum_{k=1}^{\min\{i, j\}} 1 \cdot \rho_n \max_{s, t} |a_{st}| \end{aligned}$$

Glavni rezultati (nastavak)

$$\begin{aligned}\|\Delta A\|_\infty &\leq \gamma_{3n} \rho_n \|A\|_\infty \max_{i=1, \dots, n} \sum_{j=1}^n \min\{i, j\} \\ &\leq \gamma_{3n} \rho_n \|A\|_\infty \max_{i=1, \dots, n} ni \\ &\leq n^2 \gamma_{3n} \rho_n \|A\|_\infty.\end{aligned}$$



Napomena. U dokazu ovog teorema korišten je mali ilegalni manevar:

- koristili smo **ograde za elemente** od \hat{L} i \hat{R} koje striktno **vrijede** za elemente egzaktnih matrica L i R .

Glavni rezultati (nastavak)

- Umjesto toga smo mogli **redefinirati pivotni rast** preko izračunatih elemenata $\hat{a}_{ij}^{(k)}$, ali tada bi svaka ograda za pivotni rast uključivala i **jediničnu grešku zaokruživanja**.
- Slično, mi možemo samo garantirati $|\hat{\ell}_{ij}| \leq 1 + \mathcal{O}(u)$.
- Ipak ovaj propust u korektnosti dokaza je **bezopasan** za naše potrebe.

Sličan rezultat može se postići i za **Gaussove eliminacije bez pivotiranja**, samo sa drugačijom konstantom.

- Povratna stabilnost po normi** Gaussovih eliminacija sa ili bez pivotiranja ovisi o **pivotnom rastu!**

Primjer nestabilnosti Gaussovih eliminacija s parcijalnim pivotiranjem

Primjer rubnog problema

- Numerička analiza Gaussovih eliminacija sa parcijalnim pivotiranjem nam je potvrdila da **stabilnost eliminacija ovisi o pivotnom rastu**.
- Već od prije znamo da je **pivotni rast** za parcijalno pivotiranje **manji ili jednak 2^{n-1}** .
- Isto tako znamo da se ta gornja ograda pivotnog rasta od 2^{n-1} postiže za “**umjetno**” konstruiran **Wilkinsonov primjer**.
- U ovom primjeru promotrit ćemo **rubni problem**, kod kojeg **standardna numerička metoda** korištena za njegovo rješavanje proizvodi **matricu sa eksponencijalnim pivotnim rastom**.

Primjer rubnog problema (nastavak)

Promotrimo općeniti rubni problem u dvije različite točke:

$$y' = M(t)y + q(t), \quad B_a y(a) + B_b y(b) = \beta, \quad y(t) \in \mathbb{R}^n,$$

i jedan konkretni problem definiran sljedećim parametrima

$$n = 2, \quad M(t) \equiv \begin{bmatrix} -\frac{1}{6} & 1 \\ 1 & -\frac{1}{6} \end{bmatrix}, \quad a = 0, \quad b = 60, \quad B_a = B_b = I.$$

Vrijednosti $q(t)$ i β nisu važne za naše razmatranje.

- Ovaj problem je dobro uvjetovan u smislu da rješenje y je neosjetljivo na perturbacije u ulaznim podacima $M(t)$, $q(t)$, B_a , B_b i β .

Numeričko rješavanje rubnog problema

Standardan algoritam za rješavanje problema ovog oblika je **višestruka metoda gađanja**.

- Najprije se segment $[a, b]$ razdijeli na N podsegmentata, definiranjem mreže

$$a = t_0 < t_1 < \cdots < t_N = b$$

pri čemu su

$$t_i = a + ih, \quad i = 0, 1, \dots, N, \quad h = \frac{b - a}{N}.$$

- Na svakom podsegmentu $[t_i, t_{i+1}]$, potrebno je riješiti **inicijalne probleme**

$$Y_i' = M(t)Y_i, \quad Y_i(t_i) = I,$$

$$y_{pi} = M(t)y_{pi} + q(t), \quad y_{pi}(t_i) = 0.$$

Numeričko rješavanje rubnog problema (nast.)

- Ako sa s_i definiramo vrijednost **pravog rješenja** y u t_i , tada možemo provjeriti da je

$$y(t) = Y_i(t)s_i + y_{pi}(t), \quad t \in [t_i, t_{i+1}], \quad i = 0, \dots, N - 1.$$

- Budući da $y(t)$ mora biti **neprekidna** u točkama mreže, dobivamo

$$Y(t_{i+1})s_i + y_{pi}(t_{i+1}) = s_{i+1}, \quad i = 0, \dots, N - 1.$$

- Štoviše, zbog **rubnih uvjeta** vrijedi

$$B_a s_0 + B_b s_N = \beta.$$

- Zadnje dvije jednakosti definiraju **sustav linearnih jednadžbi** čije je rješenje s_0, \dots, s_N .

Numeričko rješavanje rubnog problema (nast.)

Matrica sustava ima opći oblik

$$A = \begin{bmatrix} B_a & & & & B_b \\ -Y_0(t_1) & I & & & 0 \\ & & -Y_1(t_2) & I & \vdots \\ & & & \ddots & \ddots & 0 \\ & & & & -Y_{N-1}(t_N) & I \end{bmatrix} .$$

Za naš konkretan primjer imamo

$$Y_i(t_{i+1}) = e^{hM}$$

Numeričko rješavanje rubnog problema (nast.)

U tom slučaju matrica sustava ima **konkretan oblik**

$$A = \begin{bmatrix} I & & & & I \\ -e^{hM} & I & & & 0 \\ & -e^{hM} & I & & \vdots \\ & & \ddots & \ddots & 0 \\ & & & -e^{hM} & I \end{bmatrix}.$$

Pretpostavimo da je h **dovoljno mali**, tako da su **svi elementi** od e^{hM} po modulu ≤ 1 . To je **moгуće** jer

$$e^{hM} = I + hM + \mathcal{O}(h^2) \approx \begin{bmatrix} 1 - h/6 & h \\ h & 1 - h/6 \end{bmatrix}.$$

Numeričko rješavanje rubnog problema (nast.)

Ako se Gaussove eliminacije s **parcijalnim pivotiranjem** primijene na matricu A , tada neće doći **niti do jedne izmjene redaka (nema pivotiranja)**, i dobit ćemo sljedeću LR faktorizaciju

$$A = \begin{bmatrix} I & & & & & \\ -e^{hM} & I & & & & \\ & -e^{hM} & I & & & \\ & & -e^{hM} & I & & \\ & & & \ddots & \ddots & \\ & & & & -e^{hM} & \bar{L} \end{bmatrix} \begin{bmatrix} I & & & & & I \\ & I & & & & e^{hM} \\ & & I & & & e^{2hM} \\ & & & \ddots & & \vdots \\ & & & & I & e^{(60-h)M} \\ & & & & & \bar{R} \end{bmatrix},$$

gdje je $\bar{L}\bar{R} = (I + e^{60M})$, \bar{L} je **donje trokutasta** a \bar{R} je **gornje trokutasta**.

Numeričko rješavanje rubnog problema (nast.)

U prethodnoj faktorizaciji vidljivo je da elementi u posljednjem stupcu matrice R eksponencijalno rastu.

- Za konkretan izbor $N = 200$ tj. $h = 0.3$ imamo zadovoljen uvjet da su svi elementi od e^{hM} po modulu ≤ 1 :

$$e^{0.3M} = \begin{bmatrix} 0.9944 & 0.2897 \\ 0.2897 & 0.9944 \end{bmatrix}$$

- Najveći element u matrici R je $\approx 2.59 \cdot 10^{21}$.
- Detalje pogledajte u MATLAB simulaciji.

Potpuno pivotiranje, s druge strane, daje stabilnu faktorizaciju: najveći element u izračunatom faktoru R je 10.665545.

Rješavanje linearnih sustava: iterativne metode

Uvod u iterativne metode

- Vidjeli smo da rješenje linearnog sustava $Ax = b$ općenito ne možemo izračunati apsolutno točno.
- Također, u nekim primjenama niti točno rješenje $x = A^{-1}b$ nije puno bolje od neke dovoljno dobre aproksimacije \hat{x} , gdje obično \hat{x} zadovoljava sustav $(A + \delta A)\hat{x} = b$, blizak polaznom.
- Nadalje, Gaussove eliminacije, koje su jednostavno konačan niz formula koje vode rješenju sustava, ne garantiraju idealnu točnost.
- Osim toga, u praksi moramo biti svjesni da je računalo omeđeno ne samo u pitanju numeričke točnosti nego i u još dva važna aspekta:
 - raspoloživom memorijskom prostoru,
 - vremenu izvršavanja.

Uvod u iterativne metode (nastavak)


- Moderne primjene matematike zahtijevaju rješenja sustava **velikih dimenzija**, npr. $n > 10^5$.
- Lako se uvjeriti da je u takvim primjerima proces **Gaussovih eliminacija** često praktično **neupotrebljiv**.
- Jer, matrica dimenzije $n = 10^5$ zahtijeva $n^2 = 10^{10}$ lokacija u memoriji, svaka barem 4 bajta (veličina reprezentacije realnog broja u jednostrukoj preciznosti) — **samo spremanje** matrice koeficijenata u memoriju računala predstavlja **poteškoću**.
- Ponekad matricu držimo na vanjskoj, **sporoj memoriji** (datoteka na disku) i onda možemo **dijelove matrice učitavati** dio po dio u radnu memoriju.
- Da ne govorimo o **vremenu izvršavanja** Gaussovih eliminacija, čija je složenost $\mathcal{O}(n^3)$!

Uvod u iterativne metode (nastavak)

- U puno važnih primjena matrica sustava A je velike dimenzije, ali je **rijetko popunjena**. To znači da je **velika većina elemenata** od A jednaka **nuli**, a elementi koji nisu nula obično su
 - **pravilno raspoređeni** po matrici
 - ili čak imaju i pravilno raspoređene **numeričke vrijednosti**.

Uvod u iterativne metode (nastavak)

Jedan primjer rijetko popunjene matrice dan je na slici.



- U svakom retku broj elemenata $\neq 0$ unaprijed je poznat i broj takvih elemenata je puno manji od dimenzije n .
- To znači da je npr. računanje produkta Av složenosti puno manje od $2n^2 - n$, što je potrebno za punu matricu.

Uvod u iterativne metode (nastavak)

- Ponekad je poznat način kako su generirani elementi matrice (npr. poznato da je $a_{ij} = f_{ij}(\dots)$, gdje su $f_{ij}(\dots)$ poznate funkcije nekih parametara) pa uvijek možemo generirati dijelove matrice.
- Moguće je i da je u konkretnoj aplikaciji jedino zadano kako A djeluje kao linearni operator – postoji potprogram koji za zadani v računa Av .
- Ako je to jedini način kako doći do matrice A , kako onda riješiti $Ax = b$?

Uvod u iterativne metode (nastavak)

Prethodna diskusija nas motivira da potražimo i **drugačije pristupe** za rješavanje linearnog sustava $Ax = b$.

- Primijetimo da ne moramo nužno težiti pronalaženju **egzaktog rješenja** – umjesto toga želimo **dovoljno dobru** aproksimaciju \hat{x} .
- Zato ima smisla pokušati **konstruirati niz** $x^{(0)}, x^{(1)}, \dots, x^{(k)}, \dots$ vektora iz \mathbb{R}^n sa sljedećim svojstvima:
 - za svaki k formula za računanje $x^{(k)}$ je **jednostavna**;
 - $x^{(k)}$ **teži prema** $x = A^{-1}b$ i za neki k (obično $k \ll n$) je $x^{(k)}$ **prihvatljiva aproksimacija** za x .

Općenito o iterativnim metodama

Pretpostavimo da je A regularna matrica reda n .

- Iterativna metoda koja pronalazi približno rješenje sustava $Ax = b$ zadana je
 - početnim vektorom $x^{(0)}$
 - i načinom na koji se računa aproksimacija $x^{(k)}$ u k -tom koraku iteracije.
- U praksi se gotovo isključivo koriste **iterativne metode prvog reda**, koje iz **jednog prethodnog** vektora $x^{(k)}$ nalaze sljedeću aproksimaciju $x^{(k+1)}$.
- **Kriterij zaustavljanja** sličan je kao kod svih metoda “limes” tipa – tj. kad je $x^{(k)}$ **dovoljno dobra aproksimacija** za pravo rješenje x , **stani!**.
- Naravno, i tu postoji problem, jer pravi x **ne znamo**.

Općenito o iterativnim metodama (nastavak)

● Zbog toga, koristimo svojstvo da je konvergentan niz **Cauchyjev**, tj. da **susjedni članovi** niza moraju postati po **volji bliski**.

● Standardno, uzima se da su $x^{(k+1)}$ i $x^{(k)}$ dovoljno bliski ako je

$$\|x^{(k+1)} - x^{(k)}\| \leq \varepsilon,$$

gdje je ε neka **unaprijed zadana točnost** (reda veličine u , odnosno $n \cdot u$), a $\| \cdot \|$ neka **vektorska norma**.

● **Drugi način** za određivanje kriterija zaustavljanje je kada je **norma reziduala dovoljno mala**.

● Međutim, vidjeli smo da je taj kriterij **nepouzdan** za **loše uvjetovane matrice**.

Standardne iteracije

Iterativnu metodu pokušavamo definirati izrazom

$$x^{(k+1)} = Tx^{(k)} + c, \quad k = 0, 1, 2, \dots, \quad x^{(0)} \text{ zadan,}$$

gdje je $T \in \mathbb{R}^{n \times n}$ matrica iteracije i $c \in \mathbb{R}^n$.

Da bismo ostvarili takvu iterativnu metodu, potrebno je pažljivo rastaviti matricu A .

Definicija. Rastav matrice A je par matrica (M, N) (obje reda n) za koje vrijedi

- $A = M - N$,
- M je regularna.

Obično se M bira tako da se može lako invertirati: dijagonalna ili trokutasta.

Standardne iteracije (nastavak)

Bilo koji rastav matrice A generira iterativnu metodu na sljedeći način:

$$Ax = Mx - Nx = b \implies Mx = Nx + b,$$

pa zbog regularnosti od M izlazi

$$x = M^{-1}Nx + M^{-1}b.$$

Ako označimo $T = M^{-1}N$, $c = M^{-1}b$ onda je prethodna relacija **ekvivalentna** s

$$x = Tx + c.$$

Time smo definirali našu iterativnu metodu

$$x^{(k+1)} = Tx^{(k)} + c, \quad k \in \mathbb{N}_0.$$

Konvergenција standardnih iteracija

Pravo rješenje x je fiksna točka iteracione funkcije

$$f(x) = Tx + c.$$

To znači da u analizi konvergenције možemo koristiti poznate teoreme o fiksnoj točki (poput Banachovog u potpunim prostorima).

Lema 1. Niz iteracija $(x^{(k)})$, $k \in \mathbb{N}_0$, generiran relacijom $x^{(k+1)} = Tx^{(k)} + c$, $k \in \mathbb{N}_0$ konvergira prema rješenju linearnog sustava $Ax = b$ za sve početne vektore $x^{(0)}$ i sve desne strane b , ako je

$$\|T\| < 1,$$

pri čemu je $\| \cdot \|$ proizvoljna operatorska norma.

Konvergenција standardnih iteracija (nastavak)

Dokaz. Oduzmimo $x = Tx + c$ od $x^{(k+1)} = Tx^{(k)} + c$.

Dobivamo

$$x^{(k+1)} - x = T(x^{(k)} - x),$$

pa uzimanjem **norme** dobivamo

$$\|x^{(k+1)} - x\| \leq \|T\| \|x^{(k)} - x\| \leq \dots \leq \|T\|^{k+1} \|x^{(0)} - x\|.$$

No, zbog $\|T\| < 1$ slijedi $\|T\|^{k+1} \rightarrow 0$ za $k \rightarrow \infty$, odakle izlazi

$$\|x - x^{(k+1)}\| \rightarrow 0,$$

pa iz **neprekidnosti norme** slijedi

$$x^{(k+1)} \rightarrow x \quad \text{za svaki } x^{(0)}.$$

Konvergenција standardnih iteracija (nastavak)

No, može se dobiti i nešto bolji rezultat, korištenjem veze **spektralnog radijusa** i **operatorske norme** matrice.

Lema 2.

• Za sve operatorske norme $\| \cdot \|$ vrijedi

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

• Za sve T i sve $\varepsilon > 0$ postoji operatorska norma $\| \cdot \|_*$ takva da je

$$\|T\|_* \leq \rho(T) + \varepsilon.$$

Norma $\| \cdot \|_*$ ovisi i o T , i o ε .

Konvergenција standardnih iteracija (nastavak)

Dokaz. Da bismo dokazali da je $\rho(T) \leq \|T\|$ za bilo koju operatorsku normu, uzet ćemo $\rho(T) = |\lambda|$, i pripadni svojstveni vektor od λ , kojeg označavamo sa x . Tada vrijedi

$$\|T\| = \max_{y \neq 0} \frac{\|Ty\|}{\|y\|} \geq \frac{\|Tx\|}{\|x\|} = \frac{\|\lambda x\|}{\|x\|} = \frac{|\lambda| \|x\|}{\|x\|} = |\lambda| = \rho(T).$$

S druge strane, da bismo konstruirali operatorsku normu $\|\cdot\|_*$ takvu da je $\|T\|_* \leq \rho(T) + \varepsilon$, svedimo matricu T na njenu **Jordanovu formu**.

- Znamo da **postoji regularna matrica S** za koju je $J = S^{-1}TS$ Jordanova forma matrice T .
- **Jedinice** iznad dijagonale u J “kvare” spektralni radijus, pa je ideja da umjesto njih dobijemo zadani $\varepsilon > 0$.

Konvergenција standardnih iteracija (nastavak)

Uzmimo kao **vektorsku normu**

$$\|x\|_* = \|(SD_\varepsilon)^{-1}x\|_\infty$$

(pokažite da je to vektorska norma!), koja **generira operatorsku normu**. U toj operatorskoj normi vrijedi

$$\begin{aligned}\|T\|_* &= \max_{x \neq 0} \frac{\|Tx\|_*}{\|x\|_*} = \max_{x \neq 0} \frac{\|(SD_\varepsilon)^{-1}Tx\|_\infty}{\|(SD_\varepsilon)^{-1}x\|_\infty} \\ &= \max_{y \neq 0} \frac{\|(SD_\varepsilon)^{-1}T(SD_\varepsilon)y\|_\infty}{\|y\|_\infty} \\ &= \|(SD_\varepsilon)^{-1}T(SD_\varepsilon)\|_\infty \leq \max_i |\lambda_i| + \varepsilon = \rho(T) + \varepsilon.\end{aligned}$$



Konvergenција standardnih iteracija (nastavak)

Konačno, prethodne dvije leme daju **potpunu karakterizaciju konvergenције** iterativnih metoda.

Teorem. Niz iteracija $(x^{(k)})$, $k \in \mathbb{N}_0$, generiran relacijom $x^{(k+1)} = Tx^{(k)} + c$, $k \in \mathbb{N}_0$ **konvergira** prema rješenju linearnog sustava $Ax = b$ za **sve početne vektore** $x^{(0)}$ i **sve desne strane** b , **ako i samo ako** je

$$\rho(T) < 1,$$

pri čemu je $\rho(T)$ **spektralni radijus** matrice $T = M^{-1}N$.
Uočite da $\rho(T)$ **ovisi samo** o A i njenom rastavu, a ne o b .

Dokaz. Ako je $\rho(T) \geq 1$, **izaberimo** startnu aproksimaciju $x^{(0)}$ tako da je $x^{(0)} - x$ **svojstveni vektor** koji pripada svojstvenoj vrijednosti λ , $\rho(T) = |\lambda|$.

Konvergencija standardnih iteracija (nastavak)

Tada vrijedi

$$\begin{aligned}(x^{(k+1)} - x) &= T(x^{(k)} - x) = \dots = T^{k+1}(x^{(0)} - x) \\ &= \lambda^{k+1}(x^{(0)} - x),\end{aligned}$$

pa, očito $(k + 1)$ -a **potencija broja** koji je po apsolutnoj vrijednosti **veći ili jednak 1**, **ne može** težiti u 0.

S druge strane, ako je $\rho(T) < 1$, onda možemo **izabrati** $\varepsilon > 0$ takav da je

$$\rho(T) + \varepsilon < 1,$$

a zatim po **Lemi 2** i postoji **operatorska norma** $\| \cdot \|_*$ takva da vrijedi

$$\|T\|_* \leq \rho(T) + \varepsilon < 1.$$

Konvergencija standardnih iteracija (nastavak)

Budući da je $\|\cdot\|_*$ operatorska norma, ponovno, po prvom dijelu **Leme 2** slijedi da je

$$\rho(T) \leq \|T\|_*.$$

Zadnje dvije relacije zajedno daju da je

$$\|T\|_* < 1,$$

pa primjenom **Leme 1** dobivamo traženi rezultat. ■

Lema 1 i prethodni teorem, zapravo nam daju i **brzinu konvergencije**.

Brzina konvergencije standardnih iteracija

Definicija. Za niz aproksimacija $x^{(k)}$, $k \in \mathbb{N}_0$, reći ćemo da **konvergira** prema x s **redom** p ako je

$$\|x^{(k+1)} - x\| \leq a \|x^{(k)} - x\|^p, \quad a \in \mathbb{R}_0^+.$$

Ako je $p = 1$ (tzv. **linearna konvergencija**), mora biti $a < 1$ (tzv. **geometrijska konvergencija** s faktorom a).

U slučaju konvergentnih iterativnih metoda, **konvergencija je linearna**, a faktor je $\mathcal{O}(\rho(T)) < 1$, tj. za $q > 0$ takav da je $(1 + q)\rho(T) < 1$ i za $\varepsilon = q\rho(T)$ vrijedi

$$\|x^{(k+1)} - x\|_* \leq (1 + q)\rho(T) \|x^{(k)} - x\|_*.$$

tako da **spektralni radijus** možemo smatrati **ocjenom stope konvergencije** iterativne metode.

Izbor rastava matrice

Naravno, sljedeći cilj nam je odgovoriti na pitanje **kako odrediti rastav** matrice $A = M - N$ koji zadovoljava

- $Tx = M^{-1}Nx$ i $c = M^{-1}b$ se **lako računaju**,
- $\rho(T)$ je **malen**?

Odmah nam se nameću neka jednostavna rješenja za ova dva suprotna cilja.

- Na primjer, izaberemo li $M = I$, M je regularna, i Tx i c se lako računaju, ali **nije jasno** da smo zadovoljili da je $\rho(T) < 1$.
- S druge strane, izbor $N = 0$ je izvrstan za drugi cilj ($\rho(T) = 0$), ali **nije dobar** za prvi cilj, jer je $c = A^{-1}b$, tj. dobivamo polazni problem kojeg treba riješiti ($x = c$).

Izbor rastava matrice (nastavak)

- Dakle, rastav koji bi uvijek dobro radio **nije lako konstruirati**.
- Međutim tu će nam pomoći praksa.
- Matrice koje se javljaju u praksi su ili **pozitivno definitne** ili (strogo) **dijagonalno dominantne**, pa će za takve tipove matrica biti mnogo **lakše konstruirati** iterativne metode i pokazati da one konvergiraju.

Uvedimo sljedeću **notaciju**. Pretpostavimo da **A nema nula na dijagonali**. Tada **A** možemo zapisati kao

pri čemu je
$$A = L + D + R,$$

- **L strogo donji trokut** od **A**
- **D dijagonala** od **A**
- **R strogo gornji trokut** od **A**

Jacobijeva metoda

Ako je matrica M iz rastava matrice A dijagonalna, tada se dobivena iterativna metoda naziva **Jacobijevom metodom**.

- To je jedna od **najlakših** metoda jer moramo invertirati dijagonalnu matricu.
- Kod **Jacobijeve** metode je

$$M_J = D, \quad N_J = -(L + R),$$

odakle slijedi da je u **iteracijama** oblika

$$x^{(k+1)} = T_J x^{(k)} + c_J$$

$$T_J = -D^{-1}(L + R), \quad c_J = D^{-1}b.$$

Jacobijeva metoda (nastavak)

Promatrajući jednađbu $M_J x^{(k+1)} = N_J x^{(k)} + b$

$$Dx^{(k+1)} = -(L + R)x^{(k)} + b$$

po **komponentama** dobivamo

$$a_{ii}x_i^{(k+1)} = -\sum_{j=1}^{i-1} a_{ij}x_j^{(k)} - \sum_{j=i+1}^n a_{ij}x_j^{(k)} + b_i, \quad i = 1, \dots, n.$$

Oдавde direktno slijedi kako se **računa** i -ta komponenta $(k + 1)$ -ve iteracije:

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

Algoritam Jacobijeve metode

Algoritam (Jacobijeva metoda).

$x^{(0)}$ zadan; $k = 0$;

dok nije zadovoljen kriterij zaustavljanja radi {

za $i = 1$ do n radi {

$$x_i^{(k+1)} = b_i;$$

za $j = 1$ do $i - 1$ radi {

$$x_i^{(k+1)} = x_i^{(k+1)} - a_{ij} \cdot x_j^{(k)};$$

}

za $j = i + 1$ do n radi {

$$x_i^{(k+1)} = x_i^{(k+1)} - a_{ij} \cdot x_j^{(k)};$$

}

$$x_i^{(k+1)} = x_i^{(k+1)} / a_{ii};$$

$$k = k + 1;$$

}

}

Detalji implementacije Jacobijeve metode

- Primijetimo da kod skladištenja vektora u memoriji, novi vektor $x^{(k+1)}$ ne može se prepisati preko starog vektora $x^{(k)}$ sve dok sve komponente vektora $x^{(k+1)}$ nisu izračunate.
- Dakle, prije kraja jedne iteracije oba vektora moramo posebno skladištiti.
- Dalje, uočimo da prolaz kroz petlju po i u ovom algoritmu možemo izvršiti bilo kojim poretkom — ne nužno sekvencijalnim.
- Komponente novog vektora $x^{(k+1)}$ ovise samo o komponentama starog vektora $x^{(k)}$, a ne i o nekim novim komponentama. Zbog toga je Jacobijeva metoda idealna za paralelno računanje, jer pojedine komponente novog vektora možemo računati potpuno nezavisno.

Konvergenција Jacobijeve metode

Teorem Ako je matrica A strogo dijagonalno dominantna u smislu

$$|a_{ii}| > \sum_{\substack{j=1 \\ j \neq i}}^n |a_{ij}|, \quad i = 1, \dots, n,$$

tada **Jacobijeva** metoda **konvergira** za svaku početnu iteraciju $x^{(0)}$ prema rješenju sustava $Ax = b$.

Dokaz. Iz pretpostavke teorema vrijedi sljedeće

$$\|T_J\|_\infty = \max_{i=1, \dots, n} \sum_{j=1}^n |(T_J)_{ij}| = \max_{i=1, \dots, n} \frac{1}{|a_{ii}|} \sum_{j \neq i} |a_{ij}| < 1,$$

pa prema **Teoremu** o konvergenciji iterativnih metoda tj. prema **Lemi 1**, **Jacobijeve** iteracije **konvergiraju** za svaku početnu iteraciju. ■

Gauss–Seidelova metoda

Ako je matrica M iz rastava matrice A donje trokutasta, tada se dobivena iterativna metoda naziva Gauss–Seidelovom metodom.

● Kod Gauss–Seidelove metode je

$$M_{GS} = D + L, \quad N_{GS} = -R,$$

odakle slijedi da je u iteracijama oblika

$$x^{(k+1)} = T_{GS}x^{(k)} + c_{GS}$$

$$T_{GS} = -(D + L)^{-1}R, \quad c_{GS} = (D + L)^{-1}b.$$

Gauss–Seidelova metoda (nastavak)

Promatrajući jednadžbu $M_{GS}x^{(k+1)} = N_{GS}x^{(k)} + b$

$$(D + L)x^{(k+1)} = -Rx^{(k)} + b$$

po **komponentama** dobivamo

$$\sum_{j=1}^i a_{ij}x_j^{(k+1)} = - \sum_{j=i+1}^n a_{ij}x_j^{(k)} + b_i, \quad i = 1, \dots, n.$$

Oдавде slijedi kako se **računa** i -ta komponenta $(k + 1)$ -ve iteracije:

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

Algoritam Gauss–Seidelove metode

Algoritam (Gauss–Seidelova metoda).

$x^{(0)}$ zadan; $k = 0$;

dok nije zadovoljen kriterij zaustavljanja radi {

za $i = 1$ do n radi {

$$x_i^{(k+1)} = b_i;$$

za $j = 1$ do $i - 1$ radi {

$$x_i^{(k+1)} = x_i^{(k+1)} - a_{ij} \cdot x_j^{(k+1)};$$

}

za $j = i + 1$ do n radi {

$$x_i^{(k+1)} = x_i^{(k+1)} - a_{ij} \cdot x_j^{(k)};$$

}

$$x_i^{(k+1)} = x_i^{(k+1)} / a_{ii};$$

$$k = k + 1;$$

}

}

Detalji implementacije Gauss-Seidelove metode

- Kod računanja tekuće komponente nove iteracije $x^{(k+1)}$ **koriste** se sve do sada **izračunate** komponente od $x^{(k+1)}$.
- Time se omogućava da komponente od $x^{(k+1)}$ **prebrišu** stare vrijednosti komponentata od $x^{(k)}$, **čim se izračunaju**, tako da ne moramo pamtiti dva vektora, već samo **jedan**.
- S druge strane, **redosljed** računanja komponenti iteracije kod **Gauss–Seidelovog** algoritma je **bitan**. U algoritmu smo uzeli **prirodni redosljed** — od prve prema zadnjoj komponenti (petlja po i od 1 do n).
- To **ne** znači da je to i jedini mogući redosljed.
- U principu, možemo uzeti i bilo koji **drugi redosljed**, tj. bilo koju drugu od mogućih $n!$ permutacija jednadžbi. No, zbog sekvencijalnosti popravaka, rezultat nije isti, tj. dobivamo **drugačiju iterativnu metodu**.

Detalji implementacije Gauss-Seidelove metode

- U praksi se katkad i koriste drugačiji redosljedi, ali za sasvim posebne linearne sustave koji nastaju **diskretizacijom parcijalnih diferencijalnih jednadžbi**.
- Na primjer, za **Laplaceovu jednadžbu** u dvije dimenzije koristi se tzv. **“crveno–crni”** poredak (engl. “red–black” ordering), koji naliči šahovskoj ploči s crvenim i crnim poljima, s tim da se prvo računaju sva polja crvene boje, a zatim sva polja crne boje. Zbog posebne strukture sustava, ovaj poredak dozvoljava i **efikasnu paralelizaciju**.

Konvergenција Gauss–Seidelove metode

Teorem Ako je A strogo dijagonalno dominantna matrica po recima, onda i Jacobijeva i Gauss–Seidelova metoda konvergiraju i vrijedi

$$\|T_{GS}\|_{\infty} \leq \|T_J\|_{\infty} < 1.$$

Napomena. Dakle, Gauss–Seidelova metoda u najgorem slučaju konvergira barem tako brzo kao Jacobijeva metoda u najgorem slučaju. To ne znači da će Gauss–Seidelova metoda konvergirati brže nego Jacobijeva za bilo koji problem $Ax = b$.

Dokaz. Prema Teoremu za konvergenciju Jacobijeve metode znamo da je $\|T_J\|_{\infty} < 1$.

Konvergenција Gauss–Seidelove metode (nast.)

Za potrebe dokaza definirajmo:

$$\tilde{L} = -D^{-1}L, \quad \tilde{R} = -D^{-1}R.$$

Tada su

$$T_J = -D^{-1}(L + R) = \tilde{L} + \tilde{R},$$

$$T_{GS} = -(D + L)^{-1}R = -(I + D^{-1}L)^{-1}D^{-1}R = (I - \tilde{L})^{-1}\tilde{R}.$$

Želimo dokazati da vrijedi

$$\|T_{GS}\|_\infty = \| |T_{GS}| e \|_\infty \leq \| |T_J| e \|_\infty = \|T_J\|_\infty,$$

pri čemu je e vektor sa svim komponentama jednakim 1, tj. $e = [1, \dots, 1]^T$.

Konvergenција Gauss–Seidelove metode (nast.)

Ovu relaciju možemo lako pokazati ako dokažemo **jaču komponentnu nejednakost**

$$|(I - \tilde{L})^{-1}\tilde{R}| \cdot e = |T_{GS}| \cdot e \leq |T_J| \cdot e = (|\tilde{L}| + |\tilde{R}|) \cdot e.$$

Krenimo slijeva i iskoristimo **relaciju trokuta**. Vrijedi

$$|(I - \tilde{L})^{-1}\tilde{R}| \cdot e \leq |(I - \tilde{L})^{-1}| |\tilde{R}| \cdot e.$$

Ako je $\rho(\tilde{L}) < 1$, (a je, jer je $\rho(\tilde{L}) = 0!$), onda je $I - \tilde{L}$ **regularna** i možemo $(I - \tilde{L})^{-1}$ razviti u red

$$(I - \tilde{L})^{-1} = I + \tilde{L} + \tilde{L}^2 + \cdots + \tilde{L}^n + \cdots$$

Konvergencija Gauss–Seidelove metode (nast.)

Primijetimo da je \tilde{L} strogo donje trokutasta pa je i **nilpotentna** matrica, i vrijedi $\tilde{L}^k = 0$ za $k \geq n$. Time prethodni red postaje

$$(I - \tilde{L})^{-1} = I + \tilde{L} + \tilde{L}^2 + \dots + \tilde{L}^{n-1}.$$

Korištenjem prethodnih razmatranja dobivamo

$$\begin{aligned} |(I - \tilde{L})^{-1} \tilde{R}| \cdot e &\leq \left| \sum_{i=0}^{n-1} \tilde{L}^i \right| |\tilde{R}| \cdot e \leq \sum_{i=0}^{n-1} |\tilde{L}|^i |\tilde{R}| \cdot e \\ &\leq (I - |\tilde{L}|)^{-1} |\tilde{R}| \cdot e. \end{aligned}$$

Još moramo pokazati da je

$$(I - |\tilde{L}|)^{-1} |\tilde{R}| \cdot e \leq (|\tilde{L}| + |\tilde{R}|) \cdot e.$$

Konvergenција Gauss–Seidelove metode (nast.)

Budući da su svi članovi u redu za $(I - |\tilde{L}|)^{-1}$ nenegativni, dovoljno je pokazati da je

$$|\tilde{R}| \cdot e \leq (I - |\tilde{L}|) (|\tilde{L}| + |\tilde{R}|) \cdot e = (|\tilde{L}| + |\tilde{R}| - |\tilde{L}|^2 - |\tilde{L}| |\tilde{R}|) \cdot e,$$

odnosno

$$0 \leq (|\tilde{L}| - |\tilde{L}|^2 - |\tilde{L}| |\tilde{R}|) \cdot e = |\tilde{L}| (I - |\tilde{L}| - |\tilde{R}|) \cdot e.$$

Ponovno, budući da su svi elementi $|\tilde{L}|$ nenegativni, prethodna nejednakost bit će ispunjena ako je

$$0 \leq (I - |\tilde{L}| - |\tilde{R}|) \cdot e,$$

odnosno

$$(|\tilde{L}| + |\tilde{R}|) \cdot e \leq e.$$

Konvergenција Gauss–Seidelove metode (nast.)

Budući da je $|T_J| = |\tilde{L} + \tilde{R}| = |\tilde{L}| + |\tilde{R}|$, jer se elementi \tilde{L} i \tilde{R} nigdje ne zbrajaju, onda je posljednja nejednakost ekvivalentna s

$$|T_J| \cdot e \leq e.$$

Ovu posljednju nejednakost možemo dokazati jer je

$$\| |T_J| \cdot e \|_\infty = \|T_J\|_\infty < 1.$$

Čitanjem dokaza u obratnom redosljedu, dobivamo tražena svojstva. ■

Konvergenција Gauss–Seidelove metode (nast.)

Teorem. Ako je matrica A hermitska (simetrična) i pozitivno definitna, tada Gauss–Seidelova metoda konvergira za svaku početnu iteraciju $x^{(0)}$.

Dokaz. Neka je λ proizvoljna svojstvena vrijednost matrice T_{GS} i neka je $y \neq 0$ odgovarajući svojstveni vektor. Tada imamo

$$-Ry = \lambda(D + L)y,$$

pa ako toj jednakosti dodamo λRy s lijeve i desne strane, vrijedi

$$-(1 - \lambda)Ry = \lambda(D + L + R)y = \lambda Ay.$$

S druge strane je, ponovo zbog $-Ry = \lambda(D + L)y$

$$Ay = (D + L)y + Ry = (1 - \lambda)(D + L)y.$$

Konvergenција Gauss–Seidelove metode (nast.)

Pomnožimo sada **prvu prethodnu jednakost** skalarno sa λy , a **drugu** sa y , i oduzmimo **prvu** jednadžbu od **druge**, tada vrijedi

$$(1 - |\lambda|^2)\langle Ay, y \rangle = (1 - \lambda)(\langle Dy, y \rangle + \langle Ly, y \rangle + \langle Ry, \lambda y \rangle).$$

Promatramo sada samo **zadnji izraz** u prethodnoj jednakosti. Zbog **hermitičnosti** matrice A vrijedi da je $R^* = L$, zbog **pozitivne definitnosti** $D > 0$, a iz prve jednakosti dokaza vrijedi da je $\lambda Ly = -\lambda Dy - Ry$, pa imao

$$\begin{aligned}\langle Ry, \lambda y \rangle &= \langle y, \lambda Ly \rangle = -\langle y, \lambda Dy \rangle - \langle y, Ry \rangle \\ &= -\langle Dy, \lambda y \rangle - \langle Ly, y \rangle.\end{aligned}$$

Sada zadnji izraz ubacimo u **gornju jednakost**, čime dobivamo

Konvergenција Gauss–Seidelove metode (nast.)

$$\begin{aligned}(1 - |\lambda|^2)\langle Ay, y \rangle &= (1 - \lambda)(\langle Dy, y \rangle + \langle Ly, y \rangle - \langle Dy, \lambda y \rangle - \langle Ly, y \rangle) \\ &= (1 - \lambda)(1 - \bar{\lambda})\langle Dy, y \rangle,\end{aligned}$$

odakle zbog $\langle Ay, y \rangle > 0$ i zbog $\lambda \neq 1$ (budući da bi iz $-(1 - \lambda)Ry = \lambda Ay$ za $\lambda = 1$ slijedilo da je $Ay = 0$, što je kontradiktorno sa svojstvom pozitivne definitnosti matrice A), slijedi

$$1 - |\lambda|^2 = \frac{\langle Dy, y \rangle}{\langle Ay, y \rangle} |1 - \lambda|^2 > 0.$$

Znači za svaku svojstvenu vrijednost λ od T_{GS} vrijedi da je $|\lambda| < 1$, pa to vrijedi i za svojstvenu vrijednost koja ima maksimalnu apsolutnu vrijednost, odnosno $\rho(T_{GS}) < 1$, iz čega prema **Teoremu** o konvergenciji iterativnih metoda slijedi da Gauss–Seidelova metoda **konvergira** za svaki $x^{(0)}$. ■

Relaksacijske metode

- Kad jednom znamo konstruirati iterativni proces, nameće se vrlo jednostavna ideja za poboljšanje njezine konvergencije, uvođenjem jednog realnog parametra.
- Nove aproksimacije možemo računati u dva koraka.
 - Prvo iz $x^{(k)}$ nađemo (jednostavnu) pomoćnu sljedeću aproksimaciju $x_*^{(k+1)}$, a zatim
 - za “pravu” novu aproksimaciju $x^{(k+1)}$ uzmemo težinsku sredinu prethodne aproksimacije $x^{(k)}$ i pomoćne nove aproksimacije $x_*^{(k+1)}$

$$x^{(k+1)} = (1 - \omega)x^{(k)} + \omega x_*^{(k+1)} = x^{(k)} + \omega(x_*^{(k+1)} - x^{(k)}),$$

gdje je ω težinski parametar kojeg možemo birati.

Relaksacijske metode (nastavak)

- Očito, za $\omega = 1$ dobivamo $x^{(k+1)} = x_*^{(k+1)}$, pa je ova metoda **proširenje** metode za nalaženje pomoćnih aproksimacija.
- Obično se uzima $\omega \in \mathbb{R}$ i $\omega \neq 0$, da ne dobijemo stacionaran niz.
- Ideja za ovakav postupak dolazi iz **općih metoda za rješavanje jednadžbi i minimizaciju funkcionala**.
- Pomoćna aproksimacija $x_*^{(k+1)}$ daje **smjer** korekcije prethodne aproksimacije $x^{(k)}$ u kojem treba ići da bismo se približili pravom rješenju sustava (**smanjili rezidual** $r(x) = Ax - b$ u nekoj normi).

Relaksacijske metode (nastavak)

- Ako je $x_*^{(k+1)} - x^{(k)}$ dobar smjer korekcije, onda možemo dodati i izbor duljine koraka ω u smjeru te korekcije, tako da dobijemo što bolji $x^{(k+1)}$. (Ovakav pristup ćemo vidjeti kod metoda najbržeg silaska i konjugiranih gradijenata.)
- Općenito očekujemo da je $\omega > 0$, tj. da idemo u smjeru vektora korekcije, a ne suprotno od njega, a stvarno želimo dobiti $\omega > 1$, tako da se još više maknemo u dobrom smjeru i približimo pravom rješenju.
- Naziv “relaksacija” dolazi upravo iz minimizacijskih metoda, a odnosi se na sve iterativne metode koje koriste neki oblik minimizacije ili pokušaja minimizacije reziduala. U tom smislu, često se koristi i tradicionalni naziv “relaksacijski parametar” za ω .

Relaksacijske metode (nastavak)

- Obzirom na vrijednost parametra ω , imamo tri različita slučaja.
 - Ako je $\omega = 1$, onda se metoda svodi na pomoćnu metodu i to je tzv. obična ili **standardna relaksacija**.
 - Ako je $\omega < 1$, onda takvu metodu zovemo **podrelaksacija** (engl. “underrelaxation”),
 - a ako je $\omega > 1$ onda metodu zovemo **pre-** ili **nad-relaksacija** (engl. “overrelaxation”).
- U općem slučaju, ω se posebno računa u svakoj **pojedinoj iteraciji**, tako da dobijemo što bolji $x^{(k+1)}$.
- Postupak se svodi na **jednodimenzionalnu optimizaciju**, a ovisi o kriteriju optimalnosti za mjerenje “kvalitete” aproksimacija.

Relaksacijske metode (nastavak)

- Srećom, za neke klase linearnih sustava, koje su izrazito bitne u praksi, unaprijed se može dobro odabrati optimalni ili skoro optimalni parametar ω za maksimalno ubrzanje konvergencije iterativnih metoda,
- i to tako da isti ω vrijedi za sve iteracije.
- U većini slučajeva dobivamo $\omega > 1$ za optimalni ω , pa se takve metode standardno zovu “OverRelaxation” i skraćeno označavaju s OR.
- Obzirom na to da se ω zadaje ili bira unaprijed, a zatim koristi za sve iteracije, metoda je ovisna o jednom parametru i standardno koristimo oznaku $OR(\omega)$.

JOR metoda – Jacobi overrelaxation

Ako se u iteraciji

$$x^{(k+1)} = (1 - \omega)x^{(k)} + \omega x_*^{(k+1)} = x^{(k)} + \omega(x_*^{(k+1)} - x^{(k)}),$$

pomoćna nova aproksimacija $x_*^{(k+1)}$ računa po Jacobijevoj metodi, dobivamo **Jacobijevu nadrelaksaciju** ili **JOR** metodu.

Dakle, i -ta komponenta $(k + 1)$ -ve iteracije je oblika:

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

Kao i kod obične Jacobijeve metode, petlju po i možemo izvršiti **bilo kojim redom**, uz isti rezultat, pa se i ovdje komponente novog vektora $x^{(k+1)}$ mogu **paralelno** računati.

JOR metoda – Jacobi overrelaxation (nastavak)

Vektorski oblik iteracija u $JOR(\omega)$ metodi je

$$x^{(k+1)} = (1 - \omega)x^{(k)} + \omega(T_J x^{(k)} + c_J) := T_{JOR(\omega)} x^{(k)} + c_{JOR(\omega)}$$

pa je

$$T_{JOR(\omega)} = (1 - \omega)I + \omega T_J = (1 - \omega)I - \omega D^{-1}(L + R),$$

$$c_{JOR(\omega)} = \omega c_J = \omega D^{-1}b.$$

Pripadni rastav matrice A je

$$A = \frac{1}{\omega}D - \left(\frac{1-\omega}{\omega}D - L - R \right),$$

tj. $M = \frac{1}{\omega}D$, $N = \frac{1-\omega}{\omega}D - L - R$. Naravno, za $\omega = 1$ dobivamo **Jacobijevu** metodu.

JOR metoda – Jacobi overrelaxation (nastavak)

- Iz oblika matrice $T_{JOR(\omega)}$ vidimo da se **optimalni parametar** ω koji minimizira njen spektralni radijus može odrediti **unaprijed**, prije početka iteracija.
- Drugim riječima, treba koristiti **isti** ω u **svim** iteracijama, naravno, pod uvjetom da imamo konvergenciju.

Algoritam JOR metode

Algoritam (JOR metoda).

$x^{(0)}$ i ω zadani; $k = 0$;

dok nije zadovoljen kriterij zaustavljanja radi {

za $i = 1$ do n radi {

$$pom = (1 - \omega)x_i^{(k)}; \quad x_i^{(k+1)} = b_i;$$

za $j = 1$ do $i - 1$ radi {

$$x_i^{(k+1)} = x_i^{(k+1)} - a_{ij} \cdot x_j^{(k)};$$

}

za $j = i + 1$ do n radi {

$$x_i^{(k+1)} = x_i^{(k+1)} - a_{ij} \cdot x_j^{(k)};$$

}

$$x_i^{(k+1)} = pom + \omega \cdot x_i^{(k+1)} / a_{ii};$$

$$k = k + 1;$$

}

}

Konvergenција JOR metode

Teorem. Ako Jacobijeva metoda konvergira za svaku početnu iteraciju x_0 , onda za proizvoljno $\omega \in \langle 0, 1 \rangle$ konvergira i JOR(ω) metoda i to za svako x_0 .

Dokaz. Neka je λ proizvoljna svojstvena vrijednost Jacobijeve matrice iteracija T_J . Tada zbog konvergenције Jacobijeve metode za svako x_0 slijedi

$$|\lambda| < 1.$$

$T_{JOR(\omega)}$ je oblika $T_{JOR(\omega)} = (1 - \omega)I + \omega T_J$, pa je njezina svojstvena vrijednost μ oblika

$$\mu = 1 - \omega + \omega\lambda.$$

Konvergenција JOR metode (nastavak)

Neka je $\lambda = \alpha + \iota\beta$, za $\alpha, \beta \in \mathbb{R}$, i $\iota^2 = -1$.

- Tada zbog $|\lambda| < 1$ slijedi da je $\alpha^2 + \beta^2 < 1$ i $\alpha^2 < 1$.
- Zbog prethodno rečenog i zbog činjenice da je $1 - \omega \geq 0$, vrijedi

$$\begin{aligned} |\mu|^2 &= (1 - \omega + \omega\alpha)^2 + \omega^2\beta^2 \\ &\leq (1 - \omega)^2 + 2\omega(1 - \omega)|\alpha| + \omega^2(\alpha^2 + \beta^2) \\ &< (1 - \omega)^2 + 2\omega(1 - \omega) + \omega^2 = (1 - \omega + \omega)^2 = 1. \end{aligned}$$

Oдавде slijedi da je $\rho(T_{JOR(\omega)}) < 1$, pa prema **Teoremu** o konvergenциji iterativnih metoda, **JOR**(ω) metoda **konvergira** za svaku početnu iteraciju. ■

Konvergencija JOR metode (nastavak)

Teorem. Neka je A hermitska (simetrična) pozitivno definitna matrica i neka Jacobijeva metoda konvergira. Tada konvergira i $JOR(\omega)$ metoda za

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

gdje je $\lambda \leq 0$ najmanja svojstvena vrijednost Jacobijeve matrice iteracija T_J .

Dokaz. Neka su $\lambda_i, i = 1, \dots, n$ svojstvene vrijednosti matrice T_J .

- Zbog konvergencije Jacobijeve metode slijedi da je $|\lambda_i| < 1$ za sve $i = 1, \dots, n$.

Konvergencija JOR metode (nastavak)

- Kako su, zbog sličnosti matrice $T_J = -D^{-1}(L + L^*)$ sa **hermitskom** matricom, sve λ_i **realni** brojevi i

$$0 = \text{tr}(T_J) = \sum_{i=1}^n \lambda_i$$

slijedi da **nisu** sve λ_i **pozitivne**, te vrijedi

$$\lambda = \min_{i=1, \dots, n} \lambda_i \leq 0.$$

Ponovo vrijedi da su **svojstvene vrijednosti** matrice $T_{JOR(\omega)}$ oblika

$$\mu_i = 1 - \omega(1 - \lambda_i), \quad i = 1, \dots, n.$$

Konvergenција JOR metode (nastavak)

Kako je prema **uvjetima** teorema

$$0 < \omega(1 - \lambda) < 2, \quad \text{i} \quad \lambda_i < 1, \quad \text{za } i = 1, \dots, n$$

slijedi

$$0 < \omega(1 - \lambda_i) < \omega(1 - \lambda) < 2,$$

odnosno

$$-1 < \mu_i = 1 - \omega(1 - \lambda_i) < 1,$$

odakle je $\rho(T_{JOR(\omega)}) < 1$, pa prema **Teoremu** o konvergenciji iterativnih metoda **JOR**(ω) metoda **konvergira** za svaku početnu iteraciju. ■

Konvergenција JOR metode (nastavak)

Teorem. JOR(ω) metoda ne konvergira za

$$\omega < 0, \quad \text{ili} \quad \omega \geq 2.$$

Dokaz. Iz definicije matrice $T_{JOR(\omega)} = (1 - \omega)I + \omega T_J$ vidimo da je

$$\text{tr}(T_{JOR(\omega)}) = n(1 - \omega) = \sum_{i=1}^n \mu_i,$$

pri čemu su μ_i svojstvene vrijednosti matrice $T_{JOR(\omega)}$, imamo

$$n|1 - \omega| \leq \sum_{i=1}^n |\mu_i| \leq n\rho(T_{JOR(\omega)}).$$

Konvergenција JOR metode (nastavak)

Dakle,

$$\rho(T_{JOR(\omega)}) \geq |1 - \omega|,$$

odakle se vidi da je za $\omega < 0$ i $\omega \geq 2$ $\rho(G_{JOR,\omega}) \geq 1$, iz čega, prema **Teoremu** o konvergenciji iterativnih metoda slijedi tvrdnja teorema. ■

SOR metoda – Successive overrelaxation

● Relacija

$$x^{(k+1)} = (1 - \omega)x^{(k)} + \omega x_*^{(k+1)} = x^{(k)} + \omega(x_*^{(k+1)} - x^{(k)}),$$

koristi ideju **težinske sredine** ili duljine koraka na nivou **vektorskih** aproksimacija $x^{(k)}$.

● To prirodno odgovara **Jacobijevoj** metodi i paralelnom računanju.

● Međutim, potpuno istu ideju možemo koristiti i za poboljšanje svake **pojedine varijable** $x_i^{(k)}$, tj. pojedinačnih komponenti vektora $x^{(k)}$, što odgovara “**Gauss–Seidelovskom**” pristupu.

SOR metoda – Successive overrelaxation (nast.)

Dakle, nova aproksimacija i -te varijable ima oblik

$$x_i^{(k+1)} = (1 - \omega)x_i^{(k)} + \omega x_{i,*}^{(k+1)} = x_i^{(k)} + \omega(x_{i,*}^{(k+1)} - x_i^{(k)}), \quad i=1,\dots,n,$$

gdje je $x_{i,*}^{(k+1)}$ neka **pomoćna nova aproksimacija** i -te varijable, koju računamo tog trenutka kad nam treba, za svaki i .

- **SOR** metoda (engl. “Successive OverRelaxation” ili **ponovljena nadrelaksacija**) je proširenje ili poboljšanje **Gauss–Seidelove** metode u smislu da se pomoćna nova aproksimacija $x_{i,*}^{(k+1)}$ računa po **Gauss–Seidelovoj** metodi, pa ju označavamo s $x_{i,GS}^{(k+1)}$.
- Tada gornja relacija za i -tu komponentu nove aproksimacije u **SOR(ω)** metodi ima oblik

$$x_i^{(k+1)} = (1 - \omega)x_i^{(k)} + \omega x_{i,GS}^{(k+1)}, \quad i = 1, \dots, n.$$

SOR metoda – Successive overrelaxation (nast.)

Dakle, i -ta komponenta $(k + 1)$ -ve iteracije je oblika:

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

Iz gornje jednačbe odmah vidimo da je za $i = 1, \dots, n$

$$a_{ii}x_i^{(k+1)} + \omega \sum_{j=1}^{i-1} a_{ij}x_j^{(k+1)} = (1 - \omega)a_{ii}x_i^{(k)} - \omega \sum_{j=i+1}^n a_{ij}x_j^{(k)} + \omega b_i.$$

Ove jednačbe po komponentama možemo zapisati u **vektorskom** obliku

$$(D + \omega L)x^{(k+1)} = ((1 - \omega)D - \omega R)x^{(k)} + \omega b,$$

SOR metoda – Successive overrelaxation (nast.)

odakle slijedi

$$T_{SOR(\omega)} = (D + \omega L)^{-1}((1 - \omega)D - \omega R),$$
$$c_{SOR(\omega)} = \omega(D + \omega L)^{-1}b.$$

I ovdje vidimo da se dobra vrijednost za ω , ako postoji, može **odrediti unaprijed** za sve iteracije.

Pripadni rastav matrice A je

$$A = \frac{1}{\omega}D + L - \left(\frac{1 - \omega}{\omega}D - R \right),$$

tj. $M = \frac{1}{\omega}D + L$, $N = \frac{1 - \omega}{\omega}D - R$. Naravno, za $\omega = 1$ dobivamo Gauss–Seidelovu metodu.

Algoritam SOR metode

Algoritam (SOR metoda).

$x^{(0)}$ i ω zadani; $k = 0$;

dok nije zadovoljen kriterij zaustavljanja radi {

za $i = 1$ do n radi {

$$pom = (1 - \omega)x_i^{(k)}; \quad x_i^{(k+1)} = b_i;$$

za $j = 1$ do $i - 1$ radi {

$$x_i^{(k+1)} = x_i^{(k+1)} - a_{ij} \cdot x_j^{(k+1)};$$

}

za $j = i + 1$ do n radi {

$$x_i^{(k+1)} = x_i^{(k+1)} - a_{ij} \cdot x_j^{(k)};$$

}

$$x_i^{(k+1)} = pom + \omega \cdot x_i^{(k+1)} / a_{ii};$$

$$k = k + 1;$$

}

}

Konvergenција SOR metode

Teorem. SOR(ω) metoda ne konvergira za

$$\omega \leq 0, \quad \text{i} \quad \omega \geq 2.$$

Dokaz. Očito je da za SOR(ω) matricu iteracija vrijedi

$$\begin{aligned} \det(T_{SOR(\omega)}) &= (\det(D + \omega L))^{-1} \det((1 - \omega)D - \omega R) = \\ &= (\det(D))^{-1} (1 - \omega)^n \det(D) = (1 - \omega)^n, \end{aligned}$$

jer su $D + \omega L$ i $(1 - \omega)D - \omega R$ donja i gornja trokutasta matrica. Kako je

$$(\rho(T_{SOR(\omega)}))^n \geq \prod_{i=1}^n |\lambda_i| = |\det(T_{SOR(\omega)})| = |1 - \omega|^n,$$

Konvergencija SOR metode (nastavak)

gdje su λ_i svojstvene vrijednosti matrice $T_{SOR(\omega)}$, onda je

$$\rho(T_{SOR(\omega)}) \geq |1 - \omega|.$$

Prema **Teoremu** o konvergenciji iterativnih metoda $SOR(\omega)$ metoda **konvergirat će ako i samo** ako je $\rho(T_{SOR(\omega)}) < 1$, pa ako imamo da je $|1 - \omega| \geq 1$, tada SOR metoda **neće konvergirati**. Ovaj uvjet bit će ispunjen **ako i samo** ako je $\omega \leq 0$ i $\omega \geq 2$. ■

Konvergenција SOR metode (nastavak)

Teorem. Neka je A hermitska (simetrična) pozitivno definitna matrica. Tada $SOR(\omega)$ metoda konvergira za $\omega \in \langle 0, 2 \rangle$.

Dokaz. Neka je λ proizvoljna svojstvena vrijednost $SOR(\omega)$ matrice $T_{SOR(\omega)}$ i neka je $y \neq 0$ odgovarajući svojstveni vektor. Tada vrijedi

$$G_{SOR(\omega)}y = \lambda y,$$

odnosno

$$((1 - \omega)D - \omega R)y = \lambda(D + \omega L)y.$$

Za lijevu stranu prethodne jednakosti, direktnim računom dobivamo

$$2((1 - \omega)D - \omega R) = (2 - \omega)D - \omega A + \omega(L - R),$$

Konvergenција SOR metode (nastavak)

a za desnu stranu vrijedi

$$2(D + \omega L) = (2 - \omega)D + \omega A + \omega(L - R).$$

Koristeći se time, uz činjenicu da je zbog **hermitičnosti** matrice A , $L = R^*$, poslije skalarnog množenja sa y , iz **prve jednakosti dokaza** dobivamo

$$\begin{aligned} & (2 - \omega)\langle Dy, y \rangle - \omega\langle Ay, y \rangle + \omega\langle (R^* - R)y, y \rangle \\ & = \lambda((2 - \omega)\langle Dy, y \rangle + \omega\langle Ay, y \rangle + \omega\langle (R^* - R)y, y \rangle). \end{aligned}$$

Budući da je A **pozitivno definitna** matrica, vrijedi da je $a_{ii} > 0$ za svako $i = 1, \dots, n$, a kako je $y \neq 0$ imamo

$$\langle Ay, y \rangle > 0, \quad \langle Dy, y \rangle > 0.$$

Konvergenција SOR metode (nastavak)

Matrica $R^* - R$ je **antihermitska** pa je $\langle (R^* - R)y, y \rangle$ čisto **imaginarni broj** ili nula. Definirajmo

$$d = \langle Dy, y \rangle, \quad a = \langle Ay, y \rangle, \quad \iota u = \langle (R^* - R)y, y \rangle,$$

gdje je $\iota = \sqrt{-1}$. Sada **prethodna jednakost** glasi

$$(2 - \omega)d - \omega a + \iota \omega u = \lambda((2 - \omega)d + \omega a + \iota \omega u),$$

odakle je

$$\lambda = \frac{(2 - \omega)d - \omega a + \iota \omega u}{(2 - \omega)d + \omega a + \iota \omega u}.$$

Imaginarni dijelovi brojnika i nazivnika u izrazu za λ su **jednaki**, pa je $|\lambda| < 1$ **ako i samo ako** je

Konvergenција SOR metode (nastavak)

$$|(2 - \omega)d + \omega a| > |(2 - \omega)d - \omega a|,$$

što je, nakon kvadriranja, ekvivalentno sa

$$4\omega(2 - \omega)da > 0.$$

Nadalje, budući da su $d > 0$ i $a > 0$, to će vrijediti **ako i samo ako** je

$$\omega(2 - \omega) > 0,$$

što se postiže **ako i samo ako** je

$$\omega \in \langle 0, 2 \rangle.$$

Za takav izbor ω , vrijedi $|\lambda| < 1$ za proizvoljni λ , pa će vrijediti i $\rho(T_{SOR(\omega)}) < 1$.

Konvergenција SOR metode (nastavak)

Dakle, prema **Teoremu** o konvergenciji iterativnih metoda **SOR(ω)** metoda **konvergira** za svaku početnu iteraciju. ■

Primjer konvergencije iterativnih metoda

Primjer konvergencije iterativnih metoda

Promatramo sustav sa matricom

$$A = \begin{bmatrix} 1 & 0.01 & \cdots & 0.01 & 0.01 \\ 0.02 & 2 & \cdots & 0.02 & 0.02 \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ 0.99 & 0.99 & \cdots & 99 & 0.99 \\ 1 & 1 & \cdots & 1 & 100 \end{bmatrix},$$

i vektorom desne strane b takvim da je **egzaktno rješenje** jednako $x = [1 \ \cdots \ 1]^T$.

Primjer konvergencije iterativnih metoda (nast.)


Spektralni radijusi matrica iteracija su sljedeći:

- Za Jacobijevu metodu : $\rho(G_J) = 0.99$.
- Za Gauss–Seidelovu metodu : $\rho(G_{GS}) = 0.2144$.
- Za JOR metodu eksperimentalno je utvrđeno da optimalni parametar iznosi $\omega_{JOR} = 0.67$:
 $\rho(G_{JOR(0.67)}) = 0.3367$.
- Za SOR metodu eksperimentalno je utvrđeno da optimalni parametar iznosi $\omega_{SOR} = 0.9$:
 $\rho(G_{SOR(0.9)}) = 0.1713$.

Pogledajte **MATLAB** program!


Primjer konvergencije iterativnih metoda (nast.)

Spektralni radijusi matrice iteracije JOR metode



Primjer konvergencije iterativnih metoda (nast.)

Spektralni radijusi matrice iteracije **SOR** metode



Primjer konvergencije iterativnih metoda (nast.)

Konvergencija iterativnih metoda

