

Poglavje 2

Sistemi linearnih enačb

Tretji sklop izročkov

Fakulteta za računalništvo in informatiko
Univerza v Ljubljani

26. oktober 2020

Analiza zaokrožitvenih napak pri reševanju $Ax = b$

Sistem $Ax = b$ smo rešili numerično in dobili približek \hat{x} . Kako natančen je ta približek?

Pišimo $\hat{x} = x + \Delta x$. V resnici velja

$$A(x + \Delta x) = b + \Delta b.$$

Radi bi ocenili velikostni razred Δx v primerjavi z x . V ta namen potrebujemo nekaj osnov vektorskih in matričnih norm.

Vektorska norma je preslikava $\|\cdot\| : \mathbb{C}^n \rightarrow \mathbb{R}$, ki zadošča:

1. Pozitivna definitnost: $\|x\| \geq 0$ za vsak $x \in \mathbb{C}^n$ in $\|x\| = 0 \Leftrightarrow x = 0$.
2. Homogenost: $\|\alpha x\| = |\alpha| \|x\|$ za vsaka $\alpha \in \mathbb{C}$ in $x \in \mathbb{C}^n$
3. Trikotniška neenakost: $\|x + y\| \leq \|x\| + \|y\|$ za vsaka $x, y \in \mathbb{C}^n$.

Matrična norma je preslikava $\|\cdot\| : \mathbb{C}^{n \times n} \rightarrow \mathbb{R}$, ki zadošča:

1. Pozitivna definitnost: $\|A\| \geq 0$ za vsak $A \in \mathbb{C}^{n \times n}$ in $\|A\| = 0 \Leftrightarrow A = 0$.
2. Homogenost: $\|\alpha A\| = |\alpha| \|A\|$ za vsaka $\alpha \in \mathbb{C}$ in $A \in \mathbb{C}^{n \times n}$.
3. Trikotniška neenakost: $\|A + B\| \leq \|A\| + \|B\|$ za vsaka $A, B \in \mathbb{C}^{n \times n}$.
4. Submultiplikativnost: $\|AB\| \leq \|A\| \|B\|$ za vsaka $A, B \in \mathbb{C}^{n \times n}$.

Vektorske in matrične norme - primeri

Primer

Nekaj vektorskih norm:

1. $\|x\|_1 = \sum_{i=1}^n |x_i|$ (1-norma).
2. $\|x\|_2 = \sqrt{\sum_{i=1}^n |x_i|^2}$ (2-norma).
3. $\|x\|_\infty = \max_{i=1, \dots, n} |x_i|$ (∞ -norma).

Vsaka vektorska norma inducira matrično normo, ki jo imenujemo **operatorska norma**:

$$\|A\| := \max_{\|x\| \neq 0} \frac{\|Ax\|}{\|x\|} = \max_{\|x\|=1} \|Ax\|.$$

Analiza zaokrožitvenih napak pri reševanju $Ax = b$

Naj bo $\|\cdot\|$ matrična norma, da velja $\|I\| = 1$. Naj bo A nesingularna matrika,

$$Ax = b \quad \text{in} \quad (A + \Delta A)(x + \Delta x) = b + \Delta b.$$

Preoblikujemo:

$$(A + \Delta A)\Delta x = \Delta b - \Delta Ax.$$

Izpostavimo A :

$$A(I + A^{-1}\Delta A)\Delta x = \Delta b - \Delta Ax.$$

Predpostavimo še, da je $\|A^{-1}\| \|\Delta A\| < 1$.

Potem je

$$(I + A^{-1}\Delta A)^{-1} = I - A^{-1}\Delta A + (A^{-1}\Delta A)^2 - (A^{-1}\Delta A)^3 + \dots$$

obrnjiva matrika in velja

$$\|(I + A^{-1}\Delta A)^{-1}\| \leq \frac{1}{1 - \|A^{-1}\Delta A\|}.$$

Sledi

$$\Delta x = (I + A^{-1}\Delta A)^{-1}A^{-1}(\Delta b - \Delta Ax),$$

$$\|\Delta x\| \leq \frac{1}{1 - \|A^{-1}\Delta A\|} \|A^{-1}\| (\|\Delta b\| + \|\Delta A\| \|x\|).$$

Analiza zaokrožitvenih napak pri reševanju $Ax = b$

Ocenimo:

$$\begin{aligned}\frac{\|\Delta x\|}{\|x\|} &\leq \frac{1}{1 - \|A^{-1}\Delta A\|} \|A^{-1}\| \left(\frac{\|\Delta b\|}{\|x\|} + \|\Delta A\| \right) \\ &= \frac{\|A^{-1}\| \|A\|}{1 - \|A^{-1}\| \|\Delta A\|} \left(\frac{\|\Delta b\|}{\|A\| \|x\|} + \frac{\|\Delta A\|}{\|A\|} \right) \\ &\leq \frac{\|A^{-1}\| \|A\|}{1 - \|A^{-1}\| \|A\| \frac{\|\Delta A\|}{\|A\|}} \left(\frac{\|\Delta b\|}{\|b\|} + \frac{\|\Delta A\|}{\|A\|} \right).\end{aligned}$$

Izrazu

$$\kappa(A) = \|A\| \|A^{-1}\|$$

pravimo **občutljivost matrike** A .

Izrek

Naj bo $\|\cdot\|$ matrična norma, da velja $\|I\| = 1$. Naj bo A nesingularna matrika,

$$Ax = b \quad \text{in} \quad (A + \Delta A)(x + \Delta x) = b + \Delta b.$$

Naj bo še $\|A^{-1}\| \|\Delta A\| < 1$. Potem velja

$$\frac{\|\Delta x\|}{\|x\|} \leq \frac{\kappa(A)}{1 - \kappa(A) \frac{\|\Delta A\|}{\|A\|}} \left(\frac{\|\Delta b\|}{\|b\|} + \frac{\|\Delta A\|}{\|A\|} \right).$$

Primer

Za $A_1 = \begin{pmatrix} 1 & 1 \\ 1 & -1 \end{pmatrix}$ in $A_2 = \begin{pmatrix} 1.00 & 0.99 \\ 0.99 & 0.98 \end{pmatrix}$ velja $\kappa_2(A_1) = 1$ in $\kappa_2(A_2) = 3.9 \cdot 10^4$.

Iterativne metode za reševanje linearnih sistemov

Doslej smo iskali **točne rešitve** x^* sistema

$$Ax = b.$$

Odslej nas bodo zanimali samo **približki** \hat{x} točnih rešitev x^* .

Naprej si bomo izbrali $\epsilon > 0$ in iskali \hat{x} , ki zadošča $\|\hat{x} - x^*\| \leq \epsilon$.

Prednosti iterativnih metod pred direktnimi:

- ▶ Če je matrika A velika in ima veliko ničel, je bolje uporabiti iterativne metode.
- ▶ Ko je rezultat znotraj vnaprej predpisane natančnosti, lahko končamo računanje. Pri direktnih metodah tega vpliva nimamo.

Recimo, da ugibamo, kaj bi lahko bila prava rešitev x sistema $Ax = b$:

$$x^{(0)} \approx x$$

Kako izboljšati $x^{(0)}$? Idealno bi prišteli pravi razliko:

$$x^{(1)} = x^{(0)} + (x^* - x^{(0)}),$$

kar lahko drugače zapišemo kot

$$\begin{aligned}x^{(1)} &= x^{(0)} + (x^* - x^{(0)}) \\&= x^{(0)} + (A^{-1}b - x^{(0)}) \\&= x^{(0)} + A^{-1}(b - Ax^{(0)}) \\&= x^{(0)} + A^{-1}r^{(0)}\end{aligned}$$

Iteracija

Metoda

$$x^{(1)} = x^{(0)} + A^{-1}r^{(0)}$$

pa ni smiselna, ker bi morali izračunati A^{-1} .

Kaj pa, če bi znali aproksimirati A^{-1} ?

Recimo, da je približek $Q^{-1} \approx A^{-1}$ poceni za izračunati. Potem izračunamo

$$x^{(1)} = x^{(0)} + Q^{-1}r^{(0)}.$$

Nadaljujemo

$$x^{(k)} = x^{(k-1)} + Q^{-1}r^{(k-1)}$$

Preoblikujmo

$$x^{(k)} = x^{(k-1)} + Q^{-1}(b - Ax^{(k-1)}),$$

v obliko

$$\begin{aligned} Qx^{(k)} &= Qx^{(k-1)} + (b - Ax^{(k-1)}) \\ &= (Q - A)x^{(k-1)} + b. \end{aligned}$$

Ali drugače

$$x^{(k)} = Q^{-1}(Q - A)x^{(k-1)} + Q^{-1}b.$$

Jacobijeva iteracija

Jacobijeva iteracija aproksimira A z $Q = \text{diagonala od } A$.

```
1  $x = x^{(0)}$ 
2
3  $Q = D$ 
4
5 for  $k = 1$  to  $k_{max}$ 
6    $r = b - Ax$ 
7
8   if  $\frac{\|x^{(nov)} - x\|}{\|x\|} \leq tol$ , stop
9 else
10    $x = x^{(nov)}$ 
11    $x^{(nov)} = x + Q^{-1}r$ 
12 end
13
14  $x = x^{(nov)}$ 
```


Gauss-Seidlova iteracija

Gauss-Seidlova iteracija aproksimira A z $Q = \text{spodnji trikotnik od } A$.

```
1  $x = x^{(0)}$ 
2
3  $Q = D + L$ 
4
5 for  $k = 1$  to  $k_{max}$ 
6    $r = b - Ax$ 
7
8   if  $\frac{\|x^{(nov)} - x\|}{\|x\|} \leq tol$ , stop
9   else
10     $x = x^{(nov)}$ 
11     $x^{(nov)} = x + Q^{-1}r$ 
12  end
13
14  $x = x^{(nov)}$ 
```

Zakaj D in $D + L$?

Še enkrat pogledjmo iteracijo

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

in napako

$$x - x^{(k)} = x - x^{(k-1)} - Q^{-1}r^{(k-1)}.$$

Dobimo

$$e^{(k)} = e^{(k-1)} - Q^{-1}Ae^{(k-1)},$$

oZ.

$$e^{(k)} = (I - Q^{-1}A)e^{(k-1)},$$

oZ.

$$e^{(k)} = (I - Q^{-1}A)^k e^{(0)}.$$

Zakaj D in $D + L$?

Radi bi, da zaporedje

$$e^{(k)} = (I - Q^{-1}A)^k e^{(0)}$$

konvergira. Kdaj zaporedje $a_k = c^k$ konvergira?če velja $|c| < 1$

Podobno, naša iteracija konvergira

$$\begin{aligned}\|e^{(k)}\| &= \|(I - Q^{-1}A)^k e^{(0)}\| \\ &\leq \|I - Q^{-1}A\|^k \|e^{(0)}\|,\end{aligned}$$

če je $\|I - Q^{-1}A\| < 1$.

Trditev

Iteracija

$$x^{(k)} = x^{(k-1)} + Q^{-1}(b - Ax^{(k-1)}) = (I - Q^{-1}A)x^{(k-1)} + Q^{-1}b$$

konvergira za poljuben začetni vektor $x^{(0)}$ natanko tedaj, ko ima matrika $I - Q^{-1}A$ vse lastne vrednosti po absolutni vrednosti manjše od 1.

Zakaj Jacobi in Gauss-Seidel delujeta?

Jacobi, Gauss-Seidel (zadostni) konvergenčni izrek

Če je A diagonalno dominantna, potem Jacobijeva in Gauss-Seidlova metoda konvergirata za kateri koli začetni približek $x^{(0)}$.

Definicija: Diagonalna dominanca

Matrika je diagonalno dominantna, če je

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

za vsak i .

Jacobijev algoritem

Algoritem zgoraj uporabi naslednjo matrično reprezentacijo:

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

Diagonala nima nič skupnega z $L + U$, zato lahko zapišemo

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

Torej vsak preskok (iz $k - 1$ na k) potrebuje $\mathcal{O}(n)$ operacij za vsak element novega vektorja.

Če je za vsak vrstico i , $a_{ij} = 0$ za vse razen m vrednosti j , vsak preskok potrebuje $\mathcal{O}(mn)$ operacij.

Gauss-Seidlov algoritem

Algoritem zgoraj uporabi naslednjo matrično reprezentacijo:

$$\mathbf{x}^{(k)} = -(\mathbf{D} + \mathbf{L})^{-1} \mathbf{U} \mathbf{x}^{(k-1)} + (\mathbf{D} + \mathbf{L})^{-1} \mathbf{b}$$

Po komponentah

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

Torej vsak preskok (iz $k - 1$ na k) potrebuje $\mathcal{O}(n)$ operacij na vsak element novega vektorja.

Če je za vsak vrstico i , $a_{ij} = 0$ za vse razen m vrednost j , vsak preskok potrebuje $\mathcal{O}(mn)$ operacij.

Razlika v primerjavi z Jacobijevo metodo je ta, da so popravki shranjeni v novem vektorju. Tako pridobimo precej prihranka v spominu.