

# Predavanja 5

## Peti sklop izročkov

Fakulteta za računalništvo in informatiko  
Univerza v Ljubljani

8. november 2021

## Občutljivost sistema $Ax = b$

**Vprašanje.** Denimo, da smo sistem  $Ax = b$  z neko metodo (npr. LU razcepom) rešili numerično in dobili približek  $\hat{x}$ . Kako dober je ta približek?

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

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

Če vključimo še numerično napako v  $A$ , velja

$$(A + \Delta A)(x + \Delta x) = b + \Delta b. \quad (1)$$

Radi bi ocenili velikostni razred  $\Delta x$  v primerjavi z  $x$ , tj.  $\frac{\|\Delta x\|}{\|x\|}$ , kjer je  $\|\cdot\|$  neka vektorska norma.

Izberimo vektorsko normo  $\|\cdot\|$  in njej pripadajočo matrično normo, tj.  $\|A\| = \max_{\|x\|=1} \|Ax\|$ . Definirajmo **občutljivost** oz. **pogojenostno število** obrnljive matrike  $A$  v normi  $\|\cdot\|$ :

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

## Izrek

1. Privzemimo, da je  $\Delta A = 0$ . Potem velja:

$$\frac{\|\Delta x\|}{\|x\|} \leq \kappa(A) \frac{\|\Delta b\|}{\|b\|}.$$

2. Naj bo  $\Delta A \neq 0$ . Potem velja:

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

pri čemer smo potrebovali predpostavki, da za identično matriko  $I$  velja  $\|I\| = 1$  in matrika  $A$  zadošča  $\|A^{-1}\| \| \Delta A \| < 1$ .

**Dokaz prvega dela izreka.** Preoblikujmo (1) v

$$A\Delta x = \Delta b.$$

Po predpostavki je  $A$  obrnljiva, zato velja:

$$\Delta x = A^{-1}\Delta b.$$

Torej velja ocena

$$\|\Delta x\| \leq \|A^{-1}\| \|\Delta b\|. \quad (2)$$

Delimo (2) z  $\|x\|$  in dobimo

$$\frac{\|\Delta x\|}{\|x\|} \leq \frac{\|A^{-1}\| \|\Delta b\|}{\|x\|}. \quad (3)$$

Ker je  $Ax = b$ , sledi  $\|b\| = \|Ax\| \leq \|A\|\|x\|$ . Uporabimo to v (3) in dobimo

$$\frac{\|\Delta x\|}{\|x\|} \leq \frac{\|A\| \|A^{-1}\| \|\Delta b\|}{\|x\|} = \kappa(A) \frac{\|\Delta b\|}{\|b\|}. \quad (4)$$

**Dokaz drugega dela izreka.** Neobvezen, za radovedne. Preoblikujmo

(1) v

$$(A + \Delta A)\Delta x = \Delta b - \Delta Ax. \quad (5)$$

Po predpostavki je  $A$  obrnljiva, zato lahko izpostavimo  $A$ :

$$A(I + A^{-1}\Delta A)\Delta x = \Delta b - \Delta Ax. \quad (6)$$

Spomnimo se formule za vsoto geometrijske vrste:

$$(1 + q)^{-1} = \frac{1}{1 + q} = 1 - q + q^2 - q^3 + \dots, \quad |q| < 1. \quad (7)$$

Sedaj lahko oponašamo (7) za matrike in dobimo

$$(I + A^{-1}\Delta A)^{-1} = I - A^{-1}\Delta A + (A^{-1}\Delta A)^2 - (A^{-1}\Delta A)^3 + \dots \quad (8)$$

Iz (8) sledi (z nekaj utemeljevanja - mi lahko privzamemo)

$$\|(I + A^{-1}\Delta A)^{-1}\| \leq \frac{1}{1 - \|A^{-1}\Delta A\|}. \quad (9)$$

Pomnožimo (6) z leve z  $A^{-1}$  in nato z  $(I + A^{-1}\Delta A)^{-1}$

$$\Delta x = (I + A^{-1}\Delta A)^{-1}A^{-1}(\Delta b - \Delta Ax), \quad (10)$$

Upoštevamo še (9) v (10) in dobimo

$$\|\Delta x\| \leq \frac{1}{1 - \|A^{-1}\Delta A\|} \|A^{-1}\| (\|\Delta b\| + \|\Delta A\| \|x\|). \quad (11)$$

Delimo (11) z  $\|x\|$  in preoblikujemo:

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

## Primer

Če se spomnimo primera računanja prečišča dveh premic iz prvih predavanj, lahko vidimo, da gre za vprašanje občutljivosti matrik

$$A_1 = \begin{pmatrix} 1 & 1 \\ 1 & -1 \end{pmatrix} \quad \text{in} \quad A_2 = \begin{pmatrix} 1.00 & 0.99 \\ 0.99 & 0.98 \end{pmatrix},$$

za kateri velja  $\kappa_2(A_1) = 1$  in  $\kappa_2(A_2) = 3.9 \cdot 10^4$ , kjer  $\kappa_2$  označuje občutljivost v spektralni normi.

# Iterativne metode za reševanje $Ax = b$

Doslej smo iskali **točno rešitev**  $x^*$  sistema

$$Ax = b. \quad (12)$$

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

Naprej si bomo izbrali  $\epsilon > 0$  in iskali  $\hat{x}$ , ki zadošča pogoju

$$\|\hat{x} - x^*\| \leq \epsilon.$$

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 sistema (12)

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

*Kako izboljšati  $x^{(0)}$  ?*

Idealno bi prišteli pravi razliko:

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

kar lahko drugače zapišemo kot

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

Toda ta metoda ni smiselna, saj 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 z  $k = 2, 3, \dots$

$$x^{(k)} = x^{(k-1)} + Q^{-1} \underbrace{(b - Ax^{(k-1)})}_{r^{(k-1)}}. \quad (13)$$

# Algoritem iterativnih metod

```
1  $A$  je dana  $n \times n$  matrika, ki jo aproksimiramo z  
   matriko  $Q$ , in  $n \times 1$  vektor  $b$ .  
2 Izberi zacetni priblizek  $x = x^{(0)}$ , toleranco  
   dovoljene relativne napake  $tol$  in maksimalno  
   stevilo  $k_{max}$  korakov iteracije.  
3  
4  $x^{(nov)} = \infty$   
5 for  $k = 1$  to  $k_{max}$   
6    $r = b - Ax$   
7   if  $\frac{\|x^{(nov)} - x\|}{\|x\|} \leq tol$ , stop  
8   else  
9      $x = x^{(nov)}$   
10     $x^{(nov)} = x + Q^{-1}r$   
11 end  
12  $x = x^{(nov)}$ 
```

## Jacobijeva iteracija

Aproksimiramo  $A = [a_{ij}]_{i,j}$  z diagonalno matriko

$$D = \begin{pmatrix} a_{11} & 0 & \cdots & 0 \\ 0 & a_{22} & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \cdots & 0 & a_{nn} \end{pmatrix}.$$

Če pišemo

$$A = S + D + Z, \quad (14)$$

kjer je  $S$  strogo spodnjetrikotna matrika in  $Z$  strogo zgornjetrikotna matrika, potem (13) postane

$$\begin{aligned} x^{(k)} &= x^{(k-1)} + D^{-1}(b - Sx^{(k-1)} - Dx^{(k-1)} - Zx^{(k-1)}) \\ &= x^{(k-1)} + D^{-1}b - D^{-1}Sx^{(k-1)} - x^{(k-1)} - D^{-1}Zx^{(k-1)} \\ &= D^{-1}(b - Sx^{(k-1)} - Zx^{(k-1)}). \end{aligned} \quad (15)$$

Pišimo

$$\mathbf{x}^{(j)} = \left( x_1^{(j)} \quad x_2^{(j)} \quad \dots \quad x_n^{(j)} \right)^T$$

Po komponentah (15) pomeni

$$\boxed{x_i^{(k)} = \frac{b_i}{a_{ii}} - \sum_{j=1, j \neq i}^n \left( \frac{a_{ij}}{a_{ii}} \right) x_j^{(k-1)}}. \quad (16)$$

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

Če so v vsaki vrstici vsi razen največ  $m$  koeficientov  $a_{ij}$  neničelnih, potem za vsak korak iteracije potrebujemo  $O(mn)$  operacij.

Algoritem in primeri:

<https://zalara.github.io/jacobi.m>

<https://zalara.github.io/testjacobi.m>

<https://zalara.github.io/testjacobi2.m>

## Gauss-Seidlova iteracija

Naj bo  $A = [a_{ij}]_{i,j} = S + D + Z$  kot v (14).  $A$  aproksimiramo s spodnjetrokotno matriko

$$S + D = \begin{pmatrix} a_{11} & 0 & \cdots & 0 \\ a_{21} & a_{22} & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ a_{n1} & \cdots & a_{n,n-1} & a_{nn} \end{pmatrix}.$$

Potem (13) postane

$$\begin{aligned} x^{(k)} &= x^{(k-1)} + (D + S)^{-1}(b - (S + D)x^{(k-1)} - Zx^{(k-1)}) \\ &= x^{(k-1)} + (D + S)^{-1}b - x^{(k-1)} - (D + S)^{-1}Zx^{(k-1)} \\ &= (D + S)^{-1}(b - Zx^{(k-1)}), \end{aligned} \tag{17}$$

Algoritem in primeri:

<https://zalara.github.io/gaussseidel.m>

<https://zalara.github.io/testgaussseidel.m>

<https://zalara.github.io/testgaussseidel2.m>

Pomnožimo (17) z leve z  $D + S$  in dobimo

$$(D + S)x^{(k)} = b - Zx^{(k-1)}. \quad (18)$$

Odštejemo  $Sx^{(k)}$  od obeh strani (18) in dobimo

$$Dx^{(k)} = b - Zx^{(k-1)} - Sx^{(k)}$$

OZ.

$$x^{(k)} = D^{-1}(b - Zx^{(k-1)} - Sx^{(k)}). \quad (19)$$

Po komponentah (19) pomeni

$$x_i^{(k)} = \frac{b_i}{a_{ii}} - \sum_{j=1, j < i}^n \left( \frac{a_{ij}}{a_{ii}} \right) x_j^{(k)} - \sum_{j=1, j > i}^n \left( \frac{a_{ij}}{a_{ii}} \right) x_j^{(k-1)}. \quad (20)$$

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

Če so v vsaki vrstici vsi razen največ  $m$  koeficientov  $a_{ij}$  neničelnih, potem za vsak korak iteracije potrebujemo  $O(mn)$  operacij.

Razlika v primerjavi z Jacobijevo metodo je ta, da so popravki shranjeni v obstoječem vektorju in ne potrebujemo še enega dodatnega vektorja. Tako pridobimo precej prihranka v spominu.

# Konvergenca iterativnih metod

Brez dokaza navedimo trditev, ki zagotavlja, kdaj bo  $Q$  dobra izbira za aproksimacijo matrike  $A$ .

## Trditev

### *Iteracija*

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

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

**Dokaz.** Pišimo  $e^{(k)} = x^* - x^{(k)}$  za napako  $k$ -tega približka. Iz

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

sledi

$$x^* - x^{(k)} = x^* - x^{(k-1)} - Q^{-1}r^{(k-1)}. \quad (21)$$

(21) prepišemo v

$$e^{(k)} = e^{(k-1)} - Q^{-1}Ae^{(k-1)} = (I - Q^{-1}A)e^{(k-1)} \quad (22)$$

Rekurzivno uporabljamo (22) in dobimo

$$e^{(k)} = (I - Q^{-1}A)^2 e^{(k-2)} = (I - Q^{-1}A)^3 e^{(k-3)} = \dots = (I - Q^{-1}A)^k e^{(0)}.$$

Radi bi, da zaporedje

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

konvergira.

Kdaj zaporedje  $a_k = c^k$  konvergira? Odgovor: natanko za  $|c| < 1$ .

Podobno, naša iteracija konvergira

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

natanko tedaj, ko je  $\|I - Q^{-1}A\| < 1$ . To pa je res ravno v primeru, ko so vse lastne vrednosti matrike  $I - Q^{-1}A$  manjše od 1. □



# Kdaj Jacobi in Gauss-Seidel gotovo delujeta?

Matrika je diagonalno dominantna, če za vsak  $i$  velja  $|a_{ii}| > \sum_{j=1, j \neq i}^n |a_{ij}|$ .

## Izrek

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

**Dokaz za primer Jacobijeva iteracije.** Kot doslej pišimo  $A = S + D + Z$ .  
Velja

$$T_J = I - Q_J^{-1}A = I - D^{-1}(S + D + Z) = D^{-1}(S + Z).$$

Naj bo  $v = (v_1 \quad \dots \quad v_n)^T$  lastni vektor za  $T_J$ .  $i$ -ta komponenta vektorja  $T_J v$  je enaka

$$\frac{1}{a_{ii}} (v_1 a_{i1} + \dots + v_{i-1} a_{i,i-1} + v_{i+1} a_{i,i+1} + \dots + v_n a_{in}).$$

Sledi

$$\|T_J v\|_\infty \leq \frac{1}{|a_{ii}|} \cdot \|v\|_\infty \cdot \sum_{j=1, j \neq i}^n |a_{ij}| < \|v\|_\infty.$$

Torej so vse lastna vrednosti  $T_J$  manjše od 1. □

# SOR iteracija

Gauss-Seidlovo iteracijo za reševanje linearnih sistemov  $Ax = b$  se da pospešiti z uporabo t.i. *SOR metod*. Korak iteracije je oblike

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

kjer je  $w > 0$  in

$$T_w = (D + wS)^{-1}[(1 - w)D - wZ],$$

$$c_w = w(D + wS)^{-1}b.$$

Algoritem in primeri:

<https://zalara.github.io/sor.m>

<https://zalara.github.io/testsor.m>

<https://zalara.github.io/testsor2.m>