

MATEMATIKA 3

Dana Černá

<http://kmd.fp.tul.cz>

Katedra matematiky a didaktiky matematiky

Technická univerzita v Liberci

PŘÍMÉ METODY PRO ŘEŠENÍ SOUSTAV LINEÁRNÍCH ALGEBRAICKÝCH ROVNIC

- Základní pojmy numerické lineární algebry
- Gaussova eliminace
- LU rozklad
- Choleského rozklad

METODY ŘEŠENÍ SOUSTAV LINEÁRNÍCH ALGEBRAICKÝCH ROVNIC

Budeme uvažovat soustavu n rovnic s n neznámými:

$$\begin{array}{cccccc} a_{11}x_1 & + & a_{12}x_2 & + & \dots & + & a_{1n}x_n & = & b_1 \\ a_{21}x_1 & + & a_{22}x_2 & + & \dots & + & a_{2n}x_n & = & b_2 \\ \vdots & & & & & & \vdots & & \vdots \\ a_{n1}x_1 & + & a_{n2}x_2 & + & \dots & + & a_{nn}x_n & = & b_n \end{array}$$

Soustavu lze zapsat v maticovém tvaru $\mathbf{Ax} = \mathbf{b}$, kde

$$\mathbf{A} := \begin{pmatrix} a_{11} & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} & \dots & a_{2n} \\ \vdots & \vdots & & \vdots \\ a_{n1} & a_{n2} & \dots & a_{nn} \end{pmatrix}, \mathbf{b} := \begin{pmatrix} b_1 \\ b_2 \\ \vdots \\ b_n \end{pmatrix}, \mathbf{x} := \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{pmatrix}$$

Matice \mathbf{A} se nazývá **matice soustavy**, vektor \mathbf{b} se nazývá **vektor pravé strany**. Vektor \mathbf{x} se nazývá **vektor neznámých**.

Definujme matici:

$$\mathbf{A}_b := \begin{pmatrix} a_{11} & a_{12} & \dots & a_{1n} & b_1 \\ a_{21} & a_{22} & \dots & a_{2n} & b_2 \\ \vdots & \vdots & & \vdots & \vdots \\ a_{n1} & a_{n2} & \dots & a_{nn} & b_n \end{pmatrix}$$

Tato matice se nazývá **rozšířená matice soustavy**.

Matice soustavy, která má mnohem více nulových prvků než nenulových prvků se nazývá **řádká**. Matice, která není řádká se nazývá **hustá** nebo **plná**.

l^p - norma vektoru $\mathbf{v} = (v_1, \dots, v_n) \in \mathbb{R}^n$ je definována:

$$\|\mathbf{v}\|_p = \begin{cases} (\sum_{k=1}^n |v_k|^p)^{1/p} & \text{pro } p \in \mathbb{N}, \\ \max_{k=1, \dots, n} |v_k| & \text{pro } p = \infty. \end{cases}$$

Pro matici $\mathbf{A} = (a_{ij})_{i,j=1}^n \in \mathbb{R}^{n \times n}$ budeme definovat její p -normu:

$$\|\mathbf{A}\|_p = \max_{\mathbf{v} \neq 0} \frac{\|\mathbf{A}\mathbf{v}\|_p}{\|\mathbf{v}\|_p}$$

a Frobeniovu (Schurovu) normu:

$$\|\mathbf{A}\|_F = \left(\sum_{i=1}^n \sum_{j=1}^n |a_{ij}|^2 \right)^{1/2}.$$

Spektrální poloměr matice \mathbf{A} je definován:

$$\rho(\mathbf{A}) = \max \{ |\lambda| : \lambda \text{ je vlastní číslo matice } \mathbf{A} \}.$$

Věta: Pro každou matici $\mathbf{A} \in \mathbb{R}^{n \times n}$ a libovolnou normu matice $\|\cdot\|$ platí $\rho(\mathbf{A}) \leq \|\mathbf{A}\|$.

Věta: Pro každou matici $\mathbf{A} \in \mathbb{R}^{n \times n}$ platí

a) $\|\mathbf{A}\|_1 = \max_{1 \leq j \leq n} \sum_{i=1}^n |a_{ij}|$

b) $\|\mathbf{A}\|_\infty = \max_{1 \leq i \leq n} \sum_{j=1}^n |a_{ij}|$

c) $\|\mathbf{A}\|_2 = \sqrt{\rho(\mathbf{A}^T \mathbf{A})}$

d) Je-li matice \mathbf{A} symetrická, potom $\|\mathbf{A}\|_2 = \rho(\mathbf{A})$.

Norma $\|\cdot\|_2$ se nazývá **Euklidovská** nebo také **spektrální norma**.

PODMÍNĚNOST MATICE

Příklad:

a) Soustava
$$\begin{aligned}x + y &= 2 \\x + 1.00000001y &= 2.00000001\end{aligned}$$

má řešení $x = 1, y = 1$.

b) Soustava
$$\begin{aligned}x + y &= 2 \\x + 1.00000001y &= 2.00000002\end{aligned}$$

má řešení $x = 0, y = 2$.

c) Soustava
$$\begin{aligned}x + y &= 2 \\x + y &= 2\end{aligned}$$

má nekonečně mnoho řešení $x = t, y = 2 - t, t \in \mathbb{R}$.

Chyby v zadání matice nebo vektoru pravé strany mohou způsobit velké chyby v řešení.

Věta: O PODMÍNĚNOSTI MATICE

Předpokládejme, že $\mathbf{A} \in \mathbb{R}^{n \times n}$ je regulární matice a $\Delta\mathbf{A}$ je matice taková, že $\|\mathbf{A}^{-1}\Delta\mathbf{A}\|_2 < 1$. Potom platí

$$\frac{\|\mathbf{x}^\Delta - \mathbf{x}^*\|_2}{\|\mathbf{x}^*\|_2} \leq \frac{\|\mathbf{A}\|_2 \|\mathbf{A}^{-1}\|_2}{1 - \|\mathbf{A}^{-1}\Delta\mathbf{A}\|_2} \left(\frac{\|\Delta\mathbf{A}\|_2}{\|\mathbf{A}\|_2} + \frac{\|\Delta\mathbf{b}\|_2}{\|\mathbf{b}\|_2} \right),$$

kde \mathbf{x}^* je řešení soustavy $\mathbf{A}\mathbf{x} = \mathbf{b}$, \mathbf{x}^Δ je řešení soustavy $(\mathbf{A} + \Delta\mathbf{A})\mathbf{x} = \mathbf{b} + \Delta\mathbf{b}$.

Jestliže relativně malé změny prvků matice nebo prvků vektoru pravé strany způsobí relativně velké změny v řešení, nazývá se matice **špatně podmíněná**, jinak se matice nazývá **dobře podmíněná**. Podmíněnost charakterizuje **číslo podmíněnosti matice \mathbf{A}** , které je definováno:

$$\mathit{cond}(\mathbf{A}) := \|\mathbf{A}\|_2 \|\mathbf{A}^{-1}\|_2.$$

Platí $\mathit{cond}(A) \geq 1$. Pokud je $\mathit{cond}(A)$ velké, je matice \mathbf{A} špatně podmíněná.

METODY ŘEŠENÍ SOUSTAV LINEÁRNÍCH ALGEBRAICKÝCH ROVNIC

- Přímé - Teoreticky přesné řešení získáme po konečně mnoha krocích. Jsou vhodné pro malé plné matice, za určitých podmínek také pro velké řídké matice.
- Iterační - Počítáme posloupnost vektorů, která konverguje k přesnému řešení. Používají se soustavy s velkými řídkými maticemi.

PŘÍMÉ METODY

- Gaussova eliminace
- LU rozklad
- Choleského rozklad

1. GAUSSOVA ELIMINACE

Přímý chod:

```
for  $k = 1, \dots, n - 1$   
  for  $i = k + 1, \dots, n$   
     $a_{ik} := \frac{a_{ik}}{a_{kk}}$   
    for  $j = k + 1, \dots, n$   
       $a_{ij} := a_{ij} - a_{ik}a_{kj}$   
    end  
     $b_i := b_i - a_{ik}b_k$   
  end  
end  
end
```

Zpětný chod:

```
for  $i = n, \dots, 1$   
   $x_i := \frac{1}{a_{ii}} \left( b_i - \sum_{j=i+1}^n a_{ij}x_j \right)$   
end
```

Gaussova eliminace je pro obecné matice numericky nestabilní.
Proto se provádí **Gaussova eliminace s pivotací**.

Prvek a_{kk} , který je v k -tém kroku Gaussovy eliminace na pozici (k, k) a kterým dělíme, se nazývá **pivot**. Pokud je tento prvek malý ve srovnání s ostatními prvky, může dojít k velkým zaokrouhlovacím chybám. Proto provedeme pivotaci, tedy mezi prvky na pozicích $(k, k), \dots, (n, k)$ nalezneme prvek, který je v absolutní hodnotě největší. Řádek s tímto prvkem vyměníme s k -tým řádkem. Tento proces se nazývá *částečná* nebo také *sloupcová pivotace*.

Gaussova eliminace, vyžaduje $\mathcal{O}(n^3)$, přesněji $\frac{2n^3}{3} + \mathcal{O}(n^2)$, operací s plovoucí řádovou čárkou.

Třídíagonální matice je matice, kde $a_{ij} = 0$ pro $|i - j| > 1$.

$$\mathbf{A} = \begin{pmatrix} s_1 & t_1 & 0 & 0 & \dots & 0 \\ r_2 & s_2 & t_2 & 0 & & 0 \\ 0 & r_3 & s_3 & t_3 & & 0 \\ \vdots & & & \ddots & & \vdots \\ 0 & & 0 & r_{n-1} & s_{n-1} & t_{n-1} \\ 0 & \dots & 0 & 0 & r_n & s_n \end{pmatrix}$$

Gaussova eliminace pro třídíagonální matice vyžaduje pouze $\mathcal{O}(n)$ operací s plovoucí řádovou čárkou.

Gaussova eliminace je vhodná pro řešení soustav s malými plnými maticemi.

Gaussova eliminace je vhodná také pro určité typy velkých řídkých matic, např. pro třídiagonální matice.

U obecných velkých řídkých matic je třeba dbát na to, aby nedocházelo k zaplnění matice, tj. aby z nulových prvků nevznikaly nenulové.

2. LU ROZKLAD

Matici soustavy \mathbf{A} rozložíme na součin $\mathbf{A} = \mathbf{LU}$, kde matice \mathbf{L} je dolní trojúhelníková matice s jedničkami na diagonále a \mathbf{U} je horní trojúhelníková matice. Matici \mathbf{U} získáme pomocí Gaussovy eliminace, matice \mathbf{L} obsahuje koeficienty (s opačným znaménkem), kterými násobíme řádky při eliminaci.

Soustavu $\mathbf{Ax} = \mathbf{b}$ můžeme zapsat ve tvaru $\mathbf{LUx} = \mathbf{b}$. Označme $\mathbf{y} := \mathbf{Ux}$. Potom řešení soustavy pomocí LU-rozkladu spočívá v řešení dvou trojúhelníkových soustav: $\mathbf{Ly} = \mathbf{b}$ a $\mathbf{Ux} = \mathbf{y}$.

Příklad LU rozkladu:

$$\mathbf{A} = \begin{pmatrix} 1 & 1 & 2 \\ 1 & 0 & 2 \\ 2 & 2 & 5 \end{pmatrix} = \underbrace{\begin{pmatrix} 1 & 0 & 0 \\ 1 & 1 & 0 \\ 2 & 0 & 1 \end{pmatrix}}_{\mathbf{L}} \underbrace{\begin{pmatrix} 1 & 1 & 2 \\ 0 & -1 & 0 \\ 0 & 0 & 1 \end{pmatrix}}_{\mathbf{U}}$$

Odvození: Odečtení $l_{j,i}$ násobku j -tého řádku od i -tého řádku matice \mathbf{A} lze reprezentovat vynásobením matice \mathbf{A} maticí $\mathbf{L}_{j,i}$, kde

$$\begin{array}{c}
 i - \text{tý sloupec} \\
 \downarrow \\
 \mathbf{L}_{j,i} := \begin{pmatrix}
 1 & 0 & 0 & 0 & \dots & \dots & 0 & 0 \\
 0 & 1 & 0 & 0 & \dots & \dots & 0 & 0 \\
 0 & 0 & 1 & 0 & \dots & \dots & 0 & 0 \\
 \vdots & & & \ddots & & & & \vdots \\
 0 & -l_{j,i} & & & 1 & \dots & 0 & 0 \\
 \vdots & & & & & \ddots & & \vdots \\
 0 & 0 & \dots & & & \dots & 1 & 0 \\
 0 & 0 & \dots & & & \dots & 0 & 1
 \end{pmatrix} \leftarrow j - \text{tý řádek}
 \end{array}$$

Potom

$$\mathbf{L}_{j,i}\mathbf{A} = \begin{pmatrix} 1 & 0 & \dots & 0 \\ 0 & 1 & & 0 \\ \vdots & & & \vdots \\ 0 & \dots & -l_{j,i} & \dots & 1 & \dots & 0 \\ \vdots & & & & & & \vdots \\ 0 & 0 & \dots & 0 & 1 \end{pmatrix} \begin{pmatrix} a_{11} & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} & \dots & a_{2n} \\ \vdots & \vdots & & \vdots \\ a_{j,1} & a_{j,2} & \dots & a_{j,n} \\ \vdots & \vdots & & \vdots \\ a_{n1} & a_{n2} & \dots & a_{nn} \end{pmatrix}$$
$$= \begin{pmatrix} a_{11} & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} & \dots & a_{2n} \\ \vdots & \vdots & & \vdots \\ a_{j,1} - l_{j,i}a_{i,1} & a_{j,2} - l_{j,i}a_{i,2} & \dots & a_{j,n} - l_{j,i}a_{i,n} \\ \vdots & \vdots & & \vdots \\ a_{n1} & a_{n2} & \dots & a_{nn} \end{pmatrix}.$$

Koeficient $l_{j,i}$ zvolíme tak, aby po vynásobení maticí $\mathbf{L}_{j,i}$ byla ve výsledné matici na pozici (j, i) nula. Dostaneme

$$\mathbf{L}_{n,n-1} \cdots \mathbf{L}_{3,1} \mathbf{L}_{2,1} \mathbf{A} = \mathbf{U},$$

kde \mathbf{U} je horní trojúhelníková matice. Vyjádříme \mathbf{A} :

$$\mathbf{A} = \mathbf{L}_{2,1}^{-1} \mathbf{L}_{3,1}^{-1} \cdots \mathbf{L}_{n,n-1}^{-1} \mathbf{U},$$

a položíme $\mathbf{L} = \mathbf{L}_{2,1}^{-1} \mathbf{L}_{3,1}^{-1} \cdots \mathbf{L}_{n,n-1}^{-1}$. Matice \mathbf{L} má tvar

$$\begin{pmatrix} 1 & 0 & \cdots & 0 \\ l_{2,1} & 1 & & 0 \\ l_{3,1} & l_{3,2} & 1 & \\ \vdots & & & \\ l_{n,1} & l_{n,2} & \cdots & l_{n,n-1} & 1 \end{pmatrix}$$

a splňuje $\mathbf{A} = \mathbf{LU}$.

Doolittlův algoritmus:

1. Nalezneme matice \mathbf{L} , \mathbf{U} pomocí Gaussovy eliminace.

$$u_{11} = a_{11}$$

for $i = 1, \dots, n$

$$l_{j1} = \frac{a_{j1}}{u_{11}}$$

end

for $k = 2, \dots, n$

$$u_{1k} = a_{1k}$$

for $i = 2, \dots, k$:

$$u_{ik} = a_{ik} - \sum_{j=1}^{i-1} l_{ij} u_{jk}$$

end

for $i = k + 1, \dots, n$:

$$l_{ik} = \frac{1}{u_{kk}} \left(a_{ik} - \sum_{j=1}^{k-1} l_{ij} u_{jk} \right)$$

end

end

2. Řešíme trojúhelníkovou soustavu $\mathbf{L}\mathbf{y} = \mathbf{b}$.

3. Řešíme trojúhelníkovou soustavu $\mathbf{U}\mathbf{x} = \mathbf{y}$.

Pro obecné matice LU rozklad nemusí existovat. Pro regulární matice je vždy možné změnit pořadí řádků matice tak, aby LU rozklad existoval.

Také LU rozklad většinou provádíme s pivotací. Potom má rozklad tvar $\mathbf{PA} = \mathbf{LU}$, kde \mathbf{P} je permutační matice, tj. matice, která má v každém řádku a sloupci právě jednu jedničku, jinak pouze nuly. Vynásobení permutační matici je ekvivalentní změně pořadí řádků.

Řešení jedné soustavy pomocí LU-rozkladu je podobně časově náročné jako Gaussova eliminace, vyžaduje $\frac{2n^3}{3} + \mathcal{O}(n^2)$ operací s plovoucí řádovou čárkou.

LU - rozklad je výhodné použít především při řešení více soustav se stejnou maticí a různými pravými stranami. Potom provádíme přímý chod, který má složitost $\mathcal{O}(n^3)$, pouze jednou a pro každou pravou stranu pak provádíme dvakrát zpětný chod, který vyžaduje pouze $\mathcal{O}(n^2)$ operací s plovoucí řádovou čárkou.

3. CHOLESKÉHO ROZKLAD

Pokud je matice soustavy \mathbf{A} symetrická pozitivně definitní, potom lze použít Choleského rozklad $\mathbf{A} = \mathbf{L}\mathbf{L}^T$, kde L je dolní trojúhelníková matice (nyní nepředpokládáme jedničky na diagonále).

Matici \mathbf{L} vypočteme pomocí vzorců:

$$l_{rr} = \left(a_{rr} - \sum_{s=1}^{r-1} l_{rs}^2 \right)^{1/2}, \quad r = 1, \dots, n,$$

$$l_{ir} = \frac{1}{l_{rr}} \left(a_{ir} - \sum_{s=1}^{r-1} l_{rs} l_{is} \right), \quad i = r + 1, \dots, n.$$

Potom řešení soustavy $\mathbf{A}\mathbf{x} = \mathbf{b}$ je ekvivalentní řešení soustav $\mathbf{L}\mathbf{y} = \mathbf{b}$ a $\mathbf{L}^T\mathbf{x} = \mathbf{y}$. Řešení soustavy pomocí Choleského rozkladu vyžaduje asi polovinu času a paměti ve srovnání s Gaussovou eliminací a LU rozkladem.

Odvození:

Pro symetrickou pozitivně definitní matici \mathbf{A} velikosti 3×3 vyjádříme součin $\mathbf{A} = \mathbf{L}\mathbf{L}^T$ po složkách:

$$\begin{pmatrix} a_{1,1} & a_{2,1} & a_{3,1} \\ a_{2,1} & a_{2,2} & a_{3,2} \\ a_{3,1} & a_{3,2} & a_{3,3} \end{pmatrix} = \begin{pmatrix} l_{1,1} & 0 & 0 \\ l_{2,1} & l_{2,2} & 0 \\ l_{3,1} & l_{3,2} & l_{3,3} \end{pmatrix} \begin{pmatrix} l_{1,1} & l_{2,1} & l_{3,1} \\ 0 & l_{2,2} & l_{3,2} \\ 0 & 0 & l_{3,3} \end{pmatrix}$$
$$= \begin{pmatrix} l_{1,1}^2 & l_{1,1}l_{2,1} & l_{1,1}l_{3,1} \\ l_{1,1}l_{2,1} & l_{2,1}^2 + l_{2,2}^2 & l_{2,1}l_{3,1} + l_{2,2}l_{3,2} \\ l_{1,1}l_{3,1} & l_{2,1}l_{3,1} + l_{2,2}l_{3,2} & l_{3,1}^2 + l_{3,2}^2 + l_{3,3}^2 \end{pmatrix}$$

Dostaneme $l_{1,1} = \sqrt{a_{1,1}}$, $l_{2,1} = \frac{a_{2,1}}{l_{1,1}}$, $l_{2,2} = \sqrt{a_{2,2} - l_{2,1}^2}$,
 $l_{3,2} = \frac{a_{3,2} - l_{2,1}l_{3,1}}{l_{2,2}}$, $l_{3,3} = \sqrt{a_{3,3} - l_{3,1}^2 - l_{3,2}^2}$.

Vzorce pro matici velikosti $n \times n$ odvodíme analogickým postupem.

SROVNÁNÍ SLOŽITOSTI:

Metody pro soustavy s obecnou maticí:

METODA	SLOŽITOST
Gaussova eliminace	$\frac{2n^3}{3} + \mathcal{O}(n^2)$
Gaussova-Jordanova eliminace	$n^3 + \mathcal{O}(n^2)$
LU rozklad	$\frac{2n^3}{3} + \mathcal{O}(n^2)$
Choleského rozklad (pro sym. poz. def.)	$\frac{n^3}{3} + \mathcal{O}(n^2)$

Metody pro soustavy s třídiagonální maticí:

METODA	SLOŽITOST
Gaussova eliminace	$\mathcal{O}(n)$
LU rozklad	$\mathcal{O}(n)$

ITERAČNÍ METODY:

Maticové iterační metody:

- Jacobiho
- Gaussova-Seidelova
- Superrelaxační metoda

Gradientní iterační metody:

- Metoda sdružených gradientů

MATICOVÉ ITERAČNÍ METODY:

ODVOZENÍ: Soustavu

$$\mathbf{Ax} = \mathbf{b}$$

upravíme do tvaru

$$\mathbf{x} = \mathbf{Bx} + \mathbf{c}$$

a definujeme posloupnost vektorů

$$\mathbf{x}^{i+1} = \mathbf{Bx}^i + \mathbf{c},$$

kde \mathbf{x}^0 je zvolený počáteční vektor.

Konstruujeme posloupnost vektorů danou předpisem:

$$\mathbf{x}^{i+1} = \mathbf{B}\mathbf{x}^i + \mathbf{c}, \quad i = 0, 1, \dots,$$

kde \mathbf{x}^0 je zvolený počáteční vektor. Matice \mathbf{B} a vektor \mathbf{c} jsou zvoleny tak, že pro přesné řešení \mathbf{x}^* původní soustavy platí $\mathbf{x}^* = \mathbf{B}\mathbf{x}^* + \mathbf{c}$.

VĚTA: **Nutná a postačující podmínka konvergence**

Posloupnost \mathbf{x}^i konverguje k přesnému řešení soustavy $\mathbf{A}\mathbf{x} = \mathbf{b}$ právě tehdy, když $\rho(\mathbf{B}) < 1$.

VĚTA: **Postačující podmínka konvergence**

Posloupnost \mathbf{x}^i konverguje k přesnému řešení soustavy $\mathbf{A}\mathbf{x} = \mathbf{b}$, pokud $\|\mathbf{B}\| < 1$ pro libovolnou normu matice $\|\cdot\|$.

1. JACOBIHO METODA:

Rozložme matici **A**:

$$\mathbf{A} = \mathbf{D} + \mathbf{L} + \mathbf{U},$$

kde **D** je diagonální matice, **L** je dolní trojúhelníková matice s nulami na diagonále a **U** je horní trojúhelníková matice s nulami na diagonále. Platí

$$\begin{aligned}\mathbf{Ax} = \mathbf{b} &\Leftrightarrow \mathbf{Dx} + (\mathbf{L} + \mathbf{U})\mathbf{x} = \mathbf{b} \Leftrightarrow \mathbf{Dx} = -(\mathbf{L} + \mathbf{U})\mathbf{x} + \mathbf{b} \\ &\Leftrightarrow \mathbf{x} = -\mathbf{D}^{-1}(\mathbf{L} + \mathbf{U})\mathbf{x} + \mathbf{D}^{-1}\mathbf{b}.\end{aligned}$$

Předpis Jacobiho metody:

$$\mathbf{x}^{i+1} = -\mathbf{D}^{-1}(\mathbf{L} + \mathbf{U})\mathbf{x}^i + \mathbf{D}^{-1}\mathbf{b}, \quad i = 0, 1, \dots,$$

Předpis Jacobiho metody rozepsaný po složkách:

$$x_j^{i+1} = \frac{1}{a_{jj}} \left(b_j - \sum_{k=1}^{j-1} a_{jk} x_k^i - \sum_{k=j+1}^n a_{jk} x_k^i \right)$$

$$\begin{pmatrix} 1 & 1 & 2 & 3 \\ 1 & 4 & 2 & 1 \\ 2 & 2 & 5 & 2 \\ 7 & 5 & -3 & 1 \end{pmatrix} = \underbrace{\begin{pmatrix} 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 \\ 2 & 2 & 0 & 0 \\ 7 & 5 & -3 & 0 \end{pmatrix}}_{\mathbf{L}} + \underbrace{\begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & 4 & 0 & 0 \\ 0 & 0 & 5 & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix}}_{\mathbf{D}} + \underbrace{\begin{pmatrix} 0 & 1 & 2 & 3 \\ 0 & 0 & 2 & 1 \\ 0 & 0 & 0 & 2 \\ 0 & 0 & 0 & 0 \end{pmatrix}}_{\mathbf{U}}$$

V tomto případě je tedy iterační matice dána vztahem $\mathbf{B} = -\mathbf{D}^{-1}(\mathbf{L} + \mathbf{U})$ a posloupnost \mathbf{x}^i konverguje k přesnému řešení právě tehdy, když $\rho(-\mathbf{D}^{-1}(\mathbf{L} + \mathbf{U})) < 1$.

Tuto podmínku splňují například ostře diagonálně dominantní matice, tj. matice pro kterou platí

$$|a_{ii}| > \sum_{j=1}^{i-1} |a_{ij}| + \sum_{j=i+1}^n |a_{ij}|, \quad i = 1, \dots, n.$$

2. GAUSSOVA-SEIDELOVA METODA:

Nyní při výpočtu složek vektoru \mathbf{x}^{i+1} použijeme místo složek vektoru \mathbf{x}^i složky vektoru \mathbf{x}^{i+1} , pokud již byly vypočteny.

$$\begin{aligned}\mathbf{Ax} = \mathbf{b} &\Leftrightarrow (\mathbf{D} + \mathbf{L})\mathbf{x} + \mathbf{Ux} = \mathbf{b} \Leftrightarrow (\mathbf{D} + \mathbf{L})\mathbf{x} = -\mathbf{Ux} + \mathbf{b} \\ &\Leftrightarrow \mathbf{x} = -(\mathbf{D} + \mathbf{L})^{-1}\mathbf{Ux} + (\mathbf{D} + \mathbf{L})^{-1}\mathbf{b}.\end{aligned}$$

Předpis Gaussovy-Seidelovy metody:

$$\mathbf{x}^{i+1} = -(\mathbf{D} + \mathbf{L})^{-1}\mathbf{Ux}^i + (\mathbf{D} + \mathbf{L})^{-1}\mathbf{b}, \quad i = 0, 1, \dots,$$

Předpis Gaussovy-Seidelovy metody rozepsaný po složkách::

$$x_j^{i+1} = \frac{1}{a_{jj}} \left(b_j - \sum_{k=1}^{j-1} a_{jk}x_k^{i+1} - \sum_{k=j+1}^n a_{jk}x_k^i \right)$$

V tomto případě tedy posloupnost \mathbf{x}^i konverguje k přesnému řešení právě tehdy, když $\rho\left(-(\mathbf{D} + \mathbf{L})^{-1} \mathbf{U}\right) < 1$. Tuto podmínku splňují ostře diagonálně dominantní matice a také symetrické pozitivně definitní matice.

3. SUPERRELAXAČNÍ METODA:

Pro zrychlení konvergence je možné použít modifikaci Gaussovy-Seidelovy metody, při které konstruujeme posloupnost vektorů podle vzorce:

$$\mathbf{x}^{i+1} = (1 - \omega) \mathbf{x}^i + \omega \tilde{\mathbf{x}}^{i+1},$$

kde

$$\tilde{\mathbf{x}}^{i+1} = -(\mathbf{D} + \mathbf{L})^{-1} \mathbf{U} \mathbf{x}^i + (\mathbf{D} + \mathbf{L})^{-1} \mathbf{b}, \quad i = 0, 1, \dots$$

Parametr ω se nazývá relaxační faktor a volí se z intervalu $(0, 2)$, obvykle $\omega \in (1, 2)$. Pro symetrické pozitivně definitní matice soustavy tato volba parametru vede ke konvergenci posloupnosti \mathbf{x}^i k řešení. Volbou $\omega = 1$ dostaneme Gaussovu-Seidelovu metodu.

4. METODA SDRUŽENÝCH GRADIENTŮ:

Budeme předpokládat, že matice soustavy \mathbf{A} je symetrická pozitivně definitní. Potom řešení soustavy $\mathbf{Ax} = \mathbf{b}$ je jediným bodem, ve kterém má funkce

$$F(\mathbf{x}) = \frac{1}{2}\mathbf{x}^T \mathbf{Ax} - \mathbf{x}^T \mathbf{b}$$

minimum.

Posloupnost vektorů \mathbf{x}^i budeme konstruovat tak, že v i -tém kroku zvolíme směr \mathbf{v}^i a určíme číslo α_i tak, aby vektor

$$\mathbf{x}^{i+1} = \mathbf{x}^i + \alpha_i \mathbf{v}^i$$

byl bodem minima funkce F na přímce $\mathbf{x}^i + t\mathbf{v}^i$, $t \in \mathbb{R}$.

Volbou \mathbf{v}^i dostaneme konkrétní metodu. V případě metody sdružených gradientů volíme **A-ortogonální vektory**. To jsou vektory, pro které platí:

$$(\mathbf{v}^j)^T \mathbf{A} \mathbf{v}^i = 0, \quad i \neq j, \quad \text{a} \quad (\mathbf{v}^i)^T \mathbf{A} \mathbf{v}^i \neq 0.$$

Vektory konstruujeme postupně pomocí reziduí $\mathbf{r}^i = \mathbf{b} - \mathbf{A} \mathbf{x}^i$:

$$\mathbf{v}^{j+1} = \mathbf{r}^{j+1} + \beta_j \mathbf{v}^j,$$

kde konstanta β_j je zvolena tak, aby byla splněna **A-ortogonalita** vektorů \mathbf{v}^{j+1} a \mathbf{v}^j .

Další iterační metody: MINRES, GMRES, BiCG a jejich modifikace

Algoritmus metody sdružených gradientů:

Je dáno: \mathbf{x}^0 , \mathbf{A} symetrická pozitivně definitní, \mathbf{b} .

$$\mathbf{r}^0 = \mathbf{b} - \mathbf{A}\mathbf{x}^0, \mathbf{v}^0 = \mathbf{r}^0, i = 0$$

while $\|\mathbf{r}^i\|_2 > \epsilon$ and $i < \textit{maximum_iteraci}$

$$\alpha_j = \frac{(\mathbf{r}^i)^T \mathbf{v}^i}{(\mathbf{v}^i)^T \mathbf{A}\mathbf{v}^i}$$

$$\mathbf{x}^{i+1} = \mathbf{x}^i + \alpha_j \mathbf{v}^i$$

$$\mathbf{r}^{i+1} = \mathbf{r}^i - \alpha_j \mathbf{A}\mathbf{v}^i$$

$$\beta_j = \frac{(\mathbf{r}^{i+1})^T \mathbf{r}^{i+1}}{(\mathbf{r}^i)^T \mathbf{r}^i}$$

$$\mathbf{v}^{i+1} = \mathbf{r}^{i+1} + \beta_j \mathbf{v}^i$$

$$i = i + 1$$

end

Rychlost konvergence metody sdružených gradientů je charakterizována odhadem

$$\|\mathbf{x}^k - \mathbf{x}^*\|_A \leq 2 \left(\frac{\sqrt{\kappa_2(\mathbf{A})} - 1}{\sqrt{\kappa_2(\mathbf{A})} + 1} \right)^k \|\mathbf{x}^0 - \mathbf{x}^*\|_A,$$

kde $\|\cdot\|_A$ je energetická norma

$$\|\mathbf{x}\|_A = \sqrt{\mathbf{x}^T \mathbf{A} \mathbf{x}}$$

a κ_2 označuje číslo podmíněnosti vzhledem k $\|\cdot\|_2$ normě

$$\kappa_2(\mathbf{A}) = \|\mathbf{A}\|_2 \|\mathbf{A}^{-1}\|_2.$$

Rychlost konvergence metody sdružených gradientů tedy závisí na čísle podmíněnosti matice soustavy. Konvergenci můžeme urychlit pomocí **předpodmínění**. Místo úlohy $\mathbf{Ax} = \mathbf{b}$ budeme řešit úlohu

$$\mathbf{P}^{-1}\mathbf{A}\mathbf{P}^{-T}\mathbf{P}^T\mathbf{x} = \mathbf{P}^{-1}\mathbf{b},$$

tedy

$$\tilde{\mathbf{A}}\tilde{\mathbf{x}} = \tilde{\mathbf{b}},$$

kde

$$\tilde{\mathbf{A}} = \mathbf{P}^{-1}\mathbf{A}\mathbf{P}^{-T}, \quad \tilde{\mathbf{x}} = \mathbf{P}^T\mathbf{x}, \quad \tilde{\mathbf{b}} = \mathbf{P}^{-1}\mathbf{b}.$$

Matice \mathbf{P} se nazývá **předpodmiňovač** a volíme ji tak, aby byla regulární a aby číslo podmíněnosti matice $\mathbf{P}^{-1}\mathbf{A}\mathbf{P}^{-T}$ bylo menší než číslo podmíněnosti matice \mathbf{A} .

Mezi nejjednodušší volbu patří

$$\mathbf{P} = \begin{pmatrix} \sqrt{a_{11}} & 0 & \dots & 0 \\ 0 & \sqrt{a_{22}} & 0 & \\ \vdots & & \ddots & \\ 0 & \dots & 0 & \sqrt{a_{nn}} \end{pmatrix}.$$