


Metody numeryczne II.

Układy równań liniowych (cd.)

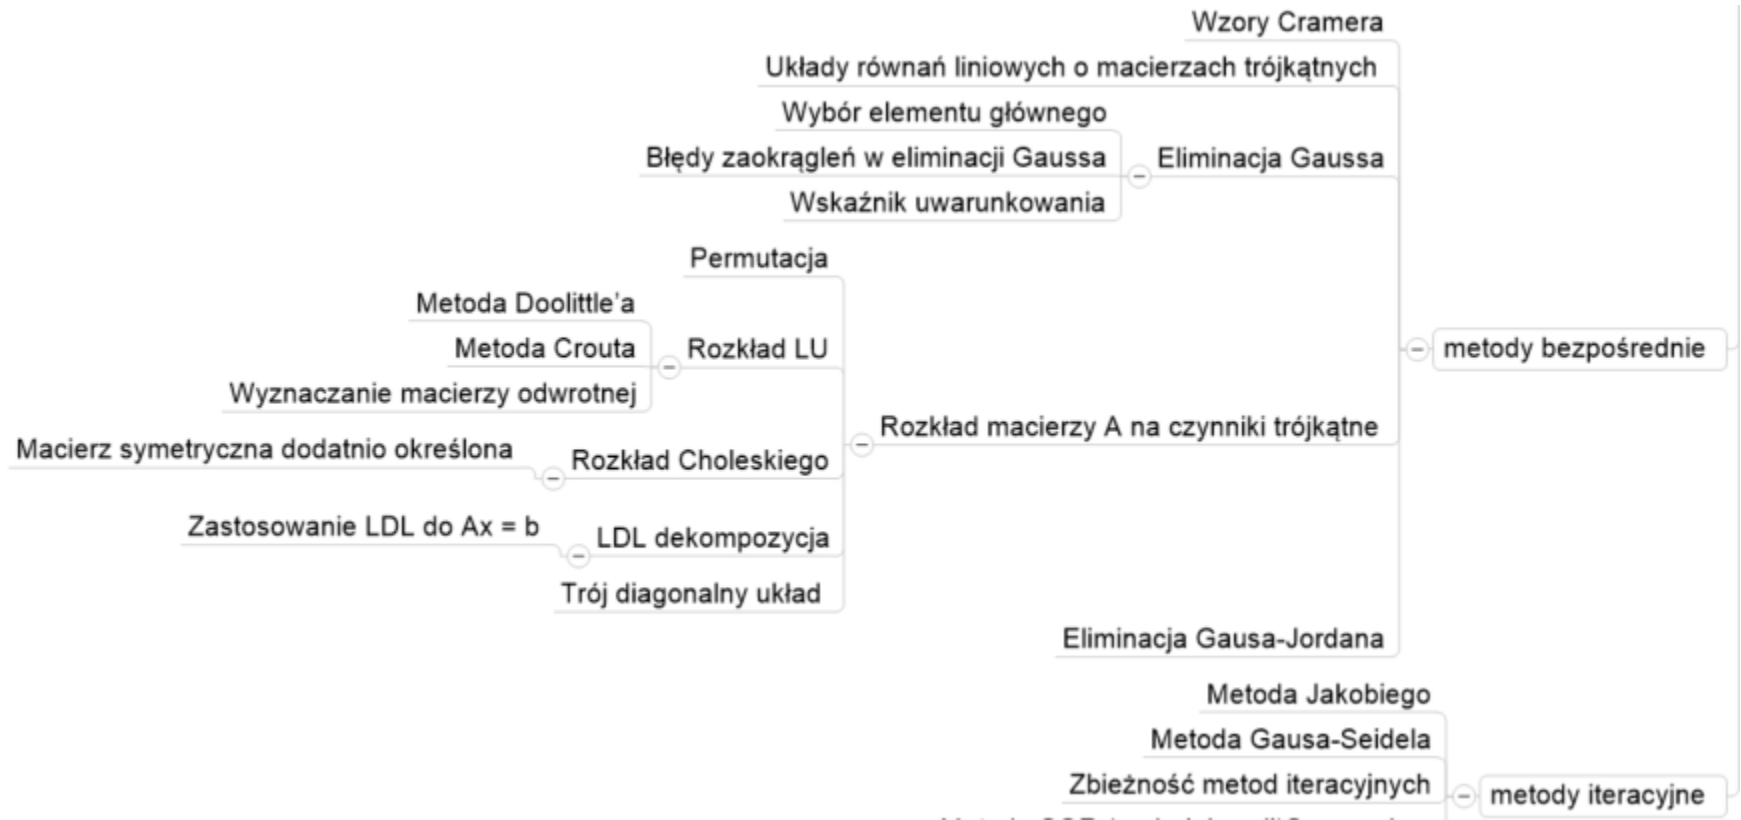
Oleksandr Sokolov

Wydział Fizyki, Astronomii i Informatyki Stosowanej UMK
<http://fizyka.umk.pl/~osokolov/MNII/>

Niektóre metody rozwiązywania układów równań liniowych



Niektóre metody rozwiązywania układów równań liniowych (cd.)



Rozkład $PA=LU$

- Dla każdej macierzy nieosobliwej ($\det(A) \neq 0$) rozkład $PA = LU$ jest zawsze możliwy, jeśli stosujemy częściowy wybór elementu głównego.
- Dla macierzy osobliwych ($\det(A) = 0$) rozkład $PA = LU$ nie istnieje.

$$PA = \begin{bmatrix} 0 & 1 & 0 \\ 0 & 0 & 1 \\ 1 & 0 & 0 \end{bmatrix} \begin{bmatrix} 1 & 2 & 3 \\ 2 & 4 & 7 \\ 1 & 5 & 8 \end{bmatrix} = \begin{bmatrix} 2 & 4 & 7 \\ 1 & 5 & 8 \\ 1 & 2 & 3 \end{bmatrix}$$

$$LU = \begin{bmatrix} 1 & 0 & 0 \\ 0.5 & 1 & 0 \\ 0.5 & 0 & 1 \end{bmatrix} \begin{bmatrix} 2 & 4 & 7 \\ 0 & 3 & 4.5 \\ 0 & 0 & -0.5 \end{bmatrix} = \begin{bmatrix} 2 & 4 & 7 \\ 1 & 5 & 8 \\ 1 & 2 & 3 \end{bmatrix}$$

```
>> [L U P]=lu(A)
```

L =

1.0000	0	0
0.5000	1.0000	0
0.5000	0	1.0000

U =

2.0000	4.0000	7.0000
0	3.0000	4.5000
0	0	-0.5000

P =

0	1	0
0	0	1
1	0	0

Macierz hermitowska

Macierz hermitowska (albo samosprężona) – macierz kwadratowa

$$A = (a_{ij})$$

równa swojemu sprzężeniu hermitowskiemu, tj. macierz spełniająca warunek

$$(a_{ij}) = (\overline{a_{ji}}).$$

Sprzężenie hermitowskie macierzy – złożenie operacji transpozycji i sprzężenia zespolonego macierzy zespolonych.

Sprzężenie zespolone – jednoargumentowe działanie algebraiczne określone na liczbach zespolonych polegające na zmianie znaku części urojonej danej liczby zespolonej.

André-Louis Cholesky
(15 October 1875, in Montguyon –
31 August 1918, in Bagneux)
was a French military officer and
mathematician.



Rozkład Choleskiego

Definicja Macierz zespoloną $\mathbf{A}$ wymiaru $n \times n$, nazywamy **dodatnio określona**, gdy:

1. $\mathbf{A} = \mathbf{A}^H$, tzn. $\mathbf{A}$ jest macierzą hermitowską.
2. Dla wszystkich $\mathbf{x} \in C^n$, $\mathbf{x} \neq 0$ zachodzi $\mathbf{x}^H \mathbf{A} \mathbf{x} > 0$.

Hermitowską macierz nazywamy **dodatnio półokreślona** gdy dla wszystkich $\mathbf{x} \in C^n$ zachodzi $\mathbf{x}^H \mathbf{A} \mathbf{x} \geq 0$.

Twierdzenie Dla każdej dodatnio określonej macierzy $\mathbf{A}$ wymiaru $n \times n$ istnieje jednoznaczna trójkątna dolna macierz $\mathbf{L}$ wymiaru $n \times n$, spełniająca warunki $l_{kk} > 0$, $k = 1, \dots, n$, oraz

$$\mathbf{A} = \mathbf{L}\mathbf{L}^H.$$

Jeżeli $\mathbf{A}$ jest rzeczywista, to również $\mathbf{L}$ jest rzeczywista.

Macierz symetryczna dodatnio określona

$$[A] \ n \times n$$

Wszystkie **główne minory** są dodatni

$$I. \det(A_{ii}) > 0 \ (i = 1, 2, \dots, n) \quad \text{Kryterium Sylwestera}$$

lub

$$II. y^T A y > 0, \quad \text{dla każdego wektora} \quad \forall y$$

Symmetrical Positive Definite (SPD)

$$[x] \ n \times 1 \quad [A][x] = [b] \quad [b] \ n \times 1$$

Macierz dodatnio określona

$$\mathbf{A} = \begin{pmatrix} a_{11} & a_{12} & \dots & a_{1n-1} & a_{1n} \\ a_{21} & a_{22} & \dots & a_{2n-1} & a_{2n} \\ \dots & \dots & \dots & \dots & \dots \\ a_{n-11} & a_{n-12} & \dots & a_{n-1n-1} & a_{n-1n} \\ a_{n1} & a_{n2} & \dots & a_{nn-1} & a_{nn} \end{pmatrix},$$

lub

$$P(\lambda) = 0,$$

$$P(\lambda) = \det(\mathbf{A} - \lambda \mathbf{I})$$

$$\Delta_1 = a_{11} > 0, \Delta_2 = \begin{vmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{vmatrix} > 0, \Delta_{n-1} = \begin{vmatrix} a_{11} & \dots & a_{1n-1} \\ \dots & \dots & \dots \\ a_{n-11} & \dots & a_{n-1n-1} \end{vmatrix} > 0, \Delta_n = \det \mathbf{A} > 0.$$

$$\mathbf{A} = \begin{pmatrix} 2 & -1 & 0 \\ -1 & 2 & -1 \\ 0 & -1 & 2 \end{pmatrix}$$

$$\mathbf{A} = \begin{pmatrix} 2 & -1 & 0 \\ -1 & 2 & -1 \\ 0 & -1 & 2 \end{pmatrix}$$

$$P(\lambda) = 0, \lambda_1 = 2 > 0, \lambda_2 = 2 - \sqrt{2} > 0, \lambda_3 = 2 + \sqrt{2} > 0.$$

$$\mathbf{A} - \lambda \mathbf{I} = \begin{pmatrix} 2-\lambda & -1 & 0 \\ -1 & 2-\lambda & -1 \\ 0 & -1 & 2-\lambda \end{pmatrix}$$

Wszystkie wartości własne są dodatnie

$$\mathbf{A} = \begin{pmatrix} 2 & -1 & 0 \\ -1 & 2 & -1 \\ 0 & -1 & 2 \end{pmatrix}, \Delta_1 = 2 > 0, \Delta_2 = \begin{vmatrix} 2 & -1 \\ -1 & 2 \end{vmatrix} = 3 > 0, \Delta_3 = \det \mathbf{A} = \begin{vmatrix} 2 & -1 & 0 \\ -1 & 2 & -1 \\ 0 & -1 & 2 \end{vmatrix} = 4 > 0.$$

Przykład

$$[A] = \begin{bmatrix} 2 & -1 & 0 \\ -1 & 2 & -1 \\ 0 & -1 & 1 \end{bmatrix}$$

I sposób

$$\det|[A]_{1 \times 1}| = |2| = 2 > 0$$

$$a_{ij} = a_{ji}$$

$$\begin{aligned} \det|[A]_{2 \times 2}| &= \begin{vmatrix} 2 & -1 \\ -1 & 2 \end{vmatrix} \\ &= 3 > 0 \end{aligned}$$

$$\begin{aligned} \det|[A]_{3 \times 3}| &= \begin{vmatrix} 2 & -1 & 0 \\ -1 & 2 & -1 \\ 0 & -1 & 1 \end{vmatrix} \\ &= 1 > 0 \end{aligned}$$

A jest SPD

2 sposób

$$scalar = y^T Ay$$

$$\begin{aligned} &= \begin{bmatrix} y_1 & y_2 & y_3 \end{bmatrix} \begin{bmatrix} 2 & -1 & 0 \\ -1 & 2 & -1 \\ 0 & -1 & 1 \end{bmatrix} \begin{bmatrix} y_1 \\ y_2 \\ y_3 \end{bmatrix} \\ &= (2y_1^2 - 2y_1y_2 + 2y_2^2) + \{y_3^2 - 2y_2y_3\} \\ &= (y_1 - y_2)^2 + y_1^2 + y_2^2 + \{y_3^2 - 2y_2y_3\} \end{aligned}$$

$$scalar = (y_1 - y_2)^2 + y_1^2 + (y_2 - y_3)^2 > 0$$

A jest SPD

Rozkład Choleskiego (cd.)

jest procedurą rozkładu *symetrycznej, dodatnio określonej macierzy*

$$\begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & \cdots & a_{nn} \end{bmatrix} = \begin{bmatrix} l_{11} & 0 & \cdots & 0 \\ l_{21} & l_{22} & \cdots & 0 \\ \vdots & \vdots & \ddots & 0 \\ l_{n1} & l_{n2} & \cdots & l_{nn} \end{bmatrix} \begin{bmatrix} l_{11} & l_{21} & \cdots & l_{n1} \\ 0 & l_{22} & \cdots & l_{n2} \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & l_{nn} \end{bmatrix}$$

$$\begin{aligned} a_{11} = l_{11}^2 &\rightarrow l_{11} = \sqrt{a_{11}} \\ a_{21} = l_{21}l_{11} &\rightarrow l_{21} = \frac{a_{12}}{l_{11}} \\ a_{22} = l_{21}^2 + l_{22}^2 &\rightarrow l_{22} = \sqrt{a_{22} - l_{21}^2} \\ a_{32} = l_{31}l_{21} + l_{32}l_{22} &\rightarrow l_{32} = \frac{a_{23} - l_{31}l_{21}}{l_{22}} \\ &\dots \end{aligned}$$

$$l_{ii} = \sqrt{\left(a_{ii} - \sum_{k=1}^{i-1} l_{ik}^2 \right)}$$

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

$$l_{ji} = \frac{a_{ij} - \sum_{k=1}^{i-1} l_{jk}l_{ik}}{l_{ii}}$$

$$j = i + 1, i + 2, \dots, n$$

Przykład

$$A = \begin{bmatrix} 4 & 2 & 2 \\ 2 & 5 & 3 \\ 2 & 3 & 6 \end{bmatrix}$$

$$l_{ii} = \sqrt{\left(a_{ii} - \sum_{k=1}^{i-1} l_{ik}^2\right)}$$

$$l_{ji} = \frac{a_{ij} - \sum_{k=1}^{i-1} l_{jk} l_{ik}}{l_{ii}}$$

znajdujemy:

$$i = 1: \quad l_{11} = \sqrt{4} = 2, \quad l_{21} = 2/2 = 1, \quad l_{31} = 2/2 = 1$$

$$i = 2: \quad l_{22} = \sqrt{5 - 1 \cdot 1} = 2, \quad l_{32} = (3 - 1 \cdot 1)/2 = 1$$

$$i = 3: \quad l_{33} = \sqrt{6 - 1 \cdot 1 - 1 \cdot 1} = 2$$

zatem

$$\begin{bmatrix} 4 & 2 & 2 \\ 2 & 5 & 3 \\ 2 & 3 & 6 \end{bmatrix} = \begin{bmatrix} 2 & 0 & 0 \\ 1 & 2 & 0 \\ 1 & 1 & 2 \end{bmatrix} \cdot \begin{bmatrix} 2 & 1 & 1 \\ 0 & 2 & 1 \\ 0 & 0 & 2 \end{bmatrix}$$

Zadanie

Otrzymać rozkład Choleskiego dla macierzy. Sprawdzić wynik.

$$\begin{pmatrix} 4 & 12 & -16 \\ 12 & 37 & -43 \\ -16 & -43 & 98 \end{pmatrix}$$

$$\begin{array}{lll} a_{11} = l_{11}^2 & \rightarrow & l_{11} = \sqrt{a_{11}} \\ a_{21} = l_{21}l_{11} & \rightarrow & l_{21} = \frac{a_{12}}{l_{11}} \\ a_{22} = l_{21}^2 + l_{22}^2 & \rightarrow & l_{22} = \sqrt{a_{22} - l_{21}^2} \\ a_{32} = l_{31}l_{21} + l_{32}l_{22} & \rightarrow & l_{32} = \frac{a_{23} - l_{31}l_{21}}{l_{22}} \\ & \dots & \\ & & l_{ji} = \frac{a_{ij} - \sum_{k=1}^{i-1} l_{jk}l_{ik}}{l_{ii}} \end{array} \quad l_{ii} = \sqrt{\left(a_{ii} - \sum_{k=1}^{i-1} l_{ik}^2 \right)}$$

Rozwiązanie

$$\begin{pmatrix} 4 & 12 & -16 \\ 12 & 37 & -43 \\ -16 & -43 & 98 \end{pmatrix} = \begin{pmatrix} 2 & 0 & 0 \\ 6 & 1 & 0 \\ -8 & 5 & 3 \end{pmatrix} \begin{pmatrix} 2 & 6 & -8 \\ 0 & 1 & 5 \\ 0 & 0 & 3 \end{pmatrix}$$

Zastosowanie


Dla symetrycznej, dodatnio określonej macierzy A

$$Ax = b$$

$$A = LL^*$$

$$LL^*x = b$$


$$L\mathbf{y} = b$$


$$L^*\mathbf{x} = \mathbf{y}$$

$$U = L^*$$

Przykład

$$y_j = \frac{b_j - \sum_{i=1}^{j-1} l_{ij} y_i}{l_{jj}}$$

$$\begin{bmatrix} l_{11} & 0 & 0 \\ l_{12} & l_{22} & 0 \\ l_{13} & l_{23} & l_{33} \end{bmatrix} \begin{Bmatrix} y_1 \\ y_2 \\ y_3 \end{Bmatrix} = \begin{Bmatrix} b_1 \\ b_2 \\ b_3 \end{Bmatrix} \quad \downarrow$$

$$l_{11}y_1 = b_1$$

$$y_1 = \frac{b_1}{l_{11}}$$

$$l_{12}y_1 + l_{22}y_2 = b_2$$

$$y_2 = b_2 - \frac{l_{12}y_1}{l_{22}}$$

$$y_3 = \frac{b_3 - l_{13}y_1 - l_{23}y_2}{l_{33}}$$

Przykład (cd.)

$$x_j = \frac{y_j - \sum_{i=j+1}^n l_{ji} x_i}{l_{jj}}$$

$$\begin{bmatrix} l_{11} & l_{12} & l_{13} \\ 0 & l_{22} & l_{23} \\ 0 & 0 & l_{33} \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} = \begin{bmatrix} y_1 \\ y_2 \\ y_3 \end{bmatrix}$$



$$l_{33} x_3 = y_3$$

$$x_3 = \frac{y_3}{l_{33}}$$

$$x_2 = \frac{y_2 - l_{23} x_3}{l_{22}}$$

$$x_1 = \frac{y_1 - l_{12} x_2 - l_{13} x_3}{l_{11}}$$

Zadanie

Rozwiązać układ przez rozkład Choleskiego

A =

$$\begin{pmatrix} 3 & -2 \\ -2 & 3 \end{pmatrix}$$

>> B

B =

$$\begin{pmatrix} 1 \\ 1 \end{pmatrix}$$

>> A⁻¹*B

ans =

$$\begin{pmatrix} 1.0000 \\ 1.0000 \end{pmatrix}$$

>> chol(A)

ans =

$$\begin{pmatrix} 1.7321 & -1.1547 \\ 0 & 1.2910 \end{pmatrix}$$

LDL* dekompozycja

$Ax = b$

Macierz A jest **symetryczna**,
ale nie koniecznie dodatnio określona

$$A = LDL^T$$

$$\begin{aligned} A &= LDL^* \\ LDL^*X &= B \\ Z &= DL^*X \\ Y &= L^*X \end{aligned}$$

$$l_{ii}=1$$

$$\begin{pmatrix} 4 & 12 & -16 \\ 12 & 37 & -43 \\ -16 & -43 & 98 \end{pmatrix}$$

$$\begin{aligned} LZ &= B \\ DY &= Z \\ L^*X &= Y \end{aligned}$$

$$\begin{pmatrix} 4 & 12 & -16 \\ 12 & 37 & -43 \\ -16 & -43 & 98 \end{pmatrix} = \begin{pmatrix} 1 & 0 & 0 \\ 3 & 1 & 0 \\ -4 & 5 & 1 \end{pmatrix} \begin{pmatrix} 4 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 9 \end{pmatrix} \begin{pmatrix} 1 & 3 & -4 \\ 0 & 1 & 5 \\ 0 & 0 & 1 \end{pmatrix}$$

LDL* faktoryzacja

$$[A] = [L][D][L]^T$$

$$\begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 \\ l_{21} & 1 & 0 \\ l_{31} & l_{32} & 1 \end{bmatrix} \begin{bmatrix} d_{11} & 0 & 0 \\ 0 & d_{22} & 0 \\ 0 & 0 & d_{33} \end{bmatrix} \begin{bmatrix} 1 & l_{21} & l_{31} \\ 0 & 1 & l_{32} \\ 0 & 0 & 1 \end{bmatrix}$$

$$d_{jj} = a_{jj} - \sum_{k=1}^{j-1} l_{jk}^2 d_{kk}$$

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

Przykład

$$A = \begin{bmatrix} 1 & 1 & 0 \\ 1 & 0 & 1 \\ 0 & 1 & 1 \end{bmatrix}$$

$$d_{jj} = a_{jj} - \sum_{k=1}^{j-1} l_{jk}^2 d_{kk}$$

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

$$\begin{bmatrix} 1 & 1 & 0 \\ 1 & 0 & 1 \\ 0 & 1 & 1 \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 \\ 1 & 1 & 0 \\ 0 & -1 & 1 \end{bmatrix} \cdot \begin{bmatrix} 1 & 0 & 0 \\ 0 & -1 & 0 \\ 0 & 0 & 2 \end{bmatrix} \cdot \begin{bmatrix} 1 & 1 & 0 \\ 0 & 1 & -1 \\ 0 & 0 & 1 \end{bmatrix}$$

Zastosowanie LDL* do $\mathbf{Ax} = \mathbf{b}$

$$[A] = [L][D][L]^T$$

$$[L][D][L]^T[x] = [b]$$

$$\begin{bmatrix} 1 & 0 & 0 \\ l_{21} & 1 & 0 \\ l_{31} & l_{32} & 1 \end{bmatrix} \begin{bmatrix} z_1 \\ z_2 \\ z_3 \end{bmatrix} = \begin{bmatrix} b_1 \\ b_2 \\ b_3 \end{bmatrix}$$

$$[L][z] = [b]$$

$$z_i = b_i - \sum_{k=1}^{i-1} L_{ik} z_k \quad \text{for } i = 1, 2, 3, \dots, n$$

$$[D][y] = [z]$$

$$\begin{bmatrix} 1 & l_{21} & l_{31} \\ 0 & 1 & l_{32} \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} = \begin{bmatrix} y_1 \\ y_2 \\ y_3 \end{bmatrix}$$

$$[L]^T[x] = [y]$$

$$x_i = y_i - \sum_{k=i+1}^n l_{ki} x_k; \quad \text{for } i = n, n-1, \dots, 1$$

Zadanie

$$Ax = b$$

Rozwiązać układ przez LDL* rozkład

A =

3	-2
-2	3

```
>> B
```

B =

1
1

```
>> A^-1*B
```

ans =

0.0769
-0.3846

Funkcje w Matlabie

```
>> A=[3 -2; -2 -3]
```

```
A =
```

```
    3    -2
```

```
   -2   -3
```

```
>> eig(A)
```

```
ans =
```

```
   -3.6056
```

```
    3.6056
```

```
>> [L,D] = ldl(A)
```

```
L =
```

```
    1.0000    0
```

```
   -0.6667    1.0000
```

```
D =
```

```
    3.0000    0
```

```
    0   -4.3333
```

```
>> A=[3 -2; -2 -3]
```

```
>> [L,U,P] = lu(A)
```

```
L =
```

```
    1.0000    0
```

```
   -0.6667    1.0000
```

```
U =
```

```
    3.0000   -2.0000
```

```
    0   -4.3333
```

```
P =
```

```
    1    0
```

```
    0    1
```

```
>> chol(A)
```

Error using chol

Matrix must be positive definite.

Macierz trójdagonalna

$$A = \begin{bmatrix} b_1 & c_1 & & & & \\ a_2 & b_2 & c_2 & & & 0 \\ & a_3 & b_3 & \ddots & & \\ & & \ddots & \ddots & \ddots & \\ & & & \ddots & \ddots & \ddots \\ & 0 & & & \ddots & \ddots \\ & & & & & \ddots & c_{n-1} \\ & & & & & a_n & \cdot & b_n \end{bmatrix}$$

LU faktoryzacja macierzy trójdzielnej

$$A = \begin{bmatrix} b_1 & c_1 & & & 0 \\ a_2 & b_2 & c_2 & & \\ & a_3 & b_3 & \ddots & \\ & & \ddots & \ddots & \\ 0 & & & \ddots & \ddots & c_{n-1} \\ & & & & a_n & \ddots & b_n \end{bmatrix} \quad L = \begin{bmatrix} 1 & & & & \\ l_2 & \ddots & & & \\ & \ddots & \ddots & & \\ & & \ddots & \ddots & \\ 0 & & & \ddots & \ddots & \\ & & & & l_n & 1 \end{bmatrix} \quad U = \begin{bmatrix} u_1 & c_1 & & & \\ & \ddots & \ddots & & \\ & & \ddots & \ddots & \\ & & & \ddots & \ddots & c_{n-1} \\ 0 & & & & u_n \end{bmatrix}$$

Elementy $l_2, \dots, l_n$ oraz $u_1, \dots, u_n$ można obliczyć rekurencyjnie ze wzorów

$$\begin{array}{l} u_1 = b_1 \\ l_i = a_i / u_{i-1} \\ u_i = b_i - l_i c_{i-1} \end{array} \quad \text{dla} \quad i = 2, 3, \dots, n$$

Zadanie

Znaleźć rozkład LU macierzy

$$T = \begin{bmatrix} 2 & 2 & 0 \\ -2 & 0 & 2 \\ 0 & -2 & 0 \end{bmatrix}$$

$$\begin{array}{l} u_1 = b_1 \\ l_i = a_i / u_{i-1} \\ u_i = b_i - l_i c_{i-1} \end{array}$$

dla $i = 2, 3, \dots, n$

Odpowiedź

```
>> [L,U] = lu([2 2 0;-2 0 2;0 -2 0])
```

L =

1	0	0
-1	1	0
0	-1	1

U =

2	2	0
0	2	2
0	0	2

Trójdagonalny układ (cd.)

$$Tx = d$$

$$LUx = d \rightarrow Ly = d$$

$$Ux = y$$

$$y_1 = d_1$$

$$y_i = d_i - l_i y_{i-1}$$

dla

$$i = 2, 3, \dots, n$$

$$x_n = y_n / u_n$$

$$x_i = (y_i - c_i x_{i+1}) / u_i$$

$$\text{dla } i = n - 1, n - 2, \dots, 1$$

$$L = \begin{bmatrix} 1 & & & 0 \\ l_2 & \ddots & & \\ & \ddots & \ddots & \\ 0 & & \ddots & l_n & 1 \end{bmatrix} \quad U = \begin{bmatrix} u_1 & c_1 & & 0 \\ & \ddots & \ddots & \\ & & \ddots & c_{n-1} \\ & 0 & & u_n \end{bmatrix}$$

Niestabilność metody

$$T = \begin{bmatrix} 1 & 1 & 0 \\ 1 & 1 & 1 \\ 0 & 1 & 1 \end{bmatrix}, \quad \det T = -1$$

$$\begin{aligned} u_1 &= b_1 \\ l_i &= a_i / u_{i-1} \\ u_i &= b_i - l_i c_{i-1} \end{aligned}$$

$$A = \begin{bmatrix} b_1 & c_1 & & & 0 \\ a_2 & b_2 & c_2 & & \\ & a_3 & b_3 & \ddots & \\ & & \ddots & \ddots & \\ 0 & & & & c_{n-1} \\ & & & a_n & & b_n \end{bmatrix}$$

otrzymujemy $u_1 = 1$, $l_2 = 1$, $u_2 = 0$, a więc niemożliwe jest obliczenie $l_3 = 1/u_2$.

$$A = \begin{bmatrix} b_1 & c_1 & & & 0 \\ a_2 & b_2 & c_2 & & \\ & a_3 & b_3 & \ddots & \\ & & \ddots & \ddots & \\ 0 & & & & c_{n-1} \\ & & & a_n & & b_n \end{bmatrix} \quad L = \begin{bmatrix} 1 & & & & 0 \\ l_2 & & & & \\ & \ddots & & & \\ 0 & & \ddots & & \\ & & & l_n & 1 \end{bmatrix} \quad U = \begin{bmatrix} u_1 & c_1 & & & 0 \\ & \ddots & \ddots & & \\ & & \ddots & \ddots & \\ 0 & & & & c_{n-1} \\ & & & u_n & \end{bmatrix}$$

Niestabilność metody

$$T = \begin{bmatrix} 1 & 1 & 0 \\ 1 & 1 & 1 \\ 0 & 1 & 1 \end{bmatrix}, \quad \det T = -1$$

$$\begin{aligned} u_1 &= b_1 \\ l_i &= a_i / u_{i-1} \\ u_i &= b_i - l_i c_{i-1} \end{aligned}$$

$$A = \begin{bmatrix} b_1 & c_1 & & & & \\ a_2 & b_2 & c_2 & & & 0 \\ & a_3 & b_3 & c_3 & & \\ & & \ddots & \ddots & \ddots & \\ 0 & & & & c_{n-1} & \\ & & & & a_n & b_n \end{bmatrix}$$

otrzymujemy $u_1 = 1$, $l_2 = 1$, $u_2 = 0$, a więc niemożliwe jest obliczenie $l_3 = 1/u_2$.

Możliwe są inne rozwiązania

$$L = \begin{bmatrix} l_1 & & & & 0 \\ & \ddots & & & \\ a_2 & & \ddots & & \\ & \ddots & & \ddots & \\ 0 & & & \ddots & a_n & l_n \end{bmatrix}, \quad U = \begin{bmatrix} 1 & u_1 & & & 0 \\ & \ddots & & & \\ & & \ddots & & \\ & & & \ddots & \\ 0 & & & & u_{n-1} & 1 \end{bmatrix}$$

$$T = LDU$$

$$T = LDL^T$$

```
>> T=[1 1 0;1 1 1;0 1 1]
```

T =

1	1	0
1	1	1
0	1	1

```
>> [L U]=lu(T)
```

L =

1	0	0
1	0	1
0	1	0

U =

1	1	0
0	1	1
0	0	1

```
>> [L U P]=lu(T)
```

L =

1	0	0
0	1	0
1	0	1

U =

1	1	0
0	1	1
0	0	1

P =

1	0	0
0	0	1
0	1	0

```
>> PT=P*T
```

PT =

1	1	0
0	1	1
1	1	1

```
>> [L U]=lu(PT)
```

L =

1	0	0
0	1	0
1	0	1

U =

1	1	0
0	1	1
0	0	1

Rzadkie macierzy

Macierz rzadka – macierz, w której większość elementów ma wartość zero.

$$\begin{pmatrix} 4 & 1 & 2 & \frac{1}{2} & 2 \\ 1 & \frac{1}{2} & 0 & 0 & 0 \\ 2 & 0 & 3 & 0 & 0 \\ \frac{1}{2} & 0 & 0 & \frac{5}{8} & 0 \\ 2 & 0 & 0 & 0 & 16 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \\ x_5 \end{pmatrix} = \begin{pmatrix} 7 \\ 3 \\ 7 \\ -4 \\ -4 \end{pmatrix}$$

$$Ly = b \quad y = \begin{pmatrix} 3.5 \\ 2.5 \\ 6 \\ -2.5 \\ -0.50 \end{pmatrix}$$

$$L^T x = y$$

$$L = \begin{pmatrix} 2 & & & & 0 \\ 0.50 & 0.50 & & & \\ 1 & -1 & 1 & & \\ 0.25 & -0.25 & -0.50 & 0.50 & \\ 1 & -1 & -2 & -3 & 1 \end{pmatrix}$$

$$x = \begin{pmatrix} 2 \\ 2 \\ 1 \\ -8 \\ -0.50 \end{pmatrix}$$


Niezerowe elementy

Problem wypełnienia (fill-in)


Faktoryzacja LU może **zwiększyć liczbę niezerowych elementów** w porównaniu do oryginalnej macierzy. Zjawisko to nazywa się **wypełnieniem** (fill-in).

```
A=[4 1 2 1/2 2;  
 1 1/2 0 0 0;  
 2 0 3 0 0;  
 1/2 0 0 5/8 0;  
 2 0 0 0 16];  
L=chol(A)';
```

Spy(A)



Spy(L)



Przykład

```
A=[4 1 2 1/2 2;  
  1 1/2 0 0 0;  
  2 0 3 0 0;  
  1/2 0 0 5/8 0;  
  2 0 0 0 16];  
L=chol(A)';
```

$L =$

2	0	0	0	0
0.5	0.5	0	0	0
1	-1	1	0	0
0.25	-0.25	-0.5	0.5	0
1	-1	-2	-3	1

Przebudowa macierzy

$$x_i \rightarrow \tilde{x}_{5-i+1}, i = 1, 2, \dots, 5$$

$$\begin{pmatrix} 4 & 1 & 2 & \frac{1}{2} & 2 \\ 1 & \frac{1}{2} & 0 & 0 & 0 \\ 2 & 0 & 3 & 0 & 0 \\ \frac{1}{2} & 0 & 0 & \frac{5}{8} & 0 \\ 2 & 0 & 0 & 0 & 16 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \\ x_5 \end{pmatrix} = \begin{pmatrix} 7 \\ 3 \\ 7 \\ -4 \\ -4 \end{pmatrix} \quad \rightarrow \quad \begin{pmatrix} 16 & 0 & 0 & 0 & 2 \\ 0 & \frac{5}{8} & 0 & 0 & \frac{1}{2} \\ 0 & 0 & 3 & 0 & 2 \\ 0 & 0 & 0 & \frac{1}{2} & 1 \\ 2 & \frac{1}{2} & 2 & 1 & 4 \end{pmatrix} \begin{pmatrix} \tilde{x}_1 \\ \tilde{x}_2 \\ \tilde{x}_3 \\ \tilde{x}_4 \\ \tilde{x}_5 \end{pmatrix} = \begin{pmatrix} -4 \\ -4 \\ 7 \\ 3 \\ 7 \end{pmatrix}$$

$$L = \begin{pmatrix} 2 & & & & 0 \\ 0.50 & 0.50 & & & \\ 1 & -1 & 1 & & \\ 0.25 & -0.25 & -0.50 & 0.50 & \\ 1 & -1 & -2 & -3 & 1 \end{pmatrix}$$

$$\tilde{L} = \begin{pmatrix} 4 & & & & 0 \\ 0 & 0.791 & & & \\ 0 & 0 & 1.73 & & \\ 0 & 0 & 0 & 0.707 & \\ 0.500 & 0.632 & 1.15 & 1.41 & 0.129 \end{pmatrix}$$

```

A=[4 1 2 1/2 2;
   1 1/2 0 0 0;
   2 0 3 0 0;
   1/2 0 0 5/8 0;
   2 0 0 0 16];
L=chol(A)';

```

```

P=[0 0 0 0 1;
   0 0 0 1 0;
   0 0 1 0 0;
   0 1 0 0 0;
   1 0 0 0 0];
Ap=P*A; %wiersze
As=Ap*P; %kolumny

```

```
>> A
```

```
A =
```

4	1	2	0.5	2
1	0.5	0	0	0
2	0	3	0	0
0.5	0	0	0.625	0
2	0	0	0	16

```
L =
```

2	0	0	0	0
0.5	0.5	0	0	0
1	-1	1	0	0
0.25	-0.25	-0.5	0.5	0
1	-1	-2	-3	1

```
As =
```

16	0	0	0	2
0	0.625	0	0	0.5
0	0	3	0	2
0	0	0	0.5	1
2	0.5	2	1	4

```
>> chol(As)'
```

```
ans =
```

4	0	0	0	0
0	0.79057	0	0	0
0	0	1.7321	0	0
0	0	0	0.70711	0
0.5	0.63246	1.1547	1.4142	0.1291

Zagadnienie optymalizacji

```
>> A
```

```
A =
```

4	1	2	0.5	2
1	0.5	0	0	0
2	0	3	0	0
0.5	0	0	0.625	0
2	0	0	0	16

```
P =
```

0	0	0	0	1
0	0	0	1	0
0	0	1	0	0
0	1	0	0	0
1	0	0	0	0


```
>> P*A*P
```

```
ans =
```


16	0	0	0	2
0	0.625	0	0	0.5
0	0	3	0	2
0	0	0	0.5	1
2	0.5	2	1	4

Schematy przebudowy



A



L





CEL: Otrzymanie stopnia rzadkości L takiego, jaki jest stopień rzadkości A



Problem optymalizacyjny

A

L



Jak przebudować A?



$A'=?$

Macierz L powtarza „wprawie”
kształt dolnej części macierzy A

Approximate Minimum Degree Permutation (AMD)

Approximate Minimum Degree (AMD) to efektywny heurystyczny algorytm do **znajdowania permutacji wierszy i kolumn rzadkiej macierzy**. Jego **celem jest minimalizacja wypełnienia** (liczby niezerowych elementów) **w trakcie dekompozycji** LU, Cholesky lub QR, co prowadzi do oszczędności pamięci i czasu obliczeń.

Dla dużych, rzadkich macierzy dekompozycje takie jak LU, Cholesky czy QR mogą prowadzić do powstawania nowych, niezerowych elementów (tzw. wypełnienia).

AMD reorganizuje macierz przez permutację wierszy i kolumn w taki sposób, aby **minimalizować to wypełnienie**, co usprawnia obliczenia.

Graf sąsiedztwa


Graf sąsiedztwa:

Każdą macierz rzadką można przedstawić jako graf nieskierowany, gdzie:

- **Wierzchołki odpowiadają wierszom** (lub kolumnom).
- Krawędzie istnieją, jeśli macierz **ma niezerowy element**.
- **Stopień wierzchołka**: Liczba krawędzi łączących dany wierzchołek z innymi odpowiada liczbie niezerowych elementów w danym wierszu lub kolumnie.

showGraphDS.m

```
A = [  
0 1 0 0;  
1 0 1 0;  
0 1 0 1;  
0 0 1 0];
```



Strategia minimalnego stopnia:
Minimalizowanie stopnia wierzchołków (liczby połączeń) minimalizuje wypełnienie w trakcie eliminacji Gaussa

Algorytm AMD

1. Inicjalizacja:

- Utwórz **graf sąsiedztwa** macierzy (na podstawie jej niezerowych elementów).
- Oblicz **stopnie wierzchołków** (liczba połączeń każdego wiersza/kolumny).

2. Wybór wierzchołka o minimalnym stopniu:

- Znajdź **wierzchołek o najmniejszym stopniu**.
- **Dodaj go do permutacji**.

3. Aktualizacja grafu (schodkowe eliminacje):

- Po wybraniu wierzchołka **aktualizuj graf**:
 - Połącz sąsiadów (operacja zwana wypełnieniem).
 - Przelicz stopnie wierzchołków.

4. Kontynuacja:

- Powtarzaj kroki, aż wszystkie **wierzchołki zostaną dodane do permutacji**.

5. Zakończenie:

- **Zwróć permutację**, która minimalizuje wypełnienie.

Przykład

$$A = \begin{bmatrix} 0 & 1 & 0 & 0 \\ 1 & 0 & 1 & 0 \\ 0 & 1 & 0 & 1 \\ 0 & 0 & 1 & 0 \end{bmatrix}$$

Krok 1: Reprezentacja macierzy jako grafu

Macierz A jest macierzą sąsiedztwa grafu nieskierowanego. Każdy wiersz/kolumna odpowiada wierzchołkowi, a niezerowe elementy oznaczają krawędzie między wierzchołkami.

- Wierzchołek 1 jest połączony z wierzchołkiem 2.
- Wierzchołek 2 jest połączony z wierzchołkami 1 i 3.
- Wierzchołek 3 jest połączony z wierzchołkami 2 i 4.
- Wierzchołek 4 jest połączony z wierzchołkiem 3.

Graf wygląda następująco: 1 - 2 - 3 - 4

Przykład

$$A = \begin{bmatrix} 0 & 1 & 0 & 0 \\ 1 & 0 & 1 & 0 \\ 0 & 1 & 0 & 1 \\ 0 & 0 & 1 & 0 \end{bmatrix}$$

Krok 2: Inicjalizacja

Algorytm AMD działa na zasadzie eliminacji wierzchołków o najmniejszym stopniu (liczbie sąsiadów). W każdym kroku wybieramy wierzchołek o najmniejszym stopniu, eliminujemy go i aktualizujemy stopnie jego sąsiadów.

- **Stopnie wierzchołków:**

- Wierzchołek 1: stopień 1 (sąsiad: 2)
- Wierzchołek 2: stopień 2 (sąsiedzi: 1, 3)
- Wierzchołek 3: stopień 2 (sąsiedzi: 2, 4)
- Wierzchołek 4: stopień 1 (sąsiad: 3)

Przykład

$$A = \begin{bmatrix} 0 & 1 & 0 & 0 \\ 1 & 0 & 1 & 0 \\ 0 & 1 & 0 & 1 \\ 0 & 0 & 1 & 0 \end{bmatrix}$$

Krok 3: Eliminacja wierzchołków

Krok 3.1: Eliminacja wierzchołka 1

- Wybieramy wierzchołek o najmniejszym stopniu (wierzchołek 1 lub 4). Załóżmy, że wybieramy wierzchołek 1.
- Eliminujemy wierzchołek 1 i dodajemy go do permutacji: $p = [1]$.
- Aktualizujemy stopnie sąsiadów wierzchołka 1:
 - Wierzchołek 2: stopień zmniejsza się z 2 do 1 (traci sąsiada 1).

Przykład

$$A = \begin{bmatrix} 0 & 1 & 0 & 0 \\ 1 & 0 & 1 & 0 \\ 0 & 1 & 0 & 1 \\ 0 & 0 & 1 & 0 \end{bmatrix}$$

Krok 3.2: Eliminacja wierzchołka 4

- Teraz wierzchołki 2 i 4 mają stopień 1. Wybieramy wierzchołek 4.
- Eliminujemy wierzchołek 4 i dodajemy go do permutacji: $p = [1, 4]$.
- Aktualizujemy stopnie sąsiadów wierzchołka 4:
 - Wierzchołek 3: stopień zmniejsza się z 2 do 1 (traci sąsiada 4).

Przykład

$$A = \begin{bmatrix} 0 & 1 & 0 & 0 \\ 1 & 0 & 1 & 0 \\ 0 & 1 & 0 & 1 \\ 0 & 0 & 1 & 0 \end{bmatrix}$$

Krok 3.3: Eliminacja wierzchołka 2

- Teraz wierzchołki 2 i 3 mają stopień 1. Wybieramy wierzchołek 2.
- Eliminujemy wierzchołek 2 i dodajemy go do permutacji: $p = [1, 4, 2]$.
- Aktualizujemy stopnie sąsiadów wierzchołka 2:
 - Wierzchołek 3: stopień zmniejsza się z 1 do 0 (traci sąsiada 2).

Przykład

$$A = \begin{bmatrix} 0 & 1 & 0 & 0 \\ 1 & 0 & 1 & 0 \\ 0 & 1 & 0 & 1 \\ 0 & 0 & 1 & 0 \end{bmatrix}$$

Krok 3.4: Eliminacja wierzchołka 3

- Pozostał tylko wierzchołek 3.
- Eliminujemy wierzchołek 3 i dodajemy go do permutacji: $p = [1, 4, 2, 3]$.

Przykład

$$A = \begin{bmatrix} 0 & 1 & 0 & 0 \\ 1 & 0 & 1 & 0 \\ 0 & 1 & 0 & 1 \\ 0 & 0 & 1 & 0 \end{bmatrix}$$

Krok 4: Permutacja

Ostateczna permutacja zwrócona przez algorytm AMD to:

$$p = [1, 4, 2, 3]$$

Oznacza to, że wiersze i kolumny macierzy A należy przepermutować w kolejności: 1, 4, 2, 3.

Przykład

$$A = \begin{bmatrix} 0 & 1 & 0 & 0 \\ 1 & 0 & 1 & 0 \\ 0 & 1 & 0 & 1 \\ 0 & 0 & 1 & 0 \end{bmatrix}$$

Krok 5: Zastosowanie permutacji do macierzy



Po zastosowaniu permutacji p do macierzy A otrzymujemy macierz A_{perm} :

$$A_{\text{perm}} = A(p, p) = \begin{bmatrix} 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ 1 & 0 & 0 & 1 \\ 0 & 1 & 1 & 0 \end{bmatrix}$$

Przykład

$$A = \begin{bmatrix} 0 & 1 & 0 & 0 \\ 1 & 0 & 1 & 0 \\ 0 & 1 & 0 & 1 \\ 0 & 0 & 1 & 0 \end{bmatrix}$$

przykladAMDprosty.m



A(P,P)

Wyrażenie `A(p, p)` w MATLAB-ie oznacza **permutację wierszy i kolumn macierzy A zgodnie z wektorem permutacji p** . Jest to sposób na zmianę kolejności wierszy i kolumn macierzy, aby uzyskać nową macierz A_{perm} , która ma lepszą strukturę (np. mniejsze wypełnienie podczas faktoryzacji LU).

Jak działa `A(p, p)` ?

1. Wektor permutacji p :

- Wektor p określa nową kolejność wierszy i kolumn.
- Przykład: Jeśli $p = [2, 1, 4, 3]$, oznacza to:
 - Wiersz 1 nowej macierzy będzie wierszem 2 starej macierzy.
 - Wiersz 2 nowej macierzy będzie wierszem 1 starej macierzy.
 - Wiersz 3 nowej macierzy będzie wierszem 4 starej macierzy.
 - Wiersz 4 nowej macierzy będzie wierszem 3 starej macierzy.
- To samo dotyczy kolumn.

Składnia `A(p, p)` :

- `A(p, p)` oznacza:
 - Wybór wierszy macierzy A zgodnie z wektorem p .
 - Wybór kolumn macierzy A zgodnie z wektorem p .

Przykład

```
A = [1 2 3;  
     4 5 6;  
     7 8 9];
```

```
p = [2, 3, 1]; % Wektor permutacji
```

```
A_perm = A(p, p); % Permutacja wierszy i kolumn
```

Macierz przed permutacją:

1	2	3
4	5	6
7	8	9

Macierz po permutacji:

5	6	4
8	9	7
2	3	1

```
>> A([3,2,1],[1,2,3])
```

ans =

7	8	9
4	5	6
1	2	3

Problem pamięciowy

```
A = eye(10000);  
whos A
```

Name	Size	Bytes	Class	Attributes
A	10000x10000	800000000	double	

This matrix uses 800-megabytes of memory.

Convert the matrix to sparse storage.

```
S = sparse(A);  
whos S
```

Name	Size	Bytes	Class	Attributes
S	10000x10000	240008	double	sparse

In sparse form, the same matrix uses roughly 0.25-megabytes of memory. In this case, y

Portret macierzy rzadkiej

$$P_{\mathbf{A}} \stackrel{\text{def}}{=} \{(i, j) \mid a_{ij} \neq 0\} \quad \text{Zbiór indeksów}$$

Macierz z niesymetrycznym portretem $\mathbf{A} \neq \mathbf{A}^T \quad \exists (i, j) \in P_{\mathbf{A}} : (j, i) \notin P_{\mathbf{A}}$

Niesymetryczna macierz z symetrycznym portretem $(i, j) \in P_{\mathbf{A}} \iff (j, i) \in P_{\mathbf{A}} \quad a_{ij} \neq a_{ji};$

Symetryczna macierz $(i, j) \in P_{\mathbf{A}} \iff (j, i) \in P_{\mathbf{A}} \quad a_{ij} = a_{ji}$

Compressed Sparse Row (CSR,CSC – column)

- **aelem**, który zawiera wszystkie niezerowe elementy macierzy A, wymienione w kolejności wierszy;
- **jptr**, który zawiera taką samą liczbę elementów jak aelem i dla każdego z nich wskazuje, w której kolumnie znajduje się dany element;
- **iptr**, który przechowuje liczbę elementów równą wymiarowi macierzy A powiększonemu o jeden. Jej i-ty element określa pozycję, od której zaczyna się i-ty wiersz macierzy w tablicach aelem i jpтр. W związku z tym $\text{iptr}[i+1] - \text{iptr}[i]$ jest równe liczbie niezerowych elementów w i-tym wierszu. Ostatni element $\text{iptr}[n+1]$ jest równy liczbie elementów w aelem plus jeden.

Można zastosować modyfikację **CSR**, w której dane są przechowywane w ten sam sposób i w tych samych tablicach, z tym, że niezerowe elementy macierzy są zestawiane nie wierszami, a kolumnami. Ten wariant jest znany jako **CSC**.

Przykład

$$\mathbf{A} = \begin{pmatrix} 9 & 0 & 0 & 3 & 1 & 0 & 1 \\ 0 & 11 & 2 & 1 & 0 & 0 & 2 \\ 0 & 1 & 10 & 2 & 0 & 0 & 0 \\ 2 & 1 & 2 & 9 & 1 & 0 & 0 \\ 1 & 0 & 0 & 1 & 12 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 & 8 & 0 \\ 2 & 2 & 0 & 0 & 3 & 0 & 8 \end{pmatrix}$$

$$n = 7$$

$$\text{aelem} = [\underbrace{9, 3, 1, 1}_{4(1)}, \underbrace{11, 2, 1, 2}_{4(5)}, \underbrace{1, 10, 2}_{3(9)}, \underbrace{2, 1, 2, 9, 1}_{5(12)}, \underbrace{1, 1, 12, 1}_{4(17)}, \underbrace{8}_{1(21)}, \underbrace{2, 2, 3, 8}_{4(22)}]$$

$$\text{jptr} = [\underbrace{1, 4, 5, 7}_{4(1)}, \underbrace{2, 3, 4, 7}_{4(5)}, \underbrace{2, 3, 4}_{3(9)}, \underbrace{1, 2, 3, 4, 5}_{5(12)}, \underbrace{1, 4, 5, 7}_{4(17)}, \underbrace{6}_{1(21)}, \underbrace{1, 2, 5, 7}_{4(22)}]$$

$$\text{iptr} = [1, 5, 9, 12, 17, 21, 22, 26]$$

Iloczyn macierzowy $z := Ax$

```
x=[1 2 3 4 5 6 7]';
```

Input: x; aelem, jptr, iptr; n

Output: z=Ax

```
for i= 1 : n {
```

```
z[i]:=0
```

```
for j = iptr[i] : iptr[i+1]-1 {
```

```
z[i]:=z[i]+x[jptr[j]]*aelem[j]
```

```
}
```

```
}
```

```
>> A*x
```

```
ans =
```

```
33
```

```
46
```

```
40
```

```
51
```

```
72
```

```
48
```

```
77
```

```
z =
```

```
33
```

```
46
```

```
40
```

```
51
```

```
72
```

```
48
```

```
77
```

25 kroków

49 kroków

```
> nnz(A)
```

```
ans =
```

```
25
```

iloczynAx.m

CSR — Compressed Sparse (lower triangle)

Aby przechowywać **macierze z symetrycznym portretem i niezerową przekątną główną**, można zastosować ten sam schemat CSR, z następującymi zmianami:

- elementy głównej przekątnej są przechowywane oddzielnie w tablicy **adiag**;
- zamiast tablicy **aelem** używana jest tablica **altr**, w której w ten sam sposób przechowywane są tylko elementy pod przekątnej macierzy. Tworzone są dla niego tablice **jptr** i **iptr**;
- dla przekątnych elementów macierzy tworzona jest tablica **autr**, która przechowuje elementy nie w rzędach, ale w kolejności kolumn. Dla **autr**, ze względu na symetrię portretu, tablice **jptr** i **iptr** nie są tworzone.

Przykład

$$\mathbf{A} = \begin{pmatrix} 9 & 0 & 0 & 3 & 1 & 0 & 1 \\ 0 & 11 & 2 & 1 & 0 & 0 & 2 \\ 0 & 1 & 10 & 2 & 0 & 0 & 0 \\ 2 & 1 & 2 & 9 & 1 & 0 & 0 \\ 1 & 0 & 0 & 1 & 12 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 & 8 & 0 \\ 2 & 2 & 0 & 0 & 3 & 0 & 8 \end{pmatrix}$$

`x=[1 2 3 4 5 6 7]';`

`adiag` = [9, 11, 10, 9, 12, 8, 8]
`altr` = [1, $\underbrace{2, 1, 2}$, $\underbrace{1, 1}$, $\underbrace{2, 2, 3}$]
`autr` = [2, $\underbrace{3, 1, 2}$, $\underbrace{1, 1}$, $\underbrace{1, 2, 1}$]
`jptr` = [2, $\underbrace{1, 2, 3}$, $\underbrace{1, 4}$, $\underbrace{1, 2, 5}$]
`iptr` = [1, 1, 1, 2, 5, 7, 7, 10]

Iloczyn macierzowy II $z := Ax$

```
>> A*x
```

```
ans =
```

```
33  
46  
40  
51  
72  
48  
77
```

49 kroków

```
>> z
```

```
ans =
```

```
33  
46  
40  
51  
72  
48  
77
```

16 kroków

Input: x; adiag, altr, autr, jptr, iptr; n

Output: z=Ax

```
for i = 1 : n { z[i]:=x[i]*adiag[i] }
```

```
for i = 1 : n {
```

```
  for j=iptr[i] : iptr[i+1]-1 {
```

```
    z[i]:=z[i]+x[jptr[j]]*altr[j]
```

```
    z[jptr[j]]:=z[jptr[j]]+x[i]*autr[j]
```

```
  }
```

```
}
```

Jeśli zamienimy referencje na tablice **altr** i **autr**,
to zamiast **$z := Ax$** zostanie obliczony iloczyn
 $z := A^T x$.

Ten sam algorytm można zastosować w przypadku **macierzy symetrycznych**. Jediną konieczną zmianą jest użycie nie dwóch tablic **altr** i **autr**, ale jednej z nich.

ILU do rozwiązywania układu równań

Incomplete Lower-Upper triangles decomposition

A: adiag, altr, autr, jptr, iptr

L: lltr, ldiag

U: uutr, udiag

lltr-CSR

$$\mathbf{L}z = f$$

$$z = \mathbf{L}^{-1}f$$

Input: f; ldiag, lltr, jptr, iptr; n

Output: $z = \mathbf{L}^{-1}f$

Additional effect: changed f

```
for i=1: n {  
  for j= iptr[i]:iptr[i+1]-1 {  
    f[i]:=f[i]-z[jptr[j]]*lltr[j]  
  }  
  z[i]:=f[i]/ldiag[i]  
}
```

uutr-CSC

$$\mathbf{U}z = f$$

$$z = \mathbf{U}^{-1}f$$

Input: f; udiag, uutr, jptr, iptr; n

Output: $z = \mathbf{U}^{-1}f$

Additional effect: changed f

```
for i=n: -1:1 {  
  z[i]:=f[i]/ldiag[i]  
  for j= iptr[i]:iptr[i+1]-1 {  
    f[jptr[j]]:=f[jptr[j]]-z[i]*uutr[j]  
  }  
}
```

Przykład

z = 0.1111 0.1818 0.2818 0.3369 0.3793 0.7500 0.6595

9 kroków

zf' = 0.1111 0.1818 0.2818 0.3369 0.3793 0.7500 0.6595

49 kroków (LU)

```
f=[1 2 3 4 5 6 7];
```

```
L=
```

```
9    0    0    0    0    0    0
0   11    0    0    0    0    0
0    1   10    0    0    0    0
2    1    2    9    0    0    0
1    0    0    1   12    0    0
0    0    0    0    0    8    0
2    2    0    0    3    0    8
];
```

$zf=L^{-1}*f$

Aminus1.m

Przykład

$$\mathbf{A} = \begin{pmatrix} 9 & 0 & 0 & 3 & 1 & 0 & 1 \\ 0 & 11 & 2 & 1 & 0 & 0 & 2 \\ 0 & 1 & 10 & 2 & 0 & 0 & 0 \\ 2 & 1 & 2 & 9 & 1 & 0 & 0 \\ 1 & 0 & 0 & 1 & 12 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 & 8 & 0 \\ 2 & 2 & 0 & 0 & 3 & 0 & 8 \end{pmatrix}$$

$$\mathbf{A} = \mathbf{L}_\mathbf{A} \mathbf{U}_\mathbf{A}$$

$$\mathbf{L}_\mathbf{A} = \begin{pmatrix} 1 & & & & & & \\ 0 & 1 & & & & & \\ 0 & 0.091 & 1 & & & & \\ 0.222 & 0.091 & 0.185 & 1 & & & \\ 0.111 & 0 & 0 & 0.085 & 1 & & \\ 0 & 0 & 0 & 0 & 0 & 1 & \\ 0.222 & 0.182 & -0.037 & -0.099 & 0.241 & 0 & 1 \end{pmatrix}$$

$$\mathbf{U}_\mathbf{A} = \begin{pmatrix} 9 & 0 & 0 & 3 & 1 & 0 & 1 \\ & 11 & 2 & 1 & 0 & 0 & 2 \\ & & 9.818 & 1.909 & 0 & 0 & -0.182 \\ & & & 7.889 & 0.778 & 0 & -0.37 \\ & & & & 11.823 & 0 & 0.92 \\ & & & & & 8 & 0 \\ & & & & & & 7.149 \end{pmatrix}$$

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

$$\mathbf{L}_\mathbf{A}y = b$$

$$\mathbf{U}_\mathbf{A}x = y.$$

Dużo nowych niezerowych elementów

>> [L U]=lu(A)

Przypadek rzadkiej macierzy - ILU

$$P_{\mathbf{A}} \stackrel{\text{def}}{=} \{(i, j) \mid a_{ij} \neq 0\} \quad \mathbf{A} = \mathbf{L}\mathbf{U} + \mathbf{R}$$

- $P_{\mathbf{L}} \subset P_{\mathbf{A}}$ i $P_{\mathbf{U}} \subset P_{\mathbf{A}}$; indeksy
- $\forall (i, j) \in P_{\mathbf{A}} : [\mathbf{L}\mathbf{U}]_{ij} = [\mathbf{A}]_{ij}$;
- $P_{\mathbf{A}} \cap P_{\mathbf{R}} = \emptyset$.

Niekompletna LU -faktoryzacja macierzy –
ILU - **incomplete LU factorization**

$$\mathbf{A} \approx \mathbf{L}\mathbf{U}$$

ILU faktoryzacja

W tej metodzie do portretu nie wprowadzano żadnych **nowych niezerowych elementów**!

Aby znaleźć macierze L i U , wygenerujemy je wiersz po wierszu. Załóżmy, że pierwsze $(k-1)$ wiersze zostały już znalezione i trzeba znaleźć k -ty wiersz. Zapiszmy blokami pierwsze k wierszy rozkładu

$$\mathbf{A} = \mathbf{LU} + \mathbf{R}$$

$$\begin{pmatrix} \mathbf{A}_{11} & \mathbf{A}_{12} \\ \mathbf{a}_{21}^T & \mathbf{a}_{22}^T \end{pmatrix} = \begin{pmatrix} \mathbf{L}_{11} & \mathbf{0} \\ \mathbf{l}_{21}^T & 1 \end{pmatrix} \begin{pmatrix} \mathbf{U}_{11} & \mathbf{U}_{12} \\ \mathbf{0} & \mathbf{u}_{22}^T \end{pmatrix} + \begin{pmatrix} \mathbf{R}_{11} & \mathbf{R}_{12} \\ \mathbf{r}_{21}^T & \mathbf{r}_{22}^T \end{pmatrix}$$

$\mathbf{l}_{21}$, $\mathbf{u}_{22}$, $\mathbf{r}_{21}$ i $\mathbf{r}_{22}$ są wektorami.

Można przepisać to tak:

$$\begin{pmatrix} \mathbf{A}_{11} & \mathbf{A}_{12} \\ \mathbf{a}_{21}^T & \mathbf{a}_{22}^T \end{pmatrix} = \begin{pmatrix} \mathbf{L}_{11}\mathbf{U}_{11} + \mathbf{R}_{11} & \mathbf{L}_{11}\mathbf{U}_{12} + \mathbf{R}_{12} \\ \mathbf{l}_{21}^T\mathbf{U}_{11} + \mathbf{r}_{21}^T & \mathbf{l}_{21}^T\mathbf{U}_{12} + \mathbf{u}_{22}^T + \mathbf{r}_{22}^T \end{pmatrix}$$

Metoda ILU faktoryzacji (cd)

Skąd mamy

$$\begin{aligned} \mathbf{l}_{21}^T \mathbf{U}_{11} + \mathbf{r}_{21}^T &= \mathbf{a}_{21}^T; \\ \mathbf{u}_{22}^T + \mathbf{r}_{22}^T &= \mathbf{a}_{22}^T - \mathbf{l}_{21}^T \mathbf{U}_{12} \end{aligned}$$

Pamiętając, że $l_{kk} \equiv 1$

rozwiązując te układy, możemy znaleźć współczynniki k-tych rzędów macierzy dekompozycji

$$l_{k1}, \dots, l_{k,k-1}, u_{kk}, \dots, u_{kn}$$

Obliczymy l_{kj} zakładając, że $l_{k1} \dots l_{k,j-1}$ zostały już znalezione.

($j < k$ zawsze dla macierzy L)

Jeżeli $a_{kj} = 0$ to $l_{kj} = 0$

Inaczej

$$\sum_{i=1}^j l_{ki} u_{ij} = \sum_{i=1}^{j-1} l_{ki} u_{ij} + l_{kj} u_{jj} = a_{kj}$$

biorąc pod uwagę fakt, że dla $i > j$ elementy górnej macierzy trójkątnej U są równe zeru.

Metoda ILU faktoryzacji (cd)

Skąd mamy

$$l_{kj} = \frac{1}{u_{jj}} \left(a_{kj} - \sum_{i=1}^{j-1} l_{ki} u_{ij} \right)$$

Przypomnijmy, że zakłada się, że rzędy macierzy L i U od pierwszego do k-tego zostały już skonstruowane. Skoro $j < k$, to wszystkie współczynniki macierzy U zostały już określone.

W sposób podobny pod warunkiem $l_{jj} \equiv 1$ można obliczyć u_{kj}

$$u_{kj} = a_{kj} - \sum_{i=1}^{k-1} l_{ki} u_{ij} \quad \text{gdy} \quad a_{kj} \neq 0,$$

Teraz dla $i > k$ elementy dolnej trójkątnej macierzy L są równe zeru.

W przypadku gdy $a_{kj} = 0$ mamy $u_{kj} = 0$

Algorytm ILU

Dla $k = \overline{1, n}$

 Dla $j = \overline{1, k-1}$

 Jeżeli $(k, j) \notin P_A$
 to $l_{kj} := 0$

 inaczej $l_{kj} := \frac{1}{u_{jj}} \left(a_{kj} - \sum_{i=1}^{j-1} l_{ki} u_{ij} \right)$

 zwiększ j

$l_{kk} := 1$

 Dla $j = \overline{k, n}$

 Jeżeli $(k, j) \notin P_A$
 to $u_{kj} := 0$

 inaczej $u_{kj} := a_{kj} - \sum_{i=1}^{k-1} l_{ki} u_{ij}$

 zwiększ j

zwiększ k

Przykład

$$A = \begin{pmatrix} 9 & 0 & 0 & 3 & 1 & 0 & 1 \\ 0 & 11 & 2 & 1 & 0 & 0 & 2 \\ 0 & 1 & 10 & 2 & 0 & 0 & 0 \\ 2 & 1 & 2 & 9 & 1 & 0 & 0 \\ 1 & 0 & 0 & 1 & 12 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 & 8 & 0 \\ 2 & 2 & 0 & 0 & 3 & 0 & 8 \end{pmatrix}$$

$$P_A = \{(1,1), (1,4), (1,5), (1,7), (2,2), \dots\}$$

Dla $k = \overline{1, n}$

Dla $j = \overline{1, k-1}$

Jeżeli $(k, j) \notin P_A$
to $l_{kj} := 0$

inaczej $l_{kj} := \frac{1}{u_{jj}} \left(a_{kj} - \sum_{i=1}^{j-1} l_{ki} u_{ij} \right)$

zwiększ j

$l_{kk} := 1$

Dla $j = \overline{k, n}$

Jeżeli $(k, j) \notin P_A$
to $u_{kj} := 0$

inaczej $u_{kj} := a_{kj} - \sum_{i=1}^{k-1} l_{ki} u_{ij}$

zwiększ j

zwiększ k

$k=1, j=0$

$l_{11}=1$

$j=1$

$(1,1) \in P_A$

$u_{11}=a_{11}=9$

$j=2$

$(1,2) \notin P_A$

$u_{12}=0$

...

$j=7$

$(1,7) \in P_A$

$u_{17}=a_{17}=1$

$k=2, j=1$

$(2,1) \notin P_A$

$l_{21}=0$

$l_{22}=1$

$j=2$

$(2,2) \in P_A$

$u_{22}=a_{22}-l_{11}*u_{12}=11-1*0=11$

...

Przykład

$$\mathbf{A} = \begin{pmatrix} 9 & 0 & 0 & 3 & 1 & 0 & 1 \\ 0 & 11 & 2 & 1 & 0 & 0 & 2 \\ 0 & 1 & 10 & 2 & 0 & 0 & 0 \\ 2 & 1 & 2 & 9 & 1 & 0 & 0 \\ 1 & 0 & 0 & 1 & 12 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 & 8 & 0 \\ 2 & 2 & 0 & 0 & 3 & 0 & 8 \end{pmatrix}$$

$$\mathbf{L} = \begin{pmatrix} 1 & & & & & & \\ 0 & 1 & & & & & \\ 0 & 0.091 & 1 & & & & \\ 0.222 & 0.091 & 0.185 & 1 & & & \\ 0.111 & 0 & 0 & 0.085 & 1 & & \\ 0 & 0 & 0 & 0 & 0 & 1 & \\ 0.222 & 0.182 & 0 & 0 & 0.235 & 0 & 1 \end{pmatrix};$$

$$\mathbf{U} = \begin{pmatrix} 9 & 0 & 0 & 3 & 1 & 0 & 1 \\ & 11 & 2 & 1 & 0 & 0 & 2 \\ & & 9.818 & 1.909 & 0 & 0 & 0 \\ & & & 7.889 & 0.778 & 0 & 0 \\ & & & & 11.823 & 0 & 0.889 \\ & & & & & 8 & 0 \\ & & & & & & 7.205 \end{pmatrix}.$$

$$\mathbf{R} = \mathbf{A} - \mathbf{LU} = \begin{pmatrix} 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & -0.182 \\ 0 & 0 & 0 & 0 & 0 & 0 & -0.404 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & -0.364 & -0.848 & 0 & 0 & 0 \end{pmatrix}.$$

Sparse w Matlabie

`S=sparse(A);`

`nnz(A)=25`

Number of nonzero matrix elements.

7x7 sparse double

val =

(1,1)	9
(4,1)	2
(5,1)	1
(7,1)	2
(2,2)	11
(3,2)	1
(4,2)	1
(7,2)	2
(2,3)	2
(3,3)	10
(4,3)	2
(1,4)	3
(2,4)	1
(3,4)	2
(4,4)	0

`[L,U,P] = ilu(S);`

permutation matrix P

S x L x 7x7 sparse double

val =

(1,1)	1.0000
(4,1)	0.2222
(5,1)	0.1111
(7,1)	0.2222
(2,2)	1.0000
(3,2)	0.0909
(4,2)	0.0909
(7,2)	0.1818
(3,3)	1.0000
(4,3)	0.1852
(4,4)	1.0000
(5,4)	0.0845
(5,5)	1.0000
(7,5)	0.2349
(6,6)	1.0000
(7,7)	1.0000

S x L x U x 7x7 sparse double

val =

(1,1)	9.0000
(2,2)	11.0000
(2,3)	2.0000
(3,3)	9.8182
(1,4)	3.0000
(2,4)	1.0000
(3,4)	1.9091
(4,4)	7.8889
(1,5)	1.0000
(4,5)	0.7778
(5,5)	11.8232
(6,6)	8.0000
(1,7)	1.0000
(2,7)	2.0000
(5,7)	0.8889
(7,7)	7.2053

S x L x U x P x 7x7 sparse double

val =

(1,1)	1
(2,2)	1
(3,3)	1
(4,4)	1
(5,5)	1
(6,6)	1
(7,7)	1

Sparse to Full

```
Lf=full(L);
Uf=full(U);
Pf=full(P);
R=A-Lf*Uf;
Af=Lf*Uf;
```

$$A = \begin{pmatrix} 9 & 0 & 0 & 3 & 1 & 0 & 1 \\ 0 & 11 & 2 & 1 & 0 & 0 & 2 \\ 0 & 1 & 10 & 2 & 0 & 0 & 0 \\ 2 & 1 & 2 & 9 & 1 & 0 & 0 \\ 1 & 0 & 0 & 1 & 12 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 & 8 & 0 \\ 2 & 2 & 0 & 0 & 3 & 0 & 8 \end{pmatrix}$$

	1	2	3	4	5	6	7
1	1	0	0	0	0	0	0
2	0	1	0	0	0	0	0
3	0	0.0909	1	0	0	0	0
4	0.2222	0.0909	0.1852	1	0	0	0
5	0.1111	0	0	0.0845	1	0	0
6	0	0	0	0	0	1	0
7	0.2222	0.1818	0	0	0.2349	0	1

	1	2	3	4	5	6	7
1	9	0	0	3	1	0	1
2	0	11	2	1	0	0	2
3	0	1	10	2	0	0	0.1818
4	2	1	2	9	1	0	0.4040
5	1	0	0	1	12	0	1
6	0	0	0	0	0	8	0
7	2	2	0.3636	0.8485	3	0	8


	1	2	3	4	5	6	7
1	9	0	0	3	1	0	1
2	0	11	2	1	0	0	2
3	0	0	9.8182	1.9091	0	0	0
4	0	0	0	7.8889	0.7778	0	0
5	0	0	0	0	11.8232	0	0.8889
6	0	0	0	0	0	8	0
7	0	0	0	0	0	0	7.2053

	1	2	3	4	5	6	7
1	0	0	0	0	0	0	0
2	0	0	0	0	0	0	0
3	0	0	0	0	0	0	-0.1818
4	0	0	0	0	0	0	-0.4040
5	0	0	0	0	0	0	0
6	0	0	0	0	0	0	0
7	0	0	-0.3636	-0.8485	0	0	0

	1	2	3	4	5	6	7
1	1	0	0	0	0	0	0
2	0	1	0	0	0	0	0
3	0	0	1	0	0	0	0
4	0	0	0	1	0	0	0
5	0	0	0	0	1	0	0
6	0	0	0	0	0	1	0
7	0	0	0	0	0	0	1

Matlab

spy(A)



Realizacja algorytmu ILU

```
iluAm x ILIOS.m x +
1 clear all;
2 PA=[1 1;1 2;2 1;2 2;2 3;3 1;3 3];
3 A=[1 1 0;2 1 3;0 0 8];
4 %A=[9 0 0 3 1 0 1;0 11 2 1 0 0 2;0 1 10 2 0 0 0; 2 1 2 9 1
5 %PA=[1 1;1 4;1 5;1 7;2 2;2 3;2 4;2 7;3 2 ;3 3;3 4;4 1; 4 2
6 n=3;
7 %n=7;
8 %U(1,1)=A(1,1);
9 %L=eye(n,n);
10
11 for k=1:n
12     for j=1:k-1
13         if isempty(findrow(num2str([k j]),num2str(PA)))
14             L(k,j)=0;
15         else
16             s=0;
17             for i=1:j-1
18                 s=L(k,i)*U(i,j);
19             end;
20             L(k,j)=1/U(j,j)*(A(k,j)-s);
21         end;%if
22     end;%j
23     L(k,k)=1;
24     for j=k:n
25         if isempty(findrow(num2str([k j]),num2str(PA)))
26             U(k,j)=0;
27         else
28             s=0;
29             for i=1:k-1
30                 s=L(k,i)*U(i,j);
31             end;
32             U(k,j)=A(k,j)-s;
33         end;%if
34     end;%j
35
36 Uend;%k
```

← $(k, j) \notin P_A$

Przypadek symetrycznej macierzy

$$\mathbf{A} = \mathbf{L}\mathbf{U}$$

$$\mathbf{A} = \mathbf{A}^T \quad \longrightarrow \quad \mathbf{L} = \mathbf{U}^T$$

$$\mathbf{A} = \mathbf{L}\mathbf{L}^T + \mathbf{R} = \mathbf{U}^T\mathbf{U} + \mathbf{R}$$

lub

$$\mathbf{A} = \mathbf{L}\mathbf{D}\mathbf{L}^T + \mathbf{R}$$

Algorytm

Dla $k = \overline{1, n}$
Dla $j = \overline{1, k-1}$
Jeżeli $(k, j) \notin P_A$
to $l_{kj} := 0$
inaczej $l_{kj} := \frac{1}{d_j} \left(a_{kj} - \sum_{i=1}^{j-1} d_i l_{ik} l_{jk} \right)$
zwiększ j
 $d_k := a_{kk} - \sum_{i=1}^{k-1} l_{ki}^2 d_i^2$
zwiększ k

Przykład


$$\mathbf{A} = \begin{pmatrix} 9 & 0 & 3 & 0 \\ 0 & 8 & 0 & 1 \\ 3 & 0 & 11 & 1 \\ 0 & 1 & 1 & 9 \end{pmatrix}$$

$$\mathbf{L} = \begin{pmatrix} 1 & & & \\ 0 & 1 & & \\ 0.333 & 0 & 1 & \\ 0 & 0.125 & 0.091 & 1 \end{pmatrix}; \quad \mathbf{D} = \text{diag}(9, 8, 11, 8.784) .$$


$$R=0$$

Zastosowania


Rozciąganie pręta



Ugięcie belki




Zginanie cienkiej płyty



Pręt rozciągany

Rozważmy pręt o powierzchni przekroju poprzecznego $A(x)$ i długości L . Pręt zrobiony jest z materiału o module Younga E . Pręt jest obciążony obciążeniem ciągłym działającym wzdłuż osi pręta o intensywności $q(x)$ i siłą skupioną P .



$N(x)$ i $N(x) + dN(x)$ są **siłami normalnymi** działającymi w przekrojach $A(x)$ i $A(x + dx)$. Korzystając z **warunku równowagi** możemy zapisać

$$-N(x) + N(x) + dN(x) + q(x)dx = 0.$$

Siłę **normalną** (podłużną) stanowi suma **naprężeń normalnych**

$$N(x) = \sigma_x(x)A(x).$$

Wykorzystując **równanie fizyczne** (konstrytywne, Hooke'a) określające zależność odkształcenia od naprężenia

$$\sigma_x(x) = E\varepsilon_x(x),$$

i **równanie geometryczne** (Cauchy'ego) wiążące ze sobą przemieszczenia i odkształcenia

$$\varepsilon_x(x) = \frac{du(x)}{dx},$$

$$EA \frac{d^2 u(x)}{dx^2} + q(x) = 0,$$

$$0 < x < L.$$

$$u(x = 0) = 0$$

$u(x)$ – przemieszczenie punkowe

Metoda różnic skończonych

Co to jest MRS?

Metoda różnic skończonych (MRS) jest przybliżoną metodą dyskretnego rozwiązywania problemów brzegowych, opisywanych zwyczajnymi lub cząstkowymi równaniami różniczkowymi.

Idea metody polega na zamianie **operatorów różniczkowych** na odpowiednie **operatory różnicowe** (ilorazy różnicowe), określone na dyskretnym i regularnym zbiorze punktów, zwanych **siatką**.

Metoda różnic skończonych

Metodę różnic skończonych zastosujemy do rozwiązania równania

$$\frac{d^2 u}{dx^2} = f(x, y)$$

W pierwszym kroku zamienimy operatory różniczkowe na odpowiednie operatory różnicowe, wykorzystamy szereg Taylora dla funkcji $u(x, y)$ w otoczeniu $u(x + h, y)$ i $u(x - h, y)$

$$u(x + h, y) = u(x, y) + \frac{du(x, y)}{dx}h + \frac{1}{2} \frac{d^2 u(x, y)}{dx^2}h^2 + \frac{1}{6} \frac{d^3 u(x, y)}{dx^3}h^3 + \dots,$$

$$u(x - h, y) = u(x, y) - \frac{du(x, y)}{dx}h + \frac{1}{2} \frac{d^2 u(x, y)}{dx^2}h^2 - \frac{1}{6} \frac{d^3 u(x, y)}{dx^3}h^3 + \dots$$

Metoda różnic skończonych

Odejmując stronami i pomijając wyrazy z h^2 i wyższe otrzymamy

$$\frac{du(x, y)}{dx} \approx \frac{1}{2h} [u(x + h, y) - u(x - h, y)].$$

Powyższą zależność nazywa się **wzorem różnicowym centralnym pierwszego rzędu**.

W przypadku sumowania stronami rozwinięć w szereg Taylora i po pominięci wyrazów z h^3 i wyższych, otrzymamy

$$\frac{d^2 u(x, y)}{dx^2} \approx \frac{1}{h^2} [u(x + h, y) - 2u(x, y) + u(x - h, y)].$$

Powyższe zależności nazywają się **wzorami różnicowymi drugiego rzędu**.

Metoda różnic skończonych


Podstawiając wzory różnicowe do wyjściowego równania, otrzymamy

$$u(x + h, y) - 2u(x, y) + u(x - h, y) = f(x, y),$$

lub


$$u(x_{i+1}, y_j) - 2u(x_i, y_j) + u(x_{i-1}, y_j) = f(x_i, y_j).$$

Na rysunku poniżej znajduje się punkty występujące we wzorach różnicowych, tworzące tzw. **gwiazdę różnicową**.




Metoda różnic skończonych

- sztywność pręta $EA = 1$,
- obciążenie $q(x) = x$,
- długość pręta $L = 1$,



Do dalszych obliczeń, przyjmijmy siatkę 6-węzłową, zatem odległość między węzłami wynosi $h = 0,2$.



$u(x)$ – przemieszczenie punkowe

Metoda różnic skończonych

Zapiszmy układ równań MRS

- węzeł 1: $u_1 = 0$, podstawowy warunek brzegowy,
- węzeł 2: $\frac{u_1 - 2u_2 + u_3}{(0, 2)^2} = -0, 2$, iloraz różnicowy centralny,
- węzeł 3: $\frac{u_2 - 2u_3 + u_4}{(0, 2)^2} = -0, 4$, iloraz różnicowy centralny,
- węzeł 4: $\frac{u_3 - 2u_4 + u_5}{(0, 2)^2} = -0, 6$, iloraz różnicowy centralny,
- węzeł 5: $\frac{u_4 - 2u_5 + u_6}{(0, 2)^2} = -0, 8$, iloraz różnicowy centralny,
- węzeł 6: $\frac{u_6 - u_5}{0, 2} = 0$, naturalny warunek brzegowy, iloraz różnicowy wstecz.

$u(x)$ – przemieszczenie punkowe

Metoda różnic skończonych

Po prostych przekształceniach otrzymamy układ równań

$$\begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 1 & -2 & 1 & 0 & 0 & 0 \\ 0 & 1 & -2 & 1 & 0 & 0 \\ 0 & 0 & 1 & -2 & 1 & 0 \\ 0 & 0 & 0 & 1 & -2 & 1 \\ 0 & 0 & 0 & 0 & 1 & 1 \end{bmatrix} \begin{bmatrix} u_1 \\ u_2 \\ u_3 \\ u_4 \\ u_5 \\ u_6 \end{bmatrix} = \begin{bmatrix} 0 \\ 1 \\ -\frac{1}{125} \\ 2 \\ -\frac{1}{125} \\ 3 \\ -\frac{1}{125} \\ 4 \\ -\frac{1}{125} \\ 0 \end{bmatrix},$$


a jego rozwiązanie wynosi

$$u_1 = 0, \quad u_2 = \frac{55}{750}, \quad u_3 = \frac{104}{750}, \quad u_4 = \frac{156}{750}, \quad u_5 = \frac{180}{750}, \quad u_6 = \frac{180}{750}.$$

A						
6x6 double						
	1	2	3	4	5	6
1	1	0	0	0	0	0
2	1	-2	1	0	0	0
3	0	1	-2	1	0	0
4	0	0	1	-2	1	0
5	0	0	0	1	-2	1
6	0	0	0	0	1	1

```
>> nnz(A)= 15
As=sparse(A)
```

Spy(A)



As						
6x6 sparse double						
val =						
(1,1)	1					
(2,1)	1					
(2,2)	-2					
(3,2)	1					
(2,3)	1					
(3,3)	-2					
(4,3)	1					
(3,4)	1					
(4,4)	-2					
(5,4)	1					
(4,5)	1					
(5,5)	-2					
(6,5)	1					
(5,6)	1					
(6,6)	1					

[L U P]=ilu(As)

```
>> [L U P]=lu(As)

L =

(1,1) 1.0000
(2,1) 1.0000
(2,2) 1.0000
(3,2) -0.5000
(3,3) 1.0000
(4,3) -0.6667
(4,4) 1.0000
(5,4) -0.7500
(5,5) 1.0000
(6,5) -0.8000
(6,6) 1.0000
```

```
U =

(1,1) 1.0000
(2,2) -2.0000
(2,3) 1.0000
(3,3) -1.5000
(3,4) 1.0000
(4,4) -1.3333
(4,5) 1.0000
(5,5) -1.2500
(5,6) 1.0000
(6,6) 1.8000
```

```
P =

(1,1) 1
(2,2) 1
(3,3) 1
(4,4) 1
(5,5) 1
(6,6) 1
```

```
>> full(L*U)
```

```
ans =

1 0 0 0 0 0
1 -2 1 0 0 0
0 1 -2 1 0 0
0 0 1 -2 1 0
0 0 0 1 -2 1
0 0 0 0 1 1
```

```
b=[0 -1/125 -2/125 -3/125 -4/125 0];
```

```
>> A^-1*b'
```

```
ans =

0
0.0267
0.0453
0.0480
0.0267
-0.0267
```

```
>> [L U P]=ilu(As);
```

```
>> y=U^-1*b';
```

```
x=L^-1*y;
```

```
>> x
```

```
x =

0
0.0217
0.0463
0.0681
0.0767
0.0613
```

Metody bezpośrednie a metody iteracyjne

$$Ax = b$$

$$A = LU$$

$$LUx = b$$

$$Ax = b \quad \longleftrightarrow \quad x = Gx + c$$

?

$$x_{k+1} = Gx_k + c$$

bezpośrednie

metody które przy braku błędów zaokrągleń dają dokładne rozwiązanie po skończonej liczbie przekształceń układu wejściowego

- duża efektywność dla układów o macierzach pełnych
- duże obciążenie pamięci
- możliwa niestabilność ze względu na błędy zaokrągleń i wskaźnika uwarunkowania

iteracyjne

polegają na konstrukcji nieskończonego ciągu wektorów, zbieżnych do szukanego rozwiązania, $x(0) \rightarrow x(1) \rightarrow x(2) \rightarrow \dots$

- efektywne dla macierzy rzadkich, dużych rozmiarów
- stosunkowo nieduże obciążenie pamięci
- problemy ze zbieżnością

Przykład


$$Ax = b \quad \longleftrightarrow \quad x = Gx + c$$
$$x_{k+1} = Gx_k + c$$

$$1.1x = 3.3$$

$$x = -0.1x + 3.3$$

$$x_{k+1} = -0.1x_k + 3.3$$

```
%1.1x=3.3  
%x=-0.1x+3.3  
x=10;  
out=[];  
for i=1:100  
    out=[out;x];  
    x=-0.1*x+3.3;  
end;  
plot(out);
```



Przykład 2

```
A=[1.1 0.2;0.3 1.2]
```

A =

```
1.1000  0.2000
0.3000  1.2000
```

```
>> G=[-0.1 -0.2;-0.3 -0.2]
```

G =

```
-0.1000 -0.2000
-0.3000 -0.2000
```

```
>> I-G
```

ans =

```
1.1000  0.2000
0.3000  1.2000
```

$$Ax = b \quad \longleftrightarrow \quad x = Gx + c$$


?

$$x_{k+1} = Gx_k + c$$

```
b=[5 6]'
```

b =

```
5
6
```



```
x=[1 1]';
Out=x';
for i=1:10
    x=G*x+b;
    Out=[Out;x'];
end;
plot(Out(:,1),'r-');
hold on;
plot(Out(:,2),'b-');
```

Metody iteracyjne

$$\begin{array}{l} Ax = b \\ A = LU \\ LUx = b \end{array}$$

$$Ax = b \longleftrightarrow x = Gx + c$$

$$x_{k+1} = Gx_k + c$$

Warunek zbieżności: **Promień spektralny** $\rho(G) < 1$

Największa co do modułu
wartość własna macierzy.

$$A = M - N \Rightarrow \mathbf{M}x = Nx + b$$

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

$$G = M^{-1}N$$

$$c = M^{-1}b$$

$$x_{k+1} = M^{-1}Nx_k + M^{-1}b$$

$$Mx_{k+1} = Nx_k + b$$

Metody iteracyjne stosowane są głównie do rozwiązywania układów o **dużej liczbie równań** i niewiadomych (nawet rzędu milionów)

Metoda Jakobiego

$$Ax = b$$

$$A = M - N$$

Dodatkowe warunki

$$M = D, \quad N = -(L + U)$$

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

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

$$\mathbf{x} = M^{-1}N\mathbf{x} + M^{-1}\mathbf{b}$$

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

$$N = \begin{bmatrix} 0 & a_{12} & \cdots & a_{1n} \\ a_{21} & 0 & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & \cdots & 0 \end{bmatrix}$$

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

Dostateczny warunek zbieżności:
Macierz dominująca


$$|a_{ii}| > \sum_{j \neq i} |a_{ij}|$$

Macierz dominująca to macierz, której wartości bezwzględne elementów na głównej przekątnej są większe od **sumy wartości** bezwzględnych pozostałych elementów w wierszach

Przykład

```
%jakobi 2 x 2
A=[10 1;1 9];b=[2 3]';
%A^-1*b
%0.1685
% 0.3146
%[L D]=ldl(A);
D=[A(1,1) 0;0 A(2,2)];
U=[0 A(1,2);0 0];
L=[0 0;A(2,1) 0];

U=L';
M=D;
N=-(L+U);
Out=[];
x=[1 1]';
Out=x;
line([0 x(1)], [0 x(2)], 'Color', 'red', 'LineStyle', '--');
hold on;
for i=1:5
    x=M^-1*(b+N*x);
    line([0 x(1)], [0 x(2)], 'Color', 'red', 'LineStyle', '--');
    Out=[Out,x];
end;
```



Out =

1.0000	0.1000	0.1778	0.1678	0.1686	0.1685
1.0000	0.2222	0.3222	0.3136	0.3147	0.3146

Algorytm

Choose an initial guess $x^{(0)}$ to the solution

$k = 0$

while convergence not reached do

for $i := 1$ step until n do

$\sigma = 0$

for $j := 1$ step until n do

if $j \neq i$ then

$$\sigma = \sigma + a_{ij}x_j^{(k)}$$

end if

end (j-loop)

$$x_i^{(k+1)} = \frac{(b_i - \sigma)}{a_{ii}}$$

end (i-loop)

check if convergence is reached

$k = k + 1$

loop (while convergence condition not reached)

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

Przykład

$$\begin{array}{rrcr} 4x_1 & - & x_2 & - & x_3 & = & 3 \\ -2x_1 & + & 6x_2 & + & x_3 & = & 9 \\ -x_1 & + & x_2 & + & 7x_3 & = & -6 \end{array}$$

$$\begin{array}{rrcr} 4x_1^{(k+1)} & - & x_2^{(k)} & - & x_3^{(k)} & = & 3 \\ -2x_1^{(k)} & + & 6x_2^{(k+1)} & + & x_3^{(k)} & = & 9 \\ -x_1^{(k)} & + & x_2^{(k)} & + & 7x_3^{(k+1)} & = & -6 \end{array}$$

$$\mathbf{x}^{(0)} = (0, 0, 0).$$

$$\begin{array}{rrcr} 4x_1^{(1)} & - & 0 & - & 0 & = & 3 \\ -2 \cdot 0 & + & 6x_2^{(1)} & + & 0 & = & 9 \\ -0 & + & 0 & + & 7x_3^{(1)} & = & -6 \end{array}$$

$$\mathbf{x}^{(1)} = (x_1^{(1)}, x_2^{(1)}, x_3^{(1)}) = (3/4, 9/6, -6/7) \approx (0.750, 1.500, -0.857)$$

Ocena błędów

k	$x^{(k)}$			$x^{(k)} - x^{(k-1)}$			$e^{(k)} = x - x^{(k)}$			$\ e^{(k)}\ $
0	0.000	0.000	0.000	-	-	-	0.000	0.000	-1.000	2.449
1	0.750	1.500	-0.857	0.000	0.000	-0.857	0.250	0.500	-0.143	0.557
2	0.911	1.893	-0.964	0.161	0.393	-0.107	0.089	0.107	-0.036	0.144
3	0.982	1.964	-0.997	0.071	0.071	-0.033	0.018	0.036	-0.003	0.040
4	0.992	1.994	-0.997	0.010	0.029	0.000	0.008	0.006	-0.003	0.011
5	0.999	1.997	-1.000	0.007	0.003	-0.003	0.001	0.003	0.000	0.003
6	0.999	2.000	-1.000	0.000	0.003	0.001	0.000	0.001	0.000	0.001
7	1.000	2.000	-1.000	0.001	0.000	0.000	0.000	0.000	0.000	0.000
8	1.000	2.000	-1.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000



Zadanie

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

$$A = \begin{bmatrix} 2 & 1 \\ 5 & 7 \end{bmatrix}, \quad b = \begin{bmatrix} 11 \\ 13 \end{bmatrix}$$

$$x^{(0)} = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$$

Obliczyć 2 iteracji przez metodę Jakobiego

$$\begin{bmatrix} a_{1,1} & a_{1,2} & \dots & a_{1,n} \\ a_{2,1} & a_{2,2} & \dots & a_{2,n} \\ \dots & \dots & \dots & \dots \\ a_{n,1} & a_{n,2} & \dots & a_{n,n} \end{bmatrix} = \begin{bmatrix} 0 & 0 & \dots & 0 \\ a_{2,1} & 0 & \dots & 0 \\ \dots & \dots & \dots & \dots \\ a_{n,1} & a_{n,2} & \dots & 0 \end{bmatrix} + \begin{bmatrix} a_{1,1} & 0 & \dots & 0 \\ 0 & a_{2,2} & \dots & 0 \\ \dots & \dots & \dots & \dots \\ 0 & 0 & \dots & a_{n,n} \end{bmatrix} + \begin{bmatrix} 0 & a_{1,2} & \dots & a_{1,n} \\ 0 & 0 & \dots & a_{2,n} \\ \dots & \dots & \dots & \dots \\ 0 & 0 & \dots & 0 \end{bmatrix}$$

Rozwiązanie

$$D^{-1} = \begin{bmatrix} 1/2 & 0 \\ 0 & 1/7 \end{bmatrix}, \quad L = \begin{bmatrix} 0 & 0 \\ 5 & 0 \end{bmatrix} \quad \text{and} \quad U = \begin{bmatrix} 0 & 1 \\ 0 & 0 \end{bmatrix}.$$

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

Przykład

```
A=[10 2 3;1 8 4;1 2 7];  
D=[10 0 0;0 8 0;0 0 7];  
L=[0 0 0;1 0 0;1 2 0];  
U=[0 2 3;0 0 4;0 0 0];  
b=[6 7 8]';  
  
%metoda bezposrednia  
%ldl - dla macierzy symetrycznej  
%lu(A) - funkcja inv(A)  
%help inv  
%help \ - A\b  
  
x=inv(A)*b;  
x1=A\b;  
  
%metoda iteracyjna  
x=[1 1 1]';  
x=inv(D)*(b-(L+U)*x)
```

Metoda Gauss-Seidla

$$Ax = b$$

$$A = M - N$$

$$Mx = Nx + b$$

Metoda Jakobiego

$$Mx_{k+1} = Nx_k + b$$

$$M = D, \quad N = -(L + U)$$

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

Niech teraz $M = D + L, \quad N = -U$

$$Dx_{k+1} = -Lx_{k+1} - Ux_k + b$$

$$(D+L)x_{k+1} = -Ux_k + b$$

$$x^{(k+1)} = D^{-1}(b - Lx^{(k+1)} - Ux^{(k)})$$


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

Dostateczny warunek zbieżności:
Macierz dominująca

$$|a_{ii}| \geq \sum_{j \neq i} |a_{ij}|$$

Przykład

```
%gauss seidel 2 x 2
A=[10 1;1 9];b=[2 3]';
%A^-1*b
%0.1685
% 0.3146
%[L D]=ldl(A);
D=[A(1,1) 0;0 A(2,2)];
U=[0 A(1,2);0 0];
L=[0 0;A(2,1) 0];
U=L';
M=D;
N=-(L+U);
Out=[];
x=[1 1]';
Out=x;
line([0 x(1)], [0 x(2)], 'Color', 'red', 'LineStyle', '--');
hold on;
for i=1:5
    x=(D+L)^-1*(b-U*x);
    line([0 x(1)], [0 x(2)], 'Color', 'red', 'LineStyle', '--');
    Out=[Out,x];
end;
```



GS

Out =

1.0000	0.1000	0.1678	0.1685	0.1685	0.1685
1.0000	0.3222	0.3147	0.3146	0.3146	0.3146

Out =

Jakobi

1.0000	0.1000	0.1778	0.1678	0.1686	0.1685
1.0000	0.2222	0.3222	0.3136	0.3147	0.3146

Algorytm

Wybierz początkowe przybliżenie $\mathbf{x}^{(0)}$

for $k := 1$ **step** 1 **until** oczekiwane przybliżenie **do**

for $i := 1$ **step** 1 **until** n **do**

$\sigma = 0$

for $j := 1$ **step** 1 **until** $i-1$ **do**

$\sigma = \sigma + a_{ij}x_j^{(k)}$

end (j-for)

for $j := i+1$ **step** 1 **until** n **do**

$\sigma = \sigma + a_{ij}x_j^{(k-1)}$

end (j-for)

$x_i^{(k)} = \frac{(b_i - \sigma)}{a_{ii}}$

end (i-for)

 sprawdź, czy osiągnięto oczekiwane przybliżenie

end (k-for)

$\mathbf{x} \approx \mathbf{x}^{(k)}$

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


Metoda Gauss-Seidla (cd.)

1 krok

2 krok

...

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

$$\begin{bmatrix} a_{11} & 0 & \dots & 0 \\ a_{21} & a_{22} & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ a_{n1} & \dots & a_{nn-1} & a_{nn} \end{bmatrix} \begin{bmatrix} x_1^{(k+1)} \\ x_2^{(k+1)} \\ \vdots \\ x_n^{(k+1)} \end{bmatrix} + \begin{bmatrix} 0 & a_{12} & \dots & a_{1n} \\ 0 & 0 & \ddots & \vdots \\ \vdots & \ddots & \ddots & a_{n-1,n} \\ 0 & \dots & 0 & 0 \end{bmatrix} \begin{bmatrix} x_1^{(k)} \\ x_2^{(k)} \\ \vdots \\ x_n^{(k)} \end{bmatrix} = \begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_n \end{bmatrix}.$$

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

$$x^{(k+1)} = (L + D)^{-1}[-Ux^{(k)} + b].$$

Przykład

$$\begin{array}{rrcrcl} 4x_1 & - & x_2 & - & x_3 & = & 3 \\ -2x_1 & + & 6x_2 & + & x_3 & = & 9 \\ -x_1 & + & x_2 & + & 7x_3 & = & -6 \end{array}$$

$$\begin{array}{rrcrcl} 4x_1^{(k+1)} & - & x_2^{(k)} & - & x_3^{(k)} & = & 3 \\ -2\downarrow x_1^{(k+1)} & + & 6x_2^{(k+1)} & + & x_3^{(k)} & = & 9 \\ -\downarrow x_1^{(k+1)} & + & \downarrow x_2^{(k+1)} & + & 7x_3^{(k+1)} & = & -6 \end{array}$$

$$\mathbf{x}^{(0)} = (0, 0, 0).$$

$$\begin{array}{rrcrcl} 4x_1^{(1)} & - & 0 & - & 0 & = & 3 \\ -2x_1^{(1)} & + & 6x_2^{(1)} & + & 0 & = & 9 \\ -x_1^{(1)} & + & x_2^{(1)} & + & 7x_3^{(1)} & = & -6 \end{array}$$

$$x_1^{(1)} = 3/4 = 0.750.$$

$$x_2^{(1)} = [9 + 2(0.750)] / 6 = 1.750$$

$$x_3^{(1)} = [-6 + 0.750 - 1.750] / 7 = -1.000$$

$$\mathbf{x}^{(1)} = (x_1(1), x_2(1), x_3(1)) = (0.750, 1.750, -1.000)$$

Ocena błędów

k	$x^{(k)}$		$x^{(k)} - x^{(k-1)}$			$e^{(k)} = x - x^{(k)}$			$\ e^{(k)}\ $	
0	0.000	0.000	0.000	-	-	-	0.000	0.000	-1.000	2.449
1	0.750	1.750	-1.000	0.000	0.000	-1.000	0.250	0.250	0.000	0.354
2	0.938	1.979	-1.006	0.188	0.229	-0.006	0.063	0.021	0.006	0.066
3	0.993	1.999	-1.001	0.056	0.020	0.005	0.007	0.001	0.001	0.007
4	0.999	2.000	-1.000	0.006	0.001	0.001	0.001	0.000	0.000	0.001
5	1.000	2.000	-1.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000



Zadanie

Rozwiązać układ za pomocą metody Gauss-Seidla

$$\begin{cases} x_1 + 6x_2 + x_3 = 9 \\ 4x_1 - x_2 + x_3 = 4 \\ -x_1 + 2x_2 + 5x_3 = 2 \end{cases}$$

Rozwiązanie

$$\begin{array}{l} x_1 + 6x_2 + x_3 = 9 \\ 4x_1 - x_2 + x_3 = 4 \\ -x_1 + 2x_2 + 5x_3 = 2 \end{array} \quad \begin{array}{l} \nearrow \\ \searrow \\ \nearrow \\ \searrow \end{array} \quad \begin{array}{l} 4x_1 - x_2 + x_3 = 4 \\ x_1 + 6x_2 + x_3 = 9 \\ -x_1 + 2x_2 + 5x_3 = 2 \end{array}$$

Macierz dominująca

$$\begin{aligned} x_1 &= \frac{1}{4}(4 + x_2 - x_3) & x_2 = 0 \text{ i } x_3 = 0 \\ x_2 &= \frac{1}{6}(9 - x_1 - x_3) \\ x_3 &= \frac{1}{5}(2 + x_1 - 2x_2) \end{aligned}$$

$$\begin{aligned} x_1 &= \frac{1}{4}(4 + 0 - 0) = 1 \\ x_2 &= \frac{1}{6}(9 - \textcircled{1} - 0) = 4/3 \approx 1.333 \\ x_3 &= \frac{1}{5}(2 + \textcircled{1} - \textcircled{2} \times 4/3) = 1/15 \approx 0.0667 \\ x_1 &= \frac{1}{4}(4 + 4/3 - 1/15) = 79/60 \approx 1.317 \\ x_2 &= \frac{1}{6}(9 - 79/60 - 1/15) = 457/360 \approx 1.269 \\ x_3 &= \frac{1}{5}(2 + 79/60 - 2 \times 457/360) = 7/45 \approx 0.1556 \end{aligned}$$

$$x_1 = 23/18 \approx 1.278, x_2 = 53/42 \approx 1.262, x_3 = 19/126 \approx 0.1508$$

Zbieżność metod iteracyjnych

$$Ax = b$$

$$Mx^{(k+1)} = Nx^{(k)} + b$$

$$x^{(k+1)} = M^{-1}Nx^{(k)} + M^{-1}b$$

$$x^{(k+1)} = Bx^{(k)} + \tilde{b}$$

Dokładne rozwiązanie

$$x = Bx + \tilde{b}$$

$$B = M^{-1}N \text{ oraz } \tilde{b} = M^{-1}b$$

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

$$e^{(k)} = x - x^{(k)}$$

$$e^{(k)} = Be^{(k-1)} = B(Be^{(k-2)}) = B^2e^{(k-2)} = \dots = B^ke^{(0)}$$

$$\|B\| < 1$$

Porównywanie

Metoda Jakobiego

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

Metoda Gauss-Seidla

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

```
>> eig(M^-1*N)
```

```
ans =
```

```
0.1054
```

```
-0.1054
```

```
>> eig((D+L)^-1*U)
```

```
ans =
```

```
0
```

```
-0.0111
```

Porównywanie (cd.)

$$\mathbf{x}^{(k+1)} = B\mathbf{x}^{(k)} + \tilde{\mathbf{b}},$$

$$A = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix}$$

Method	B
Jacobi	$D^{-1}(-L-U) = \begin{bmatrix} a_{11} & 0 \\ 0 & a_{22} \end{bmatrix}^{-1} \begin{bmatrix} 0 & -a_{12} \\ -a_{21} & 0 \end{bmatrix} = \begin{bmatrix} 0 & -\frac{a_{12}}{a_{11}} \\ -\frac{a_{21}}{a_{22}} & 0 \end{bmatrix}$
GS	$(L+D)^{-1}(-U) = \begin{bmatrix} a_{11} & 0 \\ a_{21} & a_{22} \end{bmatrix}^{-1} \begin{bmatrix} 0 & -a_{12} \\ 0 & 0 \end{bmatrix} = \begin{bmatrix} 0 & -\frac{a_{12}}{a_{11}} \\ 0 & \frac{a_{12}a_{21}}{a_{11}a_{22}} \end{bmatrix}$

Method	Eigenvalues	Eigenvectors
Jacobi	$\lambda_1 = \sqrt{\frac{a_{12}a_{21}}{a_{11}a_{22}}}, \lambda_2 = -\sqrt{\frac{a_{12}a_{21}}{a_{11}a_{22}}}$	$\mathbf{v}_1 = \begin{bmatrix} 1 \\ -\sqrt{\frac{a_{11}a_{21}}{a_{12}a_{22}}} \end{bmatrix}, \mathbf{v}_2 = \begin{bmatrix} 1 \\ \sqrt{\frac{a_{11}a_{21}}{a_{12}a_{22}}} \end{bmatrix}$
GS	$\lambda_1 = 0, \lambda_2 = -\frac{a_{12}a_{21}}{a_{11}a_{22}}$	$\mathbf{v}_1 = \begin{bmatrix} 1 \\ 0 \end{bmatrix}, \mathbf{v}_2 = \begin{bmatrix} 1 \\ -\frac{a_{21}}{a_{22}} \end{bmatrix}$

$$||B_{GS}|| = ||B_{Jacobi}||^2$$

GS a SOR

1. Krytyka klasycznej metody Gaussa-Seidela

Metoda Gaussa-Seidela (GS) jest zbieżna dla macierzy diagonalnie dominujących lub symetrycznych dodatnio określonych, ale często **zbiega wolno**.

- **Problem:** W GS nowe przybliżenie $x^{(k+1)}$ jest całkowicie zastępowane przez wartość z aktualnej iteracji, co może prowadzić do "przesuwania się" rozwiązania małymi krokami.
 - **Rozwiązanie:** Wprowadzenie **kontrolowanego kroku relaksacji**, który przyspiesza lub spowalnia zmianę zmiennych.
-

2. Inspiracja: Metoda gradientu prostego

Metoda SOR jest analogią do **optymalnego doboru kroku w metodzie gradientu prostego**:

$$x^{(k+1)} = x^{(k)} + \alpha \cdot \text{kierunek poprawy}$$

- W SOR "kierunkiem poprawy" jest różnica między iteracją GS a poprzednim przybliżeniem:

$$\text{kierunek} = (x_{\text{GS}}^{(k+1)} - x^{(k)})$$

- Parametr ω pełni rolę **optymalnego kroku** α .

Metoda SOR (nad relaksacji)

Successive Overrelaxation (SOR)

Metoda Gaussa-Seidla

$$x^{(k+1)} = D^{-1} [b - Lx^{(k+1)} - Ux^{(k)}]$$

$$Dx^{(k+1)} = b - Lx^{(k+1)} - Ux^{(k)}$$

→ $x^{(k+1)} - x^{(k)} = D^{-1} [b - Lx^{(k+1)} - Dx^{(k)} - Ux^{(k)}]$

Korekcja:

Zbieżność metody Gaussa–Seidla można przyspieszyć, wprowadzając parametr relaksacji i kolejne współrzędne nowego przybliżenia wyznaczać, kombinując ze sobą poprzednie przybliżenie oraz współrzędną nowego przybliżenia uzyskanego metodą Gaussa–Seidla:

$$x^{(k+1)} = x^{(k)} + \omega \left(x^{(k+1)} - x^{(k)} \right)_{GS}$$

$$x_i^{(k+1)} = (1 - \omega)x_i^{(k)} + \omega \tilde{x}_i^{k+1}$$

$$1 < \omega < 2$$

Gdy $\omega=1$ mamy GS

$$\left(x^{(k+1)} - x^{(k)} \right)_{GS} = D^{-1} [b - Lx^{(k+1)} - Dx^{(k)} - Ux^{(k)}]$$

→ $x^{(k+1)} = x^{(k)} + \omega D^{-1} [b - Lx^{(k+1)} - Dx^{(k)} - Ux^{(k)}]$

Zbieżność

$$\frac{1}{\omega} D x^{(k+1)} = \frac{1}{\omega} D x^{(k)} + [b - L x^{(k+1)} - D x^{(k)} - U x^{(k)}]$$

$$\left(L + \frac{1}{\omega} D \right) x^{(k+1)} = \frac{1}{\omega} D x^{(k)} + [b - D x^{(k)} - U x^{(k)}] = \left(\frac{1}{\omega} D - D - U \right) x^{(k)} + b$$

$$x^{(k+1)} = \left(L + \frac{1}{\omega} D \right)^{-1} \left[\left(\frac{1}{\omega} D - D - U \right) x^{(k)} + b \right]$$

```
>> eig(M^-1*N)
```

```
ans =
```

```
0.1054
-0.1054
```

```
>> eig((D+L)^-1*U)
```

```
ans =
```

```
0
-0.0111
```

$$\left\| \left(L + \frac{1}{\omega} D \right)^{-1} \left(\frac{1}{\omega} D - D - U \right) \right\|$$

Jacobi $D^{-1}(-L-U)$

GS $(L+D)^{-1}(-U)$

```
>> w=1.01
```

```
w =
```

```
1.0100
```

```
>> eig((1/w*D+L)^-1*(1/w*D-D-U))
```

```
ans =
```

```
-0.0043 + 0.0090i
-0.0043 - 0.0090i
```

Przykład


```
%SOR 2 x 2
A=[10 1;1 9];b=[2 3]';
%A^-1*b
%0.1685
% 0.3146
%[L D]=ldl(A);
D=[A(1,1) 0;0 A(2,2)];
U=[0 A(1,2);0 0];
L=[0 0;A(2,1) 0];

U=L';
M=D;
N=-(L+U);
w=1.1;
Out=[];
x=[1 1]';
Out=x;
line([0 x(1)], [0 x(2)], 'Color', 'red', 'LineStyle', '--');
hold on;
for i=1:5
    x=(1/w*D+L)^-1*(b+(1/w*D-D-U)*x);

    line([0 x(1)], [0 x(2)], 'Color', 'red', 'LineStyle', '--');
    Out=[Out,x];
end;
```

Out =

1.0000	0.0100	0.1898	0.1662	0.1688	0.1685
1.0000	0.2654	0.3169	0.3147	0.3146	0.3146



Porównywanie

Metoda Jakobiego

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

Metoda Gauss-Seidla

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

Metoda SOR

$$x^{(k+1)} = \left(L + \frac{1}{\omega} D \right)^{-1} \left[\left(\frac{1}{\omega} D - D - U \right) x^{(k)} + b \right]$$

Tabela algorytmów iteracyjnych

Metoda Jakobiego

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

Metoda Gauss-Seidla

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

Metoda SOR

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

Zbieżność

$$\mathbf{x}^{(k+1)} = B\mathbf{x}^{(k)} + \tilde{\mathbf{b}},$$

$$A = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix}$$

Method B

Jacobi $D^{-1}(-L-U) = \begin{bmatrix} a_{11} & 0 \\ 0 & a_{22} \end{bmatrix}^{-1} \begin{bmatrix} 0 & -a_{12} \\ -a_{21} & 0 \end{bmatrix} = \begin{bmatrix} 0 & -\frac{a_{12}}{a_{11}} \\ -\frac{a_{21}}{a_{22}} & 0 \end{bmatrix}$

GS $(L+D)^{-1}(-U) = \begin{bmatrix} a_{11} & 0 \\ a_{21} & a_{22} \end{bmatrix}^{-1} \begin{bmatrix} 0 & -a_{12} \\ 0 & 0 \end{bmatrix} = \begin{bmatrix} 0 & -\frac{a_{12}}{a_{11}} \\ 0 & \frac{a_{12}a_{21}}{a_{11}a_{22}} \end{bmatrix}$

SOR

$$\left(L + \frac{1}{\omega}D\right)^{-1} \left(\frac{1}{\omega}D - D - U\right) =$$

$$\begin{array}{c} / \qquad \qquad \qquad a_{11} \qquad \qquad \qquad \backslash \\ | \qquad \qquad a_{11} - \frac{\quad}{\quad} \qquad \qquad \qquad | \\ | \qquad \qquad \qquad w \qquad \qquad \qquad a_{12} \qquad \qquad \qquad | \\ | \qquad \qquad \frac{\quad}{\quad}, \qquad \qquad \qquad \frac{\quad}{\quad} \qquad \qquad \qquad | \\ | \qquad \qquad \qquad a_{11} \qquad \qquad \qquad a_{11} \qquad \qquad \qquad | \\ | \qquad \qquad \qquad | \qquad \qquad \qquad | \\ | \qquad \qquad / \qquad \qquad a_{11} \backslash \qquad \qquad \qquad a_{22} \qquad \qquad \qquad | \\ | \quad a_{21} \quad | \quad a_{11} - \frac{\quad}{\quad} \quad | \qquad \qquad \qquad a_{22} - \frac{\quad}{\quad} \quad | \\ | \qquad \qquad \backslash \qquad \qquad w \quad / \quad a_{12} \quad a_{21} \qquad \qquad \qquad w \qquad \qquad \qquad | \\ | \qquad \qquad \frac{\quad}{\quad}, \qquad \qquad \qquad \frac{\quad}{\quad} \qquad \qquad \qquad | \\ \backslash \qquad \qquad a_{11} \quad a_{22} \qquad \qquad \qquad a_{11} \quad a_{22} \qquad \qquad \qquad a_{22} \qquad \qquad \qquad / \end{array}$$

```
syms a11 a21 a22 a12 w
D=[a11 0;0 a22]
L=[0 0;a21 0]
U=[0 a12; 0 0]
SOR=(L+D)^-1*(1/w*D-D-U)
simplify(SOR)
pretty(SOR)
[Vs Ls]=eig(SOR)
pretty(Ls)
pretty(Vs)
```

Przykład

$$\begin{cases} 4x_1 - x_2 = 2 \\ -x_1 + 4x_2 - x_3 = 6 \\ -x_2 + 4x_3 = 2 \end{cases}$$

$$\mathbf{x} = [1, 2, 1]$$

$$\mathbf{x}^{(1)} = \mathbf{0}$$

Przykład (cd.)

Metoda Jakobiego

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

$$\mathbf{x}^{(1)} = \mathbf{0}$$

$$\mathbf{x}^{(2)} = -\mathbf{D}^{-1}(\mathbf{L} + \mathbf{U})\tilde{\mathbf{x}}^{(1)} + \mathbf{D}^{-1}\mathbf{b} =$$

$$= -\begin{bmatrix} 1/4 & 0 & 0 \\ 0 & 1/4 & 0 \\ 0 & 0 & 1/4 \end{bmatrix} \begin{bmatrix} 0 & -1 & 0 \\ -1 & 0 & -1 \\ 0 & -1 & 0 \end{bmatrix} \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix} + \begin{bmatrix} 1/4 & 0 & 0 \\ 0 & 1/4 & 0 \\ 0 & 0 & 1/4 \end{bmatrix} \begin{bmatrix} 2 \\ 6 \\ 2 \end{bmatrix} = \begin{bmatrix} 0.5 \\ 1.5 \\ 0.5 \end{bmatrix},$$

$$\mathbf{x}^{(3)} = -\mathbf{D}^{-1}(\mathbf{L} + \mathbf{U})\mathbf{x}^{(2)} + \mathbf{D}^{-1}\mathbf{b} =$$

$$= -\begin{bmatrix} 1/4 & 0 & 0 \\ 0 & 1/4 & 0 \\ 0 & 0 & 1/4 \end{bmatrix} \begin{bmatrix} 0 & -1 & 0 \\ -1 & 0 & -1 \\ 0 & -1 & 0 \end{bmatrix} \begin{bmatrix} 1/2 \\ 3/2 \\ 1/2 \end{bmatrix} + \begin{bmatrix} 1/4 & 0 & 0 \\ 0 & 1/4 & 0 \\ 0 & 0 & 1/4 \end{bmatrix} \begin{bmatrix} 2 \\ 6 \\ 2 \end{bmatrix} = \begin{bmatrix} 0.875 \\ 1.75 \\ 0.875 \end{bmatrix},$$

$$\mathbf{x}^{(4)} = -\mathbf{D}^{-1}(\mathbf{L} + \mathbf{U})\mathbf{x}^{(3)} + \mathbf{D}^{-1}\mathbf{b} = [0.9375, 1.9375, 0.9375],$$

$$\mathbf{x}^{(5)} = -\mathbf{D}^{-1}(\mathbf{L} + \mathbf{U})\mathbf{x}^{(4)} + \mathbf{D}^{-1}\mathbf{b} = [0.9844, 1.9688, 0.9844].$$

Przykład (cd.)

Metoda Gaussa-Seidela

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

$$\mathbf{x}^{(1)} = \mathbf{0}$$

$$\mathbf{x}^{(2)} = -(\mathbf{D} + \mathbf{L})^{-1} \mathbf{U} \mathbf{x}^{(1)} + (\mathbf{D} + \mathbf{L})^{-1} \mathbf{b} = [0.5000, 1.6250, 0.9062],$$

$$\mathbf{x}^{(3)} = -(\mathbf{D} + \mathbf{L})^{-1} \mathbf{U} \mathbf{x}^{(2)} + (\mathbf{D} + \mathbf{L})^{-1} \mathbf{b} = [0.9062, 1.9531, 0.9883],$$

$$\mathbf{x}^{(4)} = -(\mathbf{D} + \mathbf{L})^{-1} \mathbf{U} \mathbf{x}^{(3)} + (\mathbf{D} + \mathbf{L})^{-1} \mathbf{b} = [0.9883, 1.9941, 0.9985],$$

$$\mathbf{x}^{(5)} = -(\mathbf{D} + \mathbf{L})^{-1} \mathbf{U} \mathbf{x}^{(4)} + (\mathbf{D} + \mathbf{L})^{-1} \mathbf{b} = [0.9885, 1.9993, 0.9998].$$

Przykład (cd.)

SOR

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

$\omega=1.2$ otrzymujemy kolejno:

$$\mathbf{x}^{(2)} = [0.6000, 1.9800, 1.1940],$$

$$\mathbf{x}^{(3)} = [1.0740, 2.0844, 0.9865],$$

$$\mathbf{x}^{(4)} = [1.0105, 1.9822, 0.9974],$$

$$\mathbf{x}^{(5)} = [0.9926, 2.0005, 1.0007],$$

natomiast dla $\omega=1.1$ mamy:


$$\mathbf{x}^{(2)} = [0.5500, 1.8013, 1.0453],$$

$$\mathbf{x}^{(3)} = [0.9903, 2.0297, 1.0036],$$

$$\mathbf{x}^{(4)} = [1.0091, 2.0005, 0.9998],$$

$$\mathbf{x}^{(5)} = [0.9998, 1.9997, 0.9999].$$

Iter2.m



Rozważmy prosty układ 2×2 :

$$\begin{cases} 4x + y = 7 \\ x + 3y = 5 \end{cases}$$

Macierz tego układu jest **diagonalnie dominująca**, więc zarówno Gauss-Seidel (GS), jak i SOR będą zbieżne.

Rozwiązanie dokładne (analityczne):

$$x = 1.6, \quad y = 1.1$$

Krok 1: Metoda Gaussa-Seidela (GS)

Wzory iteracyjne GS:

$$x^{(k+1)} = \frac{7 - y^{(k)}}{4}, \quad y^{(k+1)} = \frac{5 - x^{(k+1)}}{3}$$

Start: $x^{(0)} = 0, y^{(0)} = 0$

Wyniki po 5 iteracjach:

Iteracja (k)	$x^{(k)}$	$y^{(k)}$	Błąd ($\ x^{(k)} - 1.6\ $)
1	1.750	1.083	0.150
2	1.479	1.174	0.121
3	1.706	1.098	0.106
4	1.525	1.158	0.075
5	1.660	1.113	0.060

Zbieżność jest monotoniczna, ale wolna (błąd maleje liniowo).

Krok 2: Metoda SOR z różnymi ω

Wzór SOR dla x :

$$x^{(k+1)} = x^{(k)} + \omega \left(\frac{7 - y^{(k)}}{4} - x^{(k)} \right)$$

Analogicznie dla y .

Przypadek 1: Nadrelaksacja ($\omega = 1.2$)

Wyniki po 5 iteracjach:

Iteracja (k)	$x^{(k)}$	$y^{(k)}$	Błąd ($\ x^{(k)} - 1.6\ $)
1	2.100	0.967	0.500
2	1.629	1.124	0.029
3	1.598	1.134	0.002
4	1.600	1.133	0.000
5	1.600	1.133	0.000

Obserwacja:

- Zbieżność **znacznie szybsza** niż GS – już po 3 iteracjach błąd jest minimalny!
- Dla $\omega = 1.2$ metoda osiąga rozwiązanie z dokładnością do 3 miejsc dziesiętnych w **4 iteracjach**, podczas gdy GS potrzebuje > 10 iteracji.

Przypadek 2: Podrelaksacja ($\omega = 0.8$)

Wyniki po 5 iteracjach:

Iteracja (k)	$x^{(k)}$	$y^{(k)}$	Błąd ($\ x^{(k)} - 1.6\ $)
1	1.400	1.200	0.200
2	1.520	1.160	0.080
3	1.568	1.144	0.032
4	1.587	1.138	0.013
5	1.595	1.135	0.005

Obserwacja:

- Zbieżność **wolniejsza niż GS**, ale stabilniejsza (mniejsze "przeskoki" wartości).
- Przydatna np. dla układów źle uwarunkowanych, gdzie GS może oscylować.

Krok 3: Optymalny wybór ω

Dla macierzy diagonalnie dominujących **optymalne** ω można oszacować teoretycznie. W tym przypadku:

$$\omega_{\text{opt}} \approx \frac{2}{1 + \sqrt{1 - \rho(J)^2}}$$

gdzie $\rho(J)$ to promień spektralny macierzy iteracji Jacobiego. Dla naszego układu $\rho(J) \approx 0.25$, więc:

$$\omega_{\text{opt}} \approx 1.05$$

Test dla $\omega = 1.05$:

- Rozwiązanie osiągnięte z dokładnością do 5 miejsc dziesiętnych w **3 iteracjach**.

Wnioski

1. Przyspieszenie zbieżności:

- Dla $\omega = 1.2$ SOR osiąga błąd < 0.01 w **3 iteracjach**, podczas gdy GS potrzebuje **8 iteracji**.

2. Dokładność:

- SOR z optymalnym ω redukuje błędy szybciej, minimalizując kumulację błędów zaokrągleń.

3. Ryzyko:

- $\omega > 1.5$ może prowadzić do oscylacji lub rozbieżności.


Metoda gradientowa

Rozpatrzmy rozwiązanie poniższego układu równań:

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

gdzie macierz A ($n \times n$) jest **symetryczna, rzeczywista i dodatnio określona**.

Oznaczmy rozwiązanie tego układu przez $\mathbf{x}^*$.

$$A\mathbf{x} - \mathbf{b} = 0$$


$$F(\mathbf{x}) = \mathbf{x}^T A\mathbf{x} - 2\mathbf{x}^T \mathbf{b},$$

$$F(\mathbf{x}) = \|A\mathbf{x} - \mathbf{b}\|^2$$

$$\nabla F(\mathbf{x}) = 2(A\mathbf{x} - \mathbf{b}),$$

$$\nabla F(\mathbf{x}) = 2A^T (A\mathbf{x} - \mathbf{b})$$

Metoda gradientowa (cd)

$$Ax^* = b$$

$$f(x) = \frac{1}{2}x^T Ax - x^T b \quad \min_x f(x)$$

$$\nabla f(x) = Ax - b = 0$$

Metoda gradientowa (cd)

$$p_k = -\nabla f(x_k) = r_k$$

$$x_{k+1} = x_k + \alpha_k p_k$$

$$\min_{\alpha} f(x_k + \alpha p_k)$$

Metoda gradientowa (cd)

$$\begin{aligned} f(x_k + \alpha p_k) &= \frac{1}{2}(x_k + \alpha p_k)^T A(x_k + \alpha p_k) - (x_k + \alpha p_k)^T b \\ &= \frac{1}{2}\alpha^2 p_k^T A p_k + \alpha p_k^T A x_k + -\alpha p_k^T b + \text{constant} \end{aligned}$$

$$\frac{\partial f}{\partial \alpha} = 0 \quad \Downarrow$$

$$p_k^T A x_k + \alpha p_k^T A p_k - p_k^T b = 0$$

$$\alpha = -\frac{p_k^T (A x_k - b)}{p_k^T A p_k} = \frac{p_k^T r_k}{p_k^T A p_k}$$

$$\alpha_k = \frac{p_k^T r_k}{p_k^T A p_k} = \frac{r_k^T r_k}{p_k^T A p_k}$$

Algorytm

repeat in the loop:

$$\mathbf{r} := \mathbf{b} - \mathbf{A}\mathbf{x}$$

$$\gamma := \mathbf{r}^\top \mathbf{r} / \mathbf{r}^\top \mathbf{A} \mathbf{r}$$

$$\mathbf{x} := \mathbf{x} + \gamma \mathbf{r}$$

if $\mathbf{r}^\top \mathbf{r}$ is sufficiently small, then exit loop

end repeat loop

return $\mathbf{x}$ as the result

Zbieżność



$$E(x) = \frac{1}{2}(x - x^*)^T A(x - x^*)$$

$$E(x_k) \leq \left(\frac{\lambda_{max} - \lambda_{min}}{\lambda_{max} + \lambda_{min}} \right)^{2k} E(x_0)$$


λ_{max} and λ_{min} are the largest and smallest eigenvalues of A

Przykład

```
gradAx8.m  x  +
1 - A=[1 2;3 4];
2 - b=[5 6]';
3 - %A^-1*b'
4 - % -4.0000
5 - % 4.5000
6 - xg=A\b;
7 - x=[0 0]';
8 - Ex0=1/2*(x-xg)'*A*(x-xg);
9 - L=eig(A);
10 - Lmax=L(2);
11 - Lmin=L(1);
12 - GranicaBledu=Ex0;
13 - Out=[x' Ex0 GranicaBledu];
14 - for i=1:100
15 -     r=b-A*x;
16 -     gamma=r'*r/(r'*A*r);
17 -     x=x+gamma*r;
18 -     Ex=1/2*(x-xg)'*A*(x-xg);
19 -     %GranicaBledu=((Lmax-Lmin)/(Lmax+Lmin))^(2*i)*Ex0;
20 -     GranicaBledu=((Lmax+Lmin)/(Lmax-Lmin))^(2*i)*Ex0;
21 -
22 -     Out=[Out;x' Ex GranicaBledu];
23 - end;
24 - plot(Out(:,1),'.-r');
25 - hold on;
26 - plot(Out(:,2),'.-g');
27 - figure;
28 - plot(Out(:,3),'.-r');
29 - hold on;
30 - plot(Out(:,4),'.-g');
```



Wizualizacja



Metoda gradientu sprzężonego

Mówimy, że dwa niezerowe wektory $\mathbf{u}$ i $\mathbf{v}$ są sprzężone (względem $\mathbf{A}$), jeśli

$$\mathbf{u}^T \mathbf{A} \mathbf{v} = 0.$$

Ponieważ $\mathbf{A}$ jest symetryczna i dodatnio określona

$$\langle \mathbf{u}, \mathbf{v} \rangle_{\mathbf{A}} := \langle \mathbf{A}^T \mathbf{u}, \mathbf{v} \rangle = \langle \mathbf{A} \mathbf{u}, \mathbf{v} \rangle = \langle \mathbf{u}, \mathbf{A} \mathbf{v} \rangle = \mathbf{u}^T \mathbf{A} \mathbf{v}$$

Więc, dwa wektory są sprzężone jeśli są ortogonalne względem tego iloczynu skalarnego. Sprzężoność jest relacją symetryczną.

Przypuśćmy, że $\{\mathbf{p}_k\}$ jest ciągiem n wzajemnie sprzężonych kierunków.

Dowolny wektor można
wyrazić jako ważoną sumę
liniowo niezależnych
wektorów

$$\mathbf{x}_* = \sum_{i=1}^n \alpha_i \mathbf{p}_i$$

Metoda gradientu sprzężonego (cd)

$$\mathbf{Ax}_* = \sum_{i=1}^n \alpha_i \mathbf{Ap}_i = \mathbf{b},$$

$$\mathbf{p}_k^T \mathbf{Ax}_* = \sum_{i=1}^n \alpha_i \mathbf{p}_k^T \mathbf{Ap}_i = \mathbf{p}_k^T \mathbf{b},$$

(wg liniowej niezależności)

$$\alpha_k = \frac{\mathbf{p}_k^T \mathbf{b}}{\mathbf{p}_k^T \mathbf{Ap}_k} = \frac{\langle \mathbf{p}_k, \mathbf{b} \rangle}{\langle \mathbf{p}_k, \mathbf{p}_k \rangle_{\mathbf{A}}} = \frac{\langle \mathbf{p}_k, \mathbf{b} \rangle}{\|\mathbf{p}_k\|_{\mathbf{A}}^2}$$

Co daje nam następującą metodę rozwiązywania równania $\mathbf{Ax} = \mathbf{b}$. Najpierw znajdujemy ciąg n sprzężonych kierunków, następnie obliczamy współczynniki α_k

Metoda iteracyjna

$$f(\mathbf{x}) = \frac{1}{2} \mathbf{x}^T \mathbf{A} \mathbf{x} - \mathbf{x}^T \mathbf{b}, \quad \mathbf{x} \in \mathbf{R}^n \quad \mathbf{x}_0 = \mathbf{0}$$

$$\nabla f(x) = Ax - b = 0$$

jako pierwszy wektor bazowy **p1** wybrać gradient f w $\mathbf{x} = \mathbf{x}_0$, który wynosi $\mathbf{A}\mathbf{x}_0 - \mathbf{b}$, a ponieważ wybraliśmy $\mathbf{x}_0 = \mathbf{0}$, otrzymujemy $-\mathbf{b}$. **Pozostałe wektory w bazie będą sprzężone do gradientu** (stąd nazwa metoda gradientu sprzężonego).

$$\mathbf{r}_k = \mathbf{b} - \mathbf{A}\mathbf{x}_k$$

Zauważmy, że $\mathbf{r}_k$ jest przeciwny do gradientu f w $\mathbf{x} = \mathbf{x}_k$, więc metoda gradientu prostego nakazywałaby ruch w kierunku $\mathbf{r}_k$. Tutaj jednak założyliśmy wzajemną sprzężoność kierunków $\mathbf{p}_k$, więc wybieramy kierunek najbliższy do $\mathbf{r}_k$ pod warunkiem sprzężoności. Co wyraża się wzorem:

$$\mathbf{p}_{k+1} = \mathbf{r}_k - \frac{\mathbf{p}_k^T \mathbf{A} \mathbf{r}_k}{\mathbf{p}_k^T \mathbf{A} \mathbf{p}_k} \mathbf{p}_k$$

Ortogonalizacja Grama-Schmidta

Ortogonalizacja Grama-Schmidta

Ortogonalizacja Grama-Schmidta – przekształcenie układu liniowo niezależnych wektorów przestrzeni unitarnej w układ wektorów ortogonalnych.

$$A = \mathbf{a}_1, \dots, \mathbf{a}_N$$

$$B = \mathbf{b}_1, \dots, \mathbf{b}_N \qquad \mathbf{e}_1, \dots, \mathbf{e}_N$$

$$\text{proj}_{\mathbf{b}} \mathbf{a} = \frac{\langle \mathbf{a}, \mathbf{b} \rangle}{\langle \mathbf{b}, \mathbf{b} \rangle} \mathbf{b}$$

$$\mathbf{b}_1 = \mathbf{a}_1 \qquad (1)$$

$$\mathbf{b}_2 = \mathbf{a}_2 - \text{proj}_{\mathbf{b}_1} \mathbf{a}_2 \qquad (2)$$

$$\mathbf{b}_3 = \mathbf{a}_3 - \text{proj}_{\mathbf{b}_1} \mathbf{a}_3 - \text{proj}_{\mathbf{b}_2} \mathbf{a}_3 \qquad (3)$$

$$\mathbf{b}_4 = \mathbf{a}_4 - \text{proj}_{\mathbf{b}_1} \mathbf{a}_4 - \text{proj}_{\mathbf{b}_2} \mathbf{a}_4 - \text{proj}_{\mathbf{b}_3} \mathbf{a}_4 \qquad (4)$$

$$\vdots$$

$$\mathbf{b}_N = \mathbf{a}_N - \sum_{j=1}^{N-1} \text{proj}_{\mathbf{b}_j} \mathbf{a}_N \qquad (N)$$



$$\mathbf{e}_j = \frac{\mathbf{b}_j}{\|\mathbf{b}_j\|}$$

Interpretacja geometryczna

$$b_1 = a_1$$

$$b_2 = a_2 - \text{proj}_{b_1} a_2$$

$$b_3 = a_3 - (\text{proj}_{b_1} a_3 + \text{proj}_{b_2} a_3)$$



Algorytm

$$r_0 := b - Ax_0$$

$$p_0 := r_0$$

$$k := 0$$

repeat

$$\alpha_k := \frac{r_k^\top r_k}{p_k^\top A p_k}$$

$$x_{k+1} := x_k + \alpha_k p_k$$

$$r_{k+1} := r_k - \alpha_k A p_k$$

if r_{k+1} jest "wystarczająco mały" **then** exit loop **end if**

$$\beta_k := \frac{r_{k+1}^\top r_{k+1}}{r_k^\top r_k}$$

$$p_{k+1} := r_{k+1} + \beta_k p_k$$

$$k := k + 1$$

end repeat

Wynikiem jest x_{k+1}

Zbieżność algorytmu

$$E(x_k) \leq \left(\frac{1 - \sqrt{\kappa^{-1}}}{1 + \sqrt{\kappa^{-1}}} \right)^{2k} E(x_0)$$


$$\kappa = \lambda_{max} / \lambda_{min}$$

```

function x = conjgrad(A, b, x)
    r = b - A * x;
    p = r;
    rsold = r' * r;


    for i = 1:length(b)
        Ap = A * p;
        alpha = rsold / (p' * Ap);
        x = x + alpha * p;
        r = r - alpha * Ap;
        rsnew = r' * r;
        if sqrt(rsnew) < 1e-10
            break
        end
        p = r + (rsnew / rsold) * p;
        rsold = rsnew;
    end
end

```



conjgradOS

Porównanie zbieżności



Porównanie zbieżności metody gradientu prostego (na zielono) i sprzężonego gradientu (na czerwono) dla minimalizacji formy kwadratowej powiązanej z zadaniem układem równań liniowych. Metoda sprzężonego gradientu zbiega w co najwyżej n krokach, gdzie n jest rozmiarem macierzy zadanego układu (tutaj $n=2$).

Macierz blokowa

- Dowolną macierz A można przedstawić jako macierz blokową, zbudowaną z pewnej liczby macierzy o mniejszych wymiarach:

$$\mathbf{A} = \begin{bmatrix} \mathbf{A}_{11} & \mathbf{A}_{12} & \dots & \mathbf{A}_{1n} \\ \mathbf{A}_{21} & \mathbf{A}_{22} & \dots & \mathbf{A}_{2n} \\ \dots & \dots & \dots & \dots \\ \mathbf{A}_{m1} & \mathbf{A}_{m2} & \dots & \mathbf{A}_{mn} \end{bmatrix}$$

$\mathbf{A}_{ij}$

Ma wymiar

$p_i \times q_j$

Macierz blokowo-przekątniowa

$$A = \begin{bmatrix} B_1 & 0 & \cdots & 0 \\ 0 & B_2 & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \cdots & 0 & B_N \end{bmatrix} \quad b = \begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_N \end{bmatrix} \quad \xi = \begin{bmatrix} \xi_1 \\ \xi_2 \\ \vdots \\ \xi_N \end{bmatrix}$$

gdzie ξ_i to rozwiązanie układu $B_i \xi_i = b_i$.

$$x = \bigoplus_{i=1}^N \xi_i \quad (\text{symbol } \oplus \text{ oznacza łączenie wektorów})$$

$$x = \text{vertcat}(\xi_1, \xi_2, \dots, \xi_N)$$

Przykład

Block.m

```
% Przykładowe bloki macierzy B_i
B1 = [4, 1;
      1, 3];
B2 = [5, 2;
      2, 6];
B3 = [7];

% Wektory prawej strony b_i
b1 = [10; 8];
b2 = [12; 9];
b3 = [14];

% Rozwiązanie każdego podukładu
x1 = B1 \ b1; % Lub: x1 = inv(B1) * b1;
x2 = B2 \ b2;
x3 = B3 \ b3;

% Połączenie wyników
x = [x1; x2; x3];
```

```
% Zbuduj pełną macierz blokowo-przekątniową A
A = blkdiag(B1, B2, B3);
```

```
% Oblicz residuum r = b - A*x
b = [b1; b2; b3];
r = b - A * x;
```

```
Rozwiązanie x =
2.0000
2.0000
2.0769
0.8077
2.0000

Residuum r = b - A*x =
0
0
0
0
0

Macierz A =
4      1      0      0      0
1      3      0      0      0
0      0      5      2      0
0      0      2      6      0
0      0      0      0      7
```

Macierz blokowa ogólna

$$A = \begin{pmatrix} A_{11} & A_{12} & A_{13} & \cdots & A_{1p} \\ A_{21} & A_{22} & A_{23} & \cdots & A_{2p} \\ A_{31} & A_{32} & A_{33} & \cdots & A_{3p} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ A_{p1} & A_{p2} & \cdots & \cdots & A_{pp} \end{pmatrix}, \quad x = \begin{pmatrix} \xi_1 \\ \xi_2 \\ \xi_3 \\ \vdots \\ \xi_p \end{pmatrix}, \quad b = \begin{pmatrix} \beta_1 \\ \beta_2 \\ \beta_3 \\ \vdots \\ \beta_p \end{pmatrix}$$

$$(Ax)_i = \sum_{j=1}^p A_{ij} \xi_j$$

wektor x jest jawnie oznaczony jako kolumna o blokowych składowych
 $x=(\xi_1,\xi_2,\dots,\xi_p \xi_1,\xi_2,\dots,\xi_p)$

Metoda blokowa Jakobiego

$$A = D - E - F$$

$$D = \begin{pmatrix} A_{11} & & & \\ & A_{22} & & \\ & & \ddots & \\ & & & A_{pp} \end{pmatrix},$$

$$E = - \begin{pmatrix} O & & & \\ A_{21} & O & & \\ \vdots & \vdots & \ddots & \\ A_{p1} & A_{p2} & \cdots & O \end{pmatrix}, \quad F = - \begin{pmatrix} O & A_{12} & \cdots & A_{1p} \\ & O & \cdots & A_{2p} \\ & & \ddots & \vdots \\ & & & O \end{pmatrix}$$

$$A_{ii}\xi_i^{(k+1)} = ((E + F)x_k)_i + \beta_i$$

$$\xi_i^{(k+1)} = A_{ii}^{-1} ((E + F)x_k)_i + A_{ii}^{-1} \beta_i, \quad i = 1, \dots, p,$$

Indeks i "wycina" z wektora $(E + F)x_k$ tylko tę część, która wpływa na aktualizację $\xi_i^{(k+1)}$.

Przykład

$$\begin{aligned}
 A_{11} &= \begin{pmatrix} 4 & 1 \\ 1 & 3 \end{pmatrix}, & A &= \begin{pmatrix} 4 & 1 & 0 & 2 \\ 1 & 3 & 0 & 0 \\ 1 & 0 & 5 & 0 \\ 0 & 1 & 0 & 6 \end{pmatrix} & A &= \begin{pmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{pmatrix} \\
 A_{12} &= \begin{pmatrix} 0 & 2 \\ 0 & 0 \end{pmatrix}, & A_{11} &= \begin{pmatrix} 4 & 1 \\ 1 & 3 \end{pmatrix}, & A_{12} &= \begin{pmatrix} 0 & 2 \\ 0 & 0 \end{pmatrix}, & A_{21} &= \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}, & A_{22} &= \begin{pmatrix} 5 & 0 \\ 0 & 6 \end{pmatrix} \\
 A_{21} &= \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}, \\
 A_{22} &= \begin{pmatrix} 5 & 0 \\ 0 & 6 \end{pmatrix}. \\
 D &= \begin{pmatrix} A_{11} & 0 \\ 0 & A_{22} \end{pmatrix}, & D &= \begin{pmatrix} 4 & 1 & 0 & 0 \\ 1 & 3 & 0 & 0 \\ 0 & 0 & 5 & 0 \\ 0 & 0 & 0 & 6 \end{pmatrix}, & E &= - \begin{pmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{pmatrix}, & F &= - \begin{pmatrix} 0 & 0 & 0 & 2 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix} \\
 E &= - \begin{pmatrix} 0 & 0 \\ A_{21} & 0 \end{pmatrix}, \\
 F &= - \begin{pmatrix} 0 & A_{12} \\ 0 & 0 \end{pmatrix}.
 \end{aligned}$$

blockOgolny.m

Przykład

```
% Definicja bloków macierzy A
```

```
A11 = [4, 1; 1, 3];
```

```
A12 = [0, 2; 0, 0];
```

```
A21 = [1, 0; 0, 1];
```

```
A22 = [5, 0; 0, 6];
```

```
% Pełna macierz A (do weryfikacji)
```

```
A = [A11, A12; A21, A22];
```

```
% Wektor prawej strony b (przykładowy)
```

```
b = [10; 8; 12; 9];
```

```
% Inicjalizacja rozwiązania x (startowe przybliżenie)
```

```
x = zeros(4, 1);
```

```
% Macierz diagonalna D (tylko bloki A11 i A22)
```

```
D = blkdiag(A11, A22);
```

```
% Macierze E i F (dolna i górna trójkątna część blokowa)
```

```
E = -[zeros(2), zeros(2); A21, zeros(2)];
```

```
F = -[zeros(2), A12; zeros(2), zeros(2)];
```

```
% Parametry iteracji
```

```
max_iter = 100; % Maksymalna liczba iteracji
```

```
tolerance = 1e-6; % Tolerancja zbieżności
```

```
for k = 1:max_iter
```

```
    x_old = x;
```

```
    % Oblicz (E + F) * x_old
```

```
    EFx = (E + F) * x_old;
```

```
    % Rozwiąż D * x_new = (E + F) * x_old + b (blokowo)
```

```
    % Blok 1: A11 * x1 = [EFx(1); EFx(2)] + [b(1); b(2)]
```

```
    x(1:2) = A11 \ (EFx(1:2) + b(1:2));
```

```
    % Blok 2: A22 * x2 = [EFx(3); EFx(4)] + [b(3); b(4)]
```

```
    x(3:4) = A22 \ (EFx(3:4) + b(3:4));
```

```
    % Sprawdź zbieżność
```

```
    if norm(x - x_old) < tolerance
```

```
        fprintf('Zbieżność osiągnięta po %d iteracjach.\n', k);
```


```
        break;
```

```
    end
```

```
end
```

IterBlock.m

```
A11=[1 2;3 4];
A22=[5 6;7 8];
Z=[0 0;0 0];
A12=Z;A21=Z;
A=[A11 A12;A21 A22];
%B=blkdiag(A11,A22);
b=[1 2 3 4]';
E=-[Z Z;A21 Z];
F=-[Z A12;Z Z];
D=[A11 Z;Z A22];
x=[1 1 1 1]';
OutJ=[];
for i=1:10
    OutJ=[OutJ;x'];
    x=inv(D)*(b+(E+F)*x);
end;
hold on;
plot(OutJ(:,1),'r');
plot(OutJ(:,2),'b');
plot(OutJ(:,3),'g*');
plot(OutJ(:,4),'k*');
```



IterBlock2

**Dostateczny warunek zbieżności:
Macierz dominująca**

```
A11=[10 2;3 40];
A22=[50 6;7 80];
Z=[0 0;0 0];
A12=[3 2;5 4];A21=[7 5;4 1];
A=[A11 A12;A21 A22];
%B=blkdiag(A11,A22);
b=[1 2 3 4]';
E=-[Z Z;A21 Z];
F=-[Z A12;Z Z];
D=[A11 Z;Z A22];

x=[1 1 1 1]';
OutJ=[];

ks1=[1 1]';
ks2=[2 3]';
x=[ks1; ks2];
for i=1:10
    OutJ=[OutJ;ks1' ks2'];
    %x=inv(D) * (b+(E+F) *x);
    xx=(E+F) *x;
    ks1=inv(A11) * (xx(1:2)+b(1:2));
    ks2=inv(A22) * (xx(3:4)+b(3:4));
    x=[ks1;ks2];
end;
```

A =

10	2	3	2
3	40	5	4
7	5	50	6
4	1	7	80

Regularyzacja Tichonowa

Rozważmy układ równań typu:

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

gdzie A to macierz układu (macierz przekształcenia), $\mathbf{x}$ wektor niewiadomych, $\mathbf{b}$ wektor wyjściowy. Jeśli zagadnienie to jest źle postawione (np. rozwiązanie nie istnieje, lub jest niejednoznaczne) wtedy standardowym podejściem jest rozwiązanie w sensie **najmniejszych kwadratów**. Oznacza to poszukiwanie minimum następującego funkcjonału Π ^[3]:

$$\Pi = \{A\mathbf{x} - \mathbf{b}\}^T \{A\mathbf{x} - \mathbf{b}\}.$$

Aby poprawić właściwości funkcjonału Π (np. żeby wyeliminować niefizyczne **oscylacje** w rozwiązaniu) do powyższej postaci dodaje się człon regularyzacyjny $\alpha\mathbf{x}^T\mathbf{x}$:

$$\Pi = \{A\mathbf{x} - \mathbf{b}\}^T \{A\mathbf{x} - \mathbf{b}\} + \alpha\mathbf{x}^T\mathbf{x}.$$

Wyrażenie $\mathbf{x}^T\mathbf{x}$ to kwadrat **długości wektora** $\mathbf{x}$, zaś α to parametr regularyzacyjny zwany również współczynnikiem tłumienia.

Szukanie minimum funkcjonału Π oznacza rozwiązanie równania:

$$\frac{\partial \Pi}{\partial \mathbf{x}} = 0,$$

co daje:

$$-2A^T\{\mathbf{b} - A\mathbf{x}\} + 2\alpha\mathbf{x} = 0$$

i po przekształceniu:

$$A^T\mathbf{b} = [A^T A + \alpha\mathbf{I}] \mathbf{x},$$

gdzie $\mathbf{I}$ to **macierz jednostkowa**.

Macierz stojąca po prawej stronie powyższego równania jest **macierzą symetryczną**, ponadto dzięki obecności członu $\alpha\mathbf{I}$ jest również **odwracalna**. Poza tym parametr regularyzacyjny wpływa na **określoność macierzy** i poprawia jej **uwarunkowanie**. W związku z tym rozwiązanie wyjściowego równania może być wyznaczone za pomocą:

$$\mathbf{x} = [A^T A + \alpha\mathbf{I}]^{-1} A^T \mathbf{b}.$$

Przykład

Rozważmy równanie:

$$ax = b$$

Problem pojawia się, gdy:

1. **Małe wartości a** – Dzielimy przez liczbę bliską zera, co prowadzi do dużych wartości x .
2. **Zakłócenia w b** – Mała zmiana w b powoduje ogromną zmianę w x .

👉 **Przykład:** Jeśli:

$$a = 0.01, \quad b = 1$$

Rozwiązanie to:

$$x = \frac{b}{a} = \frac{1}{0.01} = 100$$

Teraz dodajmy małe zakłócenie do b :

$$b = 1.0001 \Rightarrow x = \frac{1.0001}{0.01} = 100.01$$

Niewielka zmiana w b o 0.01% spowodowała dużą różnicę w x .

Przykład

Dodajemy dodatkowy człon regularyzacyjny:

$$\min_x ((ax - b)^2 + \lambda x^2)$$

Gdzie:

- $\lambda > 0$ – parametr regularyzacji (kontroluje karę za duże wartości x)

Aby znaleźć minimum, różniczkujemy po x :

$$\frac{d}{dx} (a^2x - 2ab + b^2 + \lambda x^2) = 0$$

$$2a^2x + 2\lambda x = 2ab$$

Po przekształceniu:

$$x = \frac{ab}{a^2 + \lambda}$$

- Bez regularyzacji: $\lambda = 0 \Rightarrow x = \frac{b}{a}$
- Z regularyzacją: $\lambda > 0$ – rozwiązanie jest mniejsze i stabilniejsze, nawet gdy a jest bliskie zera

Przykład

Założmy:

$$a = 0.01, \quad b = 1, \quad \lambda = 0.1$$

Bez regularyzacji:

$$x = \frac{1}{0.01} = 100$$

Z regularyzacją:

$$x = \frac{0.01 \times 1}{0.01^2 + 0.1} = \frac{0.01}{0.0001 + 0.1} = \frac{0.01}{0.1001} \approx 0.0999$$

```
a = 0.01;      % skalar
b = 1;         % wynik
lambda = 0.1;  % parametr regularyzacji
```

```
x = (a * b) / (a^2 + lambda);
disp(x);
```

a

```
a = 0.01;      % skalar
b = 1;         % wynik
```

```
% Różne wartości lambda
lambda_values = [0, 0.0001, 0.01, 0.1, 1];
```

```
% Obliczamy x dla każdej lambda
```

```
for lambda = lambda_values
```

```
    x = (a * b) / (a^2 + lambda);
```

```
    fprintf('Lambda: %.4f, x: %.4f\n', lambda, x);
```

```
end
```

Założmy, że losowy szum wynosił:

$$b_{\text{noisy}} = [1.01, 0.98, 1.02, 0.95, 1.03]$$

Lambda: 0.0000, x: 100.0000

Lambda: 0.0001, x: 50.0000

Lambda: 0.0100, x: 0.9901

Lambda: 0.1000, x: 0.0999

Lambda: 1.0000, x: 0.0100

λ	Rozwiązanie x dla różnych zaszumionych b	Charakterystyka
0	[101, 98, 102, 95, 103]	Niestabilne – wynik "eksploduje".
0.0001	[50.50, 49.00, 51.00, 47.50, 51.50]	Nadal duże wahania.
0.01	[0.995, 0.980, 1.010, 0.955, 1.030]	Stabilne i dokładne – dobry kompromis.
0.1	[0.0995, 0.0980, 0.1010, 0.0955, 0.1030]	Bardzo stabilne, ale zaniżone.
1.0	[0.0100, 0.0098, 0.0102, 0.0095, 0.0103]	Przesadna regularyzacja – tłumi wynik.

Regularyzacja Tichonowa

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

A – macierz współczynników (rozmiaru $m \times n$)

$\mathbf{x}$ – wektor niewiadomych (rozmiaru $n \times 1$)

$\mathbf{b}$ – wektor wynikowy (rozmiaru $m \times 1$)

Dotichonov_reg.m

Zamiast rozwiązywać układ bezpośrednio, minimalizujemy funkcję celu:

$$\|A\mathbf{x} - \mathbf{b}\|_2^2 + \lambda \|\mathbf{x}\|_2^2$$

gdzie:

- $\|\cdot\|_2$ – norma 2 (euklidesowa)
- $\lambda > 0$ – parametr regularyzacji (kontroluje kompromis między zgodnością z danymi a gładkością rozwiązania)

Postać rozwiązania

Rozwiązanie układu z regularyzacją Tichonowa można zapisać jako:

$$\mathbf{x} = (A^T A + \lambda I)^{-1} A^T \mathbf{b}$$

gdzie:

- A^T – macierz transponowana do A
- I – macierz jednostkowa o odpowiednich wymiarach
- λ – parametr regularyzacji (im większy, tym bardziej "wygładzone" rozwiązanie)

Optymalizacja parametru regularyzacji

Metoda L-krzywej

Metoda L-krzywej pomaga znaleźć optymalny parametr regularyzacji λ w problemach typu $\min_x \|Ax - b\|^2 + \lambda\|x\|^2$.

Krzywa ta wizualizuje kompromis między **normą residuum** ($\|Ax - b\|$) a **normą rozwiązania** ($\|x\|$) dla różnych λ .

1. Algorytm metody L-krzywej

1. **Oblicz rozwiązania regularyzowane** dla różnych wartości λ .
2. **Dla każdego λ zapisz:**
 - Normę residuum: $\rho(\lambda) = \|Ax_\lambda - b\|$,
 - Normę rozwiązania: $\eta(\lambda) = \|x_\lambda\|$.
3. **Narysuj log-log wykres $\eta(\lambda)$ vs. $\rho(\lambda)$.**
4. **Wybierz λ w "kącie" krzywej** – punkt optymalnego balansu między dopasowaniem do danych a stabilnością rozwiązania.

Krzywizna parametryczna w dwóch wymiarach (dla krzywej $(x(t), y(t))$) jest obliczana według wzoru:

$$\kappa = \frac{|x'(t) \cdot y''(t) - y'(t) \cdot x''(t)|}{(x'(t)^2 + y'(t)^2)^{3/2}}$$

Przykład

$$x = \frac{ab}{a^2 + \lambda}$$

$$Ax=b$$

$$a=0.01, b=1, \lambda=9.326e-05$$



$$x=$$

$$x=a*b/(a^2+\lambda)$$

$$x = 51.7438$$

LcurveFindLambda.m

Optymalne lambda: 9.326033e-05 (indeks: 17)



Dodatkowe materiały

Metoda gradientu sprzężonego

Liniowo niezależni wektory $p_k, k = 0, 1, \dots, n-1$ $p_k^T A p_j = 0, k \neq j$
względem A

Dowolny wektor można
wyrazić jako ważona suma
liniowo niezależnych
wektorów

$$\underbrace{x^* - x_0}_{\downarrow} = \underbrace{\sum_{j=0}^{n-1} \alpha_j p_j}_{\downarrow} \quad \text{Pomnożymy na } p_k^T A$$

$$p_k^T A(x^* - x_0) = p_k^T (b - Ax_0) = p_k^T r_0 \quad p_k^T A \sum_{j=0}^{n-1} \alpha_j p_j = \alpha_k p_k^T A p_k$$

(wg liniowej niezależności)

Więc mamy $p_k^T r_0 = \alpha_k p_k^T A p_k$

Oraz

$$\alpha_k = \frac{p_k^T r_0}{p_k^T A p_k}$$

Algorytm

Najpierw znajdujemy ciąg n sprzężonych kierunków, następnie obliczamy współczynniki α

Dla dowolnych liniowo niezależnych wektorów

$$v_k, \quad k = 0, 1, \dots, n - 1$$

1. Let $p_0 = v_0$.

2. For $k = 0, 1, \dots, n - 2$

$$p_{k+1} = v_{k+1} - \sum_{j=0}^k \frac{p_j^T A v_{k+1}}{p_j^T A p_j} p_j$$

End For.

Ortogonalizacja Grama-Schmidta

jako pierwszy wektor bazowy p_1 wybrać gradient f w $x = x_0$, który wynosi $Ax_0 - b$, a ponieważ wybraliśmy $x_0 = 0$, otrzymujemy $-b$. **Pozostałe wektory w bazie będą sprzężone do gradientu** (stąd nazwa metoda gradientu sprzężonego).

Algorytm (cd)

1. Pick x_0 and A -conjugate directions p_k , $k = 0, 1, \dots, n - 1$.
2. For $k = 0, 1, \dots, n - 1$

(a) Set

$$\alpha_k = \frac{p_k^T r_0}{p_k^T A p_k}.$$

(b) Let $x_{k+1} = x_k + \alpha_k p_k$.

End For.

Algorytm gradientu sprzężonego

1. Let x_0 be an initial guess.

Let $r_0 = b - Ax_0$ and $p_0 = r_0$.

2. For $k = 0, 1, 2, \dots$, until convergence,

(a) Compute the search parameter α_k and the new iterate and residual

$$\begin{aligned}\alpha_k &= \frac{r_k^T r_k}{p_k^T A p_k}, \\ x_{k+1} &= x_k + \alpha_k p_k, \\ r_{k+1} &= r_k - \alpha_k A p_k,\end{aligned}$$

(b) Compute the new search direction p_{k+1} by Gram-Schmidt on r_{k+1} and the previous p vectors to make p_{k+1} A -conjugate to the previous directions.

End For.

Algorytm gradientu sprzężonego (w całości)

1. Let x_0 be an initial guess.

Let $r_0 = b - Ax_0$ and $p_0 = r_0$.

2. For $k = 0, 1, 2, \dots$, until convergence,

- (a) Compute the search parameter α_k and the new iterate and residual

$$\begin{aligned}\alpha_k &= \frac{p_k^T r_k}{p_k^T A p_k}, \text{ (or, equivalently, } \frac{r_k^T r_k}{p_k^T A p_k} \text{)} \\ x_{k+1} &= x_k + \alpha_k p_k, \\ r_{k+1} &= r_k - \alpha_k A p_k,\end{aligned}$$

- (b) Compute the new search direction

$$\begin{aligned}\beta_k &= -\frac{p_k^T A r_{k+1}}{p_k^T A p_k}, \text{ (or, equivalently, } \frac{r_{k+1}^T r_{k+1}}{r_k^T r_k} \text{)}, \\ p_{k+1} &= r_{k+1} + \beta_k p_k,\end{aligned}$$

End For.