

Chapter 3 連立1次方程式解法:反復法

Section 1: Jacobi & Gauss-Seidel法

- 反復法は、高次元と行列の零成分が多いときに効率である。

Iterative methods are efficient when the dimension of the system is not too small and when there are many zero entries.

- 偏微分方程式解放において、零成分の多い行列に作り出されて、よく使われている。

Discretization methods for partial differential equations produce such matrices so iterative methods are used a lot.

- Principle 原理: $Ax = b$. Initial value 初期値 $x^{(0)}$ から作り出す数列 $\{x^{(k)}\}_{k=1}^{\infty}$, $\lim_{k \rightarrow \infty} |x^{(k)} - x| = 0$.

Jacobi's method ヤコビ法 (Easy !)

- $Ax = b$ から

$$\sum_j a_{ij}x_j = b_i \Rightarrow x_i = \frac{b_i}{a_{ii}} - \sum_{j \neq i} \frac{a_{ij}x_j}{a_{ii}}, \quad \text{if } a_{ii} \neq 0.$$

- From the (k-1)-th iteration $\mathbf{x}^{(k-1)}$ compute the k-th iteration $\mathbf{x}^{(k)}$ as follows:

第k-1反復 $\mathbf{x}^{(k-1)}$ から第k反復 $\mathbf{x}^{(k)}$ を以下の公式に従い計算する：

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

Jacobi's method in matrix form

$\mathbf{x}^{(k)} = T\mathbf{x}^{(k-1)} + \mathbf{c}$ という行列の形のヤコビ法

- 反復法を記述するように、また解析するように、より一般的な表現が使われていて便利である。
Iterative methods are conveniently described by a more general description.
- 連立1次方程式 $A\mathbf{x} = \mathbf{b}$ を同値の方程式 $\mathbf{x} = T\mathbf{x} + \mathbf{c}$ に変換することである：(T行列、 \mathbf{c} ベクトル)。
We transform the system $Ax=b$ to an equivalent one $x=Tx+c$ with T a matrix and \mathbf{c} a vector.
- 初期ベクトル $\mathbf{x}^{(0)}$ を選択したあと、反復を簡単に記述できる：

$$\mathbf{x}^{(k)} = T\mathbf{x}^{(k-1)} + \mathbf{c}$$

Then the iteration consists of the above formula.

Jacobi's method in vector form

$\mathbf{x}^{(k)} = T\mathbf{x}^{(k-1)} + \mathbf{c}$ というベクトル形のヤコビ法

- Let $D, -L, -U$ be the diagonal, the lower part and upper part of the matrix A .

$D, -L, -U$ を行列 A の対角分、下三角部分、上三角部分とする。

$$A = D - U - L$$

$$A = \begin{bmatrix} a_{11} & 0 & \cdots & 0 \\ 0 & a_{22} & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \cdots & 0 & a_{nn} \end{bmatrix} + \begin{bmatrix} 0 & -a_{12} & \cdots & -a_{1n} \\ \vdots & \ddots & \ddots & \vdots \\ \vdots & & \ddots & -a_{n-1,n} \\ 0 & \cdots & \cdots & 0 \end{bmatrix} + \begin{bmatrix} 0 & \cdots & \cdots & 0 \\ -a_{21} & \ddots & & \vdots \\ \vdots & \ddots & \ddots & \vdots \\ -a_{n1} & \cdots & -a_{n,n-1} & 0 \end{bmatrix}$$

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

Jacobi法のアルゴリズム

- INPUT: n, a_{ij} A の成分 \mathbf{b} の成分 b_i
精度 ϵ 最大の反復回数 N .
初期ベクトル $\mathbf{x}^{(0)} = (y_1, y_2, \dots, y_n)$
 - OUTPUT 解の近似ベクトル x_1, x_2, \dots, x_n
or 「最大反復回数を超えた。」
- Step 1: $k = 1$
- Step 2: While ($k \leq N$) do Steps 3-5
- Step 3: For $i = 1, \dots, n$ do $x_i = \frac{b_i}{a_{ii}} - \sum_{j \neq i} \frac{a_{ij}y_j}{a_{ii}}$
 - Step 4: If $\|\mathbf{x} - \mathbf{y}\|_\infty < \epsilon$ then OUTPUT \mathbf{x} ; **SUCCESS**.
 - Step 5: $k = k + 1$; For $i = 1, \dots, n$ do $y_i = x_i$
- Step 6: OUTPUT最大反復回数を超えた (**FAIL**)

Comments on the algorithm

- $\forall i, a_{ii} \neq 0$ と想定した。
もし A は非特異だったら および $a_{ii} = 0$ を満たす
 i があったら、行の置換を行うことによって $a_{ii} \neq 0$
になる。

If the matrix is nonsingular and if $a_{ii} = 0$ for some i , then a reordering of the lines permits to assume that there is no $a_{ii} = 0$.

- 精度に関するSTOP標準については、
 $\|x - y\|_{\infty} < \epsilon$ の代わりに $\frac{\|x - y\|_{\infty}}{\|x\|_{\infty}} < \epsilon$ も使われて
いる。

There is another STOP criterion for the tolerance ϵ which commonly used as well.

Gauss-Seidel 法の原理

- ヤコビ反復においての公式：

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

- 手続きによると、 $x_i^{(k)}$ を計算するとき、もう $x_j^{(k)}$, $j = 1, \dots, i - 1$ の成分を計算されているが、 $x_j^{(k-1)}$ に比べて、より明確な近似である。
- According to the process, when we compute $x_i^{(k)}$ with the above formula, values $x_j^{(k)}$, $j = 1, \dots, i - 1$ have already been computed,
- and they are more precise than $x_j^{(k-1)}$

Gauss-Seidel法の反復

$$x_i^{(k)} = \frac{b_i}{a_{ii}} - \underbrace{\sum_{j>i} \frac{a_{ij}x_j^{(k-1)}}{a_{ii}}}_{\text{Same as in Jacobi's method}} - \underbrace{\sum_{j<i} \frac{a_{ij}x_j^{(k)}}{a_{ii}}}_{\text{Use more recent update}}$$

Same as in
Jacobi's method
ヤコビ法と同じ

Use more recent
update
より新鮮な値を使う

- Jacobiアルゴリズム(ページ5)を整形する：
- Step3だけを変える。

➤ Step 3: For $i = 1, \dots, n$ do

$$x_i = \frac{b_i}{a_{ii}} - \sum_{j>i} \frac{a_{ij}y_j}{a_{ii}} - \sum_{j<i} \frac{x_j}{a_{ii}}$$

Example: comparison Jacobi vs Gauss-Seidel

- Test

$$\begin{aligned} 10x_1 - x_2 + 2x_3 &= 6 \\ -x_1 + 11x_2 - x_3 + 3x_4 &= 25 \\ 2x_1 - x_2 + 10x_3 - x_4 &= -11 \\ 3x_2 - x_3 + 8x_4 &= 15 \end{aligned}$$

- $x^{(0)} = (0,0,0,0)^T$

- Jacobi

| k | 0 | 1 | 2 | 3 | 4 | ... | 10 |
|-------------|-----|---------|---------|---------|---------|-----|---------|
| $x_1^{(k)}$ | 0.0 | 0.6000 | 1.0473 | 0.9326 | 1.0152 | ... | 1.0001 |
| $x_2^{(k)}$ | 0.0 | 2.2727 | 1.7159 | 2.053 | 1.9537 | ... | 1.9998 |
| $x_3^{(k)}$ | 0.0 | -1.1000 | -0.8052 | -1.0493 | -0.9681 | ... | -0.9998 |
| $x_4^{(k)}$ | 0.0 | 1.8750 | 0.8852 | 1.1309 | 0.9739 | ... | 0.9998 |

- Gauss-Seidel

| k | 0 | 1 | 2 | 3 | 4 | ... | 5 |
|-------------|--------|---------|--------|---------|---------|-----|---------|
| $x_1^{(k)}$ | 0.0000 | 0.6000 | 1.030 | 1.0065 | 1.0009 | ... | 1.0001 |
| $x_2^{(k)}$ | 0.0000 | 2.3272 | 2.037 | 2.0036 | 2.0003 | ... | 2.0000 |
| $x_3^{(k)}$ | 0.0000 | -0.9873 | -1.014 | -1.0025 | -1.0003 | ... | -1.0000 |
| $x_4^{(k)}$ | 0.0000 | 0.8789 | 0.984 | 0.9983 | 0.9999 | ... | 1.0000 |

Gauss-Seidel's method in matrix form

$\mathbf{x}^{(k)} = T_g \mathbf{x}^{(k-1)} + \mathbf{c}_g$ という行列の形のヤコビ法

$$A = D - U - L$$

$$A = \begin{bmatrix} a_{11} & 0 & \cdots & 0 \\ 0 & a_{22} & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \cdots & 0 & a_{nn} \end{bmatrix} + \begin{bmatrix} 0 & -a_{12} & \cdots & -a_{1n} \\ \vdots & \ddots & \ddots & \vdots \\ \vdots & & \ddots & -a_{n-1,n} \\ 0 & \cdots & \cdots & 0 \end{bmatrix} + \begin{bmatrix} 0 & \cdots & \cdots & 0 \\ -a_{21} & \ddots & & \vdots \\ \vdots & \ddots & \ddots & \vdots \\ -a_{n1} & \cdots & -a_{n,n-1} & 0 \end{bmatrix}$$

Gauss-Seidel: $(D - L)\mathbf{x}^{(k)} = U\mathbf{x}^{(k-1)} + \mathbf{b}$ が成り立つ。

- $\mathbf{x}^{(k)} = (D - L)^{-1}U\mathbf{x}^{(k-1)} + (D - L)^{-1}\mathbf{b}$
- $T_g = (D - L)^{-1}U$ and $\mathbf{c}_g = (D - L)^{-1}\mathbf{b}$ とおくと ;
 $\mathbf{x}^{(k)} = T_g \mathbf{x}^{(k-1)} + \mathbf{c}_g$