

# Chapter 3 連立1次方程式解法: 反復法

## Section 3: Overview of Relaxation method

and conjugate gradient

(過剰) 加速緩和法 と共役勾配法 (概要)

- 加速緩和法とは、基本的にGauss-Seidel反復法に基づいて加速する目的とする修正を含む方法である。  
**Relaxation methods** are based on Gauss-Seidel iteration with modifications to accelerate the convergence.
- 共役勾配法とは、降下法型の反復計算方である。  
Aは(対称) 正定値だと仮定する。  
The **conjugate gradient method** is an iterative **descent method**. (Assume that **A is symmetric definite positive**)

$$Ax^* = b \Leftrightarrow x^* = \min_{x \in \mathbb{R}^n} x^T Ax - 2x^T b$$

# Subsection 1: Relaxation method 緩和法

## Residual error 残差

- 残差 “residual error”

$$\mathbf{r}_i^{(k)} = \mathbf{b} - A\mathbf{x}_i^{(k)}$$

- Gauss-Seidelのアルゴリズムによる,

$$\mathbf{x}_1^{(1)} = \left( x_1^{(0)}, \dots, x_n^{(0)} \right)^T = \mathbf{x}^{(0)}$$

$$\mathbf{x}_2^{(1)} = \left( x_1^{(1)}, x_2^{(0)}, \dots, x_n^{(0)} \right)^T$$

$$\mathbf{x}_i^{(1)} = \left( x_1^{(1)}, x_2^{(1)}, \dots, x_{i-1}^{(1)}, x_i^{(0)}, \dots, x_n^{(0)} \right)^T$$

⋮

$$\mathbf{x}_1^{(2)} = \left( x_1^{(1)}, x_2^{(1)}, \dots, x_n^{(1)} \right)^T = \mathbf{x}^{(1)}$$

- $\mathbf{r}_i^{(k)} = \left( r_{1,i}^{(k)}, r_{2,i}^{(k)}, \dots, r_{i-1,i}^{(k)}, r_{ii}^{(k)}, \dots, r_{ni}^{(k)} \right)^T$  と書く。

- この公式  $x_i^{(k)} = x_i^{(k-1)} + \frac{r_{ii}^{(k)}}{a_{ii}}$  を Gauss-Seidel の定義に従う。

# Toward a smaller residue 残差をより地作する

- **Principle 原理:** Choose  $x_i^{(k)}$  at each step make  $\|r_{i+1}^{(k)}\|$  smaller:
- 加速係数  $\omega$  を  $x_i^{(k)} = x_i^{(k-1)} + \frac{r_{ii}^{(k)}}{a_{ii}}$  入れて  
$$x_i^{(k)} = x_i^{(k-1)} + \omega \frac{r_{ii}^{(k)}}{a_{ii}}$$
- 行列の形 :  $T_\omega = (D - \omega L)^{-1}[(1 - \omega)D + \omega U]$   
 $c_\omega = \omega(D - \omega L)^{-1} b$
- $x^{(k+1)} = T_\omega x^{(k)} + c_\omega b$
- $\omega = 1$  のとき  
 $x^{(k+1)} = (D - L)^{-1}U x^{(k)} + (D - L)^{-1}b$   
つまり、Gauss-Seidel反復である。
- $\rho(T_\omega)$  is difficult to compute in general

# Choice of $\omega$

- If  $\omega > 1$  then such methods are called over-relaxation.  
 $\omega > 1$  の時、過剰(加速)緩和法 という。

SOR: Successive Over-Relaxation  
逐次過剰緩和法

- Used in lot for linear systems coming from  
discretization of EDP (tridiagonal, diagonal dominant)  
偏微分方程式を差分近似して与える連立1次方程式  
に有用である。(対角優位行列、三重対角行列)

# Example

- Consider the following tridiagonal system:

$$\begin{aligned} 4x_1 + 3x_2 &= 24 \\ 3x_1 + 4x_2 - x_3 &= 30 \\ -x_2 + 4x_3 &= -24 \end{aligned}$$

- Compute the matrices  $D, L, U$  and  $T_g = (D - L)^{-1}U$
- Compute the vector  $c_g = (D - L)^{-1}b$
- Deduce that the equations of the Gauss-Seidel system are:

$$\begin{aligned} x_1^{(k)} &= -0.75x_2^{(k-1)} + 6 \\ x_2^{(k)} &= -0.75x_1^{(k)} + 0.25x_3^{(k-1)} + 7.5 \\ x_3^{(k)} &= 0.25x_2^{(k)} - 6 \end{aligned}$$



## Example 2 SOR with $\omega = 1.25$

- After computing the matrices

$$(D - \omega L)^{-1}, \quad (1 - \omega)D + \omega U$$

$$\begin{pmatrix} \frac{1}{4} & 0 & 0 \\ -\frac{15}{64} & \frac{1}{4} & 0 \\ -\frac{75}{1024} & \frac{5}{64} & \frac{1}{4} \end{pmatrix} \quad \begin{pmatrix} -1 & -\frac{15}{4} & 0 \\ 0 & -1 & \frac{5}{4} \\ 0 & 0 & -1 \end{pmatrix}$$

- And computing the vector  $c_s = \omega(D - \omega L)^{-1}b$

$$\left(-6, \frac{105}{8}, -\frac{243}{128}\right)^T$$

We find the SOR system  $x^{(k)} = T_s x^{(k-1)} + c_s$

$$x_1^{(k)} = -0.25x_1^{(k-1)} - 0.9375x_2^{(k-1)} + 7.5$$

$$x_2^{(k)} = -0.9375x_1^{(k)} - 0.25x_2^{(k-1)} + 0.3125x_3^{(k-1)} + 9.375$$

$$x_3^{(k)} = 0.3125x_2^{(k)} - 0.25x_3^{(k-1)} - 7.5$$

# Convergence comparison

## Gauss-Seidel Iterations

$k$	0	1	2	3	...	7
$x_1^{(k)}$	1	5.250000	3.1406250	3.0878906		3.0134110
$x_2^{(k)}$	1	3.812500	3.8828125	3.9267578		3.9888241
$x_3^{(k)}$	1	-5.046875	-5.0292969	-5.0183105		-5.0027940

## SOR Iterations ( $\omega = 1.25$ )

$k$	0	1	2	3	...	7
$x_1^{(k)}$	1	6.312500	2.6223145	3.1333027		3.0000498
$x_2^{(k)}$	1	3.5195313	3.9585266	4.0102646		4.0002586
$x_3^{(k)}$	1	-6.6501465	-4.6004238	-5.0966863		-5.0003486

# General results

- **Theorem (Ostrowski-Reich)**  
If  $A$  is a positive definite matrix (正定値行列) then  
 $\rho(T_\omega) < 1$  (convergence 収束する) for any value of  
 $0 < \omega < 2$
- Better result is known if  $A$  is moreover tridiagonal (その上、三重対角行列だったらよりよい結果が知られている)
- In general, it is difficult to choose a good  $\omega$ .

## Subsection 2: Conjugate Gradient method

- Works only for positive definite matrix (正定値行列だけ)
- Work best for sparse matrix like tridiagonal  
三重対角行列のような疎行列に適切である。
- We will describe the basic method but to be efficient, more care is necessary. 基礎な解法を記述するが、実用化するために、よりよく手配が必要：
- Because problems occur when  $A$  has small and large eigenvalues (that is has a large condition number)  
なぜならば、 $A$ は大きいとともに小さな固有値があるときに問題が生じ得る（条件数が大きいという）
- This problem cannot be known in advance. Some “preconditioning” is necessary。  
予め、条件数の大きさを測定するのは難しい、大分ほとんどの場合、前処理を行う。