

# 第8章 解线性方程组的迭代法

---

张利军

[zlj@nju.edu.cn](mailto:zlj@nju.edu.cn)

<http://cs.nju.edu.cn/zlj>





# 目录

---

- 引言
- Jacobi迭代法
- Gauss-Seidel迭代法
- 迭代法的收敛性
- 解线性方程组的超松弛迭代法



# 迭代法

□ 考虑线性方程组，其中**A**为非奇异矩阵

$$\mathbf{Ax} = \mathbf{b} \quad (8.1.1)$$

- 当**A**为低阶稠密矩阵时，第7章所讨论的选主元素消去法解式(8.1.1)的有效方法
- 但是，对于由工程技术中产生的**大型稀疏矩阵**方程组（**A**的阶数**n**很大，但零元素较多，例如  $n \geq 10^4$ ），利用迭代法求解式(8.1.1)是合适的
- 在计算机内存和运算两方面，**迭代法**都可利用**A**中有大量零元素的特点



## 例8.1

### □ 求解方程组

$$\begin{cases} 8x_1 - 3x_2 + 2x_3 = 20 \\ 4x_1 + 11x_2 - x_3 = 33 \\ 6x_1 + 3x_2 + 12x_3 = 36 \end{cases} \quad (8.1.2)$$

■ 记作

$$Ax = b$$

其中

$$A = \begin{bmatrix} 8 & -3 & 2 \\ 4 & 11 & -1 \\ 6 & 3 & 12 \end{bmatrix}, \quad x = \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix}, \quad b = \begin{bmatrix} 20 \\ 33 \\ 36 \end{bmatrix}$$

■ 方程组的精确解是

$$x^* = (3, 2, 1)^T$$



## 例8.1 (续)

■ 现将式(8.1.2)

$$\begin{cases} 8x_1 - 3x_2 + 2x_3 = 20 \\ 4x_1 + 11x_2 - x_3 = 33 \\ 6x_1 + 3x_2 + 12x_3 = 36 \end{cases} \quad (8.1.2)$$

改写成

$$\begin{cases} x_1 = \frac{1}{8}(3x_2 - 2x_3 + 20) \\ x_2 = \frac{1}{11}(-4x_1 + x_3 + 33) \\ x_3 = \frac{1}{12}(-6x_1 - 3x_2 + 36) \end{cases} \quad (8.1.3)$$



## 例8.1 (续)

■ 记为 
$$x = B_0 x + f$$

其中

$$B_0 = \begin{bmatrix} 0 & \frac{3}{8} & -\frac{2}{8} \\ -\frac{4}{11} & 0 & \frac{1}{11} \\ -\frac{6}{12} & -\frac{3}{12} & 0 \end{bmatrix} = I - D^{-1}A, \quad f = \begin{bmatrix} \frac{20}{8} \\ \frac{33}{11} \\ \frac{36}{12} \end{bmatrix} = D^{-1}b$$

■ 一般推导:

$$Dx = (D - A)x + Ax = (D - A)x + b$$

$$x = D^{-1}(D - A)x + D^{-1}b = (I - D^{-1}A)x + D^{-1}b$$



## 例8.1 (续)

- 任取初始值，例如取 $\mathbf{x}^{(0)} = (0, 0, 0)^T$ ，将这些值代入式(8.1.3)右端，得到新的值

$$\mathbf{x}^{(1)} = (x_1^{(1)}, x_2^{(1)}, x_3^{(1)})^T = (3.5, 3, 3)^T$$

- ✓ 若式(8.1.3)为等式即求得方程组的解
- 再将 $\mathbf{x}^{(1)}$ 分量代入式(8.1.3)右端，得到 $\mathbf{x}^{(2)}$
- 反复利用这个计算程序，得到一向量序列

$$\mathbf{x}^{(0)} = \begin{bmatrix} x_1^{(0)} \\ x_2^{(0)} \\ x_3^{(0)} \end{bmatrix}, \quad \mathbf{x}^{(1)} = \begin{bmatrix} x_1^{(1)} \\ x_2^{(1)} \\ x_3^{(1)} \end{bmatrix}, \dots, \quad \mathbf{x}^{(k)} = \begin{bmatrix} x_1^{(k)} \\ x_2^{(k)} \\ x_3^{(k)} \end{bmatrix}, \dots$$



## 例8.1 (续)

和一般计算公式 (迭代公式)

$$\begin{cases} x_1^{(k+1)} = (3x_2^{(k)} - 2x_3^{(k)} + 20) / 8 \\ x_2^{(k+1)} = (-4x_1^{(k)} + x_3^{(k)} + 33) / 11 \\ x_3^{(k+1)} = (-6x_1^{(k)} - 3x_2^{(k)} + 36) / 12 \end{cases} \quad (8.1.4)$$

■ 简写为  $\mathbf{x}^{(k+1)} = \mathbf{B}_0 \mathbf{x}^{(k)} + \mathbf{f}$

其中  $k$  ( $k = 0, 1, 2, \dots$ ) 表示迭代次数

■ 迭代到第10次有

逐步逼近方程组的精确解  $\mathbf{x}^*$

$$\mathbf{x}^{(10)} = (3.000032, 1.999838, 0.9998813)^T$$

$$\|\boldsymbol{\varepsilon}^{(10)}\|_\infty = 0.000187 \quad (\boldsymbol{\varepsilon}^{(10)} = \mathbf{x}^{(10)} - \mathbf{x}^*)$$



# 迭代法的收敛性

□ 对于任何一个方程组： $\boldsymbol{x} = \boldsymbol{B}\boldsymbol{x} + \boldsymbol{f}$ ，按迭代法作出的向量序列 $\boldsymbol{x}^{(k)}$ 是否一定逐步逼近方程组的解 $\boldsymbol{x}^*$ 呢？

■  $\boldsymbol{x} = \boldsymbol{B}\boldsymbol{x} + \boldsymbol{f}$ 是由 $\boldsymbol{A}\boldsymbol{x} = \boldsymbol{b}$ 变形得到的等价方程组

□ 回答是**不一定**

■ 考虑用迭代法解下述方程组

$$\begin{cases} x_1 = 2x_2 + 5 \\ x_2 = 3x_1 + 5 \end{cases}$$



## 迭代法的收敛性（续）

- 对于给定方程组  $\mathbf{x} = \mathbf{B}\mathbf{x} + \mathbf{f}$ ，设有唯一解  $\mathbf{x}^*$ ，则

$$\mathbf{x}^* = \mathbf{B}\mathbf{x}^* + \mathbf{f} \quad (8.1.5)$$

- 又设  $\mathbf{x}^{(0)}$  为任取的初始向量，按下述公式构造向量序列

$$\begin{cases} \mathbf{x}^{(1)} = \mathbf{B}\mathbf{x}^{(0)} + \mathbf{f} \\ \mathbf{x}^{(2)} = \mathbf{B}\mathbf{x}^{(1)} + \mathbf{f} \\ \dots \\ \mathbf{x}^{(k+1)} = \mathbf{B}\mathbf{x}^{(k)} + \mathbf{f} \end{cases} \quad (8.1.6)$$

- $k$  表示迭代次数



# 迭代法的收敛性（续）

## □ 定义8.1

1. 对于给定的方程组  $\mathbf{x} = \mathbf{B}\mathbf{x} + \mathbf{f}$ ，用式(8.1.6)逐步代入求近似解的方法称为**迭代法**（或称一阶定常迭代法，这里  $\mathbf{B}$  与  $k$  无关）

$$\begin{cases} \mathbf{x}^{(1)} = \mathbf{B}\mathbf{x}^{(0)} + \mathbf{f} \\ \mathbf{x}^{(2)} = \mathbf{B}\mathbf{x}^{(1)} + \mathbf{f} \\ \dots \\ \mathbf{x}^{(k+1)} = \mathbf{B}\mathbf{x}^{(k)} + \mathbf{f} \end{cases} \quad (8.1.6)$$

2. 如果  $\lim_{k \rightarrow \infty} \mathbf{x}^{(k)}$  存在（记作  $\mathbf{x}^*$ ），称此迭代法**收敛**，显然  $\mathbf{x}^*$  就是方程组的解，否则称此迭代法**发散**



## 迭代法的收敛性（续）

□ 为了研究 $\{\mathbf{x}^{(k)}\}$ 的收敛性，引进误差向量

$$\boldsymbol{\varepsilon}^{(k+1)} = \mathbf{x}^{(k+1)} - \mathbf{x}^*$$

■ 由式(8.1.6)减去(8.1.5)，得

$$\left. \begin{array}{l} \mathbf{x}^* = \mathbf{B}\mathbf{x}^* + \mathbf{f} \\ \mathbf{x}^{(k+1)} = \mathbf{B}\mathbf{x}^{(k)} + \mathbf{f} \end{array} \right\} \Rightarrow \boldsymbol{\varepsilon}^{(k+1)} = \mathbf{B}\boldsymbol{\varepsilon}^{(k)} \quad (k = 0, 1, 2, \dots)$$

■ 递推得

$$\boldsymbol{\varepsilon}^{(k)} = \mathbf{B}\boldsymbol{\varepsilon}^{(k-1)} = \dots = \mathbf{B}^k \boldsymbol{\varepsilon}^{(0)}$$

■ 要考察 $\{\mathbf{x}^{(k)}\}$ 的收敛性，就要研究 $\mathbf{B}$ 在什么条件下有 $\boldsymbol{\varepsilon}^{(k)} \rightarrow \mathbf{0}$  ( $k \rightarrow \infty$ )，亦即要研究 $\mathbf{B}$ 满足什么条件时有 $\mathbf{B}^k \rightarrow \mathbf{0}$ （零矩阵）( $k \rightarrow \infty$ )



# 目录

---

□ 引言

□ Jacobi迭代法

□ Gauss-Seidel迭代法

□ 迭代法的收敛性

□ 解线性方程组的超松弛迭代法



# Jacobi (雅可比) 迭代法

□ 设有方程组

$$\sum_{j=1}^n a_{ij}x_j = b_i \quad (i = 1, 2, \dots, n)$$

■ 记作  $Ax = b$  (8.2.1)

$A$  为非奇异矩阵且  $a_{ii} \neq 0$  ( $i = 1, 2, \dots, n$ )

□ 将  $A$  分裂为  $A = D - L - U$ , 其中

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



# Jacobi迭代法 (续)

$$\mathbf{L} = - \begin{bmatrix} 0 & & & & \\ a_{21} & 0 & & & \\ a_{31} & a_{32} & 0 & & \\ \vdots & \vdots & \ddots & \ddots & \\ a_{n1} & a_{n2} & \cdots & a_{n,n-1} & 0 \end{bmatrix} \quad \mathbf{U} = - \begin{bmatrix} 0 & a_{12} & a_{13} & \cdots & a_{1n} \\ & 0 & a_{23} & \cdots & a_{2n} \\ & & 0 & \ddots & \vdots \\ & & & \ddots & a_{n-1,n} \\ & & & & 0 \end{bmatrix}$$

□ 将  $\mathbf{Ax} = \mathbf{b}$  第  $i$  ( $i = 1, 2, \dots, n$ ) 个方程用  $a_{ii}$  去除再移项, 得到等价方程组

$$x_i = \frac{1}{a_{ii}} \left( b_i - \sum_{j=1, j \neq i}^n a_{ij} x_j \right) \quad (i = 1, 2, \dots, n) \quad (8.2.2)$$



# Jacobi迭代法（续）

$$A = D - L - U$$

□ 简记作 
$$\mathbf{x} = B_0 \mathbf{x} + \mathbf{f}$$

■ 其中 
$$B_0 = I - D^{-1}A = D^{-1}(D - A) = D^{-1}(L + U)$$

$$\mathbf{f} = D^{-1}\mathbf{b}$$

□ 对方程组(8.2.2)应用迭代法，得到解式(8.2.1)的Jacobi迭代公式

$$\begin{cases} \mathbf{x}^{(0)} = (x_1^{(0)}, x_2^{(0)}, \dots, x_n^{(0)})^T \text{ (初始向量)} \\ x_i^{(k+1)} = \frac{1}{a_{ii}} \left( b_i - \sum_{j=1, j \neq i}^n a_{ij} x_j^{(k)} \right) \end{cases} \quad (8.2.3)$$

■ 其中  $\mathbf{x}^{(k)} = (x_1^{(k)}, x_2^{(k)}, \dots, x_n^{(k)})^T$  为第  $k$  次迭代向量



## Jacobi迭代法（续）

□ 显然迭代公式(8.2.3)的矩阵形式为

$$\begin{cases} \mathbf{x}^{(0)} & \text{(初始向量)} \\ \mathbf{x}^{(k+1)} = \mathbf{B}_0 \mathbf{x}^{(k)} + \mathbf{f} \end{cases} \quad (8.2.4)$$

■ 其中 $\mathbf{B}_0$ 称为Jacobi方法迭代矩阵

□ Jacobi迭代法公式简单

■ 每迭代一次只需计算一次矩阵和向量乘法

■ 在用计算机计算时，需要两组工作单元，以存储 $\mathbf{x}^{(k)}$ 及 $\mathbf{x}^{(k+1)}$



# 目录

---

□ 引言

□ Jacobi迭代法

□ Gauss-Seidel迭代法

□ 迭代法的收敛性

□ 解线性方程组的超松弛迭代法

# Gauss-Seidel (高斯-赛德尔) 迭代法



□ 由Jacobi方法迭代公式(8.2.4)可知

$$\begin{cases} \mathbf{x}^{(0)} & \text{(初始向量)} \\ \mathbf{x}^{(k+1)} = \mathbf{B}_0 \mathbf{x}^{(k)} + \mathbf{f} \end{cases} \quad (8.2.4)$$

- 迭代的每一步计算过程，都是用 $\mathbf{x}^{(k)}$ 的全部分量来计算 $\mathbf{x}^{(k+1)}$ 的所有分量
- 显然在计算第 $i$ 个分量时，已经计算出的最新分量 $x_1^{(k+1)}, x_2^{(k+1)}, \dots, x_{i-1}^{(k+1)}$ 没有被利用
- 从直观上看，最新计算出的分量可能比旧的分量要好些。因此，对这些最新计算出来的 $\mathbf{x}^{(k+1)}$ 的分量 $x_j^{(k+1)}$ 加以利用，就得到所谓解方程组的  
Gauss-Seidel迭代法（简称G-S方法）



# Gauss-Seidel迭代法 (续)

## □ Gauss-Seidel迭代法

$$\mathbf{x}^{(0)} = \left( x_1^{(0)}, x_2^{(0)}, \dots, x_n^{(0)} \right)^T \quad (\text{初始向量})$$

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

(8.2.5)

## □ Jacobi迭代公式

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



# Gauss-Seidel迭代法 (续)

## □ Gauss-Seidel迭代法

$$\mathbf{x}^{(0)} = \left( x_1^{(0)}, x_2^{(0)}, \dots, x_n^{(0)} \right)^T \quad (\text{初始向量})$$

$$x_i^{(k+1)} = \frac{1}{a_{ii}} \left( b_i - \sum_{j=1}^{i-1} a_{ij} x_j^{(k+1)} - \sum_{j=i+1}^n a_{ij} x_j^{(k)} \right)$$
$$(k = 0, 1, 2, \dots; i = 1, 2, \dots, n), \quad (8.2.5)$$

- 第2个式子利用了最新计算出的分量  $x_1^{(k+1)}$
- 第  $i$  个式子利用了计算出的最新分量  $x_j^{(k+1)}$  ( $j = 1, 2, \dots, i - 1$ )



# Gauss-Seidel迭代法 (续)

## □ Gauss-Seidel迭代法

$$\mathbf{x}^{(0)} = \left( x_1^{(0)}, x_2^{(0)}, \dots, x_n^{(0)} \right)^T \quad (\text{初始向量})$$

$$x_i^{(k+1)} = \frac{1}{a_{ii}} \left( b_i - \sum_{j=1}^{i-1} a_{ij} x_j^{(k+1)} - \sum_{j=i+1}^n a_{ij} x_j^{(k)} \right) \quad (k = 0, 1, 2, \dots; i = 1, 2, \dots, n), \quad (8.2.5)$$

■ 可写成

$$\begin{cases} x_i^{(k+1)} = x_i^{(k)} + \Delta x_i & (k = 0, 1, 2, \dots; i = 1, 2, \dots, n) \\ \Delta x_i = \frac{1}{a_{ii}} \left( b_i - \sum_{j=1}^{i-1} a_{ij} x_j^{(k+1)} - \sum_{j=i}^n a_{ij} x_j^{(k)} \right) \end{cases}$$



# Gauss-Seidel迭代法 (续)

## □ 矩阵形式

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

$$L = - \begin{bmatrix} 0 & & & & & \\ a_{21} & 0 & & & & \\ a_{31} & a_{32} & 0 & & & \\ \vdots & \vdots & \ddots & \ddots & & \\ a_{n1} & a_{n2} & \cdots & a_{n,n-1} & 0 & \end{bmatrix} \quad U = - \begin{bmatrix} 0 & a_{12} & a_{13} & \cdots & a_{1n} \\ & 0 & a_{23} & \cdots & a_{2n} \\ & & 0 & \ddots & \vdots \\ & & & \ddots & a_{n-1,n} \\ & & & & 0 \end{bmatrix}$$

## □ Jacobi迭代公式

$$\left. \begin{aligned} \mathbf{x}^{(k+1)} &= B_0\mathbf{x}^{(k)} + \mathbf{f} \\ B_0 &= D^{-1}(L + U) \\ \mathbf{f} &= D^{-1}\mathbf{b} \end{aligned} \right\} \Rightarrow D\mathbf{x}^{(k+1)} = (L + U)\mathbf{x}^{(k)} + \mathbf{b}$$



# Gauss-Seidel迭代法（续）

## □ 矩阵形式

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

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

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

■ 假设 $(D - L)^{-1}$ 存在

## □ 可改写为

$$\mathbf{x}^{(k+1)} = G\mathbf{x}^{(k)} + \mathbf{f} \quad (8.2.6)$$

$$G = (D - L)^{-1}U, \quad \mathbf{f} = (D - L)^{-1}\mathbf{b}$$

## □ Jacobi迭代公式

$$\mathbf{x}^{(k+1)} = B_0\mathbf{x}^{(k)} + \mathbf{f}$$



## Gauss-Seidel迭代法（续）

- 应用Gauss-Seidel迭代法解式(8.2.1)就是对方程组  $\mathbf{x} = \mathbf{G}\mathbf{x} + \mathbf{f}$  应用迭代法
  - $\mathbf{G}$ 称为Gauss-Seidel迭代法的迭代矩阵
  
- Gauss-Seidel迭代法的一个明显的优点是，在用计算机计算时，只需一组工作单元，以便存放近似解，此外，每迭代一步只需计算一次矩阵与向量的乘法

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



## 例8.2

□ 用Gauss-Seidel迭代法解例8.1

$$\begin{cases} 8x_1 - 3x_2 + 2x_3 = 20 \\ 4x_1 + 11x_2 - x_3 = 33 \\ 6x_1 + 3x_2 + 12x_3 = 36 \end{cases} \quad (8.1.2)$$

■ 取 $\mathbf{x}^{(0)} = \mathbf{0}$ ，迭代公式为

$$\begin{cases} x_1^{(k+1)} = (20 + 3x_2^{(k)} - 2x_3^{(k)})/8 \\ x_2^{(k+1)} = (33 - 4x_1^{(k+1)} + x_3^{(k)})/11 \\ x_3^{(k+1)} = (36 - 6x_1^{(k+1)} - 3x_2^{(k+1)})/12 \end{cases}$$



## 例8.2（续）

- 迭代到第5次时，有

$$\boldsymbol{x}^{(5)} = (2.999843, 2.000072, 1.000061)^T$$

$$\|\boldsymbol{\varepsilon}^{(5)}\|_{\infty} = 0.00157$$

- 从此例看出，Gauss-Seidel迭代法比Jacobi迭代法收敛快（达到同样的精度所需的迭代次数较少）
- 但这个结论在**一定条件下才是对的**，甚至有这样的方程组，Jacobi方法收敛，而Gauss-Seidel迭代法却是发散的



## 例8.3

### □ 方程组

$$\begin{cases} x_1 + 2x_2 - 2x_3 = 1 \\ x_1 + x_2 + x_3 = 1 \\ 2x_1 + 2x_2 + x_3 = 1 \end{cases}$$

- 能够说明解此方程组的Jacobi迭代法收敛而Gauss-Seidel迭代法发散



# 目录

---

- 引言
- Jacobi迭代法
- Gauss-Seidel迭代法
- 迭代法的收敛性
- 解线性方程组的超松弛迭代法



# 矩阵收敛

□ **定义8.2** 设有矩阵序列  $\mathbf{A}_k = (a_{ij}^{(k)})_{n \times n} (k = 1, 2, \dots)$  及  $\mathbf{A} = (a_{ij})_{n \times n}$ , 如果

$$\lim_{k \rightarrow \infty} a_{ij}^{(k)} = a_{ij} \quad (i, j = 1, 2, \dots, n)$$

成立, 则称  $\{\mathbf{A}_k\}$  收敛于  $\mathbf{A}$ , 记作  $\lim_{k \rightarrow \infty} \mathbf{A}_k = \mathbf{A}$

□ **例8.4** 矩阵序列

$$\mathbf{A} = \begin{pmatrix} \lambda & 1 \\ 0 & \lambda \end{pmatrix}, \mathbf{A}^2 = \begin{pmatrix} \lambda^2 & 2\lambda \\ 0 & \lambda^2 \end{pmatrix}, \dots, \mathbf{A}^k = \begin{pmatrix} \lambda^k & k\lambda^{k-1} \\ 0 & \lambda^k \end{pmatrix}, \dots,$$

当  $|\lambda| < 1$  时,  $\mathbf{A}^k \rightarrow \begin{pmatrix} 0 & 0 \\ 0 & 0 \end{pmatrix}$  (当  $k \rightarrow \infty$  时)



## 矩阵收敛（续）

- 矩阵序列极限的概念可以用任何矩阵范数来描述
- 定理8.1  $\lim_{k \rightarrow \infty} \mathbf{A}_k = \mathbf{A}$ 的充要条件是  $\|\mathbf{A}_k - \mathbf{A}\| \rightarrow 0$  ( $k \rightarrow \infty$ )
- 由8.1节知，要考虑序列 $\{\mathbf{x}^{(k)}\}$ 的收敛性，就要研究 $\mathbf{B}$ 在什么条件下误差向量趋于零向量，即
$$\boldsymbol{\varepsilon}^{(k)} = \mathbf{x}^{(k)} - \mathbf{x}^* = \mathbf{B}^k \boldsymbol{\varepsilon}^{(0)} \rightarrow \mathbf{0} \quad (k \rightarrow \infty)$$



# 迭代法收敛的充要条件

□ **定理8.2** 设  $B = (b_{ij})_{n \times n}$ , 则  $B^k \rightarrow O (k \rightarrow \infty)$  的充要条件是  $\rho(B) < 1$

■ 由矩阵  $B$  的 Jordan 标准形, 存在非奇异矩阵  $P$ , 使

$$P^{-1}BP = \begin{bmatrix} J_1 & & & \\ & J_2 & & \\ & & \ddots & \\ & & & J_r \end{bmatrix} \equiv J \quad J_i = \begin{bmatrix} \lambda_i & 1 & & & \\ & \lambda_i & 1 & & \\ & & \ddots & \ddots & \\ & & & \ddots & 1 \\ & & & & \lambda_i \end{bmatrix}_{n_i \times n_i}$$

其中  $\lambda_i$  为第  $i$  个特征值,  $\sum_{i=1}^r n_i = n$



## 定理8.2证明

- 显然  $B = PJP^{-1}$ , 故

$$B^k = (PJP^{-1})^k = PJ^k P^{-1}$$

其中

$$J^k = \begin{bmatrix} J_1^k & & & \\ & J_2^k & & \\ & & \ddots & \\ & & & J_r^k \end{bmatrix} (k = 1, 2, \dots)$$

- 于是

$$B^k \rightarrow \mathbf{O} \quad (k \rightarrow \infty) \Leftrightarrow J^k \rightarrow \mathbf{O} \quad (k \rightarrow \infty)$$

$$J^k \rightarrow \mathbf{O} (k \rightarrow \infty) \Leftrightarrow J_i^k \rightarrow \mathbf{O} (k \rightarrow \infty) \quad (i = 1, 2, \dots, r)$$



## 定理8.2证明 (续)

■ 引进记号

$$\mathbf{E}_{tk} = \begin{bmatrix} \overbrace{0 \ \cdots \ 0}^{k \text{ 个}} & 1 & 0 & \cdots & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & \cdots & 0 & 1 & 0 & \cdots & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & \cdots & 0 & \vdots & \vdots & \vdots & 1 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & \cdots & 0 & \vdots & \vdots & \vdots & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & \cdots & 0 & \vdots & \vdots & \vdots & 0 \end{bmatrix}_{t \times t} \quad (\text{其中 } t = n_i)$$

- 可以证明当  $k < t$  时,  $(\mathbf{E}_{t1})^k = \mathbf{E}_{tk}$ ; 当  $k \geq t$  时  $(\mathbf{E}_{t1})^k = \mathbf{O}$



## 定理8.2证明 (续)

■ 显然

$$J_i = \begin{bmatrix} \lambda_i & & & \\ & \lambda_i & & \\ & & \ddots & \\ & & & \ddots & \\ & & & & \lambda_i \end{bmatrix} + \begin{bmatrix} 0 & 1 & & \\ & 0 & 1 & \\ & & \ddots & \ddots \\ & & & \ddots & 1 \\ & & & & 0 \end{bmatrix}$$
$$= \lambda_i \mathbf{I} + \mathbf{E}_{t1}$$

■ 可得

$$J_i^k = (\lambda_i \mathbf{I} + \mathbf{E}_{t1})^k = \sum_{j=0}^k \binom{k}{j} \lambda_i^{k-j} (\mathbf{E}_{t1})^j = \sum_{j=0}^k \binom{k}{j} \lambda_i^{k-j} \mathbf{E}_{tj}$$

(当  $k \geq t$  时  $\mathbf{E}_{tk} = \mathbf{O}$ )

$$= \sum_{j=0}^{t-1} \binom{k}{j} \lambda_i^{k-j} \mathbf{E}_{tj}$$



## 定理8.2证明 (续)

■ 进而

$$J_i^k = (\lambda_i I + E_{t1})^k = \sum_{j=0}^{t-1} \binom{k}{j} \lambda_i^{k-j} E_{tj}$$

$$= \begin{bmatrix} \lambda_i^k & \binom{k}{1} \lambda_i^{k-1} & \dots & \dots & \binom{k}{t-1} \lambda_i^{k-(t-1)} \\ & \lambda_i^k & \binom{k}{1} \lambda_i^{k-1} & \dots & \binom{k}{t-2} \lambda_i^{k-(t-2)} \\ & & \ddots & \ddots & \vdots \\ & & & \ddots & \binom{k}{1} \lambda_i^{k-1} \\ & & & & \lambda_i^k \end{bmatrix}$$

$$\text{其中 } \binom{k}{j} = \frac{k!}{j!(k-j)!} = \frac{k(k-1)\cdots(k-j+1)}{j!}$$



## 定理8.2证明 (续)

- 利用极限  $\lim_{k \rightarrow \infty} k^r c^k = 0$  ( $0 < c < 1, r \geq 0$ ), 得到

$$\binom{k}{j} \lambda^{k-j} \rightarrow 0 \quad (k \rightarrow \infty) \Leftrightarrow |\lambda| < 1$$

✓ 注意到

$$\binom{k}{j} = \frac{k!}{j!(k-j)!} = \frac{k(k-1)\cdots(k-j+1)}{j!}$$

- 所以  $\mathbf{J}_i^k \rightarrow \mathbf{O}$  ( $k \rightarrow \infty$ ) 充要条件是  $|\lambda_i| < 1$  ( $i = 1, 2, \dots, r$ ), 即  $\rho(\mathbf{B}) < 1$



# 迭代法基本定理

## □ 定理8.3 设有方程组

$$\boldsymbol{x} = \boldsymbol{B}\boldsymbol{x} + \boldsymbol{f} \quad (8.3.1)$$

对于任意初始向量 $\boldsymbol{x}^{(0)}$ 及任意 $\boldsymbol{f}$ ，解此方程组的迭代法

$$\boldsymbol{x}^{(k+1)} = \boldsymbol{B}\boldsymbol{x}^{(k)} + \boldsymbol{f}$$

收敛的充要条件是 $\rho(\boldsymbol{B}) < 1$

## □ 充分性

■ 设 $\rho(\boldsymbol{B}) < 1$ ，由定理7.18， $\boldsymbol{A} = \boldsymbol{I} - \boldsymbol{B}$ 为非奇异矩阵。因此， $\boldsymbol{A}\boldsymbol{x} = (\boldsymbol{I} - \boldsymbol{B})\boldsymbol{x} = \boldsymbol{f}$ 有唯一解，记作

$$\boldsymbol{x}^* = \boldsymbol{B}\boldsymbol{x}^* + \boldsymbol{f} \quad (8.3.2)$$



## 定理8.3证明

- 误差向量

$$\boldsymbol{\varepsilon}^{(k)} = \boldsymbol{x}^{(k)} - \boldsymbol{x}^* = \boldsymbol{B}^k \boldsymbol{\varepsilon}^{(0)}, \quad \boldsymbol{\varepsilon}^{(0)} = \boldsymbol{x}^{(0)} - \boldsymbol{x}^*$$

- 由于  $\rho(\boldsymbol{B}) < 1$ , 应用定理8.2, 有  $\boldsymbol{B}^k \rightarrow \mathbf{0}$  ( $k \rightarrow \infty$ ).
- 于是对于任意  $\boldsymbol{x}^{(0)}$  及  $\boldsymbol{f}$ , 有  $\boldsymbol{\varepsilon}^{(k)} \rightarrow \mathbf{0}$  ( $k \rightarrow \infty$ ), 即  $\boldsymbol{x}^{(k)} \rightarrow \boldsymbol{x}^*$  ( $k \rightarrow \infty$ )

### □ 必要性

- 设对于任意  $\boldsymbol{x}^{(0)}$  及任意  $\boldsymbol{f}$ , 皆有  $\lim_{k \rightarrow \infty} \boldsymbol{x}^{(k)} = \boldsymbol{x}^*$ , 其中  $\boldsymbol{x}^{(k+1)} = \boldsymbol{B}\boldsymbol{x}^{(k)} + \boldsymbol{f}$



## 定理8.3证明（续）

■ 显然，

1. 极限 $\boldsymbol{x}^*$ 是方程组 $\boldsymbol{x} = \boldsymbol{B}\boldsymbol{x} + \boldsymbol{f}$ 的解
2. 对于任意 $\boldsymbol{x}^{(0)}$ 及任意 $\boldsymbol{f}$ ，有

$$\boldsymbol{\varepsilon}^{(k)} = \boldsymbol{x}^{(k)} - \boldsymbol{x}^* = \boldsymbol{B}^k \boldsymbol{\varepsilon}^{(0)} \rightarrow \mathbf{0} \quad (k \rightarrow \infty)$$

- 由第2点可知， $\boldsymbol{B}^k \rightarrow \mathbf{0} \quad (k \rightarrow \infty)$
- 再次应用定理8.2，即得 $\rho(\boldsymbol{B}) < 1$



## 例8.5

□ 考察用Jacobi方法解例8.1方程组的收敛性

$$\begin{cases} 8x_1 - 3x_2 + 2x_3 = 20 \\ 4x_1 + 11x_2 - x_3 = 33 \\ 6x_1 + 3x_2 + 12x_3 = 36 \end{cases} \quad (8.1.2)$$

■ Jacobi方法

$$\boldsymbol{x} = \boldsymbol{B}_0 \boldsymbol{x} + \boldsymbol{f}$$

其中

$$\boldsymbol{B}_0 = \begin{bmatrix} 0 & \frac{3}{8} & -\frac{2}{8} \\ -\frac{4}{11} & 0 & \frac{1}{11} \\ -\frac{6}{12} & -\frac{3}{12} & 0 \end{bmatrix}$$



## 例8.5 (续)

- 迭代矩阵 $\mathbf{B}_0$ 的特征方程为

$$\det(\lambda \mathbf{I} - \mathbf{B}_0) = \lambda^3 + 0.034090909\lambda + 0.039772727 = 0$$

- 解得
$$\lambda_1 = -0.3082$$
$$\lambda_2 = 0.1541 + i0.3245$$
$$\lambda_3 = 0.1541 - i0.3245,$$

- 可知
$$|\lambda_1| < 1, \quad |\lambda_2| = |\lambda_3| = 0.3592 < 1$$

即 $\rho(\mathbf{B}_0) < 1$ , 所以用Jacobi迭代法是收敛的



## 例8.6

□ 考察用迭代过程的收敛性。

$$\mathbf{x}^{(k+1)} = \mathbf{B}\mathbf{x}^{(k)} + \mathbf{f} \quad (k = 0, 1, 2, \dots)$$

□ 其中  $\mathbf{B} = \begin{pmatrix} 0 & 2 \\ 3 & 0 \end{pmatrix}$ ,  $\mathbf{f} = \begin{pmatrix} 5 \\ 5 \end{pmatrix}$

■ 特征方程为

$$\det(\lambda \mathbf{I} - \mathbf{B}) = \lambda^2 - 6 = 0$$

■ 特征根  $\lambda_{1,2} = \pm\sqrt{6}$ , 即  $\rho(\mathbf{B}) > 1$

■ 说明此迭代过程不收敛



# 迭代法的收敛速度

□ 考察误差向量  $\boldsymbol{\varepsilon}^{(k)} = \boldsymbol{x}^{(k)} - \boldsymbol{x}^* = \boldsymbol{B}^k \boldsymbol{\varepsilon}^{(0)}$

■ 设  $\boldsymbol{B}$  有  $n$  个线性无关的特征向量  $\boldsymbol{u}_1, \boldsymbol{u}_2, \dots, \boldsymbol{u}_n$ , 相应的特征值为  $\lambda_1, \lambda_2, \dots, \lambda_n$

■ 由于线性无关假设,  $\boldsymbol{\varepsilon}^{(0)} = \sum_{i=1}^n a_i \boldsymbol{u}_i$ , 得

$$\boldsymbol{\varepsilon}^{(k)} = \boldsymbol{B}^k \boldsymbol{\varepsilon}^{(0)} = \sum_{i=1}^n a_i \boldsymbol{B}^k \boldsymbol{u}_i = \sum_{i=1}^n a_i \lambda_i^k \boldsymbol{u}_i$$

■ 可以看出, 当  $\rho(\boldsymbol{B}) < 1$  愈小时,  $\lambda_i^k \rightarrow 0$  ( $i = 1, 2, \dots, n; k \rightarrow \infty$ ) 愈快, 即  $\boldsymbol{\varepsilon}^{(k)} \rightarrow \mathbf{0}$  愈快, 故可用量  $\rho(\boldsymbol{B})$  来刻画迭代法的收敛快慢



## 迭代法的收敛速度（续）

- 现在依据给定精度要求来确定迭代次数 $k$ ，即使

$$[\rho(\mathbf{B})]^k \leq 10^{-s} \quad (8.3.3)$$

- 取对数得

$$k \geq \frac{s \ln 10}{-\ln \rho(\mathbf{B})}$$

- **定义8.3** 称 $R(\mathbf{B}) = -\ln \rho(\mathbf{B})$ 为迭代法的**收敛速度**

- 可以看出 $\rho(\mathbf{B}) < 1$ 愈小， $-\ln \rho(\mathbf{B})$ 就愈大，式(8.3.3)成立所需迭代次数就愈少



# 迭代矩阵的特征值

## □ 矩阵特征值的重要性

- 定理8.3表明迭代法收敛的充要条件是 $\rho(\mathbf{B}) < 1$
- 收敛速度由 $R(\mathbf{B}) = -\ln \rho(\mathbf{B})$ 决定

## □ 一般当 $n$ 较大时，矩阵特征值计算比较困难

- 定理8.3的条件比较难验证，所以最好建立与矩阵元素直接有关的条件来判别迭代法的收敛性
- 由于 $\rho(\mathbf{B}) \leq \|\mathbf{B}\|_v$  ( $v = 1, 2, \infty$  或  $F$ )，所以可用 $\|\mathbf{B}\|_v$ 来作为 $\rho(\mathbf{B})$ 上界的一种估计



# 迭代法收敛的充分条件

□ **定理8.4** 如果方程组  $\mathbf{x} = \mathbf{B}\mathbf{x} + \mathbf{f}$  的迭代公式为

$$\mathbf{x}^{(k+1)} = \mathbf{B}\mathbf{x}^{(k)} + \mathbf{f}$$

其中  $\mathbf{x}^0$  为任意初始向量，且迭代矩阵的某一范数  $\|\mathbf{B}\|_v = q < 1$ ，则：

1. 迭代法收敛

2.  $\|\mathbf{x}^* - \mathbf{x}^{(k)}\|_v \leq \frac{q}{1-q} \|\mathbf{x}^{(k)} - \mathbf{x}^{(k-1)}\|_v$

3.  $\|\mathbf{x}^* - \mathbf{x}^{(k)}\|_v \leq \frac{q^k}{1-q} \|\mathbf{x}^{(1)} - \mathbf{x}^{(0)}\|_v$



## 定理8.4证明

- 根据定理8.3和 $\rho(\mathbf{B}) \leq \|\mathbf{B}\|_v$ ，第1点显然成立

- 由 
$$\mathbf{x}^* = \mathbf{B}\mathbf{x}^* + \mathbf{f}$$

$$\mathbf{x}^{(k+1)} = \mathbf{B}\mathbf{x}^{(k)} + \mathbf{f}$$

可得

$$\mathbf{x}^* - \mathbf{x}^{(k+1)} = \mathbf{B}(\mathbf{x}^* - \mathbf{x}^{(k)}) \quad (8.3.4)$$

- 根据范数性质，可得

$$\begin{aligned} \|\mathbf{x}^* - \mathbf{x}^{(k+1)}\|_v &= \|\mathbf{B}(\mathbf{x}^* - \mathbf{x}^{(k)})\|_v \\ &\leq \|\mathbf{B}\|_v \|\mathbf{x}^* - \mathbf{x}^{(k)}\|_v = q \|\mathbf{x}^* - \mathbf{x}^{(k)}\|_v \end{aligned} \quad (8.3.6)$$

$(k = 1, 2, \dots)$

$$\|\mathbf{x}^* - \mathbf{x}^{(k+1)}\|_v \leq q \|\mathbf{x}^* - \mathbf{x}^{(k)}\|_v$$



## 定理8.4证明 (续)

(8.3.6)

- 类似可得,

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

- 因此,

$$\|\mathbf{x}^{(k+1)} - \mathbf{x}^{(k)}\|_v \leq q \|\mathbf{x}^{(k)} - \mathbf{x}^{(k-1)}\|_v \quad (8.3.5)$$

- 另一方面,

$$\begin{aligned} \|\mathbf{x}^{(k+1)} - \mathbf{x}^{(k)}\|_v &= \|\mathbf{x}^* - \mathbf{x}^{(k)} - (\mathbf{x}^* - \mathbf{x}^{(k+1)})\|_v \\ &\geq \|\mathbf{x}^* - \mathbf{x}^{(k)}\|_v - \|\mathbf{x}^* - \mathbf{x}^{(k+1)}\|_v \\ &\geq (1 - q) \|\mathbf{x}^* - \mathbf{x}^{(k)}\|_v \end{aligned}$$



$$\|\mathbf{x}^{(k+1)} - \mathbf{x}^{(k)}\|_v \leq q \|\mathbf{x}^{(k)} - \mathbf{x}^{(k-1)}\|_v$$

## 定理8.4证明（续）

(8.3.5)

■ 结合  $\|\mathbf{x}^{(k+1)} - \mathbf{x}^{(k)}\|_v \leq q \|\mathbf{x}^{(k)} - \mathbf{x}^{(k-1)}\|_v$

$$\|\mathbf{x}^{(k+1)} - \mathbf{x}^{(k)}\|_v \geq (1 - q) \|\mathbf{x}^* - \mathbf{x}^{(k)}\|_v$$

可证明第2点成立：

$$\|\mathbf{x}^* - \mathbf{x}^{(k)}\|_v \leq \frac{q}{1 - q} \|\mathbf{x}^{(k)} - \mathbf{x}^{(k-1)}\|_v$$

■ 对上式重复利用(8.3.5)，可得第3点成立：

$$\|\mathbf{x}^* - \mathbf{x}^{(k)}\|_v \leq \frac{q^k}{1 - q} \|\mathbf{x}^{(1)} - \mathbf{x}^{(0)}\|_v$$



## 例8.7

□ 任然考察例8.1，Jacobi方法

$$\boldsymbol{x} = \boldsymbol{B}_0 \boldsymbol{x} + \boldsymbol{f} \quad \boldsymbol{B}_0 = \begin{bmatrix} 0 & \frac{3}{8} & -\frac{2}{8} \\ -\frac{4}{11} & 0 & \frac{1}{11} \\ -\frac{6}{12} & -\frac{3}{12} & 0 \end{bmatrix}$$

■ 迭代矩阵 $\boldsymbol{B}_0$ 的 $\infty$ -范数为

$$\|\boldsymbol{B}\|_{\infty} = \max_{1 \leq i \leq 3} \sum_{j=1}^3 |b_{ij}| = \max \left\{ \frac{5}{8}, \frac{5}{11}, \frac{9}{12} \right\} = \frac{9}{12} < 1$$

■ 所以对例8.1应用Jacobi迭代方法是收敛的



## 例8.8

□ 设有迭代过程  $\boldsymbol{x}^{(k+1)} = \boldsymbol{B}\boldsymbol{x}^{(k)} + \boldsymbol{f}$  ( $k = 0, 1, 2, \dots$ ), 其中

$$\boldsymbol{B} = \begin{pmatrix} 0.9 & 0 \\ 0.3 & 0.8 \end{pmatrix}, \quad \boldsymbol{f} = \begin{pmatrix} 1 \\ 2 \end{pmatrix}$$

■ 可得

$$\|\boldsymbol{B}\|_{\infty} = 1.1, \quad \|\boldsymbol{B}\|_1 = 1.2$$

$$\|\boldsymbol{B}\|_2 = 1.021, \quad \|\boldsymbol{B}\|_F = \sqrt{1.54}$$

■ 虽然  $\boldsymbol{B}$  的这些范数都大于1, 但  $\boldsymbol{B}$  的特征值为  $\lambda_1 = 0.9, \lambda_2 = 0.8$ , 由定理8.3知, 此迭代过程还是收敛的



## 定理8.4的应用

□ 由定理8.4可知,  $\|B\| = q < 1$ 愈小, 迭代法收敛愈快

□ 当 $B$ 的某一种范数 $\|B\| < 1$ 时, 如果相邻两次迭代

$$\|\mathbf{x}^{(k)} - \mathbf{x}^{(k-1)}\| < \varepsilon_0$$

$\varepsilon_0$ 为给定的精度要求, 则

$$\|\mathbf{x}^* - \mathbf{x}^{(k)}\| \leq \frac{q}{1-q} \|\mathbf{x}^{(k)} - \mathbf{x}^{(k-1)}\|_v \leq \frac{q}{1-q} \varepsilon_0$$

所以在用计算机计算时通常利用 $\|\mathbf{x}^{(k)} - \mathbf{x}^{(k-1)}\| < \varepsilon_0$ 来作为控制迭代的终止条件



## 定理8.4的应用（续）

- 不过要注意，当 $q \approx 1$ 时， $\frac{q}{1-q}$ 大，尽管 $\|\mathbf{x}^{(k)} - \mathbf{x}^{(k-1)}\|$ 已非常小，但误差向量的模 $\|\boldsymbol{\varepsilon}^{(k)}\| = \|\mathbf{x}^* - \mathbf{x}^{(k)}\|$ 可能较大，迭代法收敛将是缓慢的

- 定理8.4中结论3的估计可以用来事先确定需要迭代多少次才能保证 $\|\boldsymbol{\varepsilon}^{(k)}\| < \varepsilon_0$

$$\|\mathbf{x}^* - \mathbf{x}^{(k)}\|_v \leq \frac{q^k}{1-q} \|\mathbf{x}^{(1)} - \mathbf{x}^{(0)}\|_v$$



# Gauss-Seidel迭代法的收敛性

□ 定理8.5 解方程组 $Ax = b$ 的Gauss-Seidel迭代法收敛的充要条件是 $\rho(G) < 1$ ，其中 $G$ 为Gauss-Seidel迭代法的迭代矩阵

■ Gauss-Seidel迭代法

$$x^{(k+1)} = Gx^{(k)} + f \quad (8.2.6)$$

■ 对式(8.2.6)应用定理8.3



# 特殊系数矩阵

- 在实际应用中常遇到一些线性代数方程组，其系数矩阵具有某些性质
  - 系数矩阵的对角元素占优
  - 系数矩阵可约、不可约
  - 系数矩阵为对称正定等
  
- 充分利用这些性质往往可使判定迭代法收敛的问题变得简单



# 对角占优矩阵

□ 定义8.4 (对角占优阵) 设  $\mathbf{A} = (a_{ij})_{n \times n} \in \mathbf{R}^{n \times n}$

1. 如果矩阵 $\mathbf{A}$ 满足条件

$$|a_{ii}| > \sum_{j=1, j \neq i}^n |a_{ij}| \quad (i = 1, 2, \dots, n)$$

即 $\mathbf{A}$ 的每一行对角元素的绝对值都严格大于同行其他元素绝对值之和, 则称 $\mathbf{A}$ 为严格对角占优阵

2. 如果  $|a_{ii}| \geq \sum_{j=1, j \neq i}^n |a_{ij}|$  ( $i = 1, 2, \dots, n$ ) 且至少有一个不等式严格成立, 称 $\mathbf{A}$ 为弱对角占优阵



## 例8.9

□ 显然

■  $A = \begin{bmatrix} -4 & 1 & 0 & 0 \\ 1 & -4 & 1 & 0 \\ 0 & 1 & -4 & 1 \\ 0 & 0 & 1 & -4 \end{bmatrix}$  为严格对角占优阵

■  $B = \begin{bmatrix} 1 & 1 & 0 \\ 1 & 1 & 0 \\ 0 & 1 & 2 \end{bmatrix}$  为弱对角占优阵



## 可约与不可约矩阵

□ **定义 8.5** (可约与不可约矩阵) 设  $\mathbf{A} = (a_{ij})_{n \times n} \in \mathbf{R}^{n \times n}$ , 当  $n \geq 2$  时, 如果存在  $n$  阶置换阵  $\mathbf{P}$  使

$$\mathbf{P}^T \mathbf{A} \mathbf{P} = \begin{bmatrix} \mathbf{A}_{11} & \mathbf{A}_{12} \\ \mathbf{0} & \mathbf{A}_{22} \end{bmatrix} \quad (8.3.8)$$

成立, 其中  $\mathbf{A}_{11}$  为  $r$  阶子矩阵,  $\mathbf{A}_{22}$  为  $n - r$  阶子矩阵 ( $1 \leq r \leq n$ ), 则称  $\mathbf{A}$  是**可约矩阵**。如果不存在置换阵  $\mathbf{P}$  使式(8.3.8)成立, 则称  $\mathbf{A}$  是**不可约矩阵**



## 可约与不可约矩阵（续）

- $\mathbf{A}$ 是可约矩阵，意味着 $\mathbf{Ax} = \mathbf{b}$ 可经过若干行列重排，化为两个低阶方程组求解
  - 若 $\mathbf{A}$ 经过两行交换的同时进行相应的两列的交换，称对 $\mathbf{A}$ 进行一次行列重排
- 由 $\mathbf{Ax} = \mathbf{b}$ 可化为 $\mathbf{P}^T \mathbf{A} \mathbf{P} (\mathbf{P}^T \mathbf{x}) = \mathbf{P}^T \mathbf{b}$ ，记

$$\mathbf{y} = \mathbf{P}^T \mathbf{x} = \begin{bmatrix} \mathbf{y}_1 \\ \mathbf{y}_2 \end{bmatrix}, \quad \mathbf{P}^T \mathbf{b} = \begin{bmatrix} \mathbf{d}_1 \\ \mathbf{d}_2 \end{bmatrix}$$

其中 $\mathbf{y}_1, \mathbf{d}_1$ 为 $r$ 维向量

- $\mathbf{Ax} = \mathbf{b}$ 可化为求解  $\begin{bmatrix} \mathbf{A}_{11} & \mathbf{A}_{12} \\ \mathbf{0} & \mathbf{A}_{22} \end{bmatrix} \begin{bmatrix} \mathbf{y}_1 \\ \mathbf{y}_2 \end{bmatrix} = \begin{bmatrix} \mathbf{d}_1 \\ \mathbf{d}_2 \end{bmatrix}$



## 可约与不可约矩阵（续）

- $\mathbf{A}$ 是可约矩阵，意味着 $\mathbf{Ax} = \mathbf{b}$ 可经过若干行列重排，化为两个低阶方程组求解
  - 若 $\mathbf{A}$ 经过两行交换的同时进行相应的两列的交换，称对 $\mathbf{A}$ 进行一次行列重排
- 由 $\mathbf{Ax} = \mathbf{b}$ 可化为 $\mathbf{P}^T \mathbf{A} \mathbf{P} (\mathbf{P}^T \mathbf{x}) = \mathbf{P}^T \mathbf{b}$ ，记

$$\mathbf{y} = \mathbf{P}^T \mathbf{x} = \begin{bmatrix} \mathbf{y}_1 \\ \mathbf{y}_2 \end{bmatrix}, \quad \mathbf{P}^T \mathbf{b} = \begin{bmatrix} \mathbf{d}_1 \\ \mathbf{d}_2 \end{bmatrix}$$

其中 $\mathbf{y}_1, \mathbf{d}_1$ 为 $r$ 维向量

- $\mathbf{Ax} = \mathbf{b}$ 可化为求解 
$$\begin{cases} \mathbf{A}_{11} \mathbf{y}_1 + \mathbf{A}_{12} \mathbf{y}_2 = \mathbf{d}_1 \\ \mathbf{A}_{22} \mathbf{y}_2 = \mathbf{d}_2 \end{cases}$$



## 例8.10

□ 在例8.9中矩阵***B***是可约矩阵

$$\mathbf{B} = \begin{bmatrix} 1 & 1 & 0 \\ 1 & 1 & 0 \\ 0 & 1 & 2 \end{bmatrix}$$

■ 即存在置换阵  $\mathbf{P} = \mathbf{I}_{13}$ , 使

$$\mathbf{P}^T \mathbf{B} \mathbf{P} = \begin{bmatrix} 2 & 1 & 0 \\ 0 & 1 & 1 \\ 0 & 1 & 1 \end{bmatrix}$$



# 对角占优定理

□ **定理8.6** 如果  $\mathbf{A} = (a_{ij})_{n \times n} \in \mathbf{R}^{n \times n}$  为严格对角占优阵或不可约弱对角占优阵，则  $\mathbf{A}$  是非奇异矩阵

■ 设  $\mathbf{A}$  为严格对角占优阵，下面只就这种情况证明此定理

■ 若  $\det \mathbf{A} = 0$ ，则  $\mathbf{A}\mathbf{x} = \mathbf{0}$  有非零解，记作

$$\mathbf{x} = (x_1, x_2, \dots, x_n)^T$$

■ 又记  $x_k = \max_{1 \leq i \leq n} |x_i| \neq 0$



## 对角占优定理（续）

- 由齐次方程组  $\mathbf{Ax} = \mathbf{0}$  的第  $k$  个方程

$$\sum_{j=1}^n a_{kj}x_j = 0$$

可得

$$|a_{kk}x_k| = \left| \sum_{\substack{j=1 \\ j \neq k}}^n a_{kj}x_j \right| \leq \sum_{\substack{j=1 \\ j \neq k}}^n |a_{kj}| |x_j| \leq |x_k| \sum_{\substack{j=1 \\ j \neq k}}^n |a_{kj}|$$

- 因此

$$|a_{kk}| \leq \sum_{\substack{j=1 \\ j \neq k}}^n |a_{kj}|$$

与假设矛盾，故  $\det \mathbf{A} \neq 0$ ，即  $\mathbf{A}$  非奇异阵



# 面向对角占优矩阵的收敛条件

□ **定理8.7** 如果  $A \in \mathbf{R}^{n \times n}$  为严格对角占优阵或为不可约弱对角占优阵，则对于任意的  $\mathbf{x}^{(0)}$ ，解方程组  $A\mathbf{x} = \mathbf{b}$  的Jacobi迭代法，Gauss-Seidel迭代法均收敛

■ 设  $A$  为不可约弱对角占优阵，现证明Gauss-Seidel迭代法收敛

■ 对于方程组  $A\mathbf{x} = \mathbf{b}$ ，Gauss-Seidel迭代法为

$$\mathbf{x}^{(k+1)} = G\mathbf{x}^{(k)} + \mathbf{f}$$

■ 迭代矩阵为

$$G = (D - L)^{-1}U$$



## 定理8.7证明

$$\mathbf{G} = (\mathbf{D} - \mathbf{L})^{-1}\mathbf{U}$$

- 根据定理8.3, 如果 $\mathbf{G}$ 的特征值小于1, 则Gauss-Seidel迭代法收敛

- 令 $\lambda$ 为 $\mathbf{G}$ 的特征值, 则

$$\begin{aligned}\det(\lambda\mathbf{I} - \mathbf{G}) &= \det(\lambda\mathbf{I} - (\mathbf{D} - \mathbf{L})^{-1}\mathbf{U}) \\ &= \det((\mathbf{D} - \mathbf{L})^{-1}(\lambda(\mathbf{D} - \mathbf{L}) - \mathbf{U})) \\ &= \det((\mathbf{D} - \mathbf{L})^{-1}) \cdot \det(\lambda(\mathbf{D} - \mathbf{L}) - \mathbf{U}) = 0\end{aligned}$$

- 可得

$$\det(\lambda(\mathbf{D} - \mathbf{L}) - \mathbf{U}) = 0$$

- 接下来, 将证明当 $|\lambda| \geq 1$ 时 $\det(\lambda(\mathbf{D} - \mathbf{L}) - \mathbf{U}) \neq 0$



## 定理8.7证明 (续)

■ 根据***D***、***L***和***U***的定义

$$C = \lambda(D - L) - U$$

$$= \begin{bmatrix} \lambda a_{11} & a_{12} & a_{13} & \cdots & a_{1n} \\ \lambda a_{21} & \lambda a_{22} & a_{23} & \cdots & a_{2n} \\ \vdots & \lambda a_{31} & \ddots & \ddots & \vdots \\ \vdots & \vdots & \ddots & \ddots & a_{n-1,n} \\ \lambda a_{n1} & \lambda a_{n2} & \cdots & \lambda a_{n,n-1} & \lambda a_{nn} \end{bmatrix} = (c_{ij})_{n \times n}$$

$$D = \text{diag}(a_{11}, a_{22}, \dots, a_{nn})$$

$$L = - \begin{bmatrix} 0 & & & & \\ a_{21} & 0 & & & \\ a_{31} & a_{32} & 0 & & \\ \vdots & \vdots & \ddots & \ddots & \\ a_{n1} & a_{n2} & \cdots & a_{n,n-1} & 0 \end{bmatrix}$$

$$U = - \begin{bmatrix} 0 & a_{12} & a_{13} & \cdots & a_{1n} \\ & 0 & a_{23} & \cdots & a_{2n} \\ & & 0 & \ddots & \vdots \\ & & & \ddots & a_{n-1,n} \\ & & & & 0 \end{bmatrix}$$



## 定理8.7证明（续）

- 由 $\mathbf{A}$ 为不可约矩阵，则 $\mathbf{C}$ 亦为不可约矩阵
- 由 $\mathbf{A}$ 为弱对角占优阵得到（当 $|\lambda| \geq 1$ 时）

$$\begin{aligned} |c_{ii}| = |\lambda| |a_{ii}| &\geq \sum_{j=1}^{i-1} \lambda |a_{ij}| + \sum_{j=i+1}^n \lambda |a_{ij}| \\ &\geq \sum_{j=1}^{i-1} \lambda |a_{ij}| + \sum_{j=i+1}^n |a_{ij}| = \sum_{j \neq i} |c_{ij}| \end{aligned}$$

且至少有一不等式严格成立

- 因此，当 $|\lambda| \geq 1$ 时， $\mathbf{C}$ 为不可约弱对角占优阵
- 根据定理8.6，此时 $\mathbf{C}$ 是非奇异矩阵，即 $\det \mathbf{C} \neq 0$



# 目录

---

- 引言
- Jacobi迭代法
- Gauss-Seidel迭代法
- 迭代法的收敛性
- 解线性方程组的超松弛迭代法



# 解线性方程组的超松弛迭代法

- 逐次超松弛迭代法（Successive Over Relaxation method, 简称SOR方法）
  - 是Gauss-Seidel方法的一种加速方法
  - 是解大型稀疏矩阵方程组的有效方法之一
  - 具有计算公式简单，程序设计容易，占用计算机内存较少等优点
  - 但需要选择好的加速因子（即最佳松弛因子）

## □ 设有方程组

$$Ax = b \quad (8.4.1)$$

- $A \in R^{n \times n}$  为非奇异矩阵，且设  $a_{ii} \neq 0$  ( $i = 1, 2, \dots, n$ )



# 逐次超松弛迭代法

## □ Gauss-Seidel方法

$$\mathbf{x}^{(0)} = \left( x_1^{(0)}, x_2^{(0)}, \dots, x_n^{(0)} \right)^T \quad (\text{初始向量})$$

$$x_i^{(k+1)} = \frac{1}{a_{ii}} \left( b_i - \sum_{j=1}^{i-1} a_{ij} x_j^{(k+1)} - \sum_{j=i+1}^n a_{ij} x_j^{(k)} \right)$$
$$(k = 0, 1, 2, \dots; i = 1, 2, \dots, n), \quad (8.2.5)$$

## □ 逐次超松弛迭代法

- 设已知第 $k$ 次迭代向量 $\mathbf{x}^{(k)}$ ，及第 $k + 1$ 次迭代向量 $\mathbf{x}^{(k+1)}$ 的分量 $x_j^{(k+1)}$  ( $j = 1, 2, \dots, i - 1$ )，要求计算分量 $x_i^{(k+1)}$



## 逐次超松弛迭代法（续）

- 首先用Gauss-Seidel迭代法定义辅助量

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

$(i = 1, 2, \dots, n) \quad (8.4.3)$

- 再把 $x_i^{(k+1)}$ 取为 $x_i^{(k)}$ 与 $\tilde{x}_i^{(k+1)}$ 某个平均值（即加权平均）

$$\begin{aligned} x_i^{(k+1)} &= (1 - \omega) x_i^{(k)} + \omega \tilde{x}_i^{(k+1)} \\ &= x_i^{(k)} + \omega \left( \tilde{x}_i^{(k+1)} - x_i^{(k)} \right) \end{aligned} \quad (8.4.4)$$

- ✓  $\omega$ 为松弛因子， $\omega = 1$ 为Gauss-Seidel迭代法



## 逐次超松弛迭代法（续）

- 用式(8.4.3)中的 $\tilde{x}_i^{(k+1)}$ 代人式(8.4.4)即得到解方程组 $\mathbf{Ax} = \mathbf{b}$ 的逐次超松弛迭代公式

$$\begin{cases} x_i^{(k+1)} = x_i^{(k)} + \frac{\omega}{a_{ii}} \left( b_i - \sum_{j=1}^{i-1} a_{ij} x_j^{(k+1)} - \sum_{j=i}^n a_{ij} x_j^{(k)} \right) \\ \mathbf{x}^{(k)} = \left( x_1^{(k)}, x_2^{(k)}, \dots, x_n^{(k)} \right)^T \quad (k = 0, 1, \dots; i = 1, 2, \dots, n) \end{cases}$$

- 可改写为

$$\begin{cases} x_i^{(k+1)} = x_i^{(k)} + \Delta x_i \quad (k = 0, 1, \dots; i = 1, 2, \dots, n) \\ \Delta x_i = \frac{\omega}{a_{ii}} \left( b_i - \sum_{j=1}^{i-1} a_{ij} x_j^{(k+1)} - \sum_{j=i}^n a_{ij} x_j^{(k)} \right) \end{cases}$$



## 逐次超松弛迭代法（续）

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

- 在SOR方法中，迭代一次主要的运算量是计算一次矩阵与向量的乘法
- 在计算机上应用SOR方法解方程组时只需一组工作单元，以便存放近似解
- 在用计算机计算时，可用  $|p_0| = \max_i |\Delta x_i| = \max_{1 \leq i \leq n} |x_i^{(k+1)} - x_i^{(k)}| < \varepsilon$  控制迭代终止
- 当  $\omega < 1$  时，称式(8.4.5)为低松弛法；当  $\omega > 1$  时，称式(8.4.5)为超松弛法



## 例8.11

□ 用SOR方法解方程组

$$\begin{bmatrix} -4 & 1 & 1 & 1 \\ 1 & -4 & 1 & 1 \\ 1 & 1 & -4 & 1 \\ 1 & 1 & 1 & -4 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \end{bmatrix} = \begin{bmatrix} 1 \\ 1 \\ 1 \\ 1 \end{bmatrix}$$

它的精确解为  $x^* = (-1, -1, -1, -1)^T$

■ 取  $x^{(0)} = \mathbf{0}$ , 迭代公式为

$$\begin{cases} x_1^{(k+1)} = x_1^{(k)} - \omega (1 + 4x_1^{(k)} - x_2^{(k)} - x_3^{(k)} - x_4^{(k)}) / 4 \\ x_2^{(k+1)} = x_2^{(k)} - \omega (1 - x_1^{(k+1)} + 4x_2^{(k)} - x_3^{(k)} - x_4^{(k)}) / 4 \\ x_3^{(k+1)} = x_3^{(k)} - \omega (1 - x_1^{(k+1)} - x_2^{(k+1)} + 4x_3^{(k)} - x_4^{(k)}) / 4 \\ x_4^{(k+1)} = x_4^{(k)} - \omega (1 - x_1^{(k+1)} - x_2^{(k+1)} - x_3^{(k+1)} + 4x_4^{(k)}) / 4 \end{cases}$$



## 例8.11 (续)

- 取 $\omega = 1.3$ ，第11次迭代结果为

$$x^{(11)} = (-0.999999646, -1.00000310, -0.999999953, -0.999999912)^T$$

$$\| \epsilon^{(11)} \|_2 \leq 0.46 \times 10^{-5}$$

- 对 $\omega$ 取其他值，迭代次数如右表所示，从此例可以看到，松弛因子选择得好，会使SOR方法的收敛大大加速
- 本例中， $\omega = 1.3$ 是最佳松弛因子

$\omega$	误差 $< 10^{-5}$ 的迭代次数
1.0	22
1.1	17
1.2	12
<u>1.3</u>	11 (最少迭代次数)
1.4	14
1.5	17
1.6	23
1.7	33
1.8	53
1.9	109



# SOR迭代公式的矩阵形式

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

□ 上述SOR迭代公式亦可写为

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

$(i = 1, 2, \dots, n)$  (8.4.7)

□ 用**A**的分解**A = D - L - U**，得

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



## SOR迭代公式的矩阵形式（续）

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

■ 等价于

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

■ 显然对于任何一个 $\omega$ 值， $\mathbf{D} - \omega\mathbf{L}$ 非奇异

✓ 由假设 $a_{ii} \neq 0; i = 1, 2, \dots, n$ ，可知 $\det(\mathbf{D} - \omega\mathbf{L}) \neq 0$

■ 因此

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

□ 换言之，SOR方法的迭代公式为

$$\mathbf{x}^{(k+1)} = \mathbf{L}_\omega\mathbf{x}^{(k)} + \mathbf{f} \quad (8.4.8)$$

$$\mathbf{L}_\omega = (\mathbf{D} - \omega\mathbf{L})^{-1}[(1 - \omega)\mathbf{D} + \omega\mathbf{U}], \quad \mathbf{f} = \omega(\mathbf{D} - \omega\mathbf{L})^{-1}\mathbf{b}$$



# SOR方法的收敛性

$$\mathbf{L}_\omega = (\mathbf{D} - \omega\mathbf{L})^{-1}[(1 - \omega)\mathbf{D} + \omega\mathbf{U}]$$

- $\mathbf{L}_\omega$  称为SOR方法的迭代矩阵，这说明SOR方法相当于对方程组  $\mathbf{x} = \mathbf{L}_\omega\mathbf{x} + \mathbf{f}$  应用一般迭代法，于是关于一般迭代法的理论可应用到式(8.4.8)，到下述定理
- 定理8.8 设有线性方程组  $\mathbf{Ax} = \mathbf{b}$ ，且  $a_{ii} \neq 0$  ( $i = 1, 2, \dots, n$ )，SOR方法收敛的充要条件是
$$\rho(\mathbf{L}_\omega) < 1$$



## SOR方法的收敛性（续）

- 容易验证， $Ax = b$  的最优解 $x^*$ 满足

$$x^* = L_\omega x^* + f$$

- 因此，SOR方法一定收敛到 $x^*$
- 引进超松弛迭代法的想法是希望能选择松弛因子 $\omega$ 使得SOR方法收敛较快，也就是应选择因子 $\omega$ 使 $\rho(L_\omega) = \min_{\omega} \rho(L_\omega)$
- 下面研究，对于一般方程组 $Ax = b$  ( $a_{ii} \neq 0; i = 1, 2, \dots, n$ )，松弛因子 $\omega$ 在什么范围内取值，SOR方法才可能收敛



# SOR方法收敛的必要条件

□ 定理8.9 设解式 $\mathbf{Ax} = \mathbf{b}$  ( $a_{ii} \neq 0; i = 1, 2, \dots, n$ ) 的SOR方法收敛, 则

$$0 < \omega < 2$$

■ 由设SOR方法收敛, 根据定理8.8

$$\rho(\mathbf{L}_\omega) < 1$$

■ 设 $\mathbf{L}_\omega$ 的特征值为 $\lambda_1, \lambda_2, \dots, \lambda_n$ , 则

$$|\det \mathbf{L}_\omega| = |\lambda_1 \lambda_2 \cdots \lambda_n| \leq (\rho(\mathbf{L}_\omega))^n$$

$$\Rightarrow |\det \mathbf{L}_\omega|^{1/n} \leq \rho(\mathbf{L}_\omega) < 1$$



## 定理8.9的证明

■ 根据 
$$\mathbf{L}_\omega = (\mathbf{D} - \omega\mathbf{L})^{-1}[(1 - \omega)\mathbf{D} + \omega\mathbf{U}]$$

$$\mathbf{D} = \text{diag}(a_{11}, a_{22}, \dots, a_{nn})$$

■ 可得

$$\det \mathbf{L}_\omega = \det((\mathbf{D} - \omega\mathbf{L})^{-1}) \cdot \det((1 - \omega)\mathbf{D} + \omega\mathbf{U})$$

$$= \frac{1}{a_{11}a_{22} \cdots a_{nn}} \cdot (1 - \omega)^n \cdot a_{11}a_{22} \cdots a_{nn}$$

$$= (1 - \omega)^n$$

■ 结合  $|\det \mathbf{L}_\omega|^{1/n} < 1$ , 可得

$$|1 - \omega| < 1 \Leftrightarrow 0 < \omega < 2$$



# SOR方法收敛的充分条件

- 定理8.9说明对于解一般方程组 $\mathbf{Ax} = \mathbf{b}$  ( $a_{ii} \neq 0; i = 1, 2, \dots, n$ )，SOR方法只有取松弛因子 $\omega$ 在 $(0, 2)$ 范围内才能收敛
- 而当 $\mathbf{A}$ 是对称正定矩阵时，若 $\omega$ 满足 $0 < \omega < 2$ ，则SOR方法一定收敛
- 定理8.10 如果 $\mathbf{A}$ 为对称正定矩阵，且 $0 < \omega < 2$ ，则解式 $\mathbf{Ax} = \mathbf{b}$ 的SOR方法收敛



# 最佳松弛因子理论

- 最佳松弛因子理论是由Young(1950年)针对一类椭圆型微分方程数值解得到的代数方程组  $\mathbf{Ax} = \mathbf{b}$  所建立的理论, 给出了最佳松弛因子公式

$$\omega_{\text{opt}} = \frac{2}{1 + \sqrt{1 - \rho^2(\mathbf{B}_0)}}$$

- $\rho(\mathbf{B}_0)$  是Jacobi方法迭代矩阵  $\mathbf{B}_0$  的谱半径
- 一般来说, 在实际应用中计算  $\rho(\mathbf{B}_0)$  较困难, 对某些微分方程数值解问题可考虑用第9章求近似值的方法
- 亦可由计算实践摸索出 (近似) 最佳松弛因子



# SOR算法流程

□ 用SOR方法解式 $\mathbf{Ax} = \mathbf{b}$ ，其中 $\mathbf{A}$ 为对称正定矩阵

■ 数组 $\mathbf{x}$ 为一组工作单元，开始存放初始向量，然后存放近似值解 $\mathbf{x}^{(k)}$ ，最后存放结果

■ 用

$$|p_0| = \max_{1 \leq i \leq n} |\Delta x_i| = \max_{1 \leq i \leq n} |x_i^{(k+1)} - x_i^{(k)}| < \varepsilon \quad (\text{精度要求})$$

控制控制迭代终止， $k$ 表示迭代次数

1.  $k \leftarrow 0$
2.  $x_i \leftarrow 0 \ (i = 1, 2, \dots, n)$
3.  $k \leftarrow k + 1$



## SOR算法流程（续）

4.  $p_0 \leftarrow 0$

5. 对于  $i = 1, 2, \dots, n$ , 有

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

(2) 如果  $|p| > |p_0|$ , 则  $p_0 \leftarrow p$

(3)  $x_i \leftarrow x_i + p$

6. 输出  $p_0$

7. 如果  $|p_0| > \varepsilon$ , 则转步3

8. 输出结果  $\mathbf{x}, k$



# 总结

---

## □ 引言

- 定义、迭代法收敛、发散

## □ Jacobi迭代法

- Jacobi迭代公式、Jacobi方法迭代矩阵

## □ Gauss-Seidel迭代法

- Gauss-Seidel迭代法
- Gauss-Seidel迭代法的迭代矩阵



# 总结（续）

---

## □ 迭代法的收敛性

- 迭代法基本定理
- 迭代法收敛的充分条件
- 对角占优定理、面向对角占优矩阵的收敛条件

## □ 解线性方程组的超松弛迭代法

- 逐次超松弛迭代法
- SOR方法收敛的充要条件
- SOR方法收敛的必要条件
- SOR方法收敛的充分条件