
第六章 线性方程组的迭代解法

现代数值数学和计算课程

线性方程组的迭代解法

求解大规模线性代数方程组

$$Ax = b$$

线性方程组的迭代解法

求解大规模线性代数方程组

$$Ax = b$$

我们所要讨论的格式

$$x^{(k+1)} = Bx^{(k)} + g$$

线性方程组的迭代解法

求解大规模线性代数方程组

$$Ax = b$$

我们所要讨论的格式

$$x^{(k+1)} = Bx^{(k)} + g$$

向量序列 $\{x^{(k)}\}$, 向量的分量 $x_i^{(k)}$

基本迭代法

线性代数方程组

$$\left\{ \begin{array}{l} a_{11}x_1 + a_{12}x_2 + \cdots + a_{1n}x_n = b_1 \\ a_{21}x_1 + a_{22}x_2 + \cdots + a_{2n}x_n = b_2 \\ \cdots \cdots \\ a_{n1}x_1 + a_{n2}x_2 + \cdots + a_{nn}x_n = b_n \end{array} \right.$$

基本迭代法

线性代数方程组

$$\left\{ \begin{array}{l} a_{11}x_1 + a_{12}x_2 + \cdots + a_{1n}x_n = b_1 \\ a_{21}x_1 + a_{22}x_2 + \cdots + a_{2n}x_n = b_2 \\ \cdots \cdots \\ a_{n1}x_1 + a_{n2}x_2 + \cdots + a_{nn}x_n = b_n \end{array} \right.$$

Jacobi迭代: 从第*i*个方程解出 x_i

基本迭代法

线性代数方程组

$$\left\{ \begin{array}{l} a_{11}x_1 + a_{12}x_2 + \cdots + a_{1n}x_n = b_1 \\ a_{21}x_1 + a_{22}x_2 + \cdots + a_{2n}x_n = b_2 \\ \cdots \cdots \\ a_{n1}x_1 + a_{n2}x_2 + \cdots + a_{nn}x_n = b_n \end{array} \right.$$

Jacobi迭代: 从第*i*个方程解出 x_i

$$\left\{ \begin{array}{l} x_1 = \frac{1}{a_{11}} \left(b_1 - a_{12}x_2 - a_{13}x_3 - \cdots - a_{1n}x_n \right) \\ x_2 = \frac{1}{a_{22}} \left(b_2 - a_{21}x_1 - a_{23}x_3 - \cdots - a_{2n}x_n \right) \\ \cdots \cdots \\ x_n = \frac{1}{a_{nn}} \left(b_n - a_{n1}x_1 - a_{n2}x_2 - \cdots - a_{n,n-1}x_{n-1} \right) \end{array} \right.$$

基本迭代法

线性代数方程组

$$\left\{ \begin{array}{l} a_{11}x_1 + a_{12}x_2 + \cdots + a_{1n}x_n = b_1 \\ a_{21}x_1 + a_{22}x_2 + \cdots + a_{2n}x_n = b_2 \\ \cdots \cdots \\ a_{n1}x_1 + a_{n2}x_2 + \cdots + a_{nn}x_n = b_n \end{array} \right.$$

Jacobi迭代: 从第*i*个方程解出 x_i

$$\left\{ \begin{array}{ll} x_1^{(k+1)} &= \frac{1}{a_{11}} \left(b_1 - a_{12}x_2^{(k)} - a_{13}x_3^{(k)} - \cdots - a_{1n}x_n^{(k)} \right) \\ x_2^{(k+1)} &= \frac{1}{a_{22}} \left(b_2 - a_{21}x_1^{(k)} - a_{23}x_3^{(k)} - \cdots - a_{2n}x_n^{(k)} \right) \\ \cdots &\cdots \\ x_n^{(k+1)} &= \frac{1}{a_{nn}} \left(b_n - a_{n1}x_1^{(k)} - a_{n2}x_2^{(k)} - \cdots - a_{n,n-1}x_{n-1}^{(k)} \right) \end{array} \right.$$

基本迭代法

Jacobi迭代: 从第*i*个方程解出 x_i

$$\left\{ \begin{array}{l} x_1^{(k+1)} = \frac{1}{a_{11}} \left(b_1 - a_{12}x_2^{(k)} - a_{13}x_3^{(k)} - \cdots - a_{1n}x_n^{(k)} \right) \\ x_2^{(k+1)} = \frac{1}{a_{22}} \left(b_2 - a_{21}x_1^{(k)} - a_{23}x_3^{(k)} - \cdots - a_{2n}x_n^{(k)} \right) \\ \dots \quad \dots \\ x_n^{(k+1)} = \frac{1}{a_{nn}} \left(b_n - a_{n1}x_1^{(k)} - a_{n2}x_2^{(k)} - \cdots - a_{n,n-1}x_{n-1}^{(k)} \right) \end{array} \right.$$

$$A = \begin{bmatrix} a_{11} & a_{12} & a_{13} & \cdots & a_{1n} \\ a_{21} & a_{22} & a_{23} & \cdots & a_{2n} \\ a_{31} & a_{32} & a_{33} & \cdots & a_{3n} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & a_{n3} & \cdots & a_{nn} \end{bmatrix} = D - L - U$$

基本迭代法

Jacobi迭代: 从第*i*个方程解出 x_i

$$\left\{ \begin{array}{l} x_1^{(k+1)} = \frac{1}{a_{11}} \left(b_1 - a_{12}x_2^{(k)} - a_{13}x_3^{(k)} - \cdots - a_{1n}x_n^{(k)} \right) \\ x_2^{(k+1)} = \frac{1}{a_{22}} \left(b_2 - a_{21}x_1^{(k)} - a_{23}x_3^{(k)} - \cdots - a_{2n}x_n^{(k)} \right) \\ \dots \quad \dots \\ x_n^{(k+1)} = \frac{1}{a_{nn}} \left(b_n - a_{n1}x_1^{(k)} - a_{n2}x_2^{(k)} - \cdots - a_{n,n-1}x_{n-1}^{(k)} \right) \end{array} \right.$$

Jacobi迭代的矩阵形式

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

基本迭代法

Jacobi迭代: 从第*i*个方程解出 x_i

$$\left\{ \begin{array}{l} x_1^{(k+1)} = \frac{1}{a_{11}} \left(b_1 - a_{12}x_2^{(k)} - a_{13}x_3^{(k)} - \cdots - a_{1n}x_n^{(k)} \right) \\ x_2^{(k+1)} = \frac{1}{a_{22}} \left(b_2 - a_{21}x_1^{(k)} - a_{23}x_3^{(k)} - \cdots - a_{2n}x_n^{(k)} \right) \\ \dots \quad \dots \\ x_n^{(k+1)} = \frac{1}{a_{nn}} \left(b_n - a_{n1}x_1^{(k)} - a_{n2}x_2^{(k)} - \cdots - a_{n,n-1}x_{n-1}^{(k)} \right) \end{array} \right.$$

Jacobi迭代的矩阵形式

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

$$x^{(k+1)} = \textcolor{red}{D}^{-1}(\textcolor{red}{D} - A)x^{(k)} + \textcolor{red}{D}^{-1}b$$

基本迭代法

Jacobi迭代: 从第*i*个方程解出 x_i

$$\left\{ \begin{array}{l} x_1^{(k+1)} = \frac{1}{a_{11}} \left(b_1 - a_{12}x_2^{(k)} - a_{13}x_3^{(k)} - \cdots - a_{1n}x_n^{(k)} \right) \\ x_2^{(k+1)} = \frac{1}{a_{22}} \left(b_2 - a_{21}x_1^{(k+1)} - a_{23}x_3^{(k)} - \cdots - a_{2n}x_n^{(k)} \right) \\ \cdots \quad \cdots \\ x_n^{(k+1)} = \frac{1}{a_{nn}} \left(b_n - a_{n1}x_1^{(k+1)} - a_{n2}x_2^{(k)} - \cdots - a_{n,n-1}x_{n-1}^{(k)} \right) \end{array} \right.$$

Jacobi迭代的矩阵形式

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

$$x^{(k+1)} = \textcolor{red}{D}^{-1}(\textcolor{red}{D} - A)x^{(k)} + \textcolor{red}{D}^{-1}b$$

基本迭代法

Jacobi迭代: 从第*i*个方程解出 x_i

$$\left\{ \begin{array}{l} x_1^{(k+1)} = \frac{1}{a_{11}} \left(b_1 - a_{12}x_2^{(k)} - a_{13}x_3^{(k)} - \cdots - a_{1n}x_n^{(k)} \right) \\ x_2^{(k+1)} = \frac{1}{a_{22}} \left(b_2 - a_{21}x_1^{(k+1)} - a_{23}x_3^{(k)} - \cdots - a_{2n}x_n^{(k)} \right) \\ \dots \quad \dots \\ x_n^{(k+1)} = \frac{1}{a_{nn}} \left(b_n - a_{n1}x_1^{(k+1)} - a_{n2}x_2^{(k+1)} - \cdots - a_{n,n-1}x_{n-1}^{(k)} \right) \end{array} \right.$$

Jacobi迭代的矩阵形式

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

$$x^{(k+1)} = \textcolor{red}{D}^{-1}(\textcolor{red}{D} - A)x^{(k)} + \textcolor{red}{D}^{-1}b$$

基本迭代法

Jacobi迭代: 从第*i*个方程解出 x_i

$$\left\{ \begin{array}{l} x_1^{(k+1)} = \frac{1}{a_{11}} \left(b_1 - a_{12}x_2^{(k)} - a_{13}x_3^{(k)} - \cdots - a_{1n}x_n^{(k)} \right) \\ x_2^{(k+1)} = \frac{1}{a_{22}} \left(b_2 - a_{21}x_1^{(k+1)} - a_{23}x_3^{(k)} - \cdots - a_{2n}x_n^{(k)} \right) \\ \dots \quad \dots \\ x_n^{(k+1)} = \frac{1}{a_{nn}} \left(b_n - a_{n1}x_1^{(k+1)} - a_{n2}x_2^{(k+1)} - \cdots - a_{n,n-1}x_{n-1}^{(k+1)} \right) \end{array} \right.$$

Jacobi迭代的矩阵形式

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

$$x^{(k+1)} = \textcolor{red}{D}^{-1}(\textcolor{red}{D} - A)x^{(k)} + \textcolor{red}{D}^{-1}b$$

基本迭代法

Gauss-Seidel 迭代: 从第 i 个方程解出 x_i

$$\left\{ \begin{array}{l} x_1^{(k+1)} = \frac{1}{a_{11}} \left(b_1 - a_{12}x_2^{(k)} - a_{13}x_3^{(k)} - \cdots - a_{1n}x_n^{(k)} \right) \\ x_2^{(k+1)} = \frac{1}{a_{22}} \left(b_2 - a_{21}x_1^{(k+1)} - a_{23}x_3^{(k)} - \cdots - a_{2n}x_n^{(k)} \right) \\ \dots \quad \dots \\ x_n^{(k+1)} = \frac{1}{a_{nn}} \left(b_n - a_{n1}x_1^{(k+1)} - a_{n2}x_2^{(k+1)} - \cdots - a_{n,n-1}x_{n-1}^{(k+1)} \right) \end{array} \right.$$

Jacobi 迭代的矩阵形式

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

$$x^{(k+1)} = \textcolor{red}{D}^{-1}(\textcolor{red}{D} - A)x^{(k)} + \textcolor{red}{D}^{-1}b$$

基本迭代法

Gauss-Seidel 迭代: 从第 i 个方程解出 x_i , 尽量使用新分量

$$\left\{ \begin{array}{l} x_1^{(k+1)} = \frac{1}{a_{11}} \left(b_1 - a_{12}x_2^{(k)} - a_{13}x_3^{(k)} - \cdots - a_{1n}x_n^{(k)} \right) \\ x_2^{(k+1)} = \frac{1}{a_{22}} \left(b_2 - a_{21}x_1^{(k+1)} - a_{23}x_3^{(k)} - \cdots - a_{2n}x_n^{(k)} \right) \\ \dots \quad \dots \\ x_n^{(k+1)} = \frac{1}{a_{nn}} \left(b_n - a_{n1}x_1^{(k+1)} - a_{n2}x_2^{(k+1)} - \cdots - a_{n,n-1}x_{n-1}^{(k+1)} \right) \end{array} \right.$$

Jacobi 迭代的矩阵形式

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

$$x^{(k+1)} = \textcolor{red}{D}^{-1}(\textcolor{red}{D} - A)x^{(k)} + \textcolor{red}{D}^{-1}b$$

基本迭代法

Gauss-Seidel迭代: 从第*i*个方程解出 x_i , 尽量使用新分量

$$\left\{ \begin{array}{l} x_1^{(k+1)} = \frac{1}{a_{11}} \left(b_1 - a_{12}x_2^{(k)} - a_{13}x_3^{(k)} - \cdots - a_{1n}x_n^{(k)} \right) \\ x_2^{(k+1)} = \frac{1}{a_{22}} \left(b_2 - a_{21}x_1^{(k+1)} - a_{23}x_3^{(k)} - \cdots - a_{2n}x_n^{(k)} \right) \\ \dots \quad \dots \\ x_n^{(k+1)} = \frac{1}{a_{nn}} \left(b_n - a_{n1}x_1^{(k+1)} - a_{n2}x_2^{(k+1)} - \cdots - a_{n,n-1}x_{n-1}^{(k+1)} \right) \end{array} \right.$$

Jacobi迭代的矩阵形式

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

$$x^{(k+1)} = \textcolor{red}{D}^{-1}(\textcolor{red}{D} - A)x^{(k)} + \textcolor{red}{D}^{-1}b$$

Gauss-Seidel迭代的矩阵形式

$$\textcolor{red}{D}x^{(k+1)} = b + Lx^{(k+1)} + \textcolor{blue}{U}x^{(k)}$$

基本迭代法

Gauss-Seidel迭代: 从第*i*个方程解出 x_i , 尽量使用新分量

$$\left\{ \begin{array}{l} x_1^{(k+1)} = \frac{1}{a_{11}} \left(b_1 - a_{12}x_2^{(k)} - a_{13}x_3^{(k)} - \cdots - a_{1n}x_n^{(k)} \right) \\ x_2^{(k+1)} = \frac{1}{a_{22}} \left(b_2 - a_{21}x_1^{(k+1)} - a_{23}x_3^{(k)} - \cdots - a_{2n}x_n^{(k)} \right) \\ \dots \quad \dots \\ x_n^{(k+1)} = \frac{1}{a_{nn}} \left(b_n - a_{n1}x_1^{(k+1)} - a_{n2}x_2^{(k+1)} - \cdots - a_{n,n-1}x_{n-1}^{(k+1)} \right) \end{array} \right.$$

Jacobi迭代的矩阵形式

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

$$x^{(k+1)} = \textcolor{red}{D}^{-1}(\textcolor{red}{D} - A)x^{(k)} + \textcolor{red}{D}^{-1}b$$

Gauss-Seidel迭代的矩阵形式

$$\textcolor{red}{D}x^{(k+1)} = b + Lx^{(k+1)} + \textcolor{blue}{U}x^{(k)}$$

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

基本迭代法

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

基本迭代法

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

基本迭代法

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

基本迭代法

SOR方法(超松弛, Successive OverRelaxation)

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

基本迭代法

SOR方法(超松弛, Successive OverRelaxation)

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

矩阵形式

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

基本迭代法

SOR方法(超松弛, Successive OverRelaxation)

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

矩阵形式

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

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

基本迭代法

例6.1

基本迭代法

例6.1

$$\begin{bmatrix} 2 & -1 & 0 \\ -1 & 3 & -1 \\ 0 & -1 & 2 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} = \begin{bmatrix} 1 \\ 8 \\ -5 \end{bmatrix}$$

基本迭代法

例6.1

Jacobi迭代

$$\begin{bmatrix} 2 & -1 & 0 \\ -1 & 3 & -1 \\ 0 & -1 & 2 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} = \begin{bmatrix} 1 \\ 8 \\ -5 \end{bmatrix}$$

基本迭代法

例6.1

$$\begin{bmatrix} 2 & -1 & 0 \\ -1 & 3 & -1 \\ 0 & -1 & 2 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} = \begin{bmatrix} 1 \\ 8 \\ -5 \end{bmatrix}$$

Jacobi迭代

$$\begin{cases} x_1^{(k+1)} = \frac{1}{2}(1 + x_2^{(k)}) \\ x_2^{(k+1)} = \frac{1}{3}(8 + x_1^{(k)} + x_3^{(k)}) \\ x_3^{(k+1)} = \frac{1}{2}(-5 + x_2^{(k)}) \end{cases}$$

基本迭代法

例6.1

$$\begin{bmatrix} 2 & -1 & 0 \\ -1 & 3 & -1 \\ 0 & -1 & 2 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} = \begin{bmatrix} 1 \\ 8 \\ -5 \end{bmatrix}$$

Jacobi迭代

$$\begin{cases} x_1^{(k+1)} = \frac{1}{2}(1 + x_2^{(k)}) \\ x_2^{(k+1)} = \frac{1}{3}(8 + x_1^{(k)} + x_3^{(k)}) \\ x_3^{(k+1)} = \frac{1}{2}(-5 + x_2^{(k)}) \end{cases}$$

G-S迭代

基本迭代法

例6.1

$$\begin{bmatrix} 2 & -1 & 0 \\ -1 & 3 & -1 \\ 0 & -1 & 2 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} = \begin{bmatrix} 1 \\ 8 \\ -5 \end{bmatrix}$$

Jacobi迭代

$$\begin{cases} x_1^{(k+1)} = \frac{1}{2}(1 + x_2^{(k)}) \\ x_2^{(k+1)} = \frac{1}{3}(8 + x_1^{(k)} + x_3^{(k)}) \\ x_3^{(k+1)} = \frac{1}{2}(-5 + x_2^{(k)}) \end{cases}$$

G-S迭代

$$\begin{cases} x_1^{(k+1)} = \frac{1}{2}(1 + x_2^{(k)}) \\ x_2^{(k+1)} = \frac{1}{3}(8 + x_1^{(k+1)} + x_3^{(k)}) \\ x_3^{(k+1)} = \frac{1}{2}(-5 + x_2^{(k+1)}) \end{cases}$$

基本迭代法

例6.1

$$\begin{bmatrix} 2 & -1 & 0 \\ -1 & 3 & -1 \\ 0 & -1 & 2 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} = \begin{bmatrix} 1 \\ 8 \\ -5 \end{bmatrix}$$

SOR迭代: $\omega = 1.1$

Jacobi迭代

$$\begin{cases} x_1^{(k+1)} = \frac{1}{2}(1 + x_2^{(k)}) \\ x_2^{(k+1)} = \frac{1}{3}(8 + x_1^{(k)} + x_3^{(k)}) \\ x_3^{(k+1)} = \frac{1}{2}(-5 + x_2^{(k)}) \end{cases}$$

G-S迭代

$$\begin{cases} x_1^{(k+1)} = \frac{1}{2}(1 + x_2^{(k)}) \\ x_2^{(k+1)} = \frac{1}{3}(8 + x_1^{(k+1)} + x_3^{(k)}) \\ x_3^{(k+1)} = \frac{1}{2}(-5 + x_2^{(k+1)}) \end{cases}$$

基本迭代法

例6.1

$$\begin{bmatrix} 2 & -1 & 0 \\ -1 & 3 & -1 \\ 0 & -1 & 2 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} = \begin{bmatrix} 1 \\ 8 \\ -5 \end{bmatrix}$$

Jacobi迭代

$$\begin{cases} x_1^{(k+1)} = \frac{1}{2}(1 + x_2^{(k)}) \\ x_2^{(k+1)} = \frac{1}{3}(8 + x_1^{(k)} + x_3^{(k)}) \\ x_3^{(k+1)} = \frac{1}{2}(-5 + x_2^{(k)}) \end{cases}$$

SOR迭代: $\omega = 1.1$

$$\begin{cases} x_1^{(k+1)} = x_1^{(k)} + \frac{1.1}{2}(1 - 2x_1^{(k)} + x_2^{(k)}) \\ x_2^{(k+1)} = x_2^{(k)} + \frac{1.1}{3}(8 + x_1^{(k+1)} - 3x_2^{(k)} + x_3^{(k)}) \\ x_3^{(k+1)} = x_3^{(k)} + \frac{1.1}{2}(-5 + x_2^{(k+1)} - 2x_3^{(k)}) \end{cases}$$

G-S迭代

$$\begin{cases} x_1^{(k+1)} = \frac{1}{2}(1 + x_2^{(k)}) \\ x_2^{(k+1)} = \frac{1}{3}(8 + x_1^{(k+1)} + x_3^{(k)}) \\ x_3^{(k+1)} = \frac{1}{2}(-5 + x_2^{(k+1)}) \end{cases}$$

基本迭代法

例6.1

$$\begin{bmatrix} 2 & -1 & 0 \\ -1 & 3 & -1 \\ 0 & -1 & 2 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} = \begin{bmatrix} 1 \\ 8 \\ -5 \end{bmatrix}$$

Jacobi迭代

$$\begin{cases} x_1^{(k+1)} = \frac{1}{2}(1 + x_2^{(k)}) \\ x_2^{(k+1)} = \frac{1}{3}(8 + x_1^{(k)} + x_3^{(k)}) \\ x_3^{(k+1)} = \frac{1}{2}(-5 + x_2^{(k)}) \end{cases}$$

SOR迭代: $\omega = 1.1$

$$\begin{cases} x_1^{(k+1)} = x_1^{(k)} + \frac{1.1}{2}(1 - 2x_1^{(k)} + x_2^{(k)}) \\ x_2^{(k+1)} = x_2^{(k)} + \frac{1.1}{3}(8 + x_1^{(k+1)} - 3x_2^{(k)} + x_3^{(k)}) \\ x_3^{(k+1)} = x_3^{(k)} + \frac{1.1}{2}(-5 + x_2^{(k+1)} - 2x_3^{(k)}) \end{cases}$$

G-S迭代

$$\begin{cases} x_1^{(k+1)} = \frac{1}{2}(1 + x_2^{(k)}) \\ x_2^{(k+1)} = \frac{1}{3}(8 + x_1^{(k+1)} + x_3^{(k)}) \\ x_3^{(k+1)} = \frac{1}{2}(-5 + x_2^{(k+1)}) \end{cases}$$

Run itdemo1

范数、条件数

定义6.1 $\|\bullet\|$ 定义在 n 维向量空间, 满足

- $\|x\| \geq 0$, 当且仅当 $x = 0$ 时等号成立;
- 对任意实数 α , $\|\alpha x\| = |\alpha| \|x\|$;
- 对任意向量 x, y , 成立 $\|x + y\| \leq \|x\| + \|y\|$;

称 $\|x\|$ 为向量 x 的范数。

范数、条件数

定义6.1 $\|\bullet\|$ 定义在 n 维向量空间, 满足

- $\|x\| \geq 0$, 当且仅当 $x = 0$ 时等号成立;
- 对任意实数 α , $\|\alpha x\| = |\alpha| \|x\|$;
- 对任意向量 x, y , 成立 $\|x + y\| \leq \|x\| + \|y\|$;

称 $\|x\|$ 为向量 x 的范数。

常用的范数有

$$\|x\|_2 = \sqrt{|x_1|^2 + |x_2|^2 + \cdots + |x_n|^2}$$

$$\|x\|_1 = |x_1| + |x_2| + \cdots + |x_n|$$

$$\|x\|_\infty = \max\{|x_1|, |x_2|, \dots, |x_n|\}$$

范数、条件数

定义6.2 对于任意 n 阶方阵 A , 若对应实数 $\|A\|$, 满足

- $\|A\| \geq 0$, 当且仅当 $A = 0$ 时等号成立;
- 对任意实数 α , $\|\alpha A\| = |\alpha| \|A\|$;
- 对任意方阵 A, B , 成立 $\|A + B\| \leq \|A\| + \|B\|$;
- 对任意方阵 A, B , 成立 $\|AB\| \leq \|A\| \|B\|$;

称 $\|A\|$ 为矩阵 A 的范数。

范数、条件数

定义6.2 对于任意 n 阶方阵 A , 若对应实数 $\|A\|$, 满足

- $\|A\| \geq 0$, 当且仅当 $A = 0$ 时等号成立;
- 对任意实数 α , $\|\alpha A\| = |\alpha| \|A\|$;
- 对任意方阵 A, B , 成立 $\|A + B\| \leq \|A\| + \|B\|$;
- 对任意方阵 A, B , 成立 $\|AB\| \leq \|A\| \|B\|$;

称 $\|A\|$ 为矩阵 A 的范数。

最后一个条件称为矩阵范数的相容性。

范数、条件数

定义6.2 对于任意 n 阶方阵 A , 若对应实数 $\|A\|$, 满足

- $\|A\| \geq 0$, 当且仅当 $A = 0$ 时等号成立;
- 对任意实数 α , $\|\alpha A\| = |\alpha| \|A\|$;
- 对任意方阵 A, B , 成立 $\|A + B\| \leq \|A\| + \|B\|$;
- 对任意方阵 A, B , 成立 $\|AB\| \leq \|A\| \|B\|$;

称 $\|A\|$ 为矩阵 A 的范数。

最后一个条件称为矩阵范数的相容性。

定义6.3 设 A 是 n 阶矩阵, 称 $\rho(A) = \max_{1 \leq i \leq n} |\lambda_i|$ 为 A 的谱半径, λ_i 是 A 的特征值。

范数、条件数

常用的矩阵范数

$$\|A\|_1 = \max_{1 \leq j \leq n} \sum_{i=1}^n |a_{ij}| \quad \|A\|_\infty = \max_{1 \leq i \leq n} \sum_{j=1}^n |a_{ij}|$$

$$\|A\|_2 = \sqrt{\rho(A^T A)} \quad \|A\|_F = \sqrt{\sum_{i=1}^n \sum_{j=1}^n |a_{ij}|^2}$$

范数、条件数

常用的矩阵范数

$$\|A\|_1 = \max_{1 \leq j \leq n} \sum_{i=1}^n |a_{ij}| \quad \|A\|_\infty = \max_{1 \leq i \leq n} \sum_{j=1}^n |a_{ij}|$$
$$\|A\|_2 = \sqrt{\rho(A^T A)} \quad \|A\|_F = \sqrt{\sum_{i=1}^n \sum_{j=1}^n |a_{ij}|^2}$$

矩阵范数和向量范数的相容性 $\|Ax\| \leq \|A\| \|x\|$

范数、条件数

常用的矩阵范数

$$\|A\|_1 = \max_{1 \leq j \leq n} \sum_{i=1}^n |a_{ij}| \quad \|A\|_\infty = \max_{1 \leq i \leq n} \sum_{j=1}^n |a_{ij}|$$

$$\|A\|_2 = \sqrt{\rho(A^T A)} \quad \|A\|_F = \sqrt{\sum_{i=1}^n \sum_{j=1}^n |a_{ij}|^2}$$

矩阵范数和向量范数的相容性 $\|Ax\| \leq \|A\| \|x\|$

$$\|Ax\|_1 \leq \|A\|_1 \|x\|_1 \quad \|Ax\|_\infty \leq \|A\|_\infty \|x\|_\infty$$

$$\|Ax\|_2 \leq \|A\|_2 \|x\|_2 \quad \|Ax\|_2 \leq \|A\|_F \|x\|_2$$

范数、条件数

方程组的性态:

范数、条件数

方程组的性态：

$$\begin{bmatrix} 2.0002 & 1.9998 \\ 1.9998 & 2.0002 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 4 \\ 4 \end{bmatrix}$$

范数、条件数

方程组的性态：

$$\begin{bmatrix} 2.0002 & 1.9998 \\ 1.9998 & 2.0002 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 4 \\ 4 \end{bmatrix} \quad x = (1, 1)^T$$

范数、条件数

方程组的性态：

$$\begin{bmatrix} 2.0002 & 1.9998 \\ 1.9998 & 2.0002 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 4 \\ 4 \end{bmatrix} \quad x = (1, 1)^T$$

$$\begin{bmatrix} 2.0002 & 1.9998 \\ 1.9998 & 2.0002 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 4.0002 \\ 3.9998 \end{bmatrix}$$

范数、条件数

方程组的性态：

$$\begin{bmatrix} 2.0002 & 1.9998 \\ 1.9998 & 2.0002 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 4 \\ 4 \end{bmatrix} \quad x = (1, 1)^T$$

$$\begin{bmatrix} 2.0002 & 1.9998 \\ 1.9998 & 2.0002 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 4.0002 \\ 3.9998 \end{bmatrix} \quad \tilde{x} = (1.5, 0.5)^T$$

范数、条件数

方程组的性态：

$$\begin{bmatrix} 2.0002 & 1.9998 \\ 1.9998 & 2.0002 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 4 \\ 4 \end{bmatrix} \quad x = (1, 1)^T$$

$$\begin{bmatrix} 2.0002 & 1.9998 \\ 1.9998 & 2.0002 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 4.0002 \\ 3.9998 \end{bmatrix} \quad \tilde{x} = (1.5, 0.5)^T$$

$$\frac{\|x - \tilde{x}\|_\infty}{\|x\|_\infty} = \frac{1}{2}$$

范数、条件数

方程组的性态：

$$\begin{bmatrix} 2.0002 & 1.9998 \\ 1.9998 & 2.0002 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 4 \\ 4 \end{bmatrix} \quad x = (1, 1)^T$$

$$\begin{bmatrix} 2.0002 & 1.9998 \\ 1.9998 & 2.0002 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 4.0002 \\ 3.9998 \end{bmatrix} \quad \tilde{x} = (1.5, 0.5)^T$$

$$\frac{\|x - \tilde{x}\|_\infty}{\|x\|_\infty} = \frac{1}{2}$$

$$\frac{\|b - \tilde{b}\|_\infty}{\|b\|_\infty} = \frac{1}{20000}$$

范数、条件数

$$A(x + \delta x) = b + \delta b$$

范数、条件数

$$A(x + \delta x) = b + \delta b$$

$$\delta x = A^{-1} \delta b$$

范数、条件数

$$A(x + \delta x) = b + \delta b$$

$$\delta x = A^{-1} \delta b$$

$$\|\delta x\| \leq \|A^{-1}\| \|\delta b\|$$

范数、条件数

$$A(x + \delta x) = b + \delta b$$

$$\delta x = A^{-1} \delta b$$

$$\|\delta x\| \leq \|A^{-1}\| \|\delta b\|$$

此外 $\|b\| \leq \|A\| \|x\|$

范数、条件数

$$A(x + \delta x) = b + \delta b$$

$$\delta x = A^{-1} \delta b$$

$$\|\delta x\| \leq \|A^{-1}\| \|\delta b\|$$

此外 $\|b\| \leq \|A\| \|x\|$

$$\frac{\|\delta x\|}{\|x\|} \leq \|A\| \|A^{-1}\| \frac{\|\delta b\|}{\|b\|}$$

范数、条件数

$$A(x + \delta x) = b + \delta b \quad (A + \delta A)(x + \delta x) = b$$

$$\delta x = A^{-1} \delta b$$

$$\|\delta x\| \leq \|A^{-1}\| \|\delta b\|$$

此外 $\|b\| \leq \|A\| \|x\|$

$$\frac{\|\delta x\|}{\|x\|} \leq \|A\| \|A^{-1}\| \frac{\|\delta b\|}{\|b\|}$$

范数、条件数

$$A(x + \delta x) = b + \delta b$$

$$(A + \delta A)(x + \delta x) = b$$

$$\delta x = A^{-1} \delta b$$

$$A\delta x + \delta A(x + \delta x) = 0$$

$$\|\delta x\| \leq \|A^{-1}\| \|\delta b\|$$

此外 $\|b\| \leq \|A\| \|x\|$

$$\frac{\|\delta x\|}{\|x\|} \leq \|A\| \|A^{-1}\| \frac{\|\delta b\|}{\|b\|}$$

范数、条件数

$$A(x + \delta x) = b + \delta b$$

$$(A + \delta A)(x + \delta x) = b$$

$$\delta x = A^{-1} \delta b$$

$$A\delta x + \delta A(x + \delta x) = 0$$

$$\|\delta x\| \leq \|A^{-1}\| \|\delta b\|$$

$$\delta x = -A^{-1} \delta A(x + \delta x)$$

此外 $\|b\| \leq \|A\| \|x\|$

$$\frac{\|\delta x\|}{\|x\|} \leq \|A\| \|A^{-1}\| \frac{\|\delta b\|}{\|b\|}$$

范数、条件数

$$A(x + \delta x) = b + \delta b$$

$$(A + \delta A)(x + \delta x) = b$$

$$\delta x = A^{-1} \delta b$$

$$A\delta x + \delta A(x + \delta x) = 0$$

$$\|\delta x\| \leq \|A^{-1}\| \|\delta b\|$$

$$\delta x = -A^{-1} \delta A(x + \delta x)$$

此外 $\|b\| \leq \|A\| \|x\|$ $\|\delta x\| \leq \|A^{-1}\| \|\delta A\| \|x + \delta x\|$

$$\frac{\|\delta x\|}{\|x\|} \leq \|A\| \|A^{-1}\| \frac{\|\delta b\|}{\|b\|}$$

范数、条件数

$$A(x + \delta x) = b + \delta b$$

$$(A + \delta A)(x + \delta x) = b$$

$$\delta x = A^{-1} \delta b$$

$$A\delta x + \delta A(x + \delta x) = 0$$

$$\|\delta x\| \leq \|A^{-1}\| \|\delta b\|$$

$$\delta x = -A^{-1} \delta A(x + \delta x)$$

此外 $\|b\| \leq \|A\| \|x\|$ $\|\delta x\| \leq \|A^{-1}\| \|\delta A\| \|x + \delta x\|$

$$\frac{\|\delta x\|}{\|x\|} \leq \|A\| \|A^{-1}\| \frac{\|\delta b\|}{\|b\|}$$

$$\frac{\|\delta x\|}{\|x + \delta x\|} \leq \|A\| \|A^{-1}\| \frac{\|\delta A\|}{\|A\|}$$

范数、条件数

$$A(x + \delta x) = b + \delta b$$

$$(A + \delta A)(x + \delta x) = b$$

$$\delta x = A^{-1} \delta b$$

$$A\delta x + \delta A(x + \delta x) = 0$$

$$\|\delta x\| \leq \|A^{-1}\| \|\delta b\|$$

$$\delta x = -A^{-1} \delta A(x + \delta x)$$

此外 $\|b\| \leq \|A\| \|x\|$ $\|\delta x\| \leq \|A^{-1}\| \|\delta A\| \|x + \delta x\|$

$$\frac{\|\delta x\|}{\|x\|} \leq \|A\| \|A^{-1}\| \frac{\|\delta b\|}{\|b\|}$$

$$\frac{\|\delta x\|}{\|x + \delta x\|} \leq \|A\| \|A^{-1}\| \frac{\|\delta A\|}{\|A\|}$$

定义6.4 A 为 n 阶可逆矩阵, 称 $\text{cond}(A) = \|A\| \|A^{-1}\|$ 为矩阵 A 的条件数。

范数、条件数

条件数的性质(A 可逆)

范数、条件数

条件数的性质(A 可逆)

- $\text{cond}(A) \geq 1;$

范数、条件数

条件数的性质(A 可逆)

- $\text{cond}(A) \geq 1$;
- 对任意常数 $c \neq 0$, $\text{cond}(cA) = \text{cond}(A)$;

范数、条件数

条件数的性质(A 可逆)

- $\text{cond}(A) \geq 1$;
- 对任意常数 $c \neq 0$, $\text{cond}(cA) = \text{cond}(A)$;
- 对任意正交矩阵 P , $\text{cond}_2(P) = 1$;

范数、条件数

条件数的性质(A 可逆)

- $\text{cond}(A) \geq 1$;
- 对任意常数 $c \neq 0$, $\text{cond}(cA) = \text{cond}(A)$;
- 对任意正交矩阵 P , $\text{cond}_2(P) = 1$;
- 对任意正交矩阵 P ,
 $\text{cond}_2(AP) = \text{cond}_2(PA) = \text{cond}_2(A)$.

范数、条件数

条件数的性质(A 可逆)

- $\text{cond}(A) \geq 1$;
- 对任意常数 $c \neq 0$, $\text{cond}(cA) = \text{cond}(A)$;
- 对任意正交矩阵 P , $\text{cond}_2(P) = 1$;
- 对任意正交矩阵 P ,
 $\text{cond}_2(AP) = \text{cond}_2(PA) = \text{cond}_2(A)$.

条件数小的矩阵称为良态矩阵;
条件数大的矩阵称为病态矩阵。

范数、条件数

Hilbert矩阵 $H_{ij} = \frac{1}{i+j-1}$

$$H_n = \begin{bmatrix} 1 & \frac{1}{2} & \cdots & \frac{1}{n} \\ \frac{1}{2} & \frac{1}{3} & \cdots & \frac{1}{n+1} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{1}{n} & \frac{1}{n+1} & \cdots & \frac{1}{2n-1} \end{bmatrix}$$

范数、条件数

Hilbert矩阵 $H_{ij} = \frac{1}{i+j-1}$

>> cond(hilb(3))

ans =

524.0568

范数、条件数

Hilbert矩阵 $H_{ij} = \frac{1}{i+j-1}$

```
>> cond(hilb(3))
```

```
ans =
```

524.0568

```
>> cond(hilb(6))
```

```
ans =
```

1.4951e+007

范数、条件数

Hilbert矩阵 $H_{ij} = \frac{1}{i+j-1}$

```
>> cond(hilb(3))
```

```
ans =
```

524.0568

```
>> cond(hilb(6))
```

```
ans =
```

1.4951e+007

```
>> cond(hilb(9))
```

```
ans =
```

4.9315e+011

范数、条件数

Hilbert矩阵 $H_{ij} = \frac{1}{i+j-1}$

>> cond(hilb(3))

ans =

524.0568

>> cond(hilb(6))

ans =

1.4951e+007

>> cond(hilb(9))

ans =

4.9315e+011

教材例3.5

收敛性分析和误差估计

定义6.5 设 A 是 n 阶矩阵($n \geq 2$), 若存在排列阵 P 使得

$$P^T A P = \begin{bmatrix} A_{11} & A_{12} \\ 0 & A_{22} \end{bmatrix}$$

称 A 为可约矩阵, 否则称为不可约矩阵。

收敛性分析和误差估计

定义6.5 设 A 是 n 阶矩阵($n \geq 2$), 若存在排列阵 P 使得

$$P^T A P = \begin{bmatrix} A_{11} & A_{12} \\ 0 & A_{22} \end{bmatrix}$$

称 A 为可约矩阵, 否则称为不可约矩阵。

$$Ax = b \Leftrightarrow P^T A P P^T x = P^T b$$

收敛性分析和误差估计

定义6.5 设 A 是 n 阶矩阵($n \geq 2$), 若存在排列阵 P 使得

$$P^T A P = \begin{bmatrix} A_{11} & A_{12} \\ 0 & A_{22} \end{bmatrix}$$

称 A 为可约矩阵, 否则称为不可约矩阵。

$$Ax = b \Leftrightarrow P^T A P P^T x = P^T b$$

$$\begin{bmatrix} A_{11} & A_{12} \\ 0 & A_{22} \end{bmatrix} \begin{bmatrix} \bar{x}_1 \\ \bar{x}_2 \end{bmatrix} = \begin{bmatrix} \bar{b}_1 \\ \bar{b}_2 \end{bmatrix}$$

收敛性分析和误差估计

定义6.5 设 A 是 n 阶矩阵($n \geq 2$), 若存在排列阵 P 使得

$$P^T A P = \begin{bmatrix} A_{11} & A_{12} \\ 0 & A_{22} \end{bmatrix}$$

称 A 为可约矩阵, 否则称为不可约矩阵。

定义6.6 若 n 阶方阵 A 满足

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

且其中有一个严格不等式成立, 称 A 是(行)弱对角占优矩阵; 若所有不等式严格成立, 称 A 是(行)(严格)对角占优矩阵。

收敛性分析和误差估计

引理6.1 严格对角占优矩阵或不可约弱对角占优矩阵 A 是可逆矩阵。

收敛性分析和误差估计

引理6.1 严格对角占优矩阵或不可约弱对角占优矩阵 A 是可逆矩阵。

证明(一): 假设 A 不可逆。则存在非零向量 v , 使得 $Av = 0$.

收敛性分析和误差估计

引理6.1 严格对角占优矩阵或不可约弱对角占优矩阵 A 是可逆矩阵。

证明(一): 假设 A 不可逆。则存在非零向量 v , 使得 $Av = 0$. 不妨设 $\|v\|_\infty = 1$, 且 $|v_r| = 1$.

收敛性分析和误差估计

引理6.1 严格对角占优矩阵或不可约弱对角占优矩阵 A 是可逆矩阵。

证明(一): 假设 A 不可逆。则存在非零向量 v , 使得 $Av = 0$. 不妨设 $\|v\|_\infty = 1$, 且 $|v_r| = 1$.
则 $|v_j| \leq |v_r| = 1$.

收敛性分析和误差估计

引理6.1 严格对角占优矩阵或不可约弱对角占优矩阵 A 是可逆矩阵。

证明(一): 假设 A 不可逆。则存在非零向量 v , 使得 $Av = 0$. 不妨设 $\|v\|_\infty = 1$, 且 $|v_r| = 1$. 则 $|v_j| \leq |v_r| = 1$. 从 $Av = 0$ 的第 r 个方程得到,

$$|a_{rr}| \leq \sum_{j \neq r} |a_{rj}| |v_j| \leq \sum_{j \neq r} |a_{rj}| |v_j|.$$

收敛性分析和误差估计

引理6.1 严格对角占优矩阵或不可约弱对角占优矩阵 A 是可逆矩阵。

证明(一): 假设 A 不可逆。则存在非零向量 v , 使得 $Av = 0$. 不妨设 $\|v\|_\infty = 1$, 且 $|v_r| = 1$. 则 $|v_j| \leq |v_r| = 1$. 从 $Av = 0$ 的第 r 个方程得到,

$$|a_{rr}| \leq \sum_{j \neq r} |a_{rj}| |v_j| \leq \sum_{j \neq r} |a_{rj}| |v_j|.$$

A 是严格占优的, 因此上述不等式不成立, 矛盾。

收敛性分析和误差估计

引理6.1 严格对角占优矩阵或不可约弱对角占优矩阵 A 是可逆矩阵。

证明(一): 假设 A 不可逆。则存在非零向量 v , 使得 $Av = 0$. 不妨设 $\|v\|_\infty = 1$, 且 $|v_r| = 1$. 则 $|v_j| \leq |v_r| = 1$. 从 $Av = 0$ 的第 r 个方程得到,

$$|a_{rr}| \leq \sum_{j \neq r} |a_{rj}| |v_j| \leq \sum_{j \neq r} |a_{rj}| |v_j|.$$

A 是严格占优的, 因此上述不等式不成立, 矛盾。

引理6.2 设 A 是任意 n 阶方阵, 当 $k \rightarrow \infty$ 时, $A^k \rightarrow 0$ 的充要条件是 A 的谱半径 $\rho(A) < 1$.

收敛性分析和误差估计

引理6.1 严格对角占优矩阵或不可约弱对角占优矩阵 A 是可逆矩阵。

证明(一): 假设 A 不可逆。则存在非零向量 v , 使得 $Av = 0$. 不妨设 $\|v\|_\infty = 1$, 且 $|v_r| = 1$. 则 $|v_j| \leq |v_r| = 1$. 从 $Av = 0$ 的第 r 个方程得到,

$$|a_{rr}| \leq \sum_{j \neq r} |a_{rj}| |v_j| \leq \sum_{j \neq r} |a_{rj}| |v_j|.$$

A 是严格占优的, 因此上述不等式不成立, 矛盾。

引理6.2 设 A 是任意 n 阶方阵, 当 $k \rightarrow \infty$ 时, $A^k \rightarrow 0$ 的充要条件是 A 的谱半径 $\rho(A) < 1$.

证明: 利用Jordan标准型。

收敛性分析和误差估计

定理6.1 任一矩阵 A 的谱半径不大于任一与某个向量范数相容的矩阵范数，

$$\rho(A) \leq \|A\|.$$

收敛性分析和误差估计

定理6.1 任一矩阵 A 的谱半径不大于任一与某个向量范数相容的矩阵范数，

$$\rho(A) \leq \|A\|.$$

证明：

收敛性分析和误差估计

定理6.1 任一矩阵 A 的谱半径不大于任一与某个向量范数相容的矩阵范数，

$$\rho(A) \leq \|A\|.$$

证明：假设 (λ_i, x_i) 是矩阵 A 的特征对，则 $Ax_i = \lambda_i x_i$.

收敛性分析和误差估计

定理6.1 任一矩阵 A 的谱半径不大于任一与某个向量范数相容的矩阵范数，

$$\rho(A) \leq \|A\|.$$

证明：假设 (λ_i, x_i) 是矩阵 A 的特征对，则 $Ax_i = \lambda_i x_i$. 两边取范数，

$$|\lambda_i| \|x_i\| \leq \|A\| \|x_i\|.$$

收敛性分析和误差估计

定理6.1 任一矩阵 A 的谱半径不大于任一与某个向量范数相容的矩阵范数，

$$\rho(A) \leq \|A\|.$$

证明：假设 (λ_i, x_i) 是矩阵 A 的特征对，则 $Ax_i = \lambda_i x_i$. 两边取范数，

$$|\lambda_i| \|x_i\| \leq \|A\| \|x_i\|.$$

$$|\lambda_i| \leq \|A\|$$

收敛性分析和误差估计

定理6.1 任一矩阵 A 的谱半径不大于任一与某个向量范数相容的矩阵范数，

$$\rho(A) \leq \|A\|.$$

证明：假设 (λ_i, x_i) 是矩阵 A 的特征对，则 $Ax_i = \lambda_i x_i$. 两边取范数，

$$|\lambda_i| \|x_i\| \leq \|A\| \|x_i\|.$$

$$\rho(A) = \max_i |\lambda_i| \leq \|A\|$$

收敛性分析和误差估计

定理6.2 关于迭代格式 $x^{(k+1)} = Bx^{(k)} + g$, x^* 是真解,

- 格式对任意初值 $x^{(0)}$ 收敛的充要条件为 $\rho(B) < 1$;
- 若 $\|B\| < 1$, 则有

$$\begin{aligned}\|x^{(k)} - x^*\| &\leq \frac{\|B\|^k}{1-\|B\|} \|x^{(1)} - x^{(0)}\| \\ \|x^{(k)} - x^*\| &\leq \frac{\|B\|}{1-\|B\|} \|x^{(k)} - x^{(k-1)}\|.\end{aligned}$$

收敛性分析和误差估计

定理6.2 关于迭代格式 $x^{(k+1)} = Bx^{(k)} + g$, x^* 是真解,

- 格式对任意初值 $x^{(0)}$ 收敛的充要条件为 $\rho(B) < 1$;

证明:

收敛性分析和误差估计

定理6.2 关于迭代格式 $x^{(k+1)} = Bx^{(k)} + g$, x^* 是真解,

- 格式对任意初值 $x^{(0)}$ 收敛的充要条件为 $\rho(B) < 1$;

证明:

$$\left. \begin{array}{l} x^{(k+1)} = Bx^{(k)} + g \\ x^* = Bx^* + g \end{array} \right\}$$

收敛性分析和误差估计

定理6.2 关于迭代格式 $x^{(k+1)} = Bx^{(k)} + g$, x^* 是真解,

- 格式对任意初值 $x^{(0)}$ 收敛的充要条件为 $\rho(B) < 1$;

证明:

$$\left. \begin{array}{l} x^{(k+1)} = Bx^{(k)} + g \\ x^* = Bx^* + g \end{array} \right\} \Rightarrow x^{(k+1)} - x^* = B(x^{(k)} - x^*)$$

收敛性分析和误差估计

定理6.2 关于迭代格式 $x^{(k+1)} = Bx^{(k)} + g$, x^* 是真解,

- 格式对任意初值 $x^{(0)}$ 收敛的充要条件为 $\rho(B) < 1$;

证明:

$$\left. \begin{array}{l} x^{(k+1)} = Bx^{(k)} + g \\ x^* = Bx^* + g \end{array} \right\} \Rightarrow x^{(k+1)} - x^* = B(x^{(k)} - x^*)$$

$$\Rightarrow x^{(k)} - x^* = B^k(x^{(0)} - x^*)$$

收敛性分析和误差估计

定理6.2 关于迭代格式 $x^{(k+1)} = Bx^{(k)} + g$, x^* 是真解,

- 格式对任意初值 $x^{(0)}$ 收敛的充要条件为 $\rho(B) < 1$;

证明:

$$\left. \begin{array}{l} x^{(k+1)} = Bx^{(k)} + g \\ x^* = Bx^* + g \end{array} \right\} \Rightarrow x^{(k+1)} - x^* = B(x^{(k)} - x^*)$$

$$\Rightarrow x^{(k)} - x^* = B^k(x^{(0)} - x^*)$$

$x^{(0)}$ 是任意的, 上式等价于 $B^k \rightarrow 0$, 即 $\rho(B) < 1$.

收敛性分析和误差估计

定理6.2 关于迭代格式 $x^{(k+1)} = Bx^{(k)} + g$, x^* 是真解,

- 若 $\|B\| < 1$, 则有

$$\|x^{(k)} - x^*\| \leq \frac{\|B\|^k}{1 - \|B\|} \|x^{(1)} - x^{(0)}\|.$$

证明:

收敛性分析和误差估计

定理6.2 关于迭代格式 $x^{(k+1)} = Bx^{(k)} + g$, x^* 是真解,

- 若 $\|B\| < 1$, 则有

$$\|x^{(k)} - x^*\| \leq \frac{\|B\|^k}{1 - \|B\|} \|x^{(1)} - x^{(0)}\|.$$

证明:

$$\lim_{k \rightarrow \infty} x^{(k)} = x^*$$

收敛性分析和误差估计

定理6.2 关于迭代格式 $x^{(k+1)} = Bx^{(k)} + g$, x^* 是真解,

- 若 $\|B\| < 1$, 则有

$$\|x^{(k)} - x^*\| \leq \frac{\|B\|^k}{1 - \|B\|} \|x^{(1)} - x^{(0)}\|.$$

证明:

$$\lim_{k \rightarrow \infty} x^{(k)} = x^* \Rightarrow x^{(k)} - x^* = \sum_{i=k}^{\infty} (x^{(i)} - x^{(i+1)})$$

收敛性分析和误差估计

定理6.2 关于迭代格式 $x^{(k+1)} = Bx^{(k)} + g$, x^* 是真解,

- 若 $\|B\| < 1$, 则有

$$\|x^{(k)} - x^*\| \leq \frac{\|B\|^k}{1 - \|B\|} \|x^{(1)} - x^{(0)}\|.$$

证明:

$$\begin{aligned}\|x^{(k)} - x^*\| &\leq \sum_{i=k}^{\infty} \|x^{(i)} - x^{(i+1)}\| = \sum_{i=k}^{\infty} \|B^i(x^{(0)} - x^{(1)})\| \\ &\leq \sum_{i=k}^{\infty} \|B^i\| \|x^{(0)} - x^{(1)}\| = \frac{\|B\|^k}{1 - \|B\|} \|x^{(1)} - x^{(0)}\|\end{aligned}$$

收敛性分析和误差估计

定理6.2 关于迭代格式 $x^{(k+1)} = Bx^{(k)} + g$, x^* 是真解,

- 若 $\|B\| < 1$, 则有

$$\|x^{(k)} - x^*\| \leq \frac{\|B\|}{1 - \|B\|} \|x^{(k)} - x^{(k-1)}\|.$$

证明:

收敛性分析和误差估计

定理6.2 关于迭代格式 $x^{(k+1)} = Bx^{(k)} + g$, x^* 是真解,

- 若 $\|B\| < 1$, 则有

$$\|x^{(k)} - x^*\| \leq \frac{\|B\|}{1 - \|B\|} \|x^{(k)} - x^{(k-1)}\|.$$

证明:

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

收敛性分析和误差估计

定理6.2 关于迭代格式 $x^{(k+1)} = Bx^{(k)} + g$, x^* 是真解,

- 若 $\|B\| < 1$, 则有

$$\|x^{(k)} - x^*\| \leq \frac{\|B\|}{1 - \|B\|} \|x^{(k)} - x^{(k-1)}\|.$$

证明:

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

$$\|x^{(k)} - x^*\| \leq \|B\| \|x^{(k-1)} - x^{(k)}\| + \|B\| \|x^{(k)} - x^*\|$$

收敛性分析和误差估计

定理6.2 关于迭代格式 $x^{(k+1)} = Bx^{(k)} + g$, x^* 是真解,

- 若 $\|B\| < 1$, 则有

$$\|x^{(k)} - x^*\| \leq \frac{\|B\|}{1 - \|B\|} \|x^{(k)} - x^{(k-1)}\|.$$

证明:

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

$$\|x^{(k)} - x^*\| \leq \|B\| \|x^{(k-1)} - x^{(k)}\| + \|B\| \|x^{(k)} - x^*\|$$

移项即得。

收敛性分析和误差估计

定理6.3 若 A 是严格对角占优矩阵或不可约弱对角占优矩阵，则Jacobi迭代和GS迭代收敛。

收敛性分析和误差估计

定理6.3 若 A 是严格对角占优矩阵或不可约弱对角占优矩阵，则Jacobi迭代和GS迭代收敛。

证明：

收敛性分析和误差估计

定理6.3 若 A 是严格对角占优矩阵或不可约弱对角占优矩阵，则Jacobi迭代和GS迭代收敛。

证明：Jacobi迭代， $B_J = D^{-1}(L + U)$.

收敛性分析和误差估计

定理6.3 若 A 是严格对角占优矩阵或不可约弱对角占优矩阵，则Jacobi迭代和GS迭代收敛。

证明：Jacobi迭代， $B_J = D^{-1}(L + U)$. 假设 B_J 有一特征值 $|\lambda| \geq 1$.

收敛性分析和误差估计

定理6.3 若 A 是严格对角占优矩阵或不可约弱对角占优矩阵，则Jacobi迭代和GS迭代收敛。

证明：Jacobi迭代， $B_J = D^{-1}(L + U)$. 假设 B_J 有一特征值 $|\lambda| \geq 1$.

$$\det(\lambda I - B_J) = \det(\lambda I - D^{-1}(L + U)) = 0.$$

收敛性分析和误差估计

定理6.3 若 A 是严格对角占优矩阵或不可约弱对角占优矩阵，则Jacobi迭代和GS迭代收敛。

证明：Jacobi迭代， $B_J = D^{-1}(L + U)$. 假设 B_J 有一特征值 $|\lambda| \geq 1$.

$$\det(\lambda I - B_J) = \det(\lambda I - D^{-1}(L + U)) = 0.$$

所以有

$$\det(\lambda D - L - U) = 0.$$

收敛性分析和误差估计

定理6.3 若 A 是严格对角占优矩阵或不可约弱对角占优矩阵，则Jacobi迭代和GS迭代收敛。

证明：Jacobi迭代， $B_J = D^{-1}(L + U)$. 假设 B_J 有一特征值 $|\lambda| \geq 1$.

$$\det(\lambda I - B_J) = \det(\lambda I - D^{-1}(L + U)) = 0.$$

所以有

$$\det(\lambda D - L - U) = 0.$$

但矩阵 $\lambda D - L - U$ 保持了矩阵 $A = D - L - U$ 的对角占优和不可约的性质，是一可逆矩阵。矛盾。

收敛性分析和误差估计

定理6.3 若 A 是严格对角占优矩阵或不可约弱对角占优矩阵，则Jacobi迭代和GS迭代收敛。

证明：Jacobi迭代， $B_J = D^{-1}(L + U)$. 假设 B_J 有一特征值 $|\lambda| \geq 1$.

$$\det(\lambda I - B_J) = \det(\lambda I - D^{-1}(L + U)) = 0.$$

所以有

$$\det(\lambda D - L - U) = 0.$$

但矩阵 $\lambda D - L - U$ 保持了矩阵 $A = D - L - U$ 的对角占优和不可约的性质，是一可逆矩阵。矛盾。
GS迭代部分证明完全类似Jacobi迭代。

收敛性分析和误差估计

定理6.4 若 A 是正定对称矩阵，则Jacobi迭代收敛的充要条件是 $2D - A$ 也正定。

收敛性分析和误差估计

定理6.4 若 A 是正定对称矩阵，则Jacobi迭代收敛的充要条件是 $2D - A$ 也正定。

证明：

收敛性分析和误差估计

定理6.4 若 A 是正定对称矩阵，则Jacobi迭代收敛的充要条件是 $2D - A$ 也正定。

证明：由 A 对称正定， $a_{ii} > 0$ ，

令 $D^{\frac{1}{2}} = \text{diag}(\sqrt{a_{11}}, \sqrt{a_{22}}, \dots, \sqrt{a_{nn}})$

收敛性分析和误差估计

定理6.4 若 A 是正定对称矩阵，则Jacobi迭代收敛的充要条件是 $2D - A$ 也正定。

证明：由 A 对称正定， $a_{ii} > 0$ ，

令 $D^{\frac{1}{2}} = \text{diag}(\sqrt{a_{11}}, \sqrt{a_{22}}, \dots, \sqrt{a_{nn}})$

$$B_J = D^{-1}(D - A) = I - D^{-1}A = D^{-\frac{1}{2}}(I - D^{-\frac{1}{2}}AD^{-\frac{1}{2}})D^{\frac{1}{2}}$$

收敛性分析和误差估计

定理6.4 若 A 是正定对称矩阵，则Jacobi迭代收敛的充要条件是 $2D - A$ 也正定。

证明：由 A 对称正定， $a_{ii} > 0$ ，

$$\text{令 } D^{\frac{1}{2}} = \text{diag}(\sqrt{a_{11}}, \sqrt{a_{22}}, \dots, \sqrt{a_{nn}})$$

$$B_J = D^{-1}(D - A) = I - D^{-1}A = D^{-\frac{1}{2}}(I - D^{-\frac{1}{2}}AD^{-\frac{1}{2}})D^{\frac{1}{2}}$$

B_J 相似于对称阵 $(I - D^{-\frac{1}{2}}AD^{-\frac{1}{2}})$ ，特征值均为实数。

收敛性分析和误差估计

定理6.4 若 A 是正定对称矩阵，则Jacobi迭代收敛的充要条件是 $2D - A$ 也正定。

证明：

Jacobi迭代收敛

收敛性分析和误差估计

定理6.4 若 A 是正定对称矩阵，则Jacobi迭代收敛的充要条件是 $2D - A$ 也正定。

证明：

Jacobi迭代收敛

$$\Leftrightarrow \rho(B_J) = \rho(I - D^{-\frac{1}{2}}AD^{-\frac{1}{2}}) < 1$$

收敛性分析和误差估计

定理6.4 若 A 是正定对称矩阵，则Jacobi迭代收敛的充要条件是 $2D - A$ 也正定。

证明：

Jacobi迭代收敛

$$\Leftrightarrow \rho(B_J) = \rho(I - D^{-\frac{1}{2}}AD^{-\frac{1}{2}}) < 1$$

$$\Leftrightarrow |1 - \mu(D^{-\frac{1}{2}}AD^{-\frac{1}{2}})| < 1$$

收敛性分析和误差估计

定理6.4 若 A 是正定对称矩阵，则Jacobi迭代收敛的充要条件是 $2D - A$ 也正定。

证明：

Jacobi迭代收敛

$$\Leftrightarrow \rho(B_J) = \rho(I - D^{-\frac{1}{2}}AD^{-\frac{1}{2}}) < 1$$

$$\Leftrightarrow |1 - \mu(D^{-\frac{1}{2}}AD^{-\frac{1}{2}})| < 1$$

$$\Leftrightarrow 0 < \mu(D^{-\frac{1}{2}}AD^{-\frac{1}{2}}) < 2$$

收敛性分析和误差估计

定理6.4 若 A 是正定对称矩阵，则Jacobi迭代收敛的充要条件是 $2D - A$ 也正定。

证明：

Jacobi迭代收敛

$$\Leftrightarrow \rho(B_J) = \rho(I - D^{-\frac{1}{2}}AD^{-\frac{1}{2}}) < 1$$

$$\Leftrightarrow |1 - \mu(D^{-\frac{1}{2}}AD^{-\frac{1}{2}})| < 1$$

$$\Leftrightarrow \mu(D^{-\frac{1}{2}}AD^{-\frac{1}{2}}) < 2$$

收敛性分析和误差估计

定理6.4 若 A 是正定对称矩阵，则Jacobi迭代收敛的充要条件是 $2D - A$ 也正定。

证明：

Jacobi迭代收敛

$$\Leftrightarrow \rho(B_J) = \rho(I - D^{-\frac{1}{2}}AD^{-\frac{1}{2}}) < 1$$

$$\Leftrightarrow |1 - \mu(D^{-\frac{1}{2}}AD^{-\frac{1}{2}})| < 1$$

$$\Leftrightarrow \mu(D^{-\frac{1}{2}}AD^{-\frac{1}{2}}) < 2$$

$$\Leftrightarrow 2I - D^{-\frac{1}{2}}AD^{-\frac{1}{2}} \text{ 正定}$$

收敛性分析和误差估计

定理6.4 若 A 是正定对称矩阵，则Jacobi迭代收敛的充要条件是 $2D - A$ 也正定。

证明：

Jacobi迭代收敛

$$\begin{aligned} &\Leftrightarrow \rho(B_J) = \rho(I - D^{-\frac{1}{2}}AD^{-\frac{1}{2}}) < 1 \\ &\Leftrightarrow |1 - \mu(D^{-\frac{1}{2}}AD^{-\frac{1}{2}})| < 1 \\ &\Leftrightarrow \mu(D^{-\frac{1}{2}}AD^{-\frac{1}{2}}) < 2 \\ &\Leftrightarrow 2I - D^{-\frac{1}{2}}AD^{-\frac{1}{2}} \text{ 正定} \\ &\Leftrightarrow 2D - A = D^{\frac{1}{2}}(2I - D^{-\frac{1}{2}}AD^{-\frac{1}{2}})D^{\frac{1}{2}} \text{ 正定} \end{aligned}$$

收敛性分析和误差估计

定理6.5 SOR迭代收敛的必要条件是 $0 < \omega < 2$.

收敛性分析和误差估计

定理6.5 SOR迭代收敛的必要条件是 $0 < \omega < 2$.

证明:

收敛性分析和误差估计

定理6.5 SOR迭代收敛的必要条件是 $0 < \omega < 2$.

证明: $B_{SOR} = (D - \omega L)^{-1}[(1 - \omega)D + \omega U]$.

设 $\lambda_1, \lambda_2, \dots, \lambda_n$ 是 B_{SOR} 的n个特征值。

收敛性分析和误差估计

定理6.5 SOR迭代收敛的必要条件是 $0 < \omega < 2$.

证明: $B_{SOR} = (D - \omega L)^{-1}[(1 - \omega)D + \omega U]$.

设 $\lambda_1, \lambda_2, \dots, \lambda_n$ 是 B_{SOR} 的n个特征值。

$$1 > (\rho(B_{SOR}))^n$$

收敛性分析和误差估计

定理6.5 SOR迭代收敛的必要条件是 $0 < \omega < 2$.

证明: $B_{SOR} = (D - \omega L)^{-1}[(1 - \omega)D + \omega U]$.

设 $\lambda_1, \lambda_2, \dots, \lambda_n$ 是 B_{SOR} 的n个特征值。

$$\begin{aligned} 1 &> (\rho(B_{SOR}))^n \\ &\geq |\lambda_1 \lambda_2 \cdots \lambda_n| \end{aligned}$$

收敛性分析和误差估计

定理6.5 SOR迭代收敛的必要条件是 $0 < \omega < 2$.

证明: $B_{SOR} = (D - \omega L)^{-1}[(1 - \omega)D + \omega U]$.

设 $\lambda_1, \lambda_2, \dots, \lambda_n$ 是 B_{SOR} 的n个特征值。

$$\begin{aligned} 1 &> (\rho(B_{SOR}))^n \\ &\geq |\lambda_1 \lambda_2 \cdots \lambda_n| \\ &= |\det(B_{SOR})| \end{aligned}$$

收敛性分析和误差估计

定理6.5 SOR迭代收敛的必要条件是 $0 < \omega < 2$.

证明: $B_{SOR} = (D - \omega L)^{-1}[(1 - \omega)D + \omega U]$.

设 $\lambda_1, \lambda_2, \dots, \lambda_n$ 是 B_{SOR} 的n个特征值。

$$\begin{aligned} 1 &> (\rho(B_{SOR}))^n \\ &\geq |\lambda_1 \lambda_2 \cdots \lambda_n| \\ &= |\det(B_{SOR})| \\ &= |\det((D - \omega L)^{-1})||\det((1 - \omega)D + \omega U)| \end{aligned}$$

收敛性分析和误差估计

定理6.5 SOR迭代收敛的必要条件是 $0 < \omega < 2$.

证明: $B_{SOR} = (D - \omega L)^{-1}[(1 - \omega)D + \omega U]$.

设 $\lambda_1, \lambda_2, \dots, \lambda_n$ 是 B_{SOR} 的n个特征值。

$$\begin{aligned} 1 &> (\rho(B_{SOR}))^n \\ &\geq |\lambda_1 \lambda_2 \cdots \lambda_n| \\ &= |\det(B_{SOR})| \\ &= |\det((D - \omega L)^{-1})| |\det((1 - \omega)D + \omega U)| \\ &= |a_{11}^{-1} a_{22}^{-1} \cdots a_{nn}^{-1}| |(1 - \omega)^n a_{11} a_{22} \cdots a_{nn}| \end{aligned}$$

收敛性分析和误差估计

定理6.5 SOR迭代收敛的必要条件是 $0 < \omega < 2$.

证明: $B_{SOR} = (D - \omega L)^{-1}[(1 - \omega)D + \omega U]$.

设 $\lambda_1, \lambda_2, \dots, \lambda_n$ 是 B_{SOR} 的n个特征值。

$$\begin{aligned} 1 &> (\rho(B_{SOR}))^n \\ &\geq |\lambda_1 \lambda_2 \cdots \lambda_n| \\ &= |\det(B_{SOR})| \\ &= |\det((D - \omega L)^{-1})| |\det((1 - \omega)D + \omega U)| \\ &= |a_{11}^{-1} a_{22}^{-1} \cdots a_{nn}^{-1}| |(1 - \omega)^n a_{11} a_{22} \cdots a_{nn}| \\ &= |(1 - \omega)^n| \end{aligned}$$

收敛性分析和误差估计

定理6.5 SOR迭代收敛的必要条件是 $0 < \omega < 2$.

证明: $B_{SOR} = (D - \omega L)^{-1}[(1 - \omega)D + \omega U]$.

设 $\lambda_1, \lambda_2, \dots, \lambda_n$ 是 B_{SOR} 的n个特征值。

$$\begin{aligned} 1 &> (\rho(B_{SOR}))^n \\ &\geq |\lambda_1 \lambda_2 \cdots \lambda_n| \\ &= |\det(B_{SOR})| \\ &= |\det((D - \omega L)^{-1})| |\det((1 - \omega)D + \omega U)| \\ &= |a_{11}^{-1} a_{22}^{-1} \cdots a_{nn}^{-1}| |(1 - \omega)^n a_{11} a_{22} \cdots a_{nn}| \\ &= |(1 - \omega)^n| \end{aligned}$$

所以, $0 < \omega < 2$.

收敛性分析和误差估计

定理6.6 设系数矩阵 A 对称正定, 则 $0 < \omega < 2$ 时SOR迭代收敛。

收敛性分析和误差估计

定理6.6 设系数矩阵 A 对称正定, 则 $0 < \omega < 2$ 时SOR迭代收敛。

证明:

收敛性分析和误差估计

定理6.6 设系数矩阵 A 对称正定, 则 $0 < \omega < 2$ 时SOR迭代收敛。

证明: 只需证明 B_{SOR} 的任一特征值 $|\lambda| < 1$.

收敛性分析和误差估计

定理6.6 设系数矩阵 A 对称正定, 则 $0 < \omega < 2$ 时SOR迭代收敛。

证明: 只需证明 B_{SOR} 的任一特征值 $|\lambda| < 1$. 设 x 是其对应的特征向量, 则

收敛性分析和误差估计

定理6.6 设系数矩阵 A 对称正定, 则 $0 < \omega < 2$ 时SOR迭代收敛。

证明: 只需证明 B_{SOR} 的任一特征值 $|\lambda| < 1$. 设 x 是其对应的特征向量, 则

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

收敛性分析和误差估计

定理6.6 设系数矩阵 A 对称正定, 则 $0 < \omega < 2$ 时SOR迭代收敛。

证明: 只需证明 B_{SOR} 的任一特征值 $|\lambda| < 1$. 设 x 是其对应的特征向量, 则

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

$$[(1 - \omega)D + \omega U]x = \lambda(D - \omega L)x$$

收敛性分析和误差估计

定理6.6 设系数矩阵 A 对称正定, 则 $0 < \omega < 2$ 时SOR迭代收敛。

证明: 只需证明 B_{SOR} 的任一特征值 $|\lambda| < 1$. 设 x 是其对应的特征向量, 则

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

$$[(1 - \omega)D + \omega U]x = \lambda(D - \omega L)x$$

$$(1 - \omega)x^H D x + \omega x^H U x = \lambda(x^H D x - \omega x^H L x)$$

收敛性分析和误差估计

定理6.6 设系数矩阵 A 对称正定, 则 $0 < \omega < 2$ 时SOR迭代收敛。

证明: 只需证明 B_{SOR} 的任一特征值 $|\lambda| < 1$. 设 x 是其对应的特征向量, 则

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

$$[(1 - \omega)D + \omega U]x = \lambda(D - \omega L)x$$

$$(1 - \omega)x^H D x + \omega x^H U x = \lambda(x^H D x - \omega x^H L x)$$

记 $x^H D x = \sigma$, $x^H L x = \alpha + i\beta$,

收敛性分析和误差估计

定理6.6 设系数矩阵 A 对称正定, 则 $0 < \omega < 2$ 时SOR迭代收敛。

证明: 只需证明 B_{SOR} 的任一特征值 $|\lambda| < 1$. 设 x 是其对应的特征向量, 则

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

$$[(1 - \omega)D + \omega U]x = \lambda(D - \omega L)x$$

$$(1 - \omega)x^H D x + \omega x^H U x = \lambda(x^H D x - \omega x^H L x)$$

记 $x^H D x = \sigma$, $x^H L x = \alpha + i\beta$,
则 $x^H U x = (x^H L x)^H = \alpha - i\beta$.

收敛性分析和误差估计

定理6.6 设系数矩阵 A 对称正定, 则 $0 < \omega < 2$ 时SOR迭代收敛。

证明: 只需证明 B_{SOR} 的任一特征值 $|\lambda| < 1$. 设 x 是其对应的特征向量, 则

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

$$[(1 - \omega)D + \omega U]x = \lambda(D - \omega L)x$$

$$(1 - \omega)x^H D x + \omega x^H U x = \lambda(x^H D x - \omega x^H L x)$$

记 $x^H D x = \sigma$, $x^H L x = \alpha + i\beta$,

则 $x^H U x = (x^H L x)^H = \alpha - i\beta$.

$$\lambda = \frac{(1 - \omega)\sigma + \omega(\alpha - i\beta)}{\sigma - \omega(\alpha + i\beta)}$$

收敛性分析和误差估计

定理6.6 设系数矩阵 A 对称正定, 则 $0 < \omega < 2$ 时SOR迭代收敛。

证明: 记 $x^H D x = \sigma$, $x^H L x = \alpha + i\beta$,
则 $x^H U x = (x^H L x)^H = \alpha - i\beta$.

$$\lambda = \frac{(1 - \omega)\sigma + \omega(\alpha - i\beta)}{\sigma - \omega(\alpha + i\beta)}$$

$$|\lambda|^2 = \frac{(\sigma - \omega\sigma + \omega\alpha)^2 + (\omega\beta)^2}{(\sigma - \omega\alpha)^2 + (\omega\beta)^2}$$

收敛性分析和误差估计

定理6.6 设系数矩阵 A 对称正定, 则 $0 < \omega < 2$ 时SOR迭代收敛。

证明: 记 $x^H D x = \sigma$, $x^H L x = \alpha + i\beta$,

则 $x^H U x = (x^H L x)^H = \alpha - i\beta$.

$$\lambda = \frac{(1 - \omega)\sigma + \omega(\alpha - i\beta)}{\sigma - \omega(\alpha + i\beta)}$$

$$|\lambda|^2 = \frac{(\sigma - \omega\sigma + \omega\alpha)^2 + (\omega\beta)^2}{(\sigma - \omega\alpha)^2 + (\omega\beta)^2}$$

$$(\sigma - \omega\sigma + \omega\alpha)^2 - (\sigma - \omega\alpha)^2 = \omega\sigma(2 - \omega)(2\alpha - \sigma)$$

收敛性分析和误差估计

定理6.6 设系数矩阵 A 对称正定, 则 $0 < \omega < 2$ 时SOR迭代收敛。

证明:

$$|\lambda|^2 = \frac{(\sigma - \omega\sigma + \omega\alpha)^2 + (\omega\beta)^2}{(\sigma - \omega\alpha)^2 + (\omega\beta)^2}$$

$$(\sigma - \omega\sigma + \omega\alpha)^2 - (\sigma - \omega\alpha)^2 = \omega\sigma(2 - \omega)(2\alpha - \sigma)$$

$$\sigma = x^H D x = \sum_{i=1}^n a_{ii} |x_i|^2 > 0,$$

收敛性分析和误差估计

定理6.6 设系数矩阵 A 对称正定, 则 $0 < \omega < 2$ 时SOR迭代收敛。

证明:

$$|\lambda|^2 = \frac{(\sigma - \omega\sigma + \omega\alpha)^2 + (\omega\beta)^2}{(\sigma - \omega\alpha)^2 + (\omega\beta)^2}$$

$$(\sigma - \omega\sigma + \omega\alpha)^2 - (\sigma - \omega\alpha)^2 = \omega\sigma(2 - \omega)(2\alpha - \sigma)$$

$$\sigma = x^H D x = \sum_{i=1}^n a_{ii} |x_i|^2 > 0,$$

$$\sigma - 2\alpha = x^H D x - x^H L x - x^H U x = x^H A x > 0.$$

收敛性分析和误差估计

定理6.6 设系数矩阵 A 对称正定, 则 $0 < \omega < 2$ 时SOR迭代收敛。

证明:

$$|\lambda|^2 = \frac{(\sigma - \omega\sigma + \omega\alpha)^2 + (\omega\beta)^2}{(\sigma - \omega\alpha)^2 + (\omega\beta)^2}$$

$$(\sigma - \omega\sigma + \omega\alpha)^2 - (\sigma - \omega\alpha)^2 = \omega\sigma(2 - \omega)(2\alpha - \sigma) < 0$$

$$\sigma = x^H D x = \sum_{i=1}^n a_{ii} |x_i|^2 > 0,$$

$$\sigma - 2\alpha = x^H D x - x^H L x - x^H U x = x^H A x > 0.$$

收敛性分析和误差估计

定理6.6 设系数矩阵 A 对称正定, 则 $0 < \omega < 2$ 时SOR迭代收敛。

证明:

$$|\lambda|^2 = \frac{(\sigma - \omega\sigma + \omega\alpha)^2 + (\omega\beta)^2}{(\sigma - \omega\alpha)^2 + (\omega\beta)^2} < 1$$

$$(\sigma - \omega\sigma + \omega\alpha)^2 - (\sigma - \omega\alpha)^2 = \omega\sigma(2 - \omega)(2\alpha - \sigma) < 0$$

$$\sigma = x^H D x = \sum_{i=1}^n a_{ii} |x_i|^2 > 0,$$

$$\sigma - 2\alpha = x^H D x - x^H L x - x^H U x = x^H A x > 0.$$

基于变分原理的迭代法

X

基于变分原理的迭代法

X