

数值计算方法

线性方程组的迭代解法

张晓平

2019 年 10 月 12 日

武汉大学数学与统计学院

Table of contents

1. 线性方程组的性态
2. Jacobi 迭代与 Gauss-Seidel 迭代
3. Jacobi 与 Gauss-Seidel 迭代的收敛性分析
4. 超松弛迭代法

线性方程组的性态

线性方程组的性态

向量范数

定义：向量范数

向量范数是一个 $\|\cdot\|: \mathbb{R}^n \rightarrow \mathbb{R}$ 的非负函数，它满足：

(1) 正定性：

$$\|x\| \geq 0, \quad \forall x \in \mathbb{R}^n, \quad \text{且} \quad \|x\| = 0 \iff x = 0$$

(2) 齐次性：

$$\|\alpha x\| = |\alpha| \|x\|, \quad \forall x \in \mathbb{R}^n, \quad \alpha \in \mathbb{R}$$

(3) 三角不等式：

$$\|x + y\| \leq \|x\| + \|y\|, \quad \forall x, y \in \mathbb{R}^n$$

由 (2) 和 (3) 易知, $\forall \mathbf{x}, \mathbf{y} \in \mathbb{R}^n$ 有

$$|\|\mathbf{x}\| - \|\mathbf{y}\|| \leq \|\mathbf{x} - \mathbf{y}\| \leq \max_{1 \leq i \leq n} \|e_i\| \sum_{i=1}^n |x_i - y_i|.$$

这说明 $\|\cdot\|$ 作为 \mathbb{R}^n 的实函数是连续的。

定义： p 范数

$$\|\mathbf{x}\|_p = (|x_1|^p + \cdots + |x_n|^p)^{\frac{1}{p}}, \quad p \geq 1$$

- 1 范数

$$\|\mathbf{x}\|_1 = |x_1| + \cdots + |x_n|$$

- 2 范数

$$\|\mathbf{x}\|_2 = (|x_1|^2 + \cdots + |x_n|^2)^{\frac{1}{2}} = \sqrt{\mathbf{x}^T \mathbf{x}}$$

- ∞ 范数

$$\|\mathbf{x}\|_\infty = \max_{i=1, \dots, n} \{|x_i|\}$$

定理：范数等价性

设 $\|\cdot\|_\alpha$ 和 $\|\cdot\|_\beta$ 是 \mathbb{R}^n 的任意两个范数，则存在正常数 c_1 和 c_2 使得 $\forall \mathbf{x} \in \mathbb{R}^n$ 有

$$c_1 \|\mathbf{x}\|_\alpha \leq \|\mathbf{x}\|_\beta \leq c_2 \|\mathbf{x}\|_\alpha$$

定理：范数等价性

设 $\|\cdot\|_\alpha$ 和 $\|\cdot\|_\beta$ 是 \mathbb{R}^n 的任意两个范数，则存在正常数 c_1 和 c_2 使得 $\forall \mathbf{x} \in \mathbb{R}^n$ 有

$$c_1 \|\mathbf{x}\|_\alpha \leq \|\mathbf{x}\|_\beta \leq c_2 \|\mathbf{x}\|_\alpha$$

请自行验证

$$\|\mathbf{x}\|_2 \leq \|\mathbf{x}\|_1 \leq \sqrt{n} \|\mathbf{x}\|_2,$$

$$\|\mathbf{x}\|_\infty \leq \|\mathbf{x}\|_2 \leq \sqrt{n} \|\mathbf{x}\|_\infty,$$

$$\|\mathbf{x}\|_\infty \leq \|\mathbf{x}\|_1 \leq n \|\mathbf{x}\|_\infty,$$

定理

设 $\boldsymbol{x}^{(k)}, \boldsymbol{x} \in \mathbb{R}^n$, 则

$$\lim_{k \rightarrow \infty} \|\boldsymbol{x}^{(k)} - \boldsymbol{x}\| = 0 \iff \lim_{k \rightarrow \infty} |x_i^{(k)} - x_i| = 0, \quad i = 1, \dots, n$$

线性方程组的性态

矩阵范数

性质

矩阵范数是一个 $\|\cdot\|: \mathbb{R}^{n \times n} \rightarrow \mathbb{R}$ 的非负函数, 它满足:

(1) 正定性:

$$\|A\| \geq 0, \quad \forall A \in \mathbb{R}^{n \times n}, \quad \text{且 } \|A\| = 0 \iff A = 0$$

(2) 齐次性:

$$\|\alpha A\| = |\alpha| \cdot \|A\|, \quad \forall A \in \mathbb{R}^{n \times n}, \quad \alpha \in \mathbb{R}$$

(3) 三角不等式:

$$\|A + B\| \leq \|A\| + \|B\|, \quad \forall A, B \in \mathbb{R}^{n \times n}$$

(4) 相容性:

$$\|AB\| \leq \|A\| \cdot \|B\|, \quad \forall A, B \in \mathbb{R}^{n \times n}$$

性质

1° $\mathbb{R}^{n \times n}$ 上的任意两个范数等价

2° 矩阵序列的范数收敛等价于元素收敛, 即

$$\lim_{k \rightarrow \infty} \|A_k - A\| = 0 \iff \lim_{k \rightarrow \infty} a_{ij}^{(k)} = a_{ij}, \quad i, j = 1, \dots, n,$$

其中 $A_k = (a_{ij}^{(k)})$.

定义：矩阵范数与向量范数的相容性

若矩阵范数 $\|\cdot\|_M$ 和向量范数 $\|\cdot\|_v$ 满足

$$\|\mathbf{A}\mathbf{x}\|_v \leq \|\mathbf{A}\|_M \|\mathbf{x}\|_v, \quad \mathbf{A} \in \mathbb{R}^{n \times n}, \quad \mathbf{x} \in \mathbb{R}^n,$$

则称矩阵范数 $\|\cdot\|_M$ 和向量范数 $\|\cdot\|_v$ 相容。

定义：矩阵范数与向量范数的相容性

若矩阵范数 $\|\cdot\|_M$ 和向量范数 $\|\cdot\|_v$ 满足

$$\|\mathbf{A}\mathbf{x}\|_v \leq \|\mathbf{A}\|_M \|\mathbf{x}\|_v, \quad \mathbf{A} \in \mathbb{R}^{n \times n}, \quad \mathbf{x} \in \mathbb{R}^n,$$

则称矩阵范数 $\|\cdot\|_M$ 和向量范数 $\|\cdot\|_v$ 相容。

若无特别说明，总假定矩阵范数和向量范数相容。

定义：从属范数

设 $\|\cdot\|$ 是 \mathbb{R}^n 上的一个向量范数，若定义

$$\|A\| = \max_{\|x\|=1} \|Ax\|, \quad A \in \mathbb{R}^{n \times n},$$

则称 $\|\cdot\|$ 是 $\mathbb{R}^{n \times n}$ 上的一个矩阵范数。

定义：从属范数

设 $\|\cdot\|$ 是 \mathbb{R}^n 上的一个向量范数，若定义

$$\|A\| = \max_{\|x\|=1} \|Ax\|, \quad A \in \mathbb{R}^{n \times n},$$

则称 $\|\cdot\|$ 是 $\mathbb{R}^{n \times n}$ 上的一个矩阵范数。

这样的矩阵范数 $\|\cdot\|$ 称为从属于向量范数 $\|\cdot\|$ 的矩阵范数，也称由向量范数 $\|\cdot\|$ 诱导出的算子范数。

由 \mathbb{R}^n 上的 p 范数可诱导出 $\mathbb{R}^{n \times n}$ 上的算子范数 $\|\cdot\|_p$:

$$\|A\|_p = \max_{\|x\|_p=1} \|Ax\|_p, \quad A \in \mathbb{R}^{n \times n}.$$

推论

设 $A = (a_{ij}) \in \mathbb{R}^{n \times n}$, 则

- 列范数

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

- 行范数

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

- 谱范数

$$\|A\|_2 = \sqrt{\lambda_{\max}(A^T A)}$$

其中 $\lambda_{\max}(A^T A)$ 表示 $A^T A$ 的最大特征值。

推论

设 $A = (a_{ij}) \in \mathbb{R}^{n \times n}$, 则

- 列范数

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

- 行范数

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

- 谱范数

$$\|A\|_2 = \sqrt{\lambda_{\max}(A^T A)}$$

其中 $\lambda_{\max}(A^T A)$ 表示 $A^T A$ 的最大特征值。

注

当 $A = 0$ 时定理显然成立, 以下证明只考虑 $A \neq 0$ 。

矩阵范数

证明 (列范数) :

设 $A = [\mathbf{a}_1, \dots, \mathbf{a}_n]$, 且 $\delta = \|\mathbf{a}_{j_0}\| = \max_{1 \leq j \leq n} \|\mathbf{a}_j\|_1$.

证明 (列范数) :

设 $A = [\mathbf{a}_1, \dots, \mathbf{a}_n]$, 且 $\delta = \|\mathbf{a}_{j_0}\| = \max_{1 \leq j \leq n} \|\mathbf{a}_j\|_1$. 对任意满足 $\|x\|_1 = 1$ 的 $x \in \mathbb{R}^n$, 有

$$\begin{aligned}\|A\mathbf{x}\|_1 &= \left\| \sum_{j=1}^n x_j \mathbf{a}_j \right\|_1 \leq \sum_{j=1}^n |x_j| \|\mathbf{a}_j\|_1 \\ &\leq \sum_{j=1}^n |x_j| \max_{1 \leq j \leq n} \|\mathbf{a}_j\|_1 = \|\mathbf{a}_{j_0}\|_1 = \delta.\end{aligned}$$

证明 (列范数) :

设 $A = [a_1, \dots, a_n]$, 且 $\delta = \|a_{j_0}\| = \max_{1 \leq j \leq n} \|a_j\|_1$. 对任意满足 $\|x\|_1 = 1$ 的 $x \in \mathbb{R}^n$, 有

$$\begin{aligned}\|Ax\|_1 &= \left\| \sum_{j=1}^n x_j a_j \right\|_1 \leq \sum_{j=1}^n |x_j| \|a_j\|_1 \\ &\leq \sum_{j=1}^n |x_j| \max_{1 \leq j \leq n} \|a_j\|_1 = \|a_{j_0}\|_1 = \delta.\end{aligned}$$

因 $\|e_{j_0}\| = 1$ 且 $\|Ae_{j_0}\|_1 = \|a_{j_0}\|_1 = \delta$, 故

$$\|A\|_1 = \max_{\|x\|_1=1} \|Ax\|_1 = \delta = \max_{1 \leq j \leq n} \|a_j\|_1 = \max_{1 \leq j \leq n} \sum_{i=1}^n |a_{ij}|.$$

矩阵范数

证明 (行范数) :

设 $\eta = \max_{1 \leq i \leq n} \sum_{j=1}^n |a_{ij}|$, 对任意满足 $\|x\|_{\infty} = 1$ 的 $x \in \mathbb{R}^n$, 有

$$\|Ax\|_{\infty} = \max_{1 \leq i \leq n} \left| \sum_{j=1}^n a_{ij}x_j \right| \leq \max_{1 \leq i \leq n} \sum_{j=1}^n |a_{ij}||x_j| \leq \max_{1 \leq i \leq n} \sum_{j=1}^n |a_{ij}| = \eta.$$

矩阵范数

证明 (行范数) :

设 $\eta = \max_{1 \leq i \leq n} \sum_{j=1}^n |a_{ij}|$, 对任意满足 $\|x\|_\infty = 1$ 的 $x \in \mathbb{R}^n$, 有

$$\|Ax\|_\infty = \max_{1 \leq i \leq n} \left| \sum_{j=1}^n a_{ij}x_j \right| \leq \max_{1 \leq i \leq n} \sum_{j=1}^n |a_{ij}||x_j| \leq \max_{1 \leq i \leq n} \sum_{j=1}^n |a_{ij}| = \eta.$$

设 A 的第 k 行的 1 范数最大, 即 $\eta = \sum_{j=1}^n |a_{kj}|$ 。令

$$x^* = (\operatorname{sgn}(a_{k1}), \dots, \operatorname{sgn}(a_{kn}))^T,$$

则

矩阵范数

证明 (行范数) :

设 $\eta = \max_{1 \leq i \leq n} \sum_{j=1}^n |a_{ij}|$, 对任意满足 $\|x\|_{\infty} = 1$ 的 $x \in \mathbb{R}^n$, 有

$$\|Ax\|_{\infty} = \max_{1 \leq i \leq n} \left| \sum_{j=1}^n a_{ij}x_j \right| \leq \max_{1 \leq i \leq n} \sum_{j=1}^n |a_{ij}||x_j| \leq \max_{1 \leq i \leq n} \sum_{j=1}^n |a_{ij}| = \eta.$$

设 A 的第 k 行的 1 范数最大, 即 $\eta = \sum_{j=1}^n |a_{kj}|$. 令

$$x^* = (\operatorname{sgn}(a_{k1}), \dots, \operatorname{sgn}(a_{kn}))^T,$$

则

$$A \neq 0 \implies \|x^*\|_{\infty} = 1 \implies \|Ax^*\|_{\infty} = \eta$$

证明 (行范数) :

设 $\eta = \max_{1 \leq i \leq n} \sum_{j=1}^n |a_{ij}|$, 对任意满足 $\|x\|_\infty = 1$ 的 $x \in \mathbb{R}^n$, 有

$$\|Ax\|_\infty = \max_{1 \leq i \leq n} \left| \sum_{j=1}^n a_{ij}x_j \right| \leq \max_{1 \leq i \leq n} \sum_{j=1}^n |a_{ij}| |x_j| \leq \max_{1 \leq i \leq n} \sum_{j=1}^n |a_{ij}| = \eta.$$

设 A 的第 k 行的 1 范数最大, 即 $\eta = \sum_{j=1}^n |a_{kj}|$. 令

$$x^* = (\operatorname{sgn}(a_{k1}), \dots, \operatorname{sgn}(a_{kn}))^T,$$

则

$$A \neq 0 \implies \|x^*\|_\infty = 1 \implies \|Ax^*\|_\infty = \eta$$

从而

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

矩阵范数

证明 (谱范数) :

$\|A\|_2$ 可表示为

$$\|A\|_2 = \max_{\|x\|_2=1} \|Ax\|_2 = \max_{\|x\|_2=1} \sqrt{x^T(A^T A)x}$$

显然 $A^T A$ 对称半正定, 故可设其特征值和特征向量分别为

$$\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n \geq 0, \quad v_1, \dots, v_n \in \mathbb{R}^n \text{ 且 } \|v_i\| = 1.$$

证明 (谱范数) :

$\|A\|_2$ 可表示为

$$\|A\|_2 = \max_{\|x\|_2=1} \|Ax\|_2 = \max_{\|x\|_2=1} \sqrt{x^T(A^T A)x}$$

显然 $A^T A$ 对称半正定, 故可设其特征值和特征向量分别为

$$\lambda_1 \geq \lambda_2 \geq \cdots \geq \lambda_n \geq 0, \quad v_1, \cdots, v_n \in \mathbb{R}^n \text{ 且 } \|v_i\| = 1.$$

一方面, 对任意满足 $\|x\|_2 = 1$ 的 $x \in \mathbb{R}^n$, 有 $x = \sum_{i=1}^n \alpha_i v_i$ 和

$$\sum_{i=1}^n \alpha_i^2 = 1, \text{ 于是}$$

$$x^T A^T A x = \sum_{i=1}^n \lambda_i \alpha_i^2 \leq \lambda_1.$$

证明 (谱范数) :

另一方面, 取 $x = v_1$, 则有

$$x^T A^T A x = v_1^T A^T A v_1 = v_1^T \lambda_1 v_1 = \lambda_1$$

证明 (谱范数) :

另一方面, 取 $x = v_1$, 则有

$$x^T A^T A x = v_1^T A^T A v_1 = v_1^T \lambda_1 v_1 = \lambda_1$$

于是

$$\|A\|_2 = \max_{\|x\|_2=1} \|Ax\|_2 = \sqrt{\lambda_1} = \sqrt{\lambda_{\max}(A^T A)}$$

定义：Frobenius 范数

$$\|\mathbf{A}\|_F = \sqrt{\sum_{i,j=1}^n |a_{ij}|^2}$$

它是向量 2 范数的自然推广。

定义：谱半径

设 $A \in \mathbb{C}^{n \times n}$, 称

$$\rho(A) = \max\{|\lambda| : \lambda \in \lambda(A)\}$$

为 A 的谱半径, 其中 $\lambda(A)$ 表示 A 的特征值的全体。

定理：谱半径与矩阵范数的关系

设 $A \in \mathbf{C}^{n \times n}$ ，则

(1) 对 $\mathbf{C}^{n \times n}$ 上的任意矩阵范数 $\|\cdot\|$ ，有

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

(2) $\forall \epsilon > 0$ ，存在 $\mathbf{C}^{n \times n}$ 上的矩阵范数 $\|\cdot\|$ 使得

$$\|A\| \leq \rho(A) + \epsilon$$

定理：谱半径与矩阵范数的关系

设 $A \in \mathbb{C}^{n \times n}$, 则

(1) 对 $\mathbb{C}^{n \times n}$ 上的任意矩阵范数 $\|\cdot\|$, 有

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

(2) $\forall \epsilon > 0$, 存在 $\mathbb{C}^{n \times n}$ 上的矩阵范数 $\|\cdot\|$ 使得

$$\|A\| \leq \rho(A) + \epsilon$$

证明

$$\begin{aligned} Ax = \lambda x, \quad x \neq 0 &\Rightarrow |\lambda| \|x\| = \|Ax\| \leq \|A\| \|x\| \\ &\Rightarrow |\lambda| \leq \|A\|. \end{aligned}$$

定理

设 $A \in \mathbf{C}^{n \times n}$, 则

$$\lim_{k \rightarrow \infty} A^k = 0 \iff \rho(A) < 1$$

矩阵范数

定理

设 $A \in \mathbf{C}^{n \times n}$, 则

$$\lim_{k \rightarrow \infty} A^k = 0 \iff \rho(A) < 1$$

证明

\Rightarrow 令 $|\lambda_0| = \rho(A)$, 由 $\lim_{k \rightarrow \infty} A^k = 0$ 知

$$\rho(A)^k = |\lambda_0|^k = |\lambda_0^k| \leq \rho(A^k) \leq \|A^k\|_2 < 1 \quad (k \rightarrow \infty)$$

从而有 $\rho(A) < 1$.

定理

设 $A \in \mathbf{C}^{n \times n}$, 则

$$\lim_{k \rightarrow \infty} A^k = 0 \iff \rho(A) < 1$$

证明

\Rightarrow 令 $|\lambda_0| = \rho(A)$, 由 $\lim_{k \rightarrow \infty} A^k = 0$ 知

$$\rho(A)^k = |\lambda_0|^k = |\lambda_0^k| \leq \rho(A^k) \leq \|A^k\|_2 < 1 \quad (k \rightarrow \infty)$$

从而有 $\rho(A) < 1$.

\Leftarrow

$\rho(A) < 1 \implies$ 存在范数 $\|\cdot\|$ 使得 $\|A\| < 1$

$\implies 0 \leq \|A^k\| \leq \|A\|^k \rightarrow 0, \quad k \rightarrow \infty.$

推论

设 $A \in \mathbf{C}^{n \times n}$, $\mathbf{C}^{n \times n}$ 上的 $\|\cdot\|$ 满足 $\|I\| = 1$, 则

$$\|A\| < 1 \implies \begin{cases} I - A \text{ 可逆} \\ \|(I - A)^{-1}\| \leq \frac{1}{1 - \|A\|} \end{cases}$$

矩阵范数

证明

若 $I - A$ 奇异, 则 $(I - A)x = 0$ 有非零解, 即存在 $x^* \neq 0$ 使得

$$x^* = Ax^*$$

从而

$$\|x^*\| = \|Ax^*\| \leq \|A\| \|x^*\|$$

因 $\|x^*\| > 0$, 故 $\|A\| \geq 1$, 这与已知矛盾, 从而 $I - A$ 必非奇异。

证明

若 $I - A$ 奇异, 则 $(I - A)x = 0$ 有非零解, 即存在 $x^* \neq 0$ 使得

$$x^* = Ax^*$$

从而

$$\|x^*\| = \|Ax^*\| \leq \|A\| \|x^*\|$$

因 $\|x^*\| > 0$, 故 $\|A\| \geq 1$, 这与已知矛盾, 从而 $I - A$ 必非奇异。

由 $(I - A)(I - A)^{-1} = I$ 得

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

证明

若 $I - A$ 奇异, 则 $(I - A)x = 0$ 有非零解, 即存在 $x^* \neq 0$ 使得

$$x^* = Ax^*$$

从而

$$\|x^*\| = \|Ax^*\| \leq \|A\| \|x^*\|$$

因 $\|x^*\| > 0$, 故 $\|A\| \geq 1$, 这与已知矛盾, 从而 $I - A$ 必非奇异。

由 $(I - A)(I - A)^{-1} = I$ 得

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

$$\Rightarrow \|(I - A)^{-1}\| \leq \|I\| + \|A\| \|(I - A)^{-1}\|$$

$$\Rightarrow \|(I - A)^{-1}\| \leq \frac{1}{1 - \|A\|}$$

线性方程组的性态

线性方程组的敏度分析

线性方程组的敏感性问题

考察线性方程组

$$Ax = b,$$

若给 A 和 b 以微小的扰动, 其解会有何影响。

线性方程组的敏度分析

例

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

$$\begin{bmatrix} 2.0002 & 1.9998 \\ 1.9998 & 2.0002 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 4+0.0002 \\ 4-0.0002 \end{bmatrix} \rightarrow \mathbf{x}^* = (1.5 \ 0.5)^T.$$

线性方程组的敏度分析

例

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

$$\begin{bmatrix} 2.0002 & 1.9998 \\ 1.9998 & 2.0002 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 4+0.0002 \\ 4-0.0002 \end{bmatrix} \rightarrow \mathbf{x}^* = (1.5 \ 0.5)^T.$$

$$\frac{\|\delta \mathbf{b}\|_\infty}{\|\mathbf{b}\|_\infty} = \frac{1}{20000}$$

线性方程组的敏度分析

例

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

$$\begin{bmatrix} 2.0002 & 1.9998 \\ 1.9998 & 2.0002 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 4+0.0002 \\ 4-0.0002 \end{bmatrix} \rightarrow \mathbf{x}^* = (1.5 \ 0.5)^T.$$

$$\frac{\|\delta \mathbf{b}\|_\infty}{\|\mathbf{b}\|_\infty} = \frac{1}{20000} \Rightarrow \frac{\|\mathbf{x}^* - \mathbf{x}\|_\infty}{\|\mathbf{x}\|_\infty} = \frac{1}{2}$$

线性方程组的敏度分析

考察非奇异线性方程组

$$\begin{array}{l} Ax = b \\ A \rightarrow A + \delta A \\ b \rightarrow b + \delta b \end{array} \left. \vphantom{\begin{array}{l} Ax = b \\ A \rightarrow A + \delta A \\ b \rightarrow b + \delta b \end{array}} \right\} \implies x \rightarrow x + \delta x.$$

线性方程组的敏度分析

考察非奇异线性方程组

$$\begin{array}{l} Ax = b \\ A \rightarrow A + \delta A \\ b \rightarrow b + \delta b \end{array} \left. \vphantom{\begin{array}{l} Ax = b \\ A \rightarrow A + \delta A \\ b \rightarrow b + \delta b \end{array}} \right\} \implies x \rightarrow x + \delta x.$$

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

$$\implies (A + \delta A)\delta x = \delta b - \delta Ax$$

线性方程组的敏度分析

考察非奇异线性方程组

$$\left. \begin{array}{l} Ax = b \\ A \rightarrow A + \delta A \\ b \rightarrow b + \delta b \end{array} \right\} \implies x \rightarrow x + \delta x.$$

$$\begin{aligned} (A + \delta A)(x + \delta x) &= b + \delta b \\ \implies (A + \delta A)\delta x &= \delta b - \delta Ax \end{aligned}$$

只要 $\|A^{-1}\| \cdot \|\delta A\| < 1$, 就有 $A + \delta A$ 可逆, 并且

$$\|(I + A^{-1}\delta A)^{-1}\| \leq \frac{1}{1 - \|A^{-1}\| \cdot \|\delta A\|}.$$

线性方程组的敏度分析

考察非奇异线性方程组

$$\left. \begin{array}{l} Ax = b \\ A \rightarrow A + \delta A \\ b \rightarrow b + \delta b \end{array} \right\} \implies x \rightarrow x + \delta x.$$

$$\begin{aligned} (A + \delta A)(x + \delta x) &= b + \delta b \\ \implies (A + \delta A)\delta x &= \delta b - \delta Ax \end{aligned}$$

只要 $\|A^{-1}\| \cdot \|\delta A\| < 1$, 就有 $A + \delta A$ 可逆, 并且

$$\|(I + A^{-1}\delta A)^{-1}\| \leq \frac{1}{1 - \|A^{-1}\| \cdot \|\delta A\|}.$$

于是

$$\delta x = (A + \delta A)^{-1}(\delta b - \delta Ax) = (I + A^{-1}\delta A)^{-1}A^{-1}(\delta b - \delta Ax),$$

定义：条件数

称 $\kappa(A) = \|A^{-1}\| \cdot \|A\|$ 为矩阵 A 的**条件数**。

线性方程组的敏度分析

由

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

可得

$$\|\delta x\| \leq \|(I + A^{-1}\delta A)^{-1}\| \cdot \|A^{-1}\| \cdot (\|\delta b\| + \|\delta A\| \cdot \|x\|)$$

线性方程组的敏度分析

由

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

可得

$$\begin{aligned}\|\delta x\| &\leq \|(I + A^{-1}\delta A)^{-1}\| \cdot \|A^{-1}\| \cdot (\|\delta b\| + \|\delta A\| \cdot \|x\|) \\ &\leq\end{aligned}$$

线性方程组的敏度分析

由

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

可得

$$\begin{aligned}\|\delta x\| &\leq \|(I + A^{-1}\delta A)^{-1}\| \cdot \|A^{-1}\| \cdot (\|\delta b\| + \|\delta A\| \cdot \|x\|) \\ &\leq \frac{\|A^{-1}\|}{1 - \|A^{-1}\| \cdot \|\delta A\|} (\|\delta b\| + \|\delta A\| \cdot \|x\|).\end{aligned}$$

线性方程组的敏度分析

由

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

可得

$$\begin{aligned}\|\delta x\| &\leq \|(I + A^{-1}\delta A)^{-1}\| \cdot \|A^{-1}\| \cdot (\|\delta b\| + \|\delta A\| \cdot \|x\|) \\ &\leq \frac{\|A^{-1}\|}{1 - \|A^{-1}\| \cdot \|\delta A\|} (\|\delta b\| + \|\delta A\| \cdot \|x\|).\end{aligned}$$

两端同时除以 $\|x\|$ ，并由 $\|b\| \leq \|A\| \cdot \|x\|$ 可知

$$\frac{\|\delta x\|}{\|x\|} \leq \frac{\|A^{-1}\| \|A\|}{1 - \|A^{-1}\| \cdot \|\delta A\|} \left(\frac{\|\delta b\|}{\|A\| \|x\|} + \frac{\|\delta A\|}{\|A\|} \right)$$

线性方程组的敏度分析

由

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

可得

$$\begin{aligned}\|\delta x\| &\leq \|(I + A^{-1}\delta A)^{-1}\| \cdot \|A^{-1}\| \cdot (\|\delta b\| + \|\delta A\| \cdot \|x\|) \\ &\leq \frac{\|A^{-1}\|}{1 - \|A^{-1}\| \cdot \|\delta A\|} (\|\delta b\| + \|\delta A\| \cdot \|x\|).\end{aligned}$$

两端同时除以 $\|x\|$ ，并由 $\|b\| \leq \|A\| \cdot \|x\|$ 可知

$$\begin{aligned}\frac{\|\delta x\|}{\|x\|} &\leq \frac{\|A^{-1}\| \|A\|}{1 - \|A^{-1}\| \cdot \|\delta A\|} \left(\frac{\|\delta b\|}{\|A\| \|x\|} + \frac{\|\delta A\|}{\|A\|} \right) \\ &\leq \frac{\|A^{-1}\| \|A\|}{1 - \|A^{-1}\| \cdot \|\delta A\|} \left(\frac{\|\delta b\|}{\|b\|} + \frac{\|\delta A\|}{\|A\|} \right)\end{aligned}$$

线性方程组的敏度分析

定理

条件:

- $\|\cdot\|$ 满足 $\|I\| = 1$, $A \in \mathbb{R}^{n \times n}$ 非奇异, $b \in \mathbb{R}^n$ 非零
- $\delta A \in \mathbb{R}^{n \times n}$ 满足 $\|A^{-1}\| \cdot \|\delta A\| < 1$
-

$$\begin{cases} Ax = b \\ (A + \delta A)(x + \delta x) = b + \delta b \end{cases}$$

线性方程组的敏度分析

定理

条件:

- $\|\cdot\|$ 满足 $\|I\| = 1$, $A \in \mathbb{R}^{n \times n}$ 非奇异, $b \in \mathbb{R}^n$ 非零
- $\delta A \in \mathbb{R}^{n \times n}$ 满足 $\|A^{-1}\| \cdot \|\delta A\| < 1$
-

$$\begin{cases} Ax = b \\ (A + \delta A)(x + \delta x) = b + \delta b \end{cases}$$

结论:

$$\frac{\|\delta x\|}{\|x\|} \leq \frac{\kappa(A)}{1 - \kappa(A) \frac{\|\delta A\|}{\|A\|}} \left(\frac{\|\delta A\|}{\|A\|} + \frac{\|\delta b\|}{\|b\|} \right).$$

线性方程组的敏度分析

$$\frac{\|\delta A\|}{\|A\|} \text{较小}$$

线性方程组的敏度分析

$$\frac{\|\delta A\|}{\|A\|} \text{较小}$$

$$\Rightarrow \frac{\kappa(A)}{1 - \kappa(A) \frac{\|\delta A\|}{\|A\|}} \approx \kappa(A)$$

线性方程组的敏度分析

$$\frac{\|\delta A\|}{\|A\|} \text{较小}$$

$$\Rightarrow \frac{\kappa(A)}{1 - \kappa(A) \frac{\|\delta A\|}{\|A\|}} \approx \kappa(A)$$

$$\Rightarrow \frac{\|\delta x\|}{\|x\|} \leq \kappa(A) \left(\frac{\|\delta A\|}{\|A\|} + \frac{\|\delta b\|}{\|b\|} \right)$$

线性方程组的敏度分析

$$\frac{\|\delta A\|}{\|A\|} \text{ 较小}$$

$$\Rightarrow \frac{\kappa(A)}{1 - \kappa(A) \frac{\|\delta A\|}{\|A\|}} \approx \kappa(A)$$

$$\Rightarrow \frac{\|\delta x\|}{\|x\|} \leq \kappa(A) \left(\frac{\|\delta A\|}{\|A\|} + \frac{\|\delta b\|}{\|b\|} \right)$$

结论

- x 的相对误差由 b 和 A 的相对误差之和放大 $\kappa(A)$ 倍得来

线性方程组的敏度分析

$$\frac{\|\delta A\|}{\|A\|} \text{较小}$$

$$\Rightarrow \frac{\kappa(A)}{1 - \kappa(A) \frac{\|\delta A\|}{\|A\|}} \approx \kappa(A)$$

$$\Rightarrow \frac{\|\delta x\|}{\|x\|} \leq \kappa(A) \left(\frac{\|\delta A\|}{\|A\|} + \frac{\|\delta b\|}{\|b\|} \right)$$

结论

- x 的相对误差由 b 和 A 的相对误差之和放大 $\kappa(A)$ 倍得来
- 若 $\kappa(A)$ 不大, 则扰动对解的影响也不会太大

线性方程组的敏度分析

$$\frac{\|\delta A\|}{\|A\|} \text{较小}$$

$$\Rightarrow \frac{\kappa(A)}{1 - \kappa(A) \frac{\|\delta A\|}{\|A\|}} \approx \kappa(A)$$

$$\Rightarrow \frac{\|\delta x\|}{\|x\|} \leq \kappa(A) \left(\frac{\|\delta A\|}{\|A\|} + \frac{\|\delta b\|}{\|b\|} \right)$$

结论

- x 的相对误差由 b 和 A 的相对误差之和放大 $\kappa(A)$ 倍得来
- 若 $\kappa(A)$ 不大, 则扰动对解的影响也不会太大
- 若 $\kappa(A)$ 很大, 则扰动对解的影响可能会太大

条件数在一定程度上刻画了扰动对解的影响程度。

线性方程组的敏度分析

条件数在一定程度上刻画了扰动对解的影响程度。

- 若 $\kappa(A)$ 很大，则称线性方程组 $Ax = b$ 求解问题是病态的，或者说 A 是病态的；

线性方程组的敏度分析

条件数在一定程度上刻画了扰动对解的影响程度。

- 若 $\kappa(A)$ 很大，则称线性方程组 $Ax = b$ 求解问题是病态的，或者说 A 是病态的；
- 若 $\kappa(A)$ 很小，则称该线性方程组 $Ax = b$ 求解问题是良态的，或者说 A 是良态的。

线性方程组的敏度分析

条件数与范数有关, $\mathbb{R}^{n \times n}$ 上任意两种范数下的条件数 $\kappa_\alpha(\mathbf{A})$ 与 $\kappa_\beta(\mathbf{A})$ 都是等价的, 即存在常数 c_1 和 c_2 , 使得

$$c_1 \kappa_\alpha(\mathbf{A}) \leq \kappa_\beta(\mathbf{A}) \leq c_2 \kappa_\alpha(\mathbf{A}).$$

例如,

$$\begin{aligned} \frac{1}{n} \kappa_2(\mathbf{A}) &\leq \kappa_1(\mathbf{A}) \leq n \kappa_2(\mathbf{A}), \\ \frac{1}{n} \kappa_\infty(\mathbf{A}) &\leq \kappa_2(\mathbf{A}) \leq n \kappa_\infty(\mathbf{A}), \\ \frac{1}{n^2} \kappa_1(\mathbf{A}) &\leq \kappa_\infty(\mathbf{A}) \leq n^2 \kappa_2(\mathbf{A}). \end{aligned}$$

推论

条件:

- $\|\cdot\|$ 满足条件 $\|I\| = 1$, $A \in \mathbb{R}^{n \times n}$ 非奇异
- $\delta A \in \mathbb{R}^{n \times n}$ 满足 $\|A^{-1}\| \cdot \|\delta A\| < 1$

结论

- $A + \delta A$ 非奇异
-

$$\frac{\|(A + \delta A)^{-1} - A^{-1}\|}{\|A^{-1}\|} \leq \frac{\kappa(A)}{1 - \kappa(A) \frac{\|\delta A\|}{\|A\|}} \frac{\|\delta A\|}{\|A\|}.$$

线性方程组的敏度分析

推论

条件:

- $\|\cdot\|$ 满足条件 $\|I\| = 1$, $A \in \mathbb{R}^{n \times n}$ 非奇异
- $\delta A \in \mathbb{R}^{n \times n}$ 满足 $\|A^{-1}\| \cdot \|\delta A\| < 1$

结论

- $A + \delta A$ 非奇异
-

$$\frac{\|(A + \delta A)^{-1} - A^{-1}\|}{\|A^{-1}\|} \leq \frac{\kappa(A)}{1 - \kappa(A) \frac{\|\delta A\|}{\|A\|}} \frac{\|\delta A\|}{\|A\|}.$$

这表明 $\kappa(A)$ 可当做矩阵求逆问题的条件数。

Jacobi 迭代与 Gauss-Seidel 迭代

Jacobi 迭代与 Gauss-Seidel 迭代

Jacobi 迭代法

Jacobi 迭代法

设 $a_{ii} \neq 0$,

$$\begin{cases} a_{11}x_1 + a_{12}x_2 + a_{13}x_3 = b_1 \\ a_{21}x_1 + a_{22}x_2 + a_{23}x_3 = b_2 \\ a_{31}x_1 + a_{32}x_2 + a_{33}x_3 = b_3 \end{cases}$$

Jacobi 迭代法

设 $a_{ii} \neq 0$,

$$\begin{cases} a_{11}x_1 + a_{12}x_2 + a_{13}x_3 = b_1 \\ a_{21}x_1 + a_{22}x_2 + a_{23}x_3 = b_2 \\ a_{31}x_1 + a_{32}x_2 + a_{33}x_3 = b_3 \end{cases}$$

\Rightarrow

Jacobi 迭代法

设 $a_{ii} \neq 0$,

$$\begin{cases} a_{11}x_1 + a_{12}x_2 + a_{13}x_3 = b_1 \\ a_{21}x_1 + a_{22}x_2 + a_{23}x_3 = b_2 \\ a_{31}x_1 + a_{32}x_2 + a_{33}x_3 = b_3 \end{cases}$$

$$\Rightarrow \begin{cases} x_1 = \frac{1}{a_{11}} (-a_{12}x_2 - a_{13}x_3 + b_1) \\ x_2 = \frac{1}{a_{22}} (-a_{21}x_1 - a_{23}x_3 + b_2) \\ x_3 = \frac{1}{a_{33}} (-a_{31}x_1 - a_{32}x_2 + b_3) \end{cases}$$

取 $x^{(0)} = (x_1^{(0)}, x_2^{(0)}, x_3^{(0)})^T$, 代入上式右端得

$$\begin{cases} x_1^{(1)} = \frac{1}{a_{11}} (& -a_{12}x_2^{(0)} - a_{13}x_3^{(0)} & +b_1) \\ x_2^{(1)} = \frac{1}{a_{22}} (-a_{21}x_1^{(0)} & & -a_{23}x_3^{(0)} +b_2) \\ x_3^{(1)} = \frac{1}{a_{33}} (-a_{31}x_1^{(0)} & -a_{32}x_2^{(0)} & +b_3) \end{cases}$$

Jacobi 迭代法

$$\begin{cases} x_1^{(k+1)} = \frac{1}{a_{11}} (& -a_{12}x_2^{(k)} - a_{1,3}x_3^{(k)} & +b_1) \\ x_2^{(k+1)} = \frac{1}{a_{22}} (-a_{21}x_1^{(k)} & & -a_{23}x_3^{(k)} +b_2) \\ x_3^{(k+1)} = \frac{1}{a_{33}} (-a_{31}x_1^{(k)} & -a_{32}x_2^{(k)} & +b_3) \end{cases}$$

线性方程组

$$Ax = b \quad (1)$$

线性方程组

$$Ax = b \quad (1)$$

令

$$A = D + L + U$$

其中

$$D = \text{diag}(a_{11}, a_{22}, \dots, a_{nn}), \quad a_{ii} \neq 0$$

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

线性方程组

$$Ax = b \quad (1)$$

方程 (1) 可写成

$$x = M_J x + g$$

其中

$$M_J = -D^{-1}(L + U),$$

$$g = -D^{-1}b.$$

Jacobi 迭代格式

Jacobi 迭代格式为

$$\forall \mathbf{x}^{(0)}, \quad \mathbf{x}^{(k+1)} = M_J \mathbf{x}^{(k)} + \mathbf{g}, \quad k = 0, 1, 2, \dots,$$

其中

$$M_J = -D^{-1}(L + U) \quad \rightarrow \text{Jacobi 迭代矩阵,}$$

$$\mathbf{g} = -D^{-1}\mathbf{b}.$$

Jacobi 迭代格式的分量形式

任给 $x_i^{(0)}$ ($i = 1, 2, \dots, n$),

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

Jacobi 迭代与 Gauss-Seidel 迭代

Gauss-Seidel 迭代

Jacobi 迭代

$$\begin{cases} x_1^{(k+1)} = \frac{1}{a_{11}} (-a_{12}x_2^{(k)} - a_{13}x_3^{(k)} + b_1) \\ x_2^{(k+1)} = \frac{1}{a_{22}} (-a_{21}x_1^{(k)} - a_{23}x_3^{(k)} + b_2) \\ x_3^{(k+1)} = \frac{1}{a_{33}} (-a_{31}x_1^{(k)} - a_{32}x_2^{(k)} + b_3) \end{cases}$$

Gauss-Seidel 迭代

Jacobi 迭代

$$\begin{cases} x_1^{(k+1)} = \frac{1}{a_{11}} (& -a_{12}x_2^{(k)} - a_{13}x_3^{(k)} & +b_1) \\ x_2^{(k+1)} = \frac{1}{a_{22}} (-a_{21}x_1^{(k)} & & -a_{23}x_3^{(k)} +b_2) \\ x_3^{(k+1)} = \frac{1}{a_{33}} (-a_{31}x_1^{(k)} & -a_{32}x_2^{(k)} & +b_3) \end{cases}$$

Gauss-Seidel 迭代

$$\begin{cases} x_1^{(k+1)} = \frac{1}{a_{11}} (& -a_{12}x_2^{(k)} - a_{13}x_3^{(k)} & +b_1) \\ x_2^{(k+1)} = \frac{1}{a_{22}} (-a_{21}x_1^{(k+1)} & & -a_{23}x_3^{(k)} +b_2) \\ x_3^{(k+1)} = \frac{1}{a_{33}} (-a_{31}x_1^{(k+1)} & -a_{32}x_2^{(k+1)} & +b_3) \end{cases}$$

Gauss-Seidel 迭代格式

Gauss-Seidel 迭代格式为

$$\forall \mathbf{x}^{(0)}, \quad D\mathbf{x}^{(k+1)} = -L\mathbf{x}^{(k+1)} - U\mathbf{x}^{(k)} + \mathbf{b}, \quad k = 0, 1, 2, \dots,$$

即

$$\forall \mathbf{x}^{(0)}, \quad \mathbf{x}^{(k+1)} = M_{GS}\mathbf{x}^{(k)} + \mathbf{g}, \quad k = 0, 1, 2, \dots,$$

其中

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

$$\mathbf{g} = (D + L)^{-1}\mathbf{b}.$$

Jacobi 与 Gauss-Seidel 迭代的收敛性分析

Jacobi 与 Gauss-Seidel 迭代的收敛性分析

收敛的充分必要条件

收敛的充分必要条件

定义

对于线性方程组

$$Ax = b, \quad (2)$$

给定初值 $x^{(0)}$, 称迭代格式

$$x^{(k+1)} = Mx^{(k)} + g, \quad k = 0, 1, 2, \dots, \quad (3)$$

为单步线性定常迭代, 其中

- $M \in \mathbb{R}^{n \times n}$ 为迭代矩阵,
- $g \in \mathbb{R}^n$ 为常数项,
- $x^{(0)} \in \mathbb{R}^n$ 为初始向量.

收敛的充分必要条件

定义

对于线性方程组

$$Ax = b, \quad (2)$$

给定初值 $x^{(0)}$, 称迭代格式

$$x^{(k+1)} = Mx^{(k)} + g, \quad k = 0, 1, 2, \dots, \quad (3)$$

为单步线性定常迭代, 其中

- $M \in \mathbb{R}^{n \times n}$ 为迭代矩阵,
- $g \in \mathbb{R}^n$ 为常数项,
- $x^{(0)} \in \mathbb{R}^n$ 为初始向量.

若对任意初始向量, 由 (3) 产生的迭代序列都有极限, 则称该迭代法是收敛的; 否则称为发散的。

收敛的充分必要条件

- Jacobi 迭代

$$M = -D^{-1}(L + U), \quad g = D^{-1}b$$

- Gauss-Seidel 迭代

$$M = -(D + L)^{-1}U, \quad g = (D + L)^{-1}b$$

收敛的充分必要条件

若 (3) 收敛, 记其极限为 x^* , 则两端取极限得

$$x^* = Mx^* + g \Rightarrow (I - M)x^* = g. \quad (4)$$

若该式与 (2) 等价, 则存在可逆矩阵 $G \in \mathbb{R}^{n \times n}$ 使得

$$G(I - M) = A, \quad Gg = b. \quad (5)$$

当上式成立时, 称迭代法 (3) 与方程组 (2) 相容。

收敛的充分必要条件

称

$$\mathbf{e}^{(k)} = \mathbf{x}^{(k)} - \mathbf{x}^*$$

为 \mathbf{x}^* 在第 k 步的误差向量。

收敛的充分必要条件

称

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

为 x^* 在第 k 步的误差向量。由

$$Ax^* = b \quad \xleftrightarrow{\text{同解方程}} \quad x^* = Mx^* + g$$
$$x^{(k+1)} = Mx^{(k)} + g$$

知

收敛的充分必要条件

称

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

为 x^* 在第 k 步的误差向量。由

$$Ax^* = b \quad \xleftrightarrow{\text{同解方程}} \quad x^* = Mx^* + g$$
$$x^{(k+1)} = Mx^{(k)} + g$$

知

$$e^{(k+1)} = Me^{(k)}, \quad k = 0, 1, 2, \dots$$

$$\Rightarrow e^{(k)} = M^k e^{(0)}.$$

推论

迭代法 (3) 收敛的充分必要条件是

$$M^k \rightarrow 0.$$

收敛的充分必要条件

定理

$M^k \rightarrow 0$ 的充分必要条件是 $\rho(M) < 1$.

收敛的充分必要条件

定理

$M^k \rightarrow 0$ 的充分必要条件是 $\rho(M) < 1$.

定理

迭代法 (3) 收敛的充分必要条件是 $\rho(M) < 1$.

收敛的充分必要条件

定理

$M^k \rightarrow 0$ 的充分必要条件是 $\rho(M) < 1$.

定理

迭代法 (3) 收敛的充分必要条件是 $\rho(M) < 1$.

迭代序列收敛取决于迭代矩阵的谱半径，而与初始向量的选取和常数项无关。

收敛的充分必要条件

解同一方程组时，Jacobi 迭代矩阵与 Gauss-Seidel 迭代矩阵的谱半径不一定相同，且无包含关系。

例

$$\mathbf{A}^1 = \begin{bmatrix} 1 & 2 & -2 \\ 1 & 1 & 1 \\ 2 & 2 & 1 \end{bmatrix}, \quad \mathbf{A}^2 = \begin{bmatrix} 2 & -1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & -2 \end{bmatrix}$$

收敛的充分必要条件

对于 A^1 ,

$$M_J^1 = \begin{bmatrix} 0 & -2 & 2 \\ -1 & 0 & -1 \\ -2 & -2 & 0 \end{bmatrix}, \quad M_{GS}^1 = \begin{bmatrix} 0 & -2 & 2 \\ 0 & 2 & -3 \\ 0 & 0 & 2 \end{bmatrix}$$

- 因 $\rho(M_J^1) = 1.081 \times 10^{-5}$, 故 Jacobi 迭代收敛;
- 因 $\rho(M_{GS}^1) = 2$, 故 Gauss-Seidel 迭代不收敛。

收敛的充分必要条件

对于 A^2 ,

$$M_J^2 = \begin{bmatrix} 0 & 1/2 & -1/2 \\ -1 & 0 & -1 \\ 1/2 & 1/2 & 0 \end{bmatrix}, \quad M_{GS}^2 = \begin{bmatrix} 0 & 1/2 & -1/2 \\ 0 & -1/2 & -1/2 \\ 0 & 0 & -1/2 \end{bmatrix}$$

- 因 $\rho(M_J^2) = 1.118$, 故 Jacobi 迭代不收敛;
- 因 $\rho(M_{GS}^2) = 1/2$, 故 Gauss-Seidel 迭代不收敛。

Jacobi 与 Gauss-Seidel 迭代的收敛性分析

收敛的充分条件及误差估计

收敛的充分条件及误差估计

- 很显然，计算谱半径非常困难，用它来判断迭代格式是否收敛很不方便。
- 能否找一些比较容易计算的条件呢？

定理

若 $\|A\| < 1$, 则 $I - A$ 非奇异, 且

$$\|(I - A)^{-1}\| \leq \frac{1}{1 - \|A\|}.$$

定理

对于迭代格式

$$\mathbf{x}^{(k+1)} = M\mathbf{x}^{(k)} + \mathbf{g}, \quad k = 0, 1, \dots$$

若 $\|M\| = q < 1$, 则

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

收敛的充分条件及误差估计

定理

对于迭代格式

$$\mathbf{x}^{(k+1)} = M\mathbf{x}^{(k)} + \mathbf{g}, \quad k = 0, 1, \dots$$

若 $\|M\| = q < 1$, 则

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

注

由该定理可知, 给定近似解的精度, 可计算出迭代次数, 但实际计算时用起来并不方便。

收敛的充分条件及误差估计

证明

由 $e^{(k)} = M^k e^{(0)}$ 可知

$$\|e^{(k)}\| = \|M^k e^{(0)}\| \leq \|M\|^k \|e^{(0)}\| = q^k \|e^{(0)}\|$$

收敛的充分条件及误差估计

证明

由 $e^{(k)} = M^k e^{(0)}$ 可知

$$\|e^{(k)}\| = \|M^k e^{(0)}\| \leq \|M\|^k \|e^{(0)}\| = q^k \|e^{(0)}\|$$

因 $\|M\| < 1$, 故 $(I - M)^{-1}$ 存在且 $x^* = (I - M)^{-1}g$ 。

收敛的充分条件及误差估计

证明

由 $e^{(k)} = M^k e^{(0)}$ 可知

$$\|e^{(k)}\| = \|M^k e^{(0)}\| \leq \|M\|^k \|e^{(0)}\| = q^k \|e^{(0)}\|$$

因 $\|M\| < 1$, 故 $(I - M)^{-1}$ 存在且 $x^* = (I - M)^{-1}g$ 。于是

$$\begin{aligned} e^{(0)} &= x^{(0)} - x^* = x^{(0)} - (I - M)^{-1}g \\ &= (I - M)^{-1} [x^{(0)} - (Mx^{(0)} + g)] = (I - M)^{-1} [x^{(0)} - x^{(1)}] \end{aligned}$$

从而有

$$\|e^{(0)}\| \leq \|(I - M)^{-1}\| \|x^{(0)} - x^{(1)}\|.$$

收敛的充分条件及误差估计

证明

由 $e^{(k)} = M^k e^{(0)}$ 可知

$$\|e^{(k)}\| = \|M^k e^{(0)}\| \leq \|M\|^k \|e^{(0)}\| = q^k \|e^{(0)}\|$$

因 $\|M\| < 1$, 故 $(I - M)^{-1}$ 存在且 $x^* = (I - M)^{-1}g$ 。于是

$$\begin{aligned} e^{(0)} &= x^{(0)} - x^* = x^{(0)} - (I - M)^{-1}g \\ &= (I - M)^{-1} [x^{(0)} - (Mx^{(0)} + g)] = (I - M)^{-1} [x^{(0)} - x^{(1)}] \end{aligned}$$

从而有

$$\|e^{(0)}\| \leq \|(I - M)^{-1}\| \|x^{(0)} - x^{(1)}\|.$$

注意到当 $\|M\| = q < 1$ 时, 有

$$\|(I - M)^{-1}\| \leq \frac{1}{1 - \|M\|} = \frac{1}{1 - q}.$$

从而定理得证。

定理

若 $\|M\| = q < 1$, 则

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

收敛的充分条件及误差估计

定理

若 $\|M\| = q < 1$, 则

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

注

该定理表明, 可用相邻两步近似值的差来判别迭代法是否应该终止, 这在实际编程时非常好用。

证明

由

$$\begin{aligned}\mathbf{x}^{(k)} - \mathbf{x}^* &= \mathbf{M}\mathbf{x}^{(k-1)} + \mathbf{g} - (\mathbf{M}\mathbf{x}^* + \mathbf{g}) \\ &= \mathbf{M}\mathbf{x}^{(k-1)} - \mathbf{M}\mathbf{x}^* \\ &= \mathbf{M}\mathbf{x}^{(k-1)} - \mathbf{M}(\mathbf{I} - \mathbf{M})^{-1}\mathbf{g} \\ &= \mathbf{M}(\mathbf{I} - \mathbf{M})^{-1}(\mathbf{x}^{(k-1)} - \mathbf{x}^{(k)})\end{aligned}$$

可得

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

定理得证。

注

- 用范数判定迭代法是否收敛虽然只是一个充分条件，但用起来比较方便。
- 常用 1 范数和 ∞ 范数来进行判定。
- 迭代矩阵 M_J 比较容易计算，故范数判别法对 Jacobi 迭代而比较好用。
- 迭代矩阵 M_{GS} 涉及到求下三角阵的逆，计算比较麻烦，故范数判别法不太适用于 G-S 迭代。

定理

若 A 对称且 $\forall i, a_{ii} > 0$, 则

Jacobi 迭代收敛 $\iff A, 2D - A$ 皆正定

证明

因 $a_{ii} > 0$, 故 D^{-1} 存在。

- 由

$$\begin{aligned}M_J &= -D^{-1}(L + U) = -D^{-1}(A - D) \\ &= D^{-1/2}(I - D^{-1/2}AD^{-1/2})D^{1/2}\end{aligned}$$

可知

$$M_J \sim I - D^{-1/2}AD^{-1/2}.$$

- 由 A 对称可知 $I - D^{-1/2}AD^{-1/2}$ 也对称, 从而其特征值为实数。

于是, M_J 的特征值为实数。

收敛的充分条件及误差估计

证明 (充分性) :

由

$$\text{Jacobi 迭代收敛} \iff \rho(M_J) < 1 \iff \rho(I - D^{-1/2}AD^{-1/2}) < 1$$

知

收敛的充分条件及误差估计

证明 (充分性) :

由

$$\text{Jacobi 迭代收敛} \iff \rho(M_J) < 1 \iff \rho(I - D^{-1/2}AD^{-1/2}) < 1$$

知

$$\begin{cases} D^{-1/2}AD^{-1/2} \text{的特征值} \in (0, 2) \implies \mathbf{A \text{正定}} \\ 2I - D^{-1/2}AD^{-1/2} \text{的特征值} \in (0, 2) \end{cases}$$

收敛的充分条件及误差估计

证明 (充分性) :

由

$$\text{Jacobi 迭代收敛} \iff \rho(M_J) < 1 \iff \rho(I - D^{-1/2}AD^{-1/2}) < 1$$

知

$$\begin{cases} D^{-1/2}AD^{-1/2} \text{ 的特征值} \in (0, 2) \implies \mathbf{A \text{ 正定}} \\ 2I - D^{-1/2}AD^{-1/2} \text{ 的特征值} \in (0, 2) \end{cases}$$

又因 $2I - D^{-1/2}AD^{-1/2} = D^{-1/2}(2D - A)D^{-1/2}$, 从而知 $2D - A$ 正定。

收敛的充分条件及误差估计

证明 (必要性) :

$$\left. \begin{aligned} D^{1/2}(I - M_J)D^{-1/2} &= D^{-1/2}AD^{-1/2} \\ A &\text{正定} \end{aligned} \right\}$$

$$\implies \lambda(I - M_J) > 0 \implies \lambda(M_J) < 1.$$

收敛的充分条件及误差估计

证明 (必要性) :

$$\left. \begin{aligned} D^{1/2}(I - M_J)D^{-1/2} = D^{-1/2}AD^{-1/2} \\ A \text{ 正定} \end{aligned} \right\}$$

$$\implies \lambda(I - M_J) > 0 \implies \lambda(M_J) < 1.$$

$$\left. \begin{aligned} D^{1/2}(I + M_J)D^{-1/2} = D^{-1/2}(2D - A)D^{-1/2} \\ 2D - A \text{ 正定} \end{aligned} \right\}$$

$$\implies \lambda(I + M_J) > 0 \implies \lambda(M_J) > -1.$$

收敛的充分条件及误差估计

证明 (必要性) :

$$\left. \begin{aligned} D^{1/2}(I - M_J)D^{-1/2} &= D^{-1/2}AD^{-1/2} \\ A \text{ 正定} \end{aligned} \right\}$$

$$\implies \lambda(I - M_J) > 0 \implies \lambda(M_J) < 1.$$

$$\left. \begin{aligned} D^{1/2}(I + M_J)D^{-1/2} &= D^{-1/2}(2D - A)D^{-1/2} \\ 2D - A \text{ 正定} \end{aligned} \right\}$$

$$\implies \lambda(I + M_J) > 0 \implies \lambda(M_J) > -1.$$

联立可得 $\rho(M_J) < 1$, 从而 Jacobi 迭代收敛。

定理

A 对称正定 \implies Gauss-Seidel 迭代收敛

收敛的充分条件及误差估计

证明

设 λ 与 v 为 $M_{GS} = -(D+L)^{-1}U$ 的特征值与特征向量, 故有

$$\begin{aligned} -(D+L)^{-1}Uv = \lambda v & \xleftrightarrow{U=L^T} -(D+L)^{-1}L^T v = \lambda v \\ \implies -\lambda(D+L)v = L^T v & \implies -\lambda \underbrace{v^* D v}_{\delta} - \lambda \underbrace{v^* L v}_{\alpha+i\beta} = \underbrace{v^* L^T v}_{\alpha-i\beta} \end{aligned}$$

收敛的充分条件及误差估计

证明

设 λ 与 v 为 $M_{GS} = -(D+L)^{-1}U$ 的特征值与特征向量, 故有

$$\begin{aligned} -(D+L)^{-1}Uv &= \lambda v \xleftrightarrow{U=L^T} -(D+L)^{-1}L^T v = \lambda v \\ \implies -\lambda(D+L)v &= L^T v \implies -\lambda \underbrace{v^* D v}_{\delta} - \lambda \underbrace{v^* L v}_{\alpha+i\beta} = \underbrace{v^* L^T v}_{\alpha-i\beta} \end{aligned}$$

$$-\lambda\delta - \lambda(\alpha + i\beta) = \alpha - i\beta \xrightarrow{\text{取模}} |\lambda|^2 ((\delta + \alpha)^2 + \beta^2) = \alpha^2 + \beta^2$$

$$\implies |\lambda|^2 = \frac{\alpha^2 + \beta^2}{(\delta + \alpha)^2 + \beta^2} < 1?$$

收敛的充分条件及误差估计

证明

设 λ 与 v 为 $M_{GS} = -(D+L)^{-1}U$ 的特征值与特征向量, 故有

$$\begin{aligned} -(D+L)^{-1}Uv &= \lambda v \xleftrightarrow{U=L^T} -(D+L)^{-1}L^T v = \lambda v \\ \implies -\lambda(D+L)v &= L^T v \implies -\lambda \underbrace{v^* D v}_{\delta} - \lambda \underbrace{v^* L v}_{\alpha+i\beta} = \underbrace{v^* L^T v}_{\alpha-i\beta} \end{aligned}$$

$$-\lambda\delta - \lambda(\alpha + i\beta) = \alpha - i\beta \xrightarrow{\text{取模}} |\lambda|^2 ((\delta + \alpha)^2 + \beta^2) = \alpha^2 + \beta^2$$

$$\implies |\lambda|^2 = \frac{\alpha^2 + \beta^2}{(\delta + \alpha)^2 + \beta^2} < 1?$$

事实上,

$$0 < v^* A v = v^* (D + L + L^T) v = \delta + 2\alpha$$

故

$$(\delta + \alpha)^2 + \beta^2 = \delta^2 + 2\alpha\delta + \alpha^2 + \beta^2 = \delta(\delta + 2\alpha) + \alpha^2 + \beta^2 > \alpha^2 + \beta^2.$$

定义：对角占优矩阵

设 $A = (a_{ij}) \in \mathbb{R}^{n \times n}$, 对于不等式组

$$|a_{ii}| \geq \sum_{j=1, j \neq i}^n |a_{ij}|, \quad \forall i = 1, 2, \dots, n \quad (6)$$

- 若至少存在一个 i , 不等式严格成立, 则称 A **弱严格对角占优**;
- 若对所有 i , 不等式均严格成立, 则称 A **严格对角占优**。

定理

严格对角占优矩阵是非奇异的。

证明

若 A 奇异，则 $Ax = 0$ 有非零解 x 。不妨设 $|x_i| = \|x\|_\infty = 1$ ，则

$$|a_{ii}| = |a_{ii}x_i| = \left| \sum_{j=1, j \neq i} a_{ij}x_j \right| \leq \sum_{j=1, j \neq i} |a_{ij}|,$$

这与 A 严格对角占优矛盾。

推论

若 A 为对角元皆为正的对称矩阵, 且严格对角占优, 则 A 正定。

收敛的充分条件及误差估计

推论

若 A 为对角元皆为正的对称矩阵，且严格对角占优，则 A 正定。

证明

设 $\lambda \leq 0$ ，考察矩阵 $A - \lambda I$ 。

$A - \lambda I$ 只是在 A 的对角线上加上了一些正数

$\implies A - \lambda I$ 与 A 一样，是严格对角占优的

$\implies A - \lambda I$ 非奇异

注意到 $\lambda \leq 0$ 的任意性，知 A 的特征值均大于 0，从而 A 正定。

收敛的充分条件及误差估计

定理

若 A 严格对角占优, 则 Jacobi 迭代和 Gauss-Seidel 迭代收敛。

证明

$$A \text{ 严格对角占优} \implies D \text{ 可逆}$$

收敛的充分条件及误差估计

证明 (Jacobi 迭代) :

若 M_J 的某个特征值 $|\lambda| \geq 1$, 考察 $\lambda D + L + U$.

收敛的充分条件及误差估计

证明 (Jacobi 迭代) :

若 M_J 的某个特征值 $|\lambda| \geq 1$, 考察 $\lambda D + L + U$.

A 严格对角占优

$\implies \lambda D + L + U$ 也严格对角占优

$\implies \lambda D + L + U$ 非奇异

收敛的充分条件及误差估计

证明 (Jacobi 迭代) :

若 M_J 的某个特征值 $|\lambda| \geq 1$, 考察 $\lambda D + L + U$.

A 严格对角占优

$\implies \lambda D + L + U$ 也严格对角占优

$\implies \lambda D + L + U$ 非奇异

而

$$\lambda I - M_J = \lambda I + D^{-1}(L + U) = D^{-1}(\lambda D + L + U)$$

$$\implies \det(\lambda I - M_J) = \det(D^{-1}) \cdot \det(\lambda D + L + U) \neq 0$$

这与 λ 是 M_J 的特征值矛盾, 从而 $\rho(M_J) < 1 \implies$ Jacobi 迭代收敛。

收敛的充分条件及误差估计

证明 (Gauss-Seidel 迭代) :

若 M_{GS} 的某个特征值 $|\lambda| \geq 1$, 考察 $\lambda D + \lambda L + U$

收敛的充分条件及误差估计

证明 (Gauss-Seidel 迭代) :

若 M_{GS} 的某个特征值 $|\lambda| \geq 1$, 考察 $\lambda D + \lambda L + U$

A 严格对角占优

$\implies \lambda D + \lambda L + U$ 也严格对角占优

$\implies \lambda D + \lambda L + U$ 非奇异

收敛的充分条件及误差估计

证明 (Gauss-Seidel 迭代) :

若 M_{GS} 的某个特征值 $|\lambda| \geq 1$, 考察 $\lambda D + \lambda L + U$

A 严格对角占优

$\implies \lambda D + \lambda L + U$ 也严格对角占优

$\implies \lambda D + \lambda L + U$ 非奇异

而

$$\lambda I - M_{GS} = \lambda I + (D + L)^{-1} U = (D + L)^{-1} (\lambda D + \lambda L + U)$$

$$\implies \det(\lambda I - M_{GS}) = \det((D + L)^{-1}) \cdot \det(\lambda D + \lambda L + U) \neq 0$$

这与 λ 是 M_{GS} 的特征值矛盾, 从而 $\rho(M_{GS}) < 1 \implies$ Gauss-Seidel 迭代收敛。

超松弛迭代法

超松弛迭代法

超松弛迭代 (SOR)

超松弛迭代 (SOR)

超松弛迭代可看做是 Gauss-Seidel 迭代的加速。

超松弛迭代 (SOR)

超松弛迭代可看做是 Gauss-Seidel 迭代的加速。

Gauss-Seidel 迭代:

$$\mathbf{x}^{(k+1)} = -D^{-1}L\mathbf{x}^{(k+1)} - D^{-1}U\mathbf{x}^{(k)} + D^{-1}\mathbf{b}, \quad k = 0, 1, 2, \dots$$

超松弛迭代 (SOR)

超松弛迭代可看做是 Gauss-Seidel 迭代的加速。

Gauss-Seidel 迭代:

$$\mathbf{x}^{(k+1)} = -D^{-1}L\mathbf{x}^{(k+1)} - D^{-1}U\mathbf{x}^{(k)} + D^{-1}\mathbf{b}, \quad k = 0, 1, 2, \dots$$

由

$$\begin{aligned}\mathbf{x}^{(k+1)} &= \mathbf{x}^{(k)} + \mathbf{r}^{(k)}, \\ \mathbf{r}^{(k)} &= -\mathbf{x}^{(k)} - D^{-1}L\mathbf{x}^{(k+1)} - D^{-1}U\mathbf{x}^{(k)} + D^{-1}\mathbf{b} \\ &= D^{-1}[\mathbf{b} - L\mathbf{x}^{(k+1)} - (D + U)\mathbf{x}^{(k)}]\end{aligned}$$

可看出,

超松弛迭代 (SOR)

超松弛迭代可看做是 Gauss-Seidel 迭代的加速。

Gauss-Seidel 迭代:

$$\mathbf{x}^{(k+1)} = -D^{-1}L\mathbf{x}^{(k+1)} - D^{-1}U\mathbf{x}^{(k)} + D^{-1}\mathbf{b}, \quad k = 0, 1, 2, \dots$$

由

$$\begin{aligned}\mathbf{x}^{(k+1)} &= \mathbf{x}^{(k)} + \mathbf{r}^{(k)}, \\ \mathbf{r}^{(k)} &= -\mathbf{x}^{(k)} - D^{-1}L\mathbf{x}^{(k+1)} - D^{-1}U\mathbf{x}^{(k)} + D^{-1}\mathbf{b} \\ &= D^{-1}[\mathbf{b} - L\mathbf{x}^{(k+1)} - (D + U)\mathbf{x}^{(k)}]\end{aligned}$$

可看出, 对 Gauss-Seidel 迭代来说, $\mathbf{x}^{(k+1)}$ 可看作对 $\mathbf{x}^{(k)}$ 加上修正项 $\mathbf{r}^{(k)}$ 而得到。

超松弛迭代 (SOR)

若在 $r^{(k)}$ 前加一个参数 ω ，便得松弛法

$$\begin{aligned} \mathbf{x}^{(k+1)} &= \mathbf{x}^{(k)} + \omega r^{(k)} \\ &= (1 - \omega)\mathbf{x}^{(k)} + \omega(-D^{-1}L\mathbf{x}^{(k+1)} - D^{-1}U\mathbf{x}^{(k)} + D^{-1}\mathbf{b}), \end{aligned} \tag{7}$$

其中 ω 叫做松弛因子。

超松弛迭代 (SOR)

若在 $r^{(k)}$ 前加一个参数 ω , 便得松弛法

$$\begin{aligned} \mathbf{x}^{(k+1)} &= \mathbf{x}^{(k)} + \omega r^{(k)} \\ &= (1 - \omega)\mathbf{x}^{(k)} + \omega(-D^{-1}L\mathbf{x}^{(k+1)} - D^{-1}U\mathbf{x}^{(k)} + D^{-1}\mathbf{b}), \end{aligned} \tag{7}$$

其中 ω 叫做松弛因子。

注

- $\omega > 1$ → 超松弛 (Successive Over-Relaxation, SOR)
- $\omega < 1$ → 低松弛 (Successive Under-Relaxation, SUR)
- $\omega = 1$ → Gauss-Seidel 迭代

定义：松弛法

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

其中

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

超松弛迭代 (SOR)

注

- 超松弛迭代法是解大型方程组，特别是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、占用计算机内存单元较少等优点。
- 只要松弛因子 ω 选择得好，其收敛速度就会加快。

超松弛迭代 (SOR)

例

分别用 Jacobi、Gauss-Seidel 和 SOR 求解

$$\begin{pmatrix} 5 & 1 & -1 & -2 \\ 2 & 8 & 1 & 3 \\ 1 & -2 & -4 & -1 \\ -1 & 3 & 2 & 7 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \end{pmatrix} = \begin{pmatrix} -2 \\ -6 \\ 6 \\ 12 \end{pmatrix}$$

- 终止条件:

$$\max |\Delta x_i| < \max |x_i^{(k+1)} - x_i^{(k)}| < 10^{-5}$$

- 精确解:

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

超松弛迭代 (SOR)

解 (Jacobi) :

$$\begin{cases} x_1^{(k+1)} = x_1^{(k)} + \frac{1}{5} (-2 - 5x_1^{(k)} - x_2^{(k)} + x_3^{(k)} + 2x_4^{(k)}) \\ x_2^{(k+1)} = x_2^{(k)} + \frac{1}{8} (-6 - 2x_1^{(k)} - 8x_2^{(k)} - x_3^{(k)} - 3x_4^{(k)}) \\ x_3^{(k+1)} = x_3^{(k)} - \frac{1}{4} (6 - x_1^{(k)} + 2x_2^{(k)} + 4x_3^{(k)} + x_4^{(k)}) \\ x_4^{(k+1)} = x_4^{(k)} + \frac{1}{7} (12 + x_1^{(k)} - 3x_2^{(k)} - 2x_3^{(k)} - 7x_4^{(k)}) \end{cases}$$

超松弛迭代 (SOR)

解 (Jacobi) :

$$\begin{cases} x_1^{(k+1)} = x_1^{(k)} + \frac{1}{5} (-2 - 5x_1^{(k)} - x_2^{(k)} + x_3^{(k)} + 2x_4^{(k)}) \\ x_2^{(k+1)} = x_2^{(k)} + \frac{1}{8} (-6 - 2x_1^{(k)} - 8x_2^{(k)} - x_3^{(k)} - 3x_4^{(k)}) \\ x_3^{(k+1)} = x_3^{(k)} - \frac{1}{4} (6 - x_1^{(k)} + 2x_2^{(k)} + 4x_3^{(k)} + x_4^{(k)}) \\ x_4^{(k+1)} = x_4^{(k)} + \frac{1}{7} (12 + x_1^{(k)} - 3x_2^{(k)} - 2x_3^{(k)} - 7x_4^{(k)}) \end{cases}$$

迭代 24 次后, 近似解为

$$x^{(24)} = (0.9999941, -1.9999950, -1.0000040, 2.9999990)^T$$

超松弛迭代 (SOR)

解 (GS) :

$$\begin{cases} x_1^{(k+1)} = x_1^{(k)} + \frac{1}{5} (-2 & -5x_1^{(k)} & -x_2^{(k)} & +x_3^{(k)} & +2x_4^{(k)}) \\ x_2^{(k+1)} = x_2^{(k)} + \frac{1}{8} (-6 & -2x_1^{(k+1)} & -8x_2^{(k)} & -x_3^{(k)} & -3x_4^{(k)}) \\ x_3^{(k+1)} = x_3^{(k)} - \frac{1}{4} (6 & -x_1^{(k+1)} & +2x_2^{(k+1)} & +4x_3^{(k)} & +x_4^{(k)}) \\ x_4^{(k+1)} = x_4^{(k)} + \frac{1}{7} (12 & x_1^{(k+1)} & -3x_2^{(k+1)} & -2x_3^{(k+1)} & -7x_4^{(k)}) \end{cases}$$

超松弛迭代 (SOR)

解 (GS) :

$$\begin{cases} x_1^{(k+1)} = x_1^{(k)} + \frac{1}{5} (-2 & -5x_1^{(k)} & -x_2^{(k)} & +x_3^{(k)} & +2x_4^{(k)}) \\ x_2^{(k+1)} = x_2^{(k)} + \frac{1}{8} (-6 & -2x_1^{(k+1)} & -8x_2^{(k)} & -x_3^{(k)} & -3x_4^{(k)}) \\ x_3^{(k+1)} = x_3^{(k)} - \frac{1}{4} (6 & -x_1^{(k+1)} & +2x_2^{(k+1)} & +4x_3^{(k)} & +x_4^{(k)}) \\ x_4^{(k+1)} = x_4^{(k)} + \frac{1}{7} (12 & x_1^{(k+1)} & -3x_2^{(k+1)} & -2x_3^{(k+1)} & -7x_4^{(k)}) \end{cases}$$

迭代 14 次后, 近似解为

$$x^{(14)} = (0.9999966, -1.9999970, -1.0000040, 2.9999990)^T$$

超松弛迭代 (SOR)

解 (SOR) :

$$\begin{cases} x_1^{(k+1)} = x_1^{(k)} + \frac{\omega}{5} (-2 & -5x_1^{(k)} & -x_2^{(k)} & +x_3^{(k)} & +2x_4^{(k)}) \\ x_2^{(k+1)} = x_2^{(k)} + \frac{\omega}{8} (-6 & -2x_1^{(k+1)} & -8x_2^{(k)} & -x_3^{(k)} & -3x_4^{(k)}) \\ x_3^{(k+1)} = x_3^{(k)} - \frac{\omega}{4} (6 & -x_1^{(k+1)} & +2x_2^{(k+1)} & +4x_3^{(k)} & +x_4^{(k)}) \\ x_4^{(k+1)} = x_4^{(k)} + \frac{\omega}{7} (12 & x_1^{(k+1)} & -3x_2^{(k+1)} & -2x_3^{(k+1)} & -7x_4^{(k)}) \end{cases}$$

超松弛迭代 (SOR)

解 (SOR) :

$$\begin{cases} x_1^{(k+1)} = x_1^{(k)} + \frac{\omega}{5} (-2 & -5x_1^{(k)} & -x_2^{(k)} & +x_3^{(k)} & +2x_4^{(k)}) \\ x_2^{(k+1)} = x_2^{(k)} + \frac{\omega}{8} (-6 & -2x_1^{(k+1)} & -8x_2^{(k)} & -x_3^{(k)} & -3x_4^{(k)}) \\ x_3^{(k+1)} = x_3^{(k)} - \frac{\omega}{4} (6 & -x_1^{(k+1)} & +2x_2^{(k+1)} & +4x_3^{(k)} & +x_4^{(k)}) \\ x_4^{(k+1)} = x_4^{(k)} + \frac{\omega}{7} (12 & x_1^{(k+1)} & -3x_2^{(k+1)} & -2x_3^{(k+1)} & -7x_4^{(k)}) \end{cases}$$

取 $\omega = 1.15$, 迭代 8 次后, 近似解为

$$x^{(8)} = (0.9999965, -1.9999970, -1.0000010, 2.9999990)^T$$

超松弛迭代法

收敛性分析

定义：超松弛迭代法

SOR 迭代格式为

$$\mathbf{x}^{(k+1)} = \mathbf{M}_\omega \mathbf{x}^{(k)} + \mathbf{g}$$

其中

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

$$\mathbf{g} = \omega (\mathbf{D} + \omega \mathbf{L})^{-1} \mathbf{b}.$$

定理：充分必要条件

$$\text{SOR 收斂} \iff \rho(\mathbf{M}_\omega) < 1$$

定理：必要条件

$$\text{SOR 收敛} \implies 0 < \omega < 2.$$

定理：必要条件

$$\text{SOR 收敛} \implies 0 < \omega < 2.$$

该定理表明，对任何系数矩阵，若要 SOR 收敛，必须选取松弛因子 $\omega \in (0, 2)$ 。

收敛性分析

证明

设 $\lambda_1, \lambda_2, \dots, \lambda_n$ 为 M_ω 的 n 个特征值, 由 SOR 收敛可知 $\rho(M_\omega) < 1$, 从而有 $|\det(M_\omega)| = |\lambda_1 \cdot \lambda_2 \cdots \lambda_n| < 1$.

收敛性分析

证明

设 $\lambda_1, \lambda_2, \dots, \lambda_n$ 为 M_ω 的 n 个特征值, 由 SOR 收敛可知 $\rho(M_\omega) < 1$, 从而有 $|\det(M_\omega)| = |\lambda_1 \cdot \lambda_2 \cdots \lambda_n| < 1$.

由

$$\left. \begin{aligned} M_\omega &= (I + \omega D^{-1}L)^{-1} \cdot [(1 - \omega)I - \omega D^{-1}U] \\ \det \left((I + \omega D^{-1}L)^{-1} \right) &= 1 \\ \det \left((1 - \omega)I - \omega D^{-1}U \right) &= (1 - \omega)^n \end{aligned} \right\}$$

可知

收敛性分析

证明

设 $\lambda_1, \lambda_2, \dots, \lambda_n$ 为 M_ω 的 n 个特征值, 由 SOR 收敛可知 $\rho(M_\omega) < 1$, 从而有 $|\det(M_\omega)| = |\lambda_1 \cdot \lambda_2 \cdots \lambda_n| < 1$.

由

$$\left. \begin{aligned} M_\omega &= (I + \omega D^{-1}L)^{-1} \cdot [(1 - \omega)I - \omega D^{-1}U] \\ \det\left((I + \omega D^{-1}L)^{-1}\right) &= 1 \\ \det\left((1 - \omega)I - \omega D^{-1}U\right) &= (1 - \omega)^n \end{aligned} \right\}$$

可知

$$|\det(M_\omega)| = |(1 - \omega)^n|$$

收敛性分析

证明

设 $\lambda_1, \lambda_2, \dots, \lambda_n$ 为 M_ω 的 n 个特征值, 由 SOR 收敛可知 $\rho(M_\omega) < 1$, 从而有 $|\det(M_\omega)| = |\lambda_1 \cdot \lambda_2 \cdots \lambda_n| < 1$.

由

$$\left. \begin{aligned} M_\omega &= (I + \omega D^{-1}L)^{-1} \cdot [(1 - \omega)I - \omega D^{-1}U] \\ \det\left((I + \omega D^{-1}L)^{-1}\right) &= 1 \\ \det\left((1 - \omega)I - \omega D^{-1}U\right) &= (1 - \omega)^n \end{aligned} \right\}$$

可知

$$|\det(M_\omega)| = |(1 - \omega)^n|$$

从而

$$|(1 - \omega)^n| < 1 \implies |1 - \omega| < 1 \implies 0 < \omega < 2.$$

定理

严格对角占优 } \Rightarrow SOR 收敛
 $\omega \in (0, 1)$ }

收敛性分析

证明

设 M_ω 的某个特征值 $|\lambda| \geq 1$, 考察 $(\lambda - 1 + \omega)D + \lambda\omega L + \omega U$.

收敛性分析

证明

设 M_ω 的某个特征值 $|\lambda| \geq 1$, 考察 $(\lambda - 1 + \omega)D + \lambda\omega L + \omega U$.

A 严格对角占优且 $\lambda - 1 + \omega > \lambda\omega$

收敛性分析

证明

设 M_ω 的某个特征值 $|\lambda| \geq 1$, 考察 $(\lambda - 1 + \omega)D + \lambda\omega L + \omega U$.

A 严格对角占优且 $\lambda - 1 + \omega > \lambda\omega$

$\implies (\lambda - 1 + \omega)D + \lambda\omega L + \omega U$ 也严格对角占优

收敛性分析

证明

设 M_ω 的某个特征值 $|\lambda| \geq 1$, 考察 $(\lambda - 1 + \omega)D + \lambda\omega L + \omega U$.

A 严格对角占优且 $\lambda - 1 + \omega > \lambda\omega$

$\implies (\lambda - 1 + \omega)D + \lambda\omega L + \omega U$ 也严格对角占优

$\implies (\lambda - 1 + \omega)D + \lambda\omega L + \omega U$ 非奇异

收敛性分析

证明

设 M_ω 的某个特征值 $|\lambda| \geq 1$, 考察 $(\lambda - 1 + \omega)D + \lambda\omega L + \omega U$.

A 严格对角占优且 $\lambda - 1 + \omega > \lambda\omega$

$\implies (\lambda - 1 + \omega)D + \lambda\omega L + \omega U$ 也严格对角占优

$\implies (\lambda - 1 + \omega)D + \lambda\omega L + \omega U$ 非奇异

而

$$\begin{aligned}\lambda I - M_\omega &= \lambda I - (D + \omega L)^{-1} [(1 - \omega)D - \omega U] \\ &= (D + \omega L)^{-1} [(\lambda - 1 + \omega)D + \lambda\omega L + \omega U]\end{aligned}$$

收敛性分析

证明

设 M_ω 的某个特征值 $|\lambda| \geq 1$, 考察 $(\lambda - 1 + \omega)D + \lambda\omega L + \omega U$.

A 严格对角占优且 $\lambda - 1 + \omega > \lambda\omega$

$\implies (\lambda - 1 + \omega)D + \lambda\omega L + \omega U$ 也严格对角占优

$\implies (\lambda - 1 + \omega)D + \lambda\omega L + \omega U$ 非奇异

而

$$\begin{aligned}\lambda I - M_\omega &= \lambda I - (D + \omega L)^{-1} [(1 - \omega)D - \omega U] \\ &= (D + \omega L)^{-1} [(\lambda - 1 + \omega)D + \lambda\omega L + \omega U] \\ \implies \det(\lambda I - M_\omega) &\neq 0\end{aligned}$$

收敛性分析

证明

设 M_ω 的某个特征值 $|\lambda| \geq 1$, 考察 $(\lambda - 1 + \omega)D + \lambda\omega L + \omega U$.

A 严格对角占优且 $\lambda - 1 + \omega > \lambda\omega$

$\implies (\lambda - 1 + \omega)D + \lambda\omega L + \omega U$ 也严格对角占优

$\implies (\lambda - 1 + \omega)D + \lambda\omega L + \omega U$ 非奇异

而

$$\begin{aligned}\lambda I - M_\omega &= \lambda I - (D + \omega L)^{-1} [(1 - \omega)D - \omega U] \\ &= (D + \omega L)^{-1} [(\lambda - 1 + \omega)D + \lambda\omega L + \omega U] \\ &\implies \det(\lambda I - M_\omega) \neq 0\end{aligned}$$

这与 λ 是 M_ω 的特征值矛盾, 从而 $\rho(M_\omega) < 1 \implies$ 松弛法收敛。

定理

对于实对称正定矩阵,

$$\omega \in (0, 2) \iff \text{SOR 收敛}$$

收敛性分析

证明

设 λ 与 v 是 M_ω 的特征值与特征向量, 故

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

证明

设 λ 与 v 是 M_ω 的特征值与特征向量, 故

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

因 $U = L^T$, 故

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

$$\implies [(1 - \omega)D - \omega L^T] v = \lambda(D + \omega L)v$$

$$\implies \lambda[v^* D v + \omega v^* L v] = (1 - \omega)v^* D v - \omega v^* L^T v$$

令

$$v^* D v = \delta$$

$$v^* L v = \alpha + i\beta \implies v^* L^T v = \alpha - i\beta.$$

收敛性分析

证明 (续) :

$$\lambda[\delta + \omega(\alpha + i\beta)] = (1 - \omega)\delta - \omega(\alpha - i\beta)$$

收敛性分析

证明 (续) :

$$\lambda[\delta + \omega(\alpha + i\beta)] = (1 - \omega)\delta - \omega(\alpha - i\beta)$$

$$\xrightarrow{\text{取模}} |\lambda|^2 = \frac{[(1 - \omega)\delta - \omega\alpha]^2 + \omega^2\beta^2}{(\delta - \omega\alpha)^2 + \omega^2\beta^2} < 1?$$

证明 (续) :

$$\lambda[\delta + \omega(\alpha + i\beta)] = (1 - \omega)\delta - \omega(\alpha - i\beta)$$

$$\xrightarrow{\text{取模}} |\lambda|^2 = \frac{[(1 - \omega)\delta - \omega\alpha]^2 + \omega^2\beta^2}{(\delta - \omega\alpha)^2 + \omega^2\beta^2} < 1?$$

事实上,

$$\begin{aligned} & [(1 - \omega)\delta - \omega\alpha]^2 + \omega^2\beta^2 - (\delta - \omega\alpha)^2 - \omega^2\beta^2 \\ = & (1 - \omega)^2\delta^2 - 2(1 - \omega)\omega\delta\alpha - \delta^2 + 2\omega\delta\alpha \\ = & [(1 - \omega)\delta - \omega\alpha]^2 - (\delta - \omega\alpha)^2 \\ = & \omega\delta(\delta - 2\alpha)(\omega - 2) \end{aligned}$$

证明 (续) :

又因

$$A \text{ 正定} \implies \left. \begin{array}{l} \delta > 0, \quad \delta - 2\alpha > 0 \\ 0 < \omega < 2 \end{array} \right\} \implies \omega\delta(\delta-2\alpha)(\omega-2) < 0$$

于是有

$$|\lambda|^2 < 1,$$

定理得证.