

第六章 线性方程组的迭代解法

§ 1 基本迭代法

§ 2 共轭梯度法

§ 3 广义极小残差法



□ 一个例子

$$\text{求解} \begin{cases} 8x_1 - 3x_2 + 2x_3 = 20 \\ 4x_1 + 11x_2 - x_3 = 33 \\ 6x_1 + 3x_2 + 12x_3 = 36 \end{cases}$$

即 $Ax = b$, 精确解: $x^* = (3, 2, 1)^T$

方案1 Jacobi迭代法

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

建立迭代:

$$\begin{cases} x_1^{(k+1)} = \frac{1}{8}(20 + 3x_2^{(k)} - 2x_3^{(k)}) \\ x_2^{(k+1)} = \frac{1}{11}(33 - 4x_1^{(k)} + x_3^{(k)}) \\ x_3^{(k+1)} = \frac{1}{12}(36 - 6x_1^{(k)} - 3x_2^{(k)}) \end{cases}$$
$$k = 0, 1, 2, \dots$$

取初值: $x^{(0)} = (0, 0, 0)^T$

$$x^{(1)} = (x_1^{(1)}, x_2^{(1)}, x_3^{(1)})^T = (5/2, 3, 3)^T$$

$$x^{(2)} = (x_1^{(2)}, x_2^{(2)}, x_3^{(2)})^T = (3/8, 20/11, 5/4)^T$$

.....

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

矩阵形式: $Ax = b$

$$\Leftrightarrow \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix} = \begin{pmatrix} 0 & \frac{3}{8} & \frac{-2}{8} \\ \frac{-4}{11} & 0 & \frac{1}{11} \\ \frac{-6}{12} & \frac{-3}{12} & 0 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix} + \begin{pmatrix} \frac{20}{8} \\ \frac{33}{11} \\ \frac{36}{12} \end{pmatrix}$$

$$\Leftrightarrow x = Mx + g$$

$$\Leftrightarrow x^{(k+1)} = Mx^{(k)} + g$$

方案2 Gauss-Seidel迭代法

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

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

建立迭代:

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

取初值: $x^{(0)} = (0, 0, 0)^T$

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

$$\Rightarrow x^{(0)} = (0, 0, 0)^T, x^{(1)} = (2.5, 3, 3)^T$$

... ..

$$x^{(10)} = (3.00003, 1.99983, 0.99988)^T$$

把已有的结果用上,
期待能有更好结果!

方案3 SOR迭代法

将G-S迭代等价变形:

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

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

记作:

$$x_i^{(k+1)} = x_i^{(k)} + \Delta x_i^{(k)} \quad (i = 1, 2, 3, 4)$$

建立迭代:

$$x_i^{(k+1)} = x_i^{(k)} + \omega \cdot \Delta x_i^{(k)} \quad (i = 1, 2, 3, 4)$$

即:

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

一 常用迭代法

$$\begin{cases} a_{11}x_1 + a_{12}x_2 + \cdots + a_{1n}x_n = b_1 \\ a_{21}x_1 + a_{22}x_2 + \cdots + a_{2n}x_n = b_2 \\ \dots\dots\dots \\ a_{n1}x_1 + a_{n2}x_2 + \cdots + a_{nn}x_n = b_n \end{cases}$$

1 Jacobi迭代法

假设 $a_{ii} \neq 0$, 则从第 i 个方程中解出 x_i : $a_{i1}x_1 + a_{i2}x_2 + \cdots + a_{ii}x_i + \cdots + a_{in}x_n = b_i$

$$\begin{cases} x_1 = \frac{1}{a_{11}}(b_1 - (a_{12}x_2 + \cdots + a_{1n}x_n)) \\ x_2 = \frac{1}{a_{22}}(b_2 - (a_{21}x_1 + \cdots + a_{2n}x_n)) \\ \dots\dots\dots \\ x_n = \frac{1}{a_{nn}}(b_n - (a_{n1}x_1 + \cdots + a_{n,n-1}x_{n-1})) \end{cases}$$

or. $x_i = (b_i - \sum_{\substack{j=1 \\ j \neq i}}^n a_{ij}x_j) \cdot \frac{1}{a_{ii}} \quad (i = 1, 2, \dots, n)$

$$\begin{cases} x_1^{(k+1)} = \frac{1}{a_{11}}(b_1 - (a_{12}x_2^{(k)} + \cdots + a_{1n}x_n^{(k)})) \\ x_2^{(k+1)} = \frac{1}{a_{22}}(b_2 - (a_{21}x_1^{(k)} + \cdots + a_{2n}x_n^{(k)})) \\ \dots\dots\dots \\ x_n^{(k+1)} = \frac{1}{a_{nn}}(b_n - (a_{n1}x_1^{(k)} + \cdots + a_{n,n-1}x_{n-1}^{(k)})) \end{cases}$$

or. $x_i^{(k+1)} = (b_i - \sum_{\substack{j=1 \\ j \neq i}}^n a_{ij}x_j^{(k)}) \cdot \frac{1}{a_{ii}} \quad (i = 1, 2, \dots, n)$

2 G-S迭代法

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

3 SOR迭代法

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



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

令：

$$x_i^{(k+1)} = x_i + \omega (b_i - \sum_{j=1}^{i-1} a_{ij} x_j^{(k+1)} - \sum_{j=i}^n a_{ij} x_j^{(k)}) \cdot \frac{1}{a_{ii}} \quad (i = 1, 2, \dots, n)$$

其中， ω 为松弛因子； $\omega = 1$ ，G-S迭代法；

$\omega > 1$ ，超松弛迭代法；

$\omega < 1$ ，低松弛迭代法。



二 迭代法的矩阵形式 对 $Ax = b$, 将 A 进行分解:

$$A = \begin{pmatrix} a_{11} & & & & \\ & a_{22} & & & \\ & & a_{33} & & \\ & & & \ddots & \\ & & & & a_{nn} \end{pmatrix} - \begin{pmatrix} 0 & & & & \\ -a_{21} & 0 & & & \\ -a_{31} & -a_{32} & 0 & & \\ \dots & \dots & & \ddots & \\ -a_{n1} & -a_{n2} & -a_{n3} & \dots & 0 \end{pmatrix} - \begin{pmatrix} 0 & -a_{12} & -a_{13} & \dots & -a_{1n} \\ & 0 & -a_{23} & \dots & -a_{2n} \\ & & 0 & & -a_{3n} \\ & & & \ddots & \vdots \\ & & & & 0 \end{pmatrix} \triangleq D - L - U$$

则 $Ax = b \Leftrightarrow (D - L - U)x = b \Leftrightarrow Dx = b + (L + U)x \Leftrightarrow x = D^{-1}(b + (L + U)x)$

1 Jacobi迭代法

$$\begin{aligned} x^{(k+1)} &= D^{-1}(b + (L + U)x^{(k)}) \\ &= D^{-1}b + D^{-1}(L + U)x^{(k)} \\ &= D^{-1}b + D^{-1}(D - A)x^{(k)} \\ &= (E - D^{-1}A)x^{(k)} + D^{-1}b \end{aligned}$$

2 G-S迭代法

$$\begin{aligned} x^{(k+1)} &= D^{-1}(b + Lx^{(k+1)} + Ux^{(k)}) \\ &\Rightarrow (D - L)x^{(k+1)} = (b + Ux^{(k)}) \\ &\Rightarrow x^{(k+1)} = (D - L)^{-1}(b + Ux^{(k)}) \\ &\Rightarrow x^{(k+1)} = (D - L)^{-1}Ux^{(k)} + (D - L)^{-1}b \end{aligned}$$

3 SOR迭代法

$$\begin{aligned} x^{(k+1)} &= x^{(k)} + \omega D^{-1}(b + Lx^{(k+1)} + Ux^{(k)} - Dx^{(k)}) \\ &\Rightarrow x^{(k+1)} = (D - \omega L)^{-1}[(1 - \omega)D + \omega U]x^{(k)} + \omega(D - \omega L)^{-1}b \end{aligned}$$

综上所述，三种迭代法可统一为：

$$x^{k+1} = Mx^k + g$$

其中， M 为迭代矩阵： $M_J = (E - D^{-1}A)$;

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

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

-----迭代法的矩阵形式

三 迭代法的收敛性

1 基本概念

1) 向量序列极限

设 $x^{(k)} = (x_1^{(k)}, x_2^{(k)}, \dots, x_n^{(k)})^T \in R^n$ ($k = 0, 1, \dots$), $x^* = (x_1^*, x_2^*, \dots, x_n^*)^T \in R^n$,

若 $\lim_{k \rightarrow +\infty} x_i^{(k)} = x_i^*$ ($i = 1, \dots, n$), 则称向量序列 $\{x^k\}$ 收敛于 x^* , 记作: $\lim_{k \rightarrow +\infty} x^k = x^*$.

2) 迭代法的收敛性

设 $x^{(k)}$ 是由迭代公式 $x^{k+1} = Mx^k + g$ 生成的向量序列, 若 $\lim_{k \rightarrow +\infty} x_i^{(k)}$ 存在, 则称迭代法收敛, 否则发散, 且收敛时有 $x^* = \lim_{k \rightarrow +\infty} x^{(k)}$.

3) 定理(补充)

$\lim_{k \rightarrow +\infty} x^k = x^* \Leftrightarrow \lim_{k \rightarrow +\infty} \|x^k - x^*\| = 0$, 其中 $\|\cdot\|$ 为向量任一范数。

$$\lim_{k \rightarrow +\infty} x^k = x^* \Leftrightarrow \lim_{k \rightarrow +\infty} |x_i^{(k)} - x_i^*| = 0, (i = 1, \dots, n)$$

$$\Leftrightarrow \lim_{k \rightarrow +\infty} \max_i |x_i^{(k)} - x_i^*| = 0$$

$$\Leftrightarrow \lim_{k \rightarrow +\infty} \|x^k - x^*\|_{\infty} = 0 \Leftrightarrow \lim_{k \rightarrow +\infty} \|x^k - x^*\| = 0$$

范数的等价性

2 判别条件

1) 收敛基本定理【充要条件, P131-Th1.1】

$x^{(k+1)} = Mx^{(k)} + g$ 对任意初值收敛 $\Leftrightarrow \rho(M) = \max|\lambda_i| < 1$ 。

例1 判断迭代格式 $x^{(k+1)} = \begin{bmatrix} 0 & 2 \\ 3 & 0 \end{bmatrix} x^{(k)} + \begin{bmatrix} 5 \\ 5 \end{bmatrix}$ 的收敛性。

解 \because 迭代矩阵 $M = \begin{pmatrix} 0 & 2 \\ 3 & 0 \end{pmatrix}$

$$\therefore f(\lambda) = |\lambda E - M| = \begin{vmatrix} \lambda & -2 \\ -3 & \lambda \end{vmatrix} = \lambda^2 - 6 = 0$$

$$\therefore \lambda_1 = \sqrt{6}, \lambda_2 = -\sqrt{6}$$

$\therefore \rho(M) = \max(|\lambda_1|, |\lambda_2|) = \sqrt{6} > 1$, 迭代发散!

例2 设 $Ax = b$, 其中 $A = \begin{pmatrix} 1 & 0 & a \\ 0 & 1 & -2a \\ a & 2a & 1 \end{pmatrix}$, $a \in R$.

求使Jacobi迭代过程收敛和发散的 a 的取值范围。

解 $\because M_J = E - D^{-1}A = \begin{pmatrix} 0 & 0 & -a \\ 0 & 0 & 2a \\ -a & -2a & 0 \end{pmatrix}$

$$\therefore f(\lambda) = |\lambda E - M_J| = \begin{vmatrix} \lambda & 0 & a \\ 0 & \lambda & -2a \\ a & 2a & \lambda \end{vmatrix} = \lambda(\lambda^2 + 3a^2) = 0$$

$$\therefore M_J \text{ 的特征值为: } \lambda_1 = 0, \lambda_{2,3} = \pm\sqrt{3a^2}i = \pm\sqrt{3}|a|i$$

$$\therefore \text{迭代收敛} \Leftrightarrow \rho(M_J) < 1 \Leftrightarrow \sqrt{3}|a| < 1 \Leftrightarrow |a| < \frac{1}{\sqrt{3}}$$

\therefore 当 $|a| < \frac{1}{\sqrt{3}}$ 时, Jacobi迭代收敛; 当 $|a| \geq \frac{1}{\sqrt{3}}$ 时, Jacobi迭代发散。

例3 对
$$\begin{cases} x_1 - 2x_2 + x_3 = 5 \\ ax_1 + x_2 = 4, \quad a \in R, \\ 0.5x_2 + x_3 = 6 \end{cases}$$

1) 建立G-S迭代公式;

2) 确定使G-S迭代收敛和发散的 a 的范围。

解 1) G-S迭代公式:
$$\begin{cases} x_1^{(k+1)} = 5 + x_2^{(k)} - x_3^{(k)} \\ x_2^{(k+1)} = 4 - ax_1^{(k+1)} \\ x_3^{(k+1)} = 6 - 0.5x_2^{(k+1)} \end{cases}$$

2)
$$M_G = (D - L)^{-1}U = \begin{pmatrix} 1 & & \\ a & 1 & \\ 0 & 0.5 & 1 \end{pmatrix}^{-1} \begin{pmatrix} 0 & 2 & -1 \\ 0 & 0 & \\ 0 & 0 & \end{pmatrix} = \begin{pmatrix} 0 & 2 & -1 \\ 0 & -2a & a \\ 0 & a & -0.5a \end{pmatrix}$$

$$\therefore f(\lambda) = |\lambda E - M_G| = \lambda^2(\lambda + 2.5a) = 0$$

$$\therefore M_{G-S} \text{的特征值为: } \lambda_{1,2} = 0, \lambda_3 = -2.5a$$

$$\therefore \rho(M_{G-S}) = |-2.5a| = 2.5|a|$$

$$\therefore \text{迭代收敛} \Leftrightarrow \rho(M_{G-S}) < 1 \Leftrightarrow 2.5|a| < 1 \Leftrightarrow |a| < \frac{2}{5}$$

$$\therefore \text{当 } |a| < \frac{2}{5} \text{ 时, 迭代收敛; 当 } |a| \geq \frac{2}{5} \text{ 时, 迭代发散。}$$

2) 判定条件II【充分条件, P131-推论1.1】


设迭代矩阵的某种范数满足 $\|M\| = q < 1$, 则迭代 $x^{(k+1)} = Mx^{(k)} + g$ 收敛, 且有

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

例4 设迭代矩阵 $M = \begin{bmatrix} 0.9 & 0 \\ 0.3 & 0.8 \end{bmatrix}$, 判断迭代 $x^{(k+1)} = Mx^{(k)} + g$ 是否收敛?

$$\text{易见: } \|M\|_1 = \max_{1 \leq j \leq n} \sum_{i=1}^n |M_{ij}| = 1.2 > 1$$

$$\|M\|_\infty = \max_{1 \leq i \leq n} \sum_{j=1}^n |M_{ij}| = 1.1 > 1$$



$$\text{但: } |\lambda E - M| = 0 \Rightarrow (\lambda - 0.9)(\lambda - 0.8) = 0$$

$$\Rightarrow \rho(M) = 0.9 < 1$$

\Rightarrow 收敛



3) 判定条件III【充分条件, P135-Th1.4,1.5】

对 $Ax = b$, ①若A为严格对角占优方阵, 则Jacobi和G-S迭代收敛;

②若A为对称正定矩阵, 则G-S迭代收敛。

例5 判定下面方程组用Jacobi迭代是否收敛, 如不收敛, 能否将方程组变形使之收敛。

$$\begin{cases} x_1 - 10x_2 + 20x_3 = 11 \\ -10x_1 + x_2 - 5x_3 = -14 \\ x_1 - 5x_2 - x_3 = 3 \end{cases}$$

解

$$A = \begin{pmatrix} 1 & -10 & 20 \\ -10 & 1 & -5 \\ 1 & -5 & -1 \end{pmatrix}$$

1) 若直接建立Jacobi迭代, 不满足判定条件III, 故无法判定。

2) 利用收敛基本判定定理判定

$$\therefore \mathbf{M}_J = \mathbf{E} - \mathbf{D}^{-1}\mathbf{A} = \begin{pmatrix} 0 & 10 & -20 \\ 10 & 0 & 5 \\ 1 & -5 & 0 \end{pmatrix}$$

$$\mathbf{A} = \begin{pmatrix} 1 & -10 & 20 \\ -10 & 1 & -5 \\ 1 & -5 & -1 \end{pmatrix}$$

$$\therefore f(\lambda) = |\lambda \mathbf{E} - \mathbf{M}_J| = \begin{vmatrix} \lambda & -10 & 20 \\ -10 & \lambda & -5 \\ -1 & 5 & \lambda \end{vmatrix} = \lambda^3 - 55\lambda - 1050$$

$$\therefore f(1) = 1 - 55 - 1050 < 0$$

$$f(100) = 1000000 - 1050 - 5500 > 0$$

$\therefore f(\lambda) = 0$ 在 (1, 100) 之间有根

$\therefore \rho(\mathbf{M}_J) > 1$, Jacobi 迭代发散。

注：实际上， $\lambda_1 = 11.9520, \lambda_{2,3} = -5.9760 \pm 7.22071i$

$\therefore \rho(\mathbf{M}_J) = 11.9520 > 1$, 发散!

将方程等价变形:

$$\begin{cases} x_1 - 10x_2 + 20x_3 = 11 \\ -10x_1 + x_2 - 5x_3 = -14 \\ x_1 - 5x_2 - x_3 = 3 \end{cases} \Leftrightarrow \begin{cases} -10x_1 + x_2 - 5x_3 = -14 \\ x_1 - 5x_2 - x_3 = 3 \\ x_1 - 10x_2 + 20x_3 = 11 \end{cases}$$

则 $A' = \begin{pmatrix} -10 & 1 & -5 \\ 1 & -5 & -1 \\ 1 & -10 & 20 \end{pmatrix}$, 严格对角占优!

\therefore 由判定条件III知, **Jacobi**迭代收敛

建立的**Jacobi**迭代格式为:

$$\begin{cases} x_1^{(k+1)} = (-14 - x_2^{(k)} + 5x_3^{(k)})/(-10) \\ x_2^{(k+1)} = (3 - x_1^{(k)} + x_3^{(k)})/(-5) \\ x_3^{(k+1)} = (11 - x_1^{(k)} + 10x_2^{(k)})/(20) \end{cases}$$

注：A对称正定时，不能保证Jacobi迭代收敛。

如，对称阵 $A = \begin{bmatrix} 1 & a & a \\ a & 1 & a \\ a & a & 1 \end{bmatrix}$ ，A正定 $\Leftrightarrow \begin{cases} |1| > 0 \\ \begin{vmatrix} 1 & a \\ a & 1 \end{vmatrix} = 1 - a^2 > 0 \\ |A| = (2a + 1)(1 - a) > 0 \end{cases} \Leftrightarrow -\frac{1}{2} < a < 1$

\therefore 当 $-\frac{1}{2} < a < 1$ 时，G-S迭代收敛；

但是， $M_J = E - D^{-1}A = -\begin{bmatrix} 0 & a & a \\ a & 0 & a \\ a & a & 0 \end{bmatrix}$

$\therefore |\lambda E - M_J| = (\lambda + 2a)(\lambda - a)^2$

\therefore J迭代收敛 $\Leftrightarrow \rho(M_J) < 1 \Leftrightarrow \max(|-2a|, |a|) = 2|a| < 1 \Leftrightarrow -\frac{1}{2} < a < \frac{1}{2}$

这表明，当 $-\frac{1}{2} < a < 1$ 时，A对称正定，但Jacobi不收敛。

4) 判定条件IV 【SOR迭代法, P136 - Th6,7】

- ▶ SOR迭代法收敛的必要条件是 $0 < \omega < 2$ 。
- ▶ 对 $Ax = b$, 若 A 对称正定, 则SOR迭代收敛的充要条件是 $0 < \omega < 2$ 。

第六章 线性方程组的迭代解法

§ 1 基本迭代法

§ 2 共轭梯度法

§ 3 广义极小残差法



共轭梯度法(CG法)是一种不需要任何参数求解**对称正定**线性方程组的方法, 它是由**50**年代提出来的, 近**20**年来有关研究得到了前所未有的发展, 目前相关方法和理论已相当成熟, 并成为求解**大型稀疏**线性方程组最受欢迎的一类方法。

一 Ritz变分原理

1 设 $A \in R^{n \times n}$ 为对称正定矩阵, 定义:

$$A \text{内积: } (x, y)_A = x^T A y, \forall x, y \in R^n$$

$$A \text{共轭(正交): } (x, y)_A = 0$$

$$A \text{范数: } \|x\|_A = \sqrt{x^T A x}$$

2 Ritz变分原理 (P138-Th2.1)

设 $A \in R^{n \times n}$ 是对称正定矩阵, $b \in R^n$ 是常向量, 定义

$$f(x) = \frac{1}{2} x^T A x - b^T x = \frac{1}{2} (x, x)_A - (b, x), \quad x \in R^n$$

则

$$Ax^* = b \Leftrightarrow f(x^*) = \min_{x \in R^n} f(x)$$

证明

记 $x^* = A^{-1}b$, 可得

$$2f(x) + (x^*)^T A x^* = (x - x^*)^T A (x - x^*)$$

即

$$2f(x) + \|x^*\|_A^2 = \|x - x^*\|_A^2$$

所以

$$f(x) = \min \Leftrightarrow \|x - x^*\|_A = \min \Leftrightarrow x = x^*$$

意义

把正定方程组 $Ax = b$ 的求解问题转化为极小化函数 $f(x)$ 的问题.

二 最速下降法

$$1 \text{ 梯度 } \text{grad} \vec{f} = \left(\frac{\partial f}{\partial x}, \frac{\partial f}{\partial y} \right)^T$$

方向导数

$$\frac{\partial f}{\partial l} = \frac{\partial f}{\partial x} \cos \alpha + \frac{\partial f}{\partial y} \cos \beta = (\text{grad} \vec{f}, \vec{n}) = |\text{grad} \vec{f}| \cdot |\vec{n}| \cdot \cos \langle \vec{f}, \vec{n} \rangle$$

所以，梯度方向是函数变化(增加)最快的方向；

$$\text{负梯度方向: } -\text{grad} \vec{f} = \left(-\frac{\partial f}{\partial x}, -\frac{\partial f}{\partial y} \right)^T \text{ 为 } f \text{ 下降最快的方向.}$$

2 最速下降法

任给初始点 $x^{(0)}$, 假设 $x^{(k)}$ 已求得, 在过点 $x^{(k)}$ 方向为负梯度方向的直线

$$\pi_1 = \left\{ x \in R^n \mid x = x^{(k)} + \alpha r^{(k)}, \alpha \in R \right\}$$

上搜索一点 $x^{(k+1)} = x^{(k)} + \alpha_k r^{(k)}$, 使得

$$f(x^{(k+1)}) = f(x^{(k)} + \alpha_k r^{(k)}) = \min_{\alpha \in R} f(x^{(k)} + \alpha r^{(k)})$$

则显然序列 $\{x^{(k)}\}$ 是 $f(x)$ 的下降序列, 即满足:

$$f(x^{(0)}) \geq f(x^{(1)}) \geq f(x^{(2)}) \geq \dots$$

易知:

$$r^{(k)} = -\text{grad } f(x^{(k)}) = b - Ax^{(k)}$$

下面求 α_k , 使 $f(x)$ 在直线 π_1 上的 x^{k+1} 处极小:

考察: $\varphi(\alpha) = f(x^{(k)} + \alpha r^{(k)})$

$$= \frac{1}{2} (x^{(k)} + \alpha r^{(k)})^T A (x^{(k)} + \alpha r^{(k)}) - b^T (x^{(k)} + \alpha r^{(k)})$$

$$= \frac{1}{2} \left((x^{(k)})^T Ax^{(k)} \right) + \frac{1}{2} \left((x^{(k)})^T A \alpha r^{(k)} \right) + \frac{1}{2} \alpha \left((r^{(k)})^T A x^{(k)} \right)$$

$$+ \frac{1}{2} \alpha^2 \left((r^{(k)})^T A r^{(k)} \right) - b^T x^{(k)} - \alpha b^T r^{(k)}$$

$$= \frac{1}{2} (r^{(k)}, r^{(k)})_A \alpha^2 + \left(r^{(k)T} Ax^{(k)} - b^T r^{(k)} \right) \alpha + f(x^{(k)})$$

$$= \frac{1}{2} (r^{(k)}, r^{(k)})_A \alpha^2 - (r^{(k)}, r^{(k)}) \alpha + f(x^{(k)})$$

$$\begin{aligned} & r^{(k)T} Ax^{(k)} - r^{(k)T} b \\ &= r^{(k)T} (Ax^{(k)} - b) \\ &= -r^{(k)T} \cdot r^{(k)} \end{aligned}$$

$$\therefore \text{当 } \alpha_k = \frac{(\mathbf{r}^{(k)}, \mathbf{r}^{(k)})}{(\mathbf{r}^{(k)}, \mathbf{r}^{(k)})_A} \text{ 时, } \varphi(\alpha) \text{ 取得最小, 即 } \mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + \frac{(\mathbf{r}^{(k)}, \mathbf{r}^{(k)})}{(\mathbf{r}^{(k)}, \mathbf{r}^{(k)})_A} \mathbf{r}^{(k)}$$

3 算法2.1(最速下降法)

任取初值 $\mathbf{x}^{(0)} \in \mathbb{R}^n$, 计算 $\mathbf{r}^{(0)} = \mathbf{b} - A\mathbf{x}^{(0)}$

for $k = 0, 1, 2, \dots$

$$\alpha_k = \frac{(\mathbf{r}^{(k)}, \mathbf{r}^{(k)})}{(\mathbf{r}^{(k)}, \mathbf{r}^{(k)})_A}$$

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + \alpha_k \mathbf{r}^{(k)}$$

$$\mathbf{r}^{(k+1)} = \mathbf{b} - A\mathbf{x}^{(k+1)}$$

end

4 收敛性

➤ 引理2.0

设 (λ, \mathbf{x}) 为方阵 A 的特征对, $P(A) = a_0 I + a_1 A + a_2 A^2 + \dots + a_n A^n$ 为矩阵多项式,

则 $(P(\lambda), \mathbf{x})$ 是 $P(A)$ 的特征对.

引理2.1

设 A 是 n 阶对称正定矩阵, 特征值为 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n > 0$, $P(t)$ 为 t 的一个多项式,

则

$$\|P(A)x\|_A \leq \max_{1 \leq i \leq n} |p(\lambda_i)| \cdot \|x\|_A, \forall x \in R^n$$

证明 设 $\alpha_1, \alpha_2, \dots, \alpha_n$ 为 A 的 n 个单位正交特征向量系, 则对 $\forall x \in R^n$, 设

$$x = \sum_{i=1}^n k_i \alpha_i$$

则
$$\|x\|_A^2 = x^T A x = \left(\sum_{i=1}^n k_i \alpha_i \right)^T A \left(\sum_{i=1}^n k_i \alpha_i \right) = \sum_{i=1}^n k_i^2 \lambda_i$$

$$P(A)x = P(A) \sum_{i=1}^n k_i \alpha_i = \sum_{i=1}^n k_i P(A) \alpha_i = \sum_{i=1}^n k_i P(\lambda_i) \alpha_i$$

所以
$$\|p(A)x\|_A^2 = (p(A)x, Ap(A)x) = \left(\sum_{i=1}^n k_i p(\lambda_i) \alpha_i, \sum_{i=1}^n k_i \lambda_i p(\lambda_i) \alpha_i \right)$$

$$= \sum_{i=1}^n k_i^2 \lambda_i p^2(\lambda_i) \leq \max_{1 \leq i \leq n} |p(\lambda_i)|^2 \sum_{i=1}^n k_i^2 \lambda_i = \left(\max_{1 \leq i \leq n} |p(\lambda_i)| \right)^2 \|x\|_A^2$$

► 定理2.2

设 A 是 n 阶对称正定矩阵, 特征值为 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n > 0$, 则由最速下降法产生的迭代序列 $x^{(k)}$ 满足

$$\|x^{(k)} - x^*\|_A \leq \left(\frac{\lambda_1 - \lambda_n}{\lambda_1 + \lambda_n} \right)^k \|x^{(0)} - x^*\|_A = \left(\frac{\kappa_2 - 1}{\kappa_2 + 1} \right)^k \|x^{(0)} - x^*\|_A$$

其中 x^* 是 $f(x)$ 的极小点, $\kappa_2 = \text{cond}_2(A) = \lambda_1 / \lambda_n$.

证明 $\because f(x^{(k)}) \leq f(x^{(k-1)} + \alpha r^{(k-1)}), \forall \alpha \in R$

$$\begin{aligned} \therefore (x^{(k)} - x^*)^T A(x^{(k)} - x^*) &\leq (x^{(k-1)} + \alpha r^{(k-1)} - x^*)^T A(x^{(k-1)} + \alpha r^{(k-1)} - x^*) \\ &= [(I - \alpha A)(x^{(k-1)} - x^*)]^T A[(I - \alpha A)(x^{(k-1)} - x^*)] \end{aligned}$$

记 $p_\alpha(t) = 1 - \alpha t$, 则上式为

$$\|x^{(k)} - x^*\|_A^2 \leq \|P_\alpha(A)(x^{(k-1)} - x^*)\|_A^2$$

$$f(x) = \frac{1}{2} x^T A x - b^T x$$

由引理1, 得

$$\|P(A)x\|_A \leq \max_{1 \leq i \leq n} |p(\lambda_i)| \cdot \|x\|_A, \forall x \in R^n$$

$$\|x^{(k)} - x^*\|_A \leq \max_{1 \leq i \leq n} |P_\alpha(\lambda_i)| \cdot \|x^{(k-1)} - x^*\|_A, \forall \alpha \in R$$

而

$$\min_{\alpha \in \mathbb{R}} \max_{\lambda_n \leq t \leq \lambda_1} |p_\alpha(t)| = \min_{\alpha \in \mathbb{R}} \max_{\lambda_n \leq t \leq \lambda_1} |1 - \alpha t| = \frac{\lambda_1 - \lambda_n}{\lambda_1 + \lambda_n}$$

所以


$$\|x^{(k)} - x^*\|_A \leq \frac{\lambda_1 - \lambda_n}{\lambda_1 + \lambda_n} \|x^{(k-1)} - x^*\|_A$$

$$\leq \left(\frac{\lambda_1 - \lambda_n}{\lambda_1 + \lambda_n} \right)^k \|x^{(0)} - x^*\|_A = \left(\frac{\kappa_2 - 1}{\kappa_2 + 1} \right)^k \|x^{(0)} - x^*\|_A$$

注： 1) $\because 0 \leq \frac{\lambda_1 - \lambda_n}{\lambda_1 + \lambda_n} < 1$, 所以方法对任意 $x^{(0)}$ 都收敛;

但当 $\lambda_1 \gg \lambda_n$ (即 $\kappa_2 = \text{cond}_2(A)$ 很大时), 收敛速度慢.

2) 示意图



三 共轭梯度法

➤ 公式推导

step1: 任取 $x_0 \in R^n$, 令下山方向 $p_0 = r_0 = b - Ax_0$, 则

$$\alpha_0 = \frac{(r_0, r_0)}{(r_0, r_0)_A} = \frac{r_0^T r_0}{p_0^T A p_0}, \quad x_1 = x_0 + \alpha_0 p_0, \quad r_1 = b - Ax_1$$

... ..

stepk+1: 下山方向取为过 x_k 且由 r_k 和 p_{k-1} 张成的二维平面

$$\pi_2 = \{x = x_k + \xi r_k + \eta p_{k-1} : \xi, \eta \in R\}$$

找出使函数 $\varphi(\xi, \eta)$ 下降最快的方向作为新的下山方向 p_k :

$$\text{令 } \varphi(\xi, \eta) = f(x_k + \xi r_k + \eta p_{k-1})$$

$$= \frac{1}{2} (x_k + \xi r_k + \eta p_{k-1})^T A (x_k + \xi r_k + \eta p_{k-1}) - b^T (x_k + \xi r_k + \eta p_{k-1})$$

直接计算得:

$$\begin{cases} \frac{\partial \varphi}{\partial \xi} = \xi r_k^T A r_k + \eta r_k^T A p_{k-1} - r_k^T r_k \\ \frac{\partial \varphi}{\partial \eta} = \xi r_k^T A p_{k-1} + \eta p_{k-1}^T A p_{k-1} \end{cases}$$

令 $\frac{\partial \varphi}{\partial \xi} = \frac{\partial \varphi}{\partial \eta} = 0$, 知 $\varphi(\xi, \eta)$ 在 π_2 内存在唯一极小点:

$$\tilde{x} = x_k + \xi_0 r_k + \eta_0 p_{k-1}$$

其中 ξ_0, η_0 满足:
$$\begin{cases} \xi_0 r_k^T A r_k + \eta_0 r_k^T A p_{k-1} = r_k^T r_k \\ \xi_0 r_k^T A p_{k-1} + \eta_0 p_{k-1}^T A p_{k-1} = 0 \end{cases}$$

\therefore 当 $r_k \neq 0$ 时 (即 $x_k \neq x^*$), 有 $\xi_0 \neq 0$

\therefore 可取 $p_k = \frac{1}{\xi_0} (\tilde{x} - x_k) = r_k + \frac{\eta_0}{\xi_0} p_{k-1}$ 为新下山方向, 令 $\beta_{k-1} = \frac{\eta_0}{\xi_0} = -\frac{r_k^T A p_{k-1}}{p_{k-1}^T A p_{k-1}}$

此时:

$$x_{k+1} = x_k + \alpha_k p_k$$

其中: $\alpha_k = \frac{(r_k, p_k)}{(p_k, p_k)_A}$

$$x_{k+1} = x_k + \alpha_k p_k$$

$$r_{k+1} = b - A x_{k+1}$$

$$\beta_k = -\frac{r_{k+1}^T A p_k}{p_k^T A p_k}$$

$$p_{k+1} = r_{k+1} + \beta_k p_k$$

➤ 算法2.3(共轭梯度法)

给定容差tol, 任选初值 $x^{(0)}$, 计算 $p^{(0)} = r^{(0)} = b - Ax^{(0)}$

for $k = 1, 2, \dots$

$$\alpha_{k-1} = \frac{(r^{(k-1)}, p^{(k-1)})}{(p^{(k-1)}, p^{(k-1)})_A} = \frac{(r^{(k-1)}, r^{(k-1)})}{(p^{(k-1)}, p^{(k-1)})_A}$$

$$x^{(k)} = x^{(k-1)} + \alpha_{k-1} p^{(k-1)}$$

$$r^{(k)} = r^{(k-1)} - \alpha_{k-1} A p^{(k-1)}$$

如果 $\|r^{(k)}\|_2 / \|b\|_2 < tol$, 则停止

$$\beta_{k-1} = -\frac{(r^{(k)}, p^{(k-1)})_A}{(p^{(k-1)}, p^{(k-1)})_A} = \frac{(r^{(k)}, r^{(k)})}{(r^{(k-1)}, r^{(k-1)})}$$

$$p^{(k)} = r^{(k)} + \beta_{k-1} p^{(k-1)}$$

end

➤ 收敛性 (TH2.6)

共轭梯度法计算的近似解 $x^{(k)}$ 满足

$$\|x^{(k)} - x^*\|_A \leq 2 \left(\frac{\sqrt{\kappa_2} - 1}{\sqrt{\kappa_2} + 1} \right)^k \|x^{(0)} - x^*\|_A \quad \text{其中 } \kappa_2 = \text{cond}_2(A) = \lambda_1 / \lambda_n.$$

➤ Matlab: `[x,Flag,RelRes,Iter] = pcg(A, b, tol, maxit)`