

6.4 共轭梯度法

朱升峰

华东师范大学 数学科学学院

2022 年 12 月

等价问题

共轭梯度法简称 CG (conjugate gradient) 方法, 对应于求一个二次函数的极值.
设 $A = (a_{ij}) \in \mathbb{R}^{n \times n}$ 是对称正定矩阵, $b = (b_1, b_2, \dots, b_n)^T$, 求解线性方程组

$$Ax = b.$$

考虑二次函数 $\varphi : \mathbb{R}^n \rightarrow \mathbb{R}$:

$$\varphi(x) = \frac{1}{2}(Ax, x) - (b, x) = \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n a_{ij} x_i x_j - \sum_{j=1}^n b_j x_j.$$

函数 φ 有如下性质:

(1) 对一切 $x \in \mathbb{R}^n$, $\varphi(x)$ 的梯度

$$\nabla \varphi(x) = Ax - b$$

(2) 对一切 $x, y \in \mathbb{R}^n$ 及 $\alpha \in \mathbb{R}$,

$$\begin{aligned}\varphi(x + \alpha y) &= \frac{1}{2}(A(x + \alpha y), x + \alpha y) - (b, x + \alpha y) \\ &= \varphi(x) + \alpha(Ax - b, y) + \frac{\alpha^2}{2}(Ay, y)\end{aligned}$$

(3) 设 $x^* = A^{-1}b$ 是线性方程组的解, 则有

$$\varphi(x^*) = -\frac{1}{2}(b, A^{-1}b) = -\frac{1}{2}(Ax^*, x^*)$$

且对一切 $x \in \mathbb{R}^n$, 有

$$\begin{aligned}\varphi(x) - \varphi(x^*) &= \frac{1}{2}(Ax, x) - (Ax^*, x) + \frac{1}{2}(Ax^*, x^*) \\ &= \frac{1}{2}(A(x - x^*), x - x^*).\end{aligned}$$

最速下降法

定理 1

设 A 对称正定, 则 x^* 为线性方程组 $Ax = b$ 的解的充分必要条件是 x^* 满足

$$\varphi(x^*) = \min_{x \in \mathbb{R}^n} \varphi(x)$$

由定理可知, 求 $x^* \in \mathbb{R}^n$ 使 $\varphi(x)$ 达到最小值, 这就是求解线性方程组等价的变分问题. 求解方法是构造一个向量序列 $\{x^{(k)}\}$ 使 $\varphi(x^{(k)}) \rightarrow \varphi(x^*)$

最速下降法

通常求 $\varphi(\mathbf{x})$ 的极小点 \mathbf{x}^* 可转化为求一维问题的极小, 即从 $\mathbf{x}^{(0)}$ 出发, 找一个方向 $\mathbf{p}^{(0)}$, 令 $\mathbf{x}^{(1)} = \mathbf{x}^{(0)} + \alpha \mathbf{p}^{(0)}$, 使 $\varphi(\mathbf{x}^{(1)}) = \min_{\alpha \in \mathbb{R}} \varphi(\mathbf{x}^{(0)} + \alpha \mathbf{p}^{(0)})$.

一般地, 令

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

使

$$\varphi(\mathbf{x}^{(k+1)}) = \min_{\alpha \in \mathbb{R}} \varphi(\mathbf{x}^{(k)} + \alpha \mathbf{p}^{(k)})$$

$$\varphi(\mathbf{x}^{(k)} + \alpha \mathbf{p}^{(k)}) = \varphi(\mathbf{x}^{(k)}) + \alpha (\mathbf{A}\mathbf{x}^{(k)} - \mathbf{b}, \mathbf{p}^{(k)}) + \frac{\alpha^2}{2} (\mathbf{A}\mathbf{p}^{(k)}, \mathbf{p}^{(k)})$$

$$\frac{d\varphi(\mathbf{x}^{(k)} + \alpha \mathbf{p}^{(k)})}{d\alpha} = (\mathbf{A}\mathbf{x}^{(k)} - \mathbf{b}, \mathbf{p}^{(k)}) + \alpha (\mathbf{A}\mathbf{p}^{(k)}, \mathbf{p}^{(k)}) = 0$$

于是可得

$$\alpha_k = -\frac{(\mathbf{A}\mathbf{x}^{(k)} - \mathbf{b}, \mathbf{p}^{(k)})}{(\mathbf{A}\mathbf{p}^{(k)}, \mathbf{p}^{(k)})}, \quad (2)$$

样得到的 α_k 显然满足

$$\varphi\left(\mathbf{x}^{(k)} + \alpha_k \mathbf{p}^{(k)}\right) \leq \varphi\left(\mathbf{x}^{(k)} + \alpha \mathbf{p}^{(k)}\right), \quad \forall \alpha \in \mathbb{R},$$

这就是求 $\varphi(x)$ 极小点的下降算法, 这里 $\mathbf{p}^{(k)}$ 是任选的一个方向, 如果我们选一个方向 $\mathbf{p}^{(k)}$ 使 $\varphi(x)$ 在点 $\mathbf{x}^{(k)}$ 沿 $\mathbf{p}^{(k)}$ 下降最快, 从 $\mathbf{x}^{(k)}$ 出发, 先找一个使函数值 $\varphi(x)$ 减少最快的方向, 这就是正交于椭球面的函数 $\varphi(x)$ 的负梯度方向

$$-\nabla \varphi\left(\mathbf{x}^{(k)}\right) = -\left(\frac{\partial \varphi\left(\mathbf{x}^{(k)}\right)}{\partial x_1}, \frac{\partial \varphi\left(\mathbf{x}^{(k)}\right)}{\partial x_2}, \dots, \frac{\partial \varphi\left(\mathbf{x}^{(k)}\right)}{\partial x_n}\right)^T$$

由 $\nabla \varphi(x) = \mathbf{A}x^{(k)} - \mathbf{b}$ 有

$$\mathbf{p}^{(k)} = -\nabla \varphi\left(\mathbf{x}^{(k)}\right) = -(\mathbf{A}x^{(k)} - \mathbf{b}) = \mathbf{r}^{(k)}.$$

α_k 的计算公式

$$\alpha_k = \frac{(\mathbf{r}^{(k)}, \mathbf{r}^{(k)})}{(\mathbf{A}\mathbf{r}^{(k)}, \mathbf{r}^{(k)})}, \tag{3}$$

最速下降法

于是

$$\mathbf{x}^{(k+1)} = \mathbf{x}^{(k)} + \alpha_k \mathbf{r}^{(k)}, \quad k = 0, 1, \dots, \quad (4)$$

其中 $\mathbf{r}^{(k)} = \mathbf{b} - \mathbf{A}\mathbf{x}^{(k)}$ 为剩余向量. 由 (3) 式和(4)式计算得到的向量序列 $\{\mathbf{x}^{(k)}\}$ 称为解线性方程组的**最速下降法**. 由于

$$\begin{aligned} (\mathbf{r}^{(k+1)}, \mathbf{r}^{(k)}) &= \left(\mathbf{b} - \mathbf{A}\left(\mathbf{x}^{(k)} + \alpha_k \mathbf{r}^{(k)}\right), \mathbf{r}^{(k)}\right) \\ &= (\mathbf{r}^{(k)}, \mathbf{r}^{(k)}) - \alpha_k (\mathbf{A}\mathbf{r}^{(k)}, \mathbf{r}^{(k)}) \\ &= 0, \end{aligned}$$

说明两个相邻的搜索方向是正交的.

最速下降法

还可证明由(3)式和(4)式得到的 $\{\varphi(\mathbf{x}^{(k)})\}$ 是单调下降有下界的序列, 它存在极限, 满足

$$\lim_{k \rightarrow \infty} \mathbf{x}^{(k)} = \mathbf{x}^* = \mathbf{A}^{-1} \mathbf{b}$$

而且

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

其中 λ_1, λ_n 分别为对称正定矩阵 \mathbf{A} 的最大与最小特征值. $\|\mathbf{u}\|_A = (\mathbf{A}\mathbf{u}, \mathbf{u})^{\frac{1}{2}}$,
当 $\lambda_1 \gg \lambda_2$, 时收敛是很慢的, 而且当 $\|\mathbf{r}^{(k)}\|$ 很小时, 由于舍入误差影响, 计算
将出现不稳定, 这个算法实际中很少使用, 需要寻找对整体而言下降更快的算
法.

共轭梯度法

CG 方法是一种求解大型稀疏对称正定方程组十分有效的方法. 仍然选择一组搜索方向 $p^{(0)}, p^{(1)}, \dots$. 但它不再是具有正交性的 $r^{(0)}, r^{(1)}, \dots$ 方向. 如果按方向 $p^{(0)}, p^{(1)}, \dots, p^{(k-1)}$ 已进行 k 次一维搜索, 求得 $x^{(k)}$, 下一步确定 $p^{(k)}$ 方向能使 $x^{(k+1)}$ 更快地求得 x^* , 在 $p^{(k)}$ 确定后. 仍按(1)式和(2)式的下降算法求得 α_k , 若已算出 $x^{(k)}$ (不失一般性设 $x^{(0)} = \mathbf{0}$), 则由(1)式有

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

$$\mathbf{x}^{(k)} = \alpha_0 \mathbf{p}^{(0)} + \alpha_1 \mathbf{p}^{(1)} + \cdots + \alpha_{k-1} \mathbf{p}^{(k-1)}$$

开始可取 $\mathbf{p}^{(0)} = \mathbf{r}^{(0)}$, 当 $k \geq 1$ 时确定 $\mathbf{p}^{(k)}$ 除了使

$$\varphi\left(\mathbf{x}^{(k+1)}\right) = \min_{\alpha} \varphi(\mathbf{x}^{(k)} + \alpha \mathbf{p}^{(k)})$$

还希望 $\{p^{(k)}\}$ 的选择使

$$\varphi(\mathbf{x}^{(k+1)}) = \min_{x \in \text{span}(p^{(0)}, p^{(1)}, \dots, p^{(k)})} \varphi(x), \quad (5)$$

这里 $x \in \text{span}\{p^{(0)}, p^{(1)}, \dots, p^{(k)}\}$ 可表示为

$$x = \mathbf{y} + \alpha p^{(k)}, \quad \mathbf{y} \in \text{span}\{p^{(0)}, p^{(1)}, \dots, p^{(k-1)}\}, \quad \alpha \in \mathbb{R}. \quad (6)$$

所以有

$$\varphi(x) = \varphi(\mathbf{y} + \alpha p^{(k)}) = \varphi(\mathbf{y}) + \alpha(\mathbf{A}\mathbf{y}, p^{(k)}) - \alpha(\mathbf{b}, p^{(k)}) + \frac{\alpha^2}{2}(\mathbf{A}p^{(k)}, p^{(k)}) \quad (7)$$

(6)式表示在 y 已确定的情况下, 选 $p^{(k)}$ 使 x 在整个空间 $\{p^{(0)}, p^{(1)}, \dots, p^{(k)}\}$ 中小, 为了使 (5)式极小化, 需要对 α 及 y 分别求极小.

在(7)式中出现的“交叉项” $(A\mathbf{y}, \mathbf{p}^{(k)})$ 必须令它为0,即

$$(A\mathbf{y}, \mathbf{p}^{(k)}) = 0, \quad \forall \mathbf{y} \in \text{span} \left\{ \mathbf{p}^{(0)}, \mathbf{p}^{(1)}, \dots, \mathbf{p}^{(k-1)} \right\},$$

也就是 $(A\mathbf{p}^{(j)}, \mathbf{p}^{(k)}) = 0, \quad j = 0, 1, \dots, k-1.$

如果对 $k = 1, 2, \dots$ 每步都如此选择 $\mathbf{p}^{(k)}$, 则它符合以下定义.

定义 2

设 A 对称正定, 若 \mathbb{R}^n 中向量组 $\{\mathbf{p}^{(0)}, \mathbf{p}^{(1)}, \dots, \mathbf{p}^{(m)}\}$ 满足

$$(A\mathbf{p}^{(i)}, \mathbf{p}^{(j)}) = 0, \quad i \neq j, i, j = 0, 1, \dots, m,$$

则称它为 \mathbb{R}^n 中一个 A -共轭向量组或称 A -正交向量组.

显然, 当 $m < n$ 时, 不含零向量的 A -共轭向量组线性无关, 当 $A = I$ 时 A -共轭性就是一般的正交性.

若取 $\{p^{(0)}, p^{(1)}, \dots\}$ 是 A -共轭的, 考虑(5)式的解, $p^{(k)}$ 使 (7)式中 $(Ay, p^{(k)}) = 0$ 于是问题 (5) 可分离为两个极小问题, 由 (7)式可得

$$\begin{aligned} \min_{x \in \text{span}\{p^{(0)}, p^{(1)}, \dots, p^{(k)}\}} \varphi(x) &= \min_{\alpha, y} \varphi(y + \alpha p^{(k)}) \\ &= \min_y \varphi(y) + \min_{\alpha} \left[\frac{\alpha^2}{2} (Ap^{(k)}, p^{(k)}) + \alpha(Ay, p^{(k)}) - \alpha(b, p^{(k)}) \right] \end{aligned}$$

第一个极小 $y \in \text{span}\{p^{(0)}, p^{(1)}, \dots, p^{(k-1)}\}$ 的解 $y = x^{(k)}$

第二个极小就是 (1)式的极小, 由 $r^{(k)} = b - Ax^{(k)}$ 及 (2)式得

$$\alpha_k = \frac{(r^{(k)}, p^{(k)})}{(Ap^{(k)}, p^{(k)})} \quad (8)$$

CG 法中向量组 $\{p^{(0)}, p^{(1)}, \dots\}$ 的选择, 可令 $p^{(0)} = r^{(0)}$, $p^{(k)}$ 选为 $p^{(0)}, p^{(1)}, \dots, p^{(k-1)}$ 的 A -轭, 它并不唯一, 可选为 $r^{(k)}$ 与 $p^{(k-1)}$ 的线性组合, 不妨设

$$p^{(k)} = r^{(k)} + \beta_{k-1} p^{(k-1)}, \quad (9)$$

利用 $(p^{(k)}, Ap^{k-1}) = 0$, 可定出

$$\beta_{k-1} = -\frac{(r^{(k)}, Ap^{(k-1)})}{(p^{(k-1)}, Ap^{(k-1)})}, \quad (10)$$

这样由(9)式和(10)式得到的 $p^{(k)}$ 与 $p^{(k-1)}$ 是 A -共轭的.

根据以上分析, 取 $x^{(0)} \in \mathbb{R}^n$, $r^{(0)} = b - Ax^{(0)}$, $p^{(0)} = r^{(0)}$ 可按(1) 式和(8) 式求得 $\alpha_0, x^{(1)}$, 再由(9) 式和 (10)式求得 $\beta_0, p^{(1)}$, 从而可得到序列 $\{x^{(k)}\}$, 这就是 CG 算法.

下面对(8)式作进一步简化. 由

$$\mathbf{r}^{(k+1)} = \mathbf{b} - \mathbf{A}\mathbf{x}^{(k+1)} = \mathbf{r}^{(k)} - \alpha_k \mathbf{A}\mathbf{p}^{(k)} \quad (11)$$

有

$$\begin{aligned} (\mathbf{r}^{(k+1)}, \mathbf{p}^{(k)}) &= (\mathbf{r}^{(k)}, \mathbf{p}^{(k)}) - \alpha_k (\mathbf{A}\mathbf{p}^{(k)}, \mathbf{p}^{(k)}) = 0 \\ (\mathbf{r}^{(k)}, \mathbf{p}^{(k)}) &= (\mathbf{r}^{(k)}, \mathbf{r}^{(k)} + \beta_{k-1} \mathbf{p}^{(k-1)}) = (\mathbf{r}^{(k)}, \mathbf{r}^{(k)}) \end{aligned}$$

再代回(8), 有

$$\alpha_k = \frac{(\mathbf{r}^{(k)}, \mathbf{r}^{(k)})}{(\mathbf{p}^{(k)}, \mathbf{A}\mathbf{p}^{(k)})} \quad (12)$$

由此看出, 当 $\mathbf{r}^{(k)} \neq \mathbf{0}$ 时, $\alpha_k > 0$.

定理 3

由(1)式、(9)-(12)式组成的CG算法得到的序列 $\{r^{(k)}\}$ 及 $\{p^{(k)}\}$ 以下性质:

(1) $(r^{(i)}, r^{(j)}) = 0(i \neq j)$, 即 $\{r^{(k)}\}$ 构成 \mathbb{R}^n 中的正交向量组.

(2) $(Ap^{(i)}, p^{(j)}) = (p^{(i)}, Ap^{(j)}) = 0(i \neq j)$, 即 $\{p^{(k)}\}$ 为一个 A -共轭向量组.

根据定理的证明还可化简 β_k 的计算, 由(10)

$$\begin{aligned}\beta_k &= -\frac{(r^{(k+1)}, Ap^{(k)})}{(p^{(k)}, Ap^{(k)})} = \frac{-(r^{(k+1)}, \alpha_k^{-1}(r^{(k)} - r^{(k+1)}))}{(r^{(k)} + \beta_{k-1}p^{(k-1)}, Ap^{(k)})} \\ &= \frac{(r^{(k+1)}, r^{(k+1)})}{\alpha_k(r^{(k)}, Ap^{(k)})} = \frac{(r^{(k+1)}, r^{(k+1)})}{(r^{(k)}, r^{(k)})}.\end{aligned}\tag{13}$$

此可见, 若 $r^{(k+1)} \neq \mathbf{0}$, 则 $\beta_k > 0$. 根据(4.17)式和(4.18)式可将CG算法归纳如下.

CG 算法

(1) 任取 $x^{(0)} \in \mathbb{R}^n$, 计算 $r^{(0)} = b - Ax^{(0)}$, 取 $p^{(0)} = r^{(0)}$.

(2) 对 $k = 0, 1, \dots$, 计算

$$\alpha_k = \frac{(r^{(k)}, r^{(k)})}{(p^{(k)}, Ap^{(k)})}$$

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

$$r^{(k+1)} = r^{(k)} - \alpha_k Ap^{(k)}, \beta_k = \frac{(r^{(k+1)}, r^{(k+1)})}{(r^{(k)}, r^{(k)})}$$

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

(3) 若 $r^{(k)} = \mathbf{0}$, 或 $(p^{(k)}, Ap^{(k)}) = 0$, 计算停止, 则 $x^{(k)} = x^*$. 由于 A 正定, 故当 $(p^{(k)}, Ap^{(k)}) = 0$ 时, $p^{(k)} = \mathbf{0}$, 而 $(r^{(k)}, r^{(k)}) = (r^{(k)}, p^{(k)}) = 0$, 也即 $r^{(k)} = \mathbf{0}$.

例

例 用 CG 法解线性方程组

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

解 显然 $A = \begin{pmatrix} 3 & 1 \\ 1 & 2 \end{pmatrix}$ 是对称正定的. 取 $\mathbf{x}^{(0)} = (0, 0)^T$, 则
 $\mathbf{p}^{(0)} = \mathbf{r}^{(0)} = \mathbf{b} - A\mathbf{x}^{(0)} = (5, 5)^T$

$$\alpha_0 = \frac{(\mathbf{r}^{(0)}, \mathbf{p}^{(0)})}{(\mathbf{A}\mathbf{p}^{(0)}, \mathbf{p}^{(0)})} = \frac{2}{7}$$

$$\mathbf{x}^{(1)} = \mathbf{x}^{(0)} + \alpha_0 \mathbf{p}^{(0)} = \left(\frac{10}{7}, \frac{10}{7} \right)^T$$

$$\mathbf{r}^{(1)} = \mathbf{r}^{(0)} - \alpha_0 \mathbf{A} \mathbf{p}^{(0)} = \left(-\frac{5}{7}, \frac{5}{7} \right)^T$$

$$\beta_0 = \frac{(\mathbf{r}^{(1)}, \mathbf{r}^{(1)})}{(\mathbf{r}^{(0)}, \mathbf{r}^{(0)})} = \frac{1}{49}$$

$$\mathbf{p}^{(1)} = \mathbf{r}^{(1)} + \beta_0 \mathbf{p}^{(0)} = \left(-\frac{30}{49}, \frac{40}{49} \right)^T$$

类似可以算出 $\alpha_1 = \frac{7}{10}$, $\mathbf{x}^{(2)} = (1, 2)^T$ 为方程的解.