

求函数极小点的记忆梯度法

蔡火萤

(数学系)

记忆梯度法是共轭梯度法的推广和改进,它存在很多优点,是一个值得重视的算法。不过在它的每一迭代步中,都要作一次二维搜索。以往处理这个问题,常常采用牛顿法^[1],由于牛顿法对初值要求十分苛刻^[3],在实用上很不理想。本文提出一类函数的极值问题,在使用记忆梯度法求解时,采用线性化方法处理二维搜索问题,获得较好的计算效果。

假设 $f: D \subset R^n \rightarrow R^1$ 在凸集合 $D_0 \subset D$ 上二次连续可微,并且它的 Hessian 矩阵 $H(X)$ 在 D_0 上的全局极小点 X^* , 即 $f(X^*) = \min_{X \in D_0} f(X)$ 。

今于 D_0 上适当取出一个初始近似点 $X_0 \in D_0$, 并按最速下降法求出它的第一个近似点 X_1 。即:

$$\begin{aligned} X_1 &= X_0 + \omega_0 p_0 \\ p_0 &= -\nabla f(X_0) \\ \omega_0 &: \min_{\omega} f(X_0 + \omega p_0) \end{aligned}$$

然后再按下列方法求出它的第二个近似点 X_2 。

$$\begin{aligned} X_2 &= X_1 - \omega_0^{(1)} \nabla f(X_1) + \omega_1^{(1)} \Delta X_0 \\ \Delta X_0 &= X_1 - X_0 \\ \omega_0^{(1)}, \omega_1^{(1)} &: \min_{\omega_0, \omega_1} f[X_1 - \omega_0 \nabla f(X_1) + \omega_1 \Delta X_0] \end{aligned}$$

一般地当 X_1, X_2, \dots, X_K 被求出之后 ($K \geq 1$), 便可以按如下方式求出:

$$\left. \begin{aligned} X_{K+1} &= X_K - \omega_0^{(K)} \nabla f(X_K) + \omega_1^{(K)} \Delta X_{K-1} \\ \Delta X_{K-1} &= X_K - X_{K-1} \\ \omega_0^{(K)}, \omega_1^{(K)} &: \min_{\omega_0, \omega_1} f(X_K - \omega_0 \nabla f(X_K) + \omega_1 \Delta X_{K-1}) \end{aligned} \right\} \quad (1)$$

在我们的假设下关系式(1)等价于方程组^[1]

$$\left. \begin{aligned} \nabla f(X_{K+1})^T \nabla f(X_K) &= 0 \\ \nabla f(X_{K+1})^T \Delta X_{K-1} &= 0 \end{aligned} \right\} \quad (2)$$

进而推知:

$$\nabla f(X_{K+1})^T \Delta X_K = 0$$

在 $\nabla f(X_{K+1}) \neq 0$ 的情况下, $\nabla f(X_{K+1})$ 与 ΔX_K 线性无关.

下面我们采用线性化的方法求解(2)式. 因为:

$$\begin{aligned}\nabla f(X_{K+1}) &= \nabla f(X_K + \Delta X_K) \\ &= \nabla f(X_K) + H(X_K) \Delta X_K + \dots \\ &\approx \nabla f(X_K) + H(X_K) \left[-\omega_0^{(K)} \nabla f(X_K) + \omega_1^{(K)} \Delta X_{K-1} \right] \\ &= \nabla f(X_K) - \omega_0^{(K)} H(X_K) \nabla f(X_K) + \omega_1^{(K)} H(X_K) \Delta X_{K-1}\end{aligned}$$

所以我们得到近似线性方程组:

$$\left. \begin{aligned}\Delta f(X_K)^T \nabla f(X_K) - \omega_0^{(K)} \nabla f(X_K)^T H(X_K) \nabla f(X_K) \\ + \omega_1^{(K)} \nabla f(X_K)^T H(X_K) \Delta X_{K-1} &= 0 \\ \Delta X_{K-1}^T \nabla f(X_K) - \omega_0^{(K)} \Delta X_{K-1}^T H(X_K) \nabla f(X_K) \\ + \omega_1^{(K)} \Delta X_{K-1}^T H(X_K) \Delta X_{K-1} &= 0\end{aligned}\right\} \quad (3)$$

因为 $\nabla f(X_K)$ 与 ΔX_{K-1} 线性无关, 所以(3)式的系数行列式为 $-\Delta^{(K)}$, 其中:

$$\begin{aligned}\Delta^{(K)} &= \begin{bmatrix} \nabla f(X_K)^T H(X_K) \nabla f(X_K) \\ \Delta X_{K-1}^T H(X_K) \Delta X_{K-1} \end{bmatrix} \\ &\quad - \begin{bmatrix} \nabla f(X_K)^T H(X_K) \Delta X_{K-1} \end{bmatrix}^2 > 0^{[2]}\end{aligned}$$

因此(3)式有唯一解:

$$\begin{aligned}\omega_0^{(K)} &= \frac{1}{\Delta^{(K)}} \|\nabla f(X_K)\|_2^2 \left[\Delta X_{K-1}^T H(X_K) \Delta X_{K-1} \right] \\ \omega_1^{(K)} &= \frac{1}{\Delta^{(K)}} \|\Delta f(X_K)\|_2^2 \left[\nabla f(X_K)^T H(X_K) \Delta X_{K-1} \right]\end{aligned}$$

下面我们要证明的这样求出的二维搜索因子, 保证目标函数下降, 事实上因为:

$$f(X_{K+1}) - f(X_K) = \nabla f(X_K)^T \Delta X_K + \dots$$

略去高价微量, 得到:

$$\begin{aligned}f(X_{K+1}) - f(X_K) &= \nabla f(X_K)^T \left[-\omega_0^{(K)} \nabla f(X_K) + \omega_1^{(K)} \Delta X_{K-1} \right] \\ &= -\omega_0^{(K)} \|\nabla f(X_K)\|_2^2 < 0\end{aligned}$$

$$\therefore f(X_{K+1}) < f(X_K)$$

将上述算法归结成如下计算步骤:

1. 给出初值 X_0 及允许误差 $\varepsilon > 0$.
2. 计算:

$$P_0 = -\nabla f(X_0)$$

$$\omega_0 = \min_{\omega} f(X_0 + \omega P_0)$$

$$X_1 = X_0 + \omega_0 P_0$$

3. 假设已经求出 X_1, X_2, \dots, X_K ($K \geq 1$).

计算:

$$X_{K+1} = X_K - \omega_0^{(K)} \nabla f(X_K) + \omega_1^{(K)} \Delta X_{K-1}$$

$$\Delta X_{K-1} = X_K - X_{K-1}$$

$$\omega_0^{(K)} = \frac{1}{\|\Delta^{(K)}\|} \|\nabla f(X_K)\|_2 \left[\Delta X_{K-1}^T H(X_K) \Delta X_{K-1} \right]$$

$$\omega_1^{(K)} = \frac{1}{\|\Delta^{(K)}\|} \|\nabla f(X_K)\|_2 \left[\nabla f(X_K)^T H(X_K) \Delta X_{K-1} \right]$$

$$\Delta^{(K)} = \left[\nabla f(X_K)^T H(X_K) \nabla f(X_K) \right] \left[\Delta X_{K-1}^T H(X_K) \Delta X_{K-1} \right] - \left[\nabla f(X_K)^T H(X_K) \Delta X_{K-1} \right]^2$$

4. 检查精度及判别转移.

如果 $\|\nabla f(X_{K+1})\|_2 \leq \varepsilon$, 则停机, 并以 X_{K+1} 作为 X^* 满足精度要求的近似值. 否则, 如果 $K+1 < n$, 则将 X_{K+1} 代替 X_K , 并且转去执行 3.

如果 $K+1 = n$, 则用 X_{K+1} 代替 X_0 实行再开始过程, 并且转去执行 2.

算例: 将这个算法用于求目标函数为:

$$\begin{aligned} f(x_1, x_2, x_3, x_4) = & 100(x_1^2 - x_2)^2 + (x_1 - 1)^2 + (x_3 - 1)^2 \\ & + 90(x_3^2 - x_4^2 + 10.1 \left[(x_2 - 1)^2 + (x_4 - 1)^2 \right] \\ & + 19.8(x_2 - 1)(x_4 - 1) \end{aligned}$$

的极小问题时, 从任意点 X_0 出发, 利用最速下降法求前 K 个近似点, 使 $\|\nabla f(X_K)\|_2 \leq 1.0$, 然后再从 X_K 出发, 按上述算法进行迭代只须 40 次左右便可达到 $\|\nabla f(X_{K+40})\|_2 \leq 10^{-4}$. 而在同样情况下, 采用 F—R 共轭梯度法, 则须迭代 100 次左右, 才能达到同样效果. 我们这样处理二维搜索问题, 不仅保证目标函数严格下降, 同时易证迭代收敛, 并且编制程序简单, 实用方便.

参 考 文 献

- [1] 王德人, 非线性方程组解法与最优化方法, 人民教育出版社, (1982).
- [2] 北京大学编, 高等代数, 人民教育出版社, (1978).
- [3] Б. П. Демидович и И. А. Марон, Основы вычислительной математики, Государственное издательство физико-математической литературы М., (1963).