

# 一种新参数下的记忆梯度算法<sup>①</sup>

公锦凤, 于宪伟

渤海大学 数学系, 辽宁 锦州 121000

**摘要:** 提出了一种记忆梯度法的主要参数的新形式, 分析了该算法在 Wolfe-Powell 搜索下的全局收敛性和线性收敛速度.

**关键词:** 记忆梯度法; Wolfe-Powell 线性搜索; 收敛性

**中图分类号:** O224

**文献标识码:** A

共轭梯度法是求解无约束优化问题  $\min_{x \in \mathbb{R}^n} f(x)$  的一种重要方法. 标准共轭梯度法的迭代格式如下:

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

$$d_k = \begin{cases} -g_k & k = 1, \\ -g_k + \beta_k d_{k-1} & k \geq 2 \end{cases}$$

其中:  $\alpha_k$  是由某种线性搜索获得的步长因子,  $d_k$  是第  $k$  次迭代时的搜索方向,  $g_k$  表示  $f(x)$  在  $x_k$  处的梯度  $\nabla f(x)$ , 参数  $\beta_k$  的常见形式有  $\beta_k^{\text{PRP}}$ ,  $\beta_k^{\text{HS}}$ ,  $\beta_k^{\text{DY}}$ ,  $\beta_k^{\text{LS}}$  等<sup>[1]</sup>. 但是很多共轭梯度法对一般非线性函数来说不具有全局收敛性, 为了保证算法具有全局收敛性, 人们提出了记忆梯度算法<sup>[2]</sup>.

记忆梯度算法的每步迭代中不需要计算和存储矩阵, 因而适于解决大型优化问题. 步长  $\alpha_k$  的选择也有很多种, 大体可分为精确搜索和非精确搜索规则. 在非精确搜索步长规则中, 具有代表性的是 Armijo-Goldstein 准则和 Wolfe-Powell 准则<sup>[3,4]</sup>.

Wolfe-Powell 步长规则为: 在第  $k$  次迭代中选择步长  $\alpha_k$  满足

$$\begin{cases} f(x_k + \alpha_k d_k) \leq f(x_k) + \mu \alpha_k g_k^T d_k \\ g_{k+1}^T d_k \geq \sigma g_k^T d_k \end{cases}$$

其中  $\mu \in (0, \frac{1}{2})$ ,  $\sigma \in (\mu, 1)$ .

为了改进算法的性能, 以便求解大型无约束优化问题, 提出一种新参数下的记忆梯度算法, 并对 Wolfe-Powell 线性搜索下该算法的全局收敛性和线性收敛速度进行了分析.

为了简便记  $f(x_k) = f_k$ ,  $g(x_k) = g_k$ .

## 1 新参数下的记忆梯度算法描述

算法中各参数设置为:  $\rho \in (0, 1)$ ,  $\mu \in (0, \frac{1}{2})$ ,  $\sigma \in (\mu, 1)$

Step 1 令  $k := 1$ , 若  $\|g(k)\| = 0$ , 则终止, 否则转下一步;

Step 2 令  $x_{k+1} = x_k + \alpha_k d_k(\beta_k)$

① 收稿日期: 2007-04-28

基金项目: 辽宁省教育厅基金资助项目(2006018).

作者简介: 公锦凤(1982-), 女, 山东蒙阴人, 硕士研究生, 主要从事最优化理论与算法研究.

其中:

$$d_k(\beta_k) = \begin{cases} -g_k & k = 1 \\ -[(1-\beta_k)g_k + \beta_k g_{k-1}] & k \geq 2 \end{cases}, \beta_k \in [0, s_k], s_k = \begin{cases} \rho/2 & k = 1 \\ \rho \|g_k\|^2 / [\|g_k\|^2 + |g_k^T g_{k-1}|] & k \geq 2 \end{cases}$$

$\alpha_k$  由 Wolfe-Powell 搜索规则确定;

Step 3  $k := k + 1$ , 转 Step 1.

## 2 算法收敛性研究

为了证明算法的收敛性, 需要如下几个引理.

**引理 1** 对  $k \geq 1$ ,  $g_k^T d_k \leq -(1-\rho) \|g_k\|^2$ .

**证** 若  $k = 1$ , 则  $g_k^T d_k = g_k^T \cdot -g_k = -\|g_k\|^2 \leq -(1-\rho) \|g_k\|^2$ ;

若  $k \geq 2$ , 则  $-g_k^T d_k = g_k^T \cdot [(1-\beta_k)g_k + \beta_k g_{k-1}] \geq \|g_k\|^2 - \beta_k (\|g_k\|^2 + |g_k^T g_{k-1}|)$ ,

而  $\beta_k \in [0, s_k] \geq \|g_k\|^2 - \rho \|g_k\|^2 = (1-\rho) \|g_k\|^2$ . 证毕.

**引理 2** 对  $k \geq 2$ ,  $\|d_k\|^2 \leq \delta_k^2$ , 其中  $\delta_k = \max_{1 \leq i \leq k} \{ \|g_i\| \}$ .

**证** 由  $\varphi(x) = \|x\|^2 (x \in R^n)$  为凸函数及  $\beta_k \in [0, 1]$  知  $\|d_k\|^2 = \|(1-\beta_k)g_k + \beta_k g_{k-1}\|^2 \leq (1-\beta_k) \|g_k\|^2 + \beta_k \|g_{k-1}\|^2 \leq \max(\|g_k\|^2, \|g_{k-1}\|^2) = \delta_k^2$ .

设定如下假设:

(i) 目标函数  $f(x)$  在水平集  $L_0 = \{x \in R^n \mid f(x) \leq f(x_0)\}$  上有界.

(ii)  $f(x)$  为二次连续可微的凸函数,  $g(x) = \nabla f(x)$  在包含  $L_0$  的开凸集上 Lipschitz 连续,  $f(x)$  具有唯一极小点  $x^*$ , 且存在  $0 < m \leq M$ , 对下列各式成立:

$$\frac{1}{2} m \|x - x^*\|^2 \leq f(x) - f(x^*) \leq \frac{1}{2} M \|x - x^*\|^2, \forall x \in R^n \tag{1}$$

$$m \|x - y\|^2 \leq (g(x) - g(y))^T (x - y) \leq M \|x - y\|^2, \forall x, y \in R^n \tag{2}$$

$$\|g(x) - g(y)\| \leq M \|x - y\|, \forall x, y \in B;$$

此时  $L = M$ . 利用 Cauchy-Schwartz 不等式和 (2) 可得

$$m \|x - x^*\| \leq \|g(x)\| \leq M \|x - x^*\| \tag{3}$$

**引理 3** 若假设 (ii) 成立, 则  $\alpha_k \geq \frac{-(1-\sigma)g_k^T d_k}{L \|d_k\|^2}$ .

**证** 由 Cauchy-Schwartz 不等式和 Wolfe-Powell 步长规则可得

$$\alpha_k L \|d_k\|^2 \geq \|g(x_k + \alpha_k d_k) - g_k\| \cdot \|d_k\| \geq [g(x_k + \alpha_k d_k) - g_k]^T \cdot d_k$$

即  $\alpha_k \geq \frac{-(1-\sigma)g_k^T d_k}{L \|d_k\|^2}$ , 证毕.

**定理 1** 若 (i)(ii) 成立, 算法产生无穷点列  $\{x_k\}$ , 则

$$\sum_{k=2}^{\infty} \frac{\|g_k\|^2}{\max\left\{1, \frac{\|g_{k-1}\|^2}{\|g_k\|^2}\right\}} < +\infty \tag{4}$$

**证** 由 Wolfe-Powell 搜索规则以及引理 1, 2, 3 知

$$\begin{aligned} f_k - f_{k+1} &\geq -\alpha_k \mu g_k^T d_k \geq \frac{(1-\sigma)g_k^T d_k}{L \|d_k\|^2} \mu \cdot g_k^T d_k \geq \frac{\mu(1-\sigma)(g_k^T d_k)^2}{L \cdot \max\{\|g_k\|^2, \|g_{k-1}\|^2\}} \\ &\geq \frac{\mu(1-\sigma)}{L} \cdot \frac{(1-\rho)^2 \|g_k\|^4}{\max\{\|g_k\|^2, \|g_{k-1}\|^2\}} \geq \frac{\mu(1-\sigma)(1-\rho)^2}{L} \cdot \frac{\|g_k\|^2}{\max\left\{1, \frac{\|g_{k-1}\|^2}{\|g_k\|^2}\right\}} \end{aligned}$$

因  $\{f_k\}$  为单调下降数列且有界, 则其必有极限, 因此 (4) 式成立.

**推论** 由定理 1 可得  $\sum_{k=2}^{\infty} \frac{\|g_k\|^4}{\delta_k^2} < +\infty$ , 其中  $\delta_k = \max_{1 \leq i \leq k} \{ \|g_i\| \}$ .

**定理 2** 若 (i)(ii) 成立, 算法产生无穷点列  $\{x_k\}$ , 则  $\lim_{k \rightarrow \infty} \|g_k\| = 0$ .

证 首先证明  $\{\|g_k\|\}$  有界.

反证, 若  $\{\|g_k\|\}$  无界, 则  $\delta_k = \max_{1 \leq i \leq k} \{\|g_i\|\} \rightarrow \infty, k \rightarrow \infty$ , 因而必存在无穷子集  $N$ , 对  $\forall k \in N$  满足

$$\|g_k\| = \delta_k \quad (5)$$

且

$$\|g_k\| \rightarrow \infty, k \in N, k \rightarrow \infty \quad (6)$$

由(5)式知  $\sum_{k \in N} \|g_k\|^2 = \sum_{k \in N} \frac{\|g_k\|^4}{\delta_k^2} \leq \sum_{k=2} \frac{\|g_k\|^4}{\delta_k^2} < +\infty$ , 即  $\sum_{k \in N} \|g_k\|^2 < +\infty$ , 其中  $N$  为无穷集. 从而  $\|g_k\| \rightarrow 0, k \in N, k \rightarrow \infty$ . 这与(6)式矛盾, 因此  $\{\|g_k\|\}$  必有界, 不妨设为  $M'$ , 即  $\delta_k \leq M'$ . 由定理

1 的推论可得  $\sum_{k=2}^{\infty} \frac{\|g_k\|^4}{\delta_k^2} < +\infty$ , 其中  $\delta_k = \max_{1 \leq i \leq k} \{\|g_i\|\}$ , 故  $\sum_{k=2}^{\infty} \frac{\|g_k\|^4}{M'} \leq \sum_{k=2}^{\infty} \frac{\|g_k\|^4}{\delta_k^2}$ , 所以  $\lim_{k \rightarrow \infty} \|g_k\| = 0$ .

证毕.

**定理 3** 若假设 (ii) 成立, 算法产生无穷点列  $\{x_k\}$ , 则  $\{x_k\} \rightarrow x^*$ , 其中  $x^*$  是  $f(x)$  的唯一极小点, 而且

$$R_1 = \limsup_{k \rightarrow \infty} \|x_{k+1} - x^*\|^{\frac{1}{k}} < 1.$$

证 由定理 1 的证明可知

$$f_k - f_{k+1} \geq \frac{\mu(1-\sigma)(1-\rho)^2}{L} \cdot \frac{\|g_k\|^2}{\max\left\{1, \frac{\|g_{k-1}\|^2}{\|g_k\|^2}\right\}}$$

记  $\xi = \frac{\mu(1-\sigma)(1-\rho)^2}{L} \cdot \frac{\|g_k\|^2}{\max\left\{1, \frac{\|g_{k-1}\|^2}{\|g_k\|^2}\right\}}$ , 则  $f_k - f_{k+1} \geq \xi \|g_k\|^2$ .

由式(1), (3) 可得  $f_k - f_{k+1} \geq \xi \|g_k\|^2 \geq \xi m^2 \|x_k - x^*\|^2 \geq \frac{2\xi m^2 (f_k - f^*)}{M}$ . 记  $\theta = \frac{2\xi m^2}{M}$ , 则

$$f_k - f_{k+1} \geq \theta (f_k - f^*) \quad (7)$$

由  $\theta = \frac{2\xi m^2}{M} = \frac{2m^2\mu}{ML \max\left\{1, \frac{\|g_{k-1}\|^2}{\|g_k\|^2}\right\}} \cdot (1-\sigma)(1-\rho)^2 \leq (1-\sigma)(1-\rho)^2$  可知  $\theta < 1$ .

由(7)式知  $f_{k+1} - f^* \leq (1-\theta)(f_k - f^*) \leq \dots \leq (1-\theta)^k (f_1 - f^*)$ , 再由(1)式可得  $\|x_{k+1} - x^*\|^2 \leq \frac{2}{m} (f_{k+1} - f^*) \leq (1-\theta)^k \frac{2(f_1 - f^*)}{m}$ , 从而

$$\|x_{k+1} - x^*\| \leq (1-\theta)^{\frac{k}{2}} \cdot \sqrt{\frac{2(f_1 - f^*)}{m}},$$

$$\limsup_{k \rightarrow \infty} \|x_{k+1} - x^*\|^{\frac{1}{k}} \leq \lim_{k \rightarrow \infty} (1-\theta)^{\frac{1}{2}} \cdot \sqrt[2k]{\frac{2(f_1 - f^*)}{m}} < 1$$

即  $R_1 < 1$ , 从而  $\{x_k\}$  线性收敛于  $x^*$ .

证毕.

### 3 数值实验

在共轭梯度中, 当  $\beta_k$  分别取

$$\beta_k^{\text{PRP}} = \frac{g_k^T (g_k - g_{k-1})}{\|g_{k-1}\|^2}, \beta_k^{\text{HS}} = \frac{g_k^T (g_k - g_{k-1})}{d_{k-1}^T g_{k-1}}, \beta_k^{\text{LS}} = -\frac{g_k^T (g_k - g_{k-1})}{g_{k-1}^T d_{k-1}}$$

时, 相应的算法分别被称为 PRP、HS、LS 共轭梯度算法<sup>[1]</sup>, 本文的算法简记为 GM.

**实验 1**

$$f(x) = (x_1 + 10x_2)^4 + 5(x_3 - x_4)^4 + (x_2 - 2x_3)^4 + 10(x_1 - x_4)^4$$

$$x_0 = (2, 2, -2, -2)^T, x^* = (0, 0, 0, 0)^T, f^* = 0$$

### 实验 2 扩展 Powell 函数

$$f(x) = \sum_{i=1}^{n-3} [(x_i + 10x_{i+1})^2 + 5(x_{i+2} - x_{i+3})^2 + (x_{i+1} - 2x_{i+2})^4 + 10(x_i - x_{i+3})^4]$$

$$x_0 = (3, -1, 0, 1, \dots, 3, -1, 0, 1)^T, x^* = (0, 0, \dots, 0)^T, f^* = 0, n = 200$$

### 实验 3 设置扩展 Powell 函数中参数 $n = 1\ 000$ , 重新实验.

数值实验结果结果如表 1 所示.

表 1 各种算法的迭代次数, 函数值和梯度值的计算次数比较

实验	PRP	HS	LS	GM
	$NI/(NF + NG)$	$NI/(NF + NG)$	$NI/(NF + NG)$	$NI/(NF + NG)$
1	24/521	46/309	60/1101	22/160
2	136/1251	121/1618	78/1548	68/306
3	145/4765	143/2656	181/4050	84/1678

在表 1 中,  $NI$ 、 $NF$ 、 $NG$  分别是迭代次数、函数值的计算次数、梯度值的计算次数, 终止条件是精度  $\leq 10^{-8}$ , 计算结果表明本文算法是比较有效的, 即当达到同样精度时的迭代次数, 函数值和梯度值的计算次数, 都比其它算法要少, 这在解决大型优化问题方面是具有较大优越性.

### 参考文献:

- [1] 戴或虹, 袁亚湘. 非线性共扼梯度法 [M]. 上海: 上海科学技术出版社, 2001.
- [2] Miele a, Cantrell J W. Study on a Memory Gradient Method for the Minimization of Functions [J]. J Optim Thory Apple, 1969, 3(6): 459 - 470.
- [3] 袁亚湘, 孙文瑜. 最优化理论与方法 [M]. 北京: 科学出版社, 2003.
- [4] 谢 政, 李建平, 汤泽滢. 非线性最优化 [M]. 长沙: 国防科技大学出版社, 2003: 9.

## A New Parameter of Memory Gradient Method

GONG Jin-feng, YU Xian-wei

Department of Mathematics, Bohai University, Liaoning, Jinzhou 121000

**Abstract:** In this paper, a new formula of main parameter of memory gradient method is proposed, and analyzed the global convergence and convergence rate of this method with Wolfe-Powell line search rule. Numerical results show that the new method is efficient, and it can be used in large scale optimization problems.

**Key words:** memory gradient method; wolfe-powell line search; convergence

责任编辑 张 构