

一个共轭梯度方法的全局收敛性*

The Global Convergence of a Conjugate Gradient Method

洪 玲, 莫利柳, 韦增欣

HONG Ling, MO Li-liu, WEI Zeng-xin

(广西大学数学与信息科学学院, 广西南宁 530004)

(College of Mathematics and Information Science, Guangxi University, Nanning, Guangxi, 530004, China)

摘要: 给出一种较弱的线搜索: 寻找一个步长 $t_k = \rho^{j_k} \Delta_k$ 满足 $f(x_k + \rho^j d_k) - f(x_k) \leq \alpha \rho^j g_k^T d_k - \frac{m}{2} (\rho^j)^2 \|d_k\|^2$, $\alpha \in (0, 1)$, $\rho \in (0, 1)$, $m > 0$ 和 $g_{k+1}^T d_{k+1} < 0$, 将此线搜索应用于求解共轭梯度公式的 β_k^* , 得到一种新共轭梯度算法, 并证明新算法具有全局收敛, 用数值实验说明新算法是有效的.

关键词: 无约束优化 共轭梯度法 线搜索 全局收敛性

中图法分类号: O224 文献标识码: A 文章编号: 1005-9164(2007)03-0239-05

Abstract: A line search is proposed. Under some suitable weak condition, we search a stepsize $t_k = \rho^{j_k} \Delta_k$ satisfying $f(x_k + \rho^j d_k) - f(x_k) \leq \alpha \rho^j g_k^T d_k - \frac{m}{2} (\rho^j)^2 \|d_k\|^2$, $\alpha \in (0, 1)$, $\rho \in (0, 1)$, $m > 0$ and $g_{k+1}^T d_{k+1} < 0$. A new algorithm is obtained by using the present line search, and its global convergence is proved. Preliminary numerical results show that this method is efficient.

Key words: unconstrained optimization, conjugate gradient method, line search, global convergence

考虑无约束优化问题

$$\min \{f(x) | x \in R^n\}, \quad (1)$$

其中 $f: R^n \rightarrow R$ 为连续可微函数. 共轭梯度法是用来求解无约束优化问题(1)式的一种方法, 其迭代公式为:

$$x_{k+1} = x_k + t_k d_k, \quad (2)$$

$$d_k = \begin{cases} -g_k, & k=1, \\ -g_k + \beta_k d_{k-1}, & k \geq 2. \end{cases} \quad (3)$$

其中 $g_k = \nabla f(x_k)$, d_k 为搜索方向, t_k 为步长因子, β_k 为参数. 关于 β_k 的计算公式有很多, 其中较著名的公式有^[1~5]:

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

最近, 文献[6]给出了一种新的 Armijo-type 线

收稿日期: 2006-11-29

修回日期: 2007-02-02

作者简介: 洪 玲(1971-), 女, 讲师, 主要从事最优化理论与方法研究工作。

* 广西自然科学基金项目(No. 0542043)资助。

广西科学 2007 年 8 月 第 14 卷第 3 期

搜索(ATLS). 寻找一个步长 $t_k = \rho^{j_k}$, j_k 是最小的正整数 j , 并满足:

$$f(x_k + \rho^j d_k) - f(x_k) \leq \alpha \rho^j g_k^T d_k - \frac{m}{2} (\rho^j)^2 \|d_k\|^2, \alpha \in (0, 1), \rho \in (0, 1), m > 0, \quad (4)$$

$$g(x_k + \rho^j d_k)^T Q_k(j) \leq -c \|g(x_k + \rho^j d_k)\|^2, c \in (0, 1). \quad (5)$$

其中,

$$Q_k(j) = -g(x_k + \rho^j d_k) + \beta_{k+1}^{PRP} d_k. \quad (6)$$

并已证明该线搜索下 PRP 方法的全局收敛性.

文献[7]给出了一种新的 β_k^* 计算公式, 即

$$\beta_k^* = \frac{g_k^T(g_k - \frac{\|g_k\|}{\|g_{k-1}\|} g_{k-1})}{\|g_{k-1}\|^2}, \quad (7)$$

并且已证明 $\beta_k^* \geq 0$ 以及在精确线搜索、GL 线搜索、WWP 线搜索下的全局收敛性, 其数值结果甚至要优于著名的 PRP 方法. 本文吸收文献[6, 7]的思想, 给出一种较弱的线搜索: 寻找一个步长 $t_k = \rho^{j_k} \Delta_k$ 满足线搜索条件(4)式和较弱条件, 即

$$g_{k+1}^T d_{k+1} < 0. \quad (8)$$

并将此线搜索应用于 β_k^* , 得出了一个具有全局收敛的共轭梯度法.

1 算法

定义 $\|d_k\|_{Q_k} = \sqrt{d_k^T Q_k d_k}$ 和 $\Delta_k = \frac{|g_k^T d_k|}{\|d_k\|_{Q_k}^2}$, 其中 $\{Q_k\}$ 是一个对角阵序列.

在上述基础上, 提出如下新的算法 1:

步骤 1: 取 $Q_1 \in R^{n \times n}$, 初始点 $x_1 \in R^n$, 当 $k = 1$ 时, $d_1 = -g_1$. 若 $g_1 = 0$, 则停止.

步骤 2: 寻找一个 $t_k = \rho^k \Delta_k > 0$ 满足(4)式和(8)式.

步骤 3: 令 $x_{k+1} = x_k + t_k d_k$, $g_{k+1} = g(x_{k+1})$. 若 $g_{k+1} = 0$, 则停止.

步骤 4: 利用公式(7)式计算 β_{k+1}^* , 利用公式(3)式计算 d_{k+1} .

步骤 5: 通过某些方法计算 Q_{k+1} , 然后令 $k := k + 1$, 转步骤 2.

2 算法的全局收敛性

引理 2.1 对 $\forall k$, 假设 $\|g_k\| \neq 0$, 则一定存在一个 j_k , 使得由上述算法产生的步长 $t_k = \rho^{j_k} \Delta_k$ 满足(4)式和(8)式.

证明 如果 $g_k^T d_k < 0$, 先证存在一个 j_0 , 对 $\forall j \geq j_0$, 使得公式(4)式成立.

假设结论不成立, 则存在一个无穷点列 $\{j_l\}$, 使得

$$f(x_k + \rho^{j_l} \Delta_k d_k) - f(x_k) > \alpha \rho^{j_l} \Delta_k g_k^T d_k - \frac{m}{2} (\rho^{j_l} \Delta_k)^2 \|d_k\|^2,$$

由 Taylor's 展开式, 有

$$\rho^{j_l} \Delta_k g_k^T d_k + o(\rho^{j_l} \Delta_k) > \alpha \rho^{j_l} \Delta_k g_k^T d_k - \frac{m}{2} (\rho^{j_l} \Delta_k)^2 \|d_k\|^2,$$

两边除以 $\rho^{j_l} \Delta_k$, 当 $j_l \rightarrow \infty$, 得到

$$g_k^T d_k \geq \alpha g_k^T d_k.$$

由于 $g_k^T d_k < 0$, 得到 $\alpha > 1$. 这与条件 $\alpha \in (0, 1)$ 矛盾, 所以这种情况成立.

再证明 $\exists j_1 \in (j_0, +\infty)$, 使得公式(8)式成立.

由 $d_{k+1} = -g(x_k + \rho^k \Delta_k d_k) + \beta_{k+1}^* d_k$, 得

$$g(x_k + \rho^k \Delta_k d_k)^T d_{k+1} = g(x_k + \rho^k \Delta_k d_k)^T (-g(x_k + \rho^k \Delta_k d_k) + \beta_{k+1}^* d_k) = -\|g(x_k + \rho^k \Delta_k d_k)\|^2 + \beta_{k+1}^* g(x_k + \rho^k \Delta_k d_k)^T d_k,$$

当 $j \rightarrow \infty$, 由于 $\|g_k\| \neq 0$ 以及上面的第二项小于等于 0, 有

$$g(x_k + \rho^j \Delta_k d_k)^T d_{k+1} < 0.$$

所以这种情况也成立, 即引理成立.

我们注意到 $g_1^T d_1 < 0$, 由归纳法得出对 $\forall k$, 都有 $g_k^T d_k < 0$.

为了建立上述算法的全局收敛性, 我们需要假设存在 $\lambda_{\min} > 0$ 和 $\lambda_{\max} > 0$, 使得对所有 $d \in R^n$, 都有 $\lambda_{\min} d^T d \leq d^T Q_k d \leq \lambda_{\max} d^T d$. (9)

这个条件应该是满足的, 比如令 $Q_k = |\delta_k| I$ 和 $|\delta_k| \in [\lambda_{\min}, \lambda_{\max}]$.

和所有共轭梯度方法相同, 本文总假设目标函数满足以下假设:

假设 A 水平集 $\Omega = \{x \in R^n | f(x) \leq f(x_1)\}$ 有界;

假设 B 在水平集上梯度 $g(x)$ 是 Lipschitz 连续, 即存在常量 $L > 0$,

$$\|g(x) - g(y)\| \leq L \|x - y\|, \forall x, y \in \Omega. \quad (10)$$

由于 $\{f(x_k)\}$ 是一个下降序列, 显然有: 上述算法产生的序列 $\{x_k\}$ 包含在 Ω 中; 存在一个常数 f^* , 使得 $\lim_{k \rightarrow \infty} f(x_k) = f^*$. (11)

引理 2.2 若假设 A 成立, 则有:

$$\lim_{k \rightarrow \infty} t_k \|d_k\| = 0, \quad (12)$$

$$\lim_{k \rightarrow \infty} -t_k g_k^T d_k = 0. \quad (13)$$

该引理的证明与文献[6,8] 的证明类似, 为了文章的完整性, 我们把整个证明过程写出来.

证明 对于(11)式, 我们有

$$\sum_{k=1}^{\infty} (f(x_k) - f(x_{k+1})) = \lim_{N \rightarrow \infty} \sum_{k=1}^N (f(x_k) - f(x_{k+1})) = \lim_{N \rightarrow \infty} (f(x_1) - f(x_{k+1})) = f(x_1) - f^*,$$

$$\text{因此 } \sum_{k=1}^{\infty} (f(x_k) - f(x_{k+1})) < +\infty.$$

上式结果和 $f(x_k + t_k d_k) - f(x_k) \leq \alpha t_k g_k^T d_k - \frac{m}{2} t_k^2 \|d_k\|^2$ 联立得

$$\sum_{k=1}^{\infty} t_k^2 \|d_k\|^2 < +\infty, \sum_{k=1}^{\infty} -t_k g_k^T d_k < +\infty.$$

故(12)式和(13)式成立.

引理 2.3 若假设 A 和 B 成立, 则存在两个正常数 M_1, M_2 , 使得 $\forall k$, 都有

$$t_k \geq M_1 |g_k^T d_k| / \|d_k\|^2 \text{ 或 } t_k \geq M_2 \|g_k\|^2 / \|d_k\|^2. \quad (14)$$

证明 分两种情况: $t_k = \Delta_k$ 和 $t_k < \Delta_k$.

情形 1 当 $t_k = \Delta_k$ 时, 由于 $t_k \|d_k\|^2 =$

$$\Delta_k \|d_k\|^2 \geq \frac{|g_k^T d_k|}{\lambda_{\max}}, \text{ 得}$$

$$t_k \geq \frac{|g_k^T d_k|}{\lambda_{\max} \|d_k\|^2}. \quad (15)$$

情形 2 当 $t_k < \Delta_k$, 在这种情形中, $\frac{t_k}{\rho}$ 不能同时满足(4)式和(8)式.

情形 2.1 当 t_k/ρ 不满足(4)式, 有

$$f(x_k + (t_k/\rho)d_k) - f(x_k) > \alpha(t_k/\rho)g_k^T d_k - \frac{m}{2}(t_k/\rho)^2 \|d_k\|^2,$$

对上面不等式使用中值定理, 有 $\theta_k \in (0, 1)$, 使得

$$g(x_k + \theta_k(t_k/\rho)d_k)^T (t_k/\rho)d_k > \alpha(t_k/\rho)g_k^T d_k - \frac{m}{2}(t_k/\rho)^2 \|d_k\|^2,$$

上面不等式两边除以 t_k/ρ , 得

$$g(x_k + \theta_k(t_k/\rho)d_k)^T d_k > \alpha g_k^T d_k - \frac{m}{2}(t_k/\rho) \|d_k\|^2,$$

上式两边减 $g_k^T d_k$, 得

$$(g(x_k + \theta_k(t_k/\rho)d_k) - g_k)^T d_k > -(1 - \alpha)g_k^T d_k - \frac{m}{2}(t_k/\rho) \|d_k\|^2,$$

由假设 B, 有

$$L\theta_k(t_k/\rho) \|d_k\|^2 > -(1 - \alpha)g_k^T d_k - \frac{m}{2}(t_k/\rho) \|d_k\|^2,$$

因此

$$t_k > \frac{2(1 - \alpha)\rho(-g_k^T d_k)}{2L\theta_k + m \|d_k\|^2}.$$

又利用 $\theta_k \in (0, 1)$, 有

$$t_k > \frac{2(1 - \alpha)\rho}{2L + m} \frac{|g_k^T d_k|}{\|d_k\|^2}. \quad (16)$$

情形 2.2 当 t_k/ρ 不满足(8)式, 在这种情形中, 有

$$0 \leq g(x_k + (t_k/\rho)d_k)^T d_{k+1},$$

由(3)式得

$$\begin{aligned} 0 &\leq -\|g(x_k + (t_k/\rho)d_k)\|^2 + [(g(x_k + (t_k/\rho)d_k)^T (g(x_k + (t_k/\rho)d_k) - \\ &\quad \frac{\|g_{k+1}\|}{\|g_k\|} g(x_k)))/\|g_k\|^2] g(x_k + (t_k/\rho)d_k)^T d_k \leq - \\ &\quad \|g(x_k + (t_k/\rho)d_k)\|^2 + [(\|g(x_k + (t_k/\rho)d_k) - \\ &\quad \frac{\|g_{k+1}\|}{\|g_k\|} g(x_k)))/\|g_k\|^2] \|d_k\| \leq -\|g(x_k + (t_k/\rho)d_k) - g_k + g_k - \\ &\quad \frac{\|g_{k+1}\|}{\|g_k\|} g(x_k)\|/\|g_k\|^2] \|d_k\| \leq -\|g(x_k + (t_k/\rho)d_k) - g_k + g_k - \\ &\quad \frac{\|g_{k+1}\|}{\|g_k\|} g(x_k)\|/\|g_k\|^2] \|d_k\| \leq -\|g(x_k + (t_k/\rho)d_k)\|^2 + \|g(x_k + (t_k/\rho)d_k)\|^2 \end{aligned}$$

$$\frac{\|g(x_k + (t_k/\rho)d_k) - g_k\| + (\|g_k\| - \|g_{k+1}\|)}{\|g_k\|^2}$$

• $\|d_k\|$, 因此 $0 \leq -\|g(x_k + (t_k/\rho)d_k)\|^2 + \frac{\|g(x_k + (t_k/\rho)d_k)\|^2}{\|g_k\|^2} - 2\|g(x_k + (t_k/\rho)d_k) - g(x_k)\| \|d_k\|$.

上式两边除 $\|g(x_k + (t_k/\rho)d_k)\|^2$, 得

$$0 \leq -1 +$$

$$\frac{2\|g(x_k + (t_k/\rho)d_k) - g(x_k)\| \|d_k\|}{\|g_k\|^2}, \quad (17)$$

利用假设 B, 得

$$0 \leq -1 + \frac{2L(t_k/\rho) \|d_k\|^2}{\|g_k\|^2},$$

因此, $t_k \geq (\rho/2L)(\|g_k\|^2/\|d_k\|^2)$. (18)

情形 2 证明完毕.

由(15)式, (16)式和(18)式, 令 $M_1 = \min\{\frac{1}{\lambda_{\max}}, \frac{2(1 - \alpha)\rho}{2L + m}\}$ 和 $M_2 = \frac{\rho}{2L}$.

由情形 1 和情形 2 引理得证.

引理 2.4 若假设 A 和 B 成立, $\exists \varepsilon > 0$, 使得对 $\forall k$,

$$\|g_k\| \geq \varepsilon, \quad (19)$$

则存在一个常数 $M_3 > 0$, 使得对 $\forall k$, 有

$$\|d_k\| \leq M_3. \quad (20)$$

证明 由 d_k 的定义, 有 $\|d_k\| \leq \|g_k\| + \|\beta_k^*\| \|d_{k-1}\| \leq \|g_k\| + (\|g_k\| \|g_k - \frac{\|g_k\|}{\|g_{k-1}\|} g_{k-1}\| / \|g_{k-1}\|^2) \|d_{k-1}\| \leq \|g_k\| + \frac{2\|g_k\| \|g_k - g_{k-1}\|}{\|g_{k-1}\|^2} \|d_{k-1}\|,$

利用假设 B, 得

$$\|d_k\| \leq \|g_k\| + \|g_k\| \frac{2Lt_{k-1} \|d_{k-1}\|}{\varepsilon^2} \|d_{k-1}\|, \quad (21)$$

另一方面, 由 $\{x_k\}$ 有界和假设 B, 能推导出: $\exists M_4 > 0$, 使得对 $\forall k$, 有

$$\|g_k\| \leq M_4. \quad (22)$$

由(21)式和(22)式得到下面的不等式:

$$\|d_k\| \leq M_4 + \frac{2M_4 L}{\varepsilon^2} t_{k-1} \|d_{k-1}\|^2 = M_4 + \left(\frac{2M_4 L}{\varepsilon^2} t_{k-1} \|d_{k-1}\| \right) \|d_{k-1}\|, \quad (23)$$

由引理 2.2 给出的(12)式意味着存在一个常数 $q \in (0, 1)$ 和一个整数 k_0 , 使得 $\forall k \geq k_0$, 有

$$\frac{2M_4 L}{\varepsilon^2} t_{k-1} \|d_{k-1}\| \leq q,$$

因此 $\forall k > k_0$, 有 $\|d_k\| \leq M_4 + q \|d_{k-1}\| \leq$

$$M_4(1+q+q^2+\cdots+q^{k-k_0-1})+q^{k-k_0}\|d_{k_0}\|\leqslant \frac{M_4}{1-q}+q^{k-k_0}\|d_{k_0}\|\leqslant \frac{M_4}{1-q}+\|d_{k_0}\|.$$

令 $M_3 = \max\{\|d_1\|, \|d_2\|, \dots, \|d_{k_0}\|, \frac{M_4}{1-q} + \|d_{k_0}\|\}$, 推导出对 $\forall k, (20)$ 式成立.

由以上引理, 推出上述新算法 1 的全局收敛性.

定理 2.1 若假设 A 和 B 成立, $\{x_k\}$ 由上述算法产生, 则

$$\liminf_{k \rightarrow \infty} \|g_k\| = 0. \quad (24)$$

证明 假设结论不成立, 则 $\exists \epsilon > 0$, 使得对 $\forall k, (19)$ 式成立. 由引理 2.4, 有 $\|d_k\| \leq M_3$. 因此, 由等式(12) 式和序列 $\{\|d_k\|\}$ 有界, 得出

$$\lim_{k \rightarrow \infty} t_k \|d_k\|^2 = 0, \quad (25)$$

由引理 2.3, 若 $t_k \geq M_1 |g_k^T d_k| / \|d_k\|^2$, 联立(25) 式得

$$\lim_{k \rightarrow \infty} |g_k^T d_k| = 0, \quad (26)$$

另一方面, 由(3) 式得

$$g_k^T d_k = -\|g_k\|^2 + \frac{g_k^T (g_k - \frac{\|g_k\|}{\|g_{k-1}\|} g_{k-1})}{\|g_{k-1}\|^2}.$$

$$g_k^T d_{k-1},$$

$$\begin{aligned} \text{由假设 B, 得 } \|g_k\|^2 &\leq |g_k^T d_k| + \\ &\frac{\|g_k\|^2 2 L t_k \|d_k\|^2}{\|g_{k-1}\|^2}, \end{aligned} \quad (27)$$

又由(19) 式、(22) 式、(25) 式和(26) 式以及对(27) 式取极限, 得 $\lim_{k \rightarrow \infty} \|g_k\| = 0$, 这与(19) 式矛盾.

若 $t_k \geq M_2 \|g_k\|^2 / \|d_k\|^2$, 得 $\|g_k\|^2 \leq \frac{t_k \|d_k\|^2}{M_2}$.

结合(25) 式和在上述不等式中当 $k \rightarrow \infty$, 得到结论与(19) 式矛盾. 因此定理成立.

3 数值试验

在这一部分中, 我们对两个共轭梯度法进行数值试验, 数值试验中的 10 个函数来自 <ftp://ftp.mathworks.com/>, 使用的数学软件为 MATLAB7.01. 终止条件为 $\|g(x_k)\| \leq 10^{-5}$. 表中的相关符号表示如下:

MPRP: 试验参数为 $\beta_k^{PRP} + (4) + (5)$, 其中 $\rho = 0.5, \alpha = 0.1, c = 0.05, m = 0.1$;

NCG: 试验参数为 $\beta_k^* (7) + (4) + (8)$.

对于算法 1, 我们限制 Q_k 为一个对角阵, 比如

$Q_k = |\delta_k| I$, 这里 δ_k 由以下公式计算:

$$\delta_k^{(1)} = \frac{y_k^T s_k}{s_k^T s_k}, \delta_k^{(2)} = \frac{y_k^T y_k}{y_k^T s_k}, \quad (28)$$

其中 $y_k = g(x_{k+1}) - g(x_k), s_k = x_{k+1} - x_k$, 在文献[9]

中, 公式(28) 曾经被用作最速下降法的步长. 另外, 为了保证条件(9) 式成立, 我们可以通过下面的方法来更新 Q_{k+1} , 即

$$Q_{k+1} = \begin{cases} |\delta_k| I, & |\delta_k| \in [\lambda_{\min}, \lambda_{\max}], \\ Q_k, & \text{其它.} \end{cases} \quad (29)$$

其中 $\rho = 0.5, \alpha = 0.1, m = 0.1, \lambda_{\min} = 10^{-30}, \lambda_{\max} = 10^{30}, Q_1 = I$. 特别地, 我们测试以下三个方案:

NCG1: 算法 1, 其中对所有的 $k > 0, Q_k = I$.

NCG2: 算法 1, 其中 Q_k 由(29) 式来更新, $\delta_k = \delta_k^{(1)}$.

NCG3: 算法 1, 其中 Q_k 由(29) 式来更新, $\delta_k = \delta_k^{(2)}$.

表 1 列出了数值结果, 其中各列意义为 Problem 表示测试问题的名称, Dim 表示目标函数的维数, — 表示方法对这个数值例子失效, NI/NF/NG 分别表示迭代次数 / 目标函数计算次数 / 目标梯度函数计算次数.

表 1 两个共轭梯度法的数值结果

Table 1 Numerical results for two conjugate gradient methods

Problem	Dim	NI/NF/NG			
		MPRP	NCG1	NCG2	NCG3
Gauss	3	11/20/13	9/26/13	4/8/5	4/8/5
Gulf	3	1/2/2	1/5/2	1/5/2	1/5/2
Penl	2	9/14/11	6/14/8	7/13/9	7/13/9
Vardim	2	6/30/8	10/54/20	5/13/6	5/13/6
	50	13/273/18	20/405/21	24/62/25	24/62/25
Trig	3	127/127/127	60/63/61	24/42/26	61/94/62
	50	309/309/309	132/134/133	94/237/97	136/167/137
	100	271/271/271	137/139/138	78/174/80	145/165/148
Ie	3	11/17/17	15/35/20	8/11/10	8/11/10
	50	13/20/19	15/37/22	8/11/10	8/11/10
	100	13/20/19	15/37/22	9/12/11	9/12/11
	200	14/21/20	15/37/22	9/12/11	9/12/11
	500	16/41/22	15/37/22	9/12/11	9/12/11
Trid	3	24/88/28	35/152/40	21/36/25	28/40/31
	50	45/277/52	41/264/47	43/73/46	44/61/47
	100	39/248/48	36/243/40	36/60/42	60/90/66
Lin	2	13/15/15	1/3/2	1/3/2	1/3/2
	50	15/17/17	1/3/2	1/3/2	1/3/2
	500	16/18/18	1/3/2	1/3/2	1/3/2
	1000	16/18/18	1/3/2	1/3/2	1/3/2
Lin1	2	9/54/10	8/65/9	2/10/3	2/10/3
Lin2	4	9/65/10	21/190/22	2/11/3	2/11/3

由表 1 可以看出, NCG1, NCG2, NCG3 的数值结果都比 MPRP 好, 特别地, NCG2, NCG3 的数值结果相当好, 说明我们新的共轭梯度法是很有效的.

参考文献:

- [1] DAI Y H. Conjugate gradient methods with armijo-type line search [J]. *Acta Mathematical Applicata Sinica (English Series)*, 2002, 18(1): 123-130.
- [2] POLAK B T. The conjugate gradient method in extreme problems [J]. *USSR Comput Math and Math Phys*, 1969, 9: 94-112.
- [3] POLAK E, RIBIRE G. Note sur la convergence de directions conjugées [J]. *Rev Francaise Informat Recherche Operatinelle 3e Annee*, 1969, 16: 35-43.
- [4] HESTENES M R, STIEFEL E. Method of conjugate gradient for solving linear equations [J]. *J Res Nat Bur stand*, 1952, 49: 409-436.
- [5] DAI Y H, YUAN Y. A nonlinear conjugate gradient method with a strong global convergence property [J]. *SIAM J Optim*, 1999, 10: 177-182.
- [6] WEI Z X, LI G H, QI L Q. On the global convergence of the polak-ribiere-polyak conjugate gradient method with an armijo-type inexact line search for nonconvex unconstrained optimization problems [M]. Hong Kong: The Hong Kong Polytechnic University, 2002.
- [7] WEI Z X, YAO S W, LIU L Y. The convergence properties of some new conjugate gradient methods [J]. *Applied Mathematics and Computation*, 2006 (183): 1341-1350.
- [8] YU G H, GUAN L T, WEI Z X. A globally convergent polak-ribiere-polyak conjugate gradient method with armijo-type line search [J]. *Numerical Mathematics*, 2006, 15(4): 357-367.
- [9] DAI Y H, YUAN Y X. A nonlinear conjugate gradient method with a strong global convergence property [J]. *SIAM Journal on Optimization*, 1999, 10(1): 177-182.

(责任编辑:邓大玉)

(上接第 238 页 Continue from page 238)

- [6] JIAN J B, TANG C M. An SQP feasible descent algorithm for nonlinear inequality constrained optimization without strict complementarity [J]. *Computers and Mathematics with Applications*, 2005, 49 (2~3): 223-238.
- [7] JIAN J B, ZHENG H Y, TANG C M, et al. A new superlinearly convergent norm-relaxed method of strong sub-feasible direction for inequality constrained optimization [J]. *Applied Mathematics and Computation*,

2006, 182(2): 955-976.

- [8] JIAN J B, ZHENG H Y, HU Q J, et al. A new norm-relaxed method of strongly sub-feasible direction for inequality constrained optimization [J]. *Applied Mathematics and Computation*, 2005, 168(1): 1-28.
- [9] 袁亚湘, 孙文瑜. 最优化理论与方法 [M]. 北京: 科学出版社, 1997.

(责任编辑:邓大玉)