

# 一个既约差商算法及其整体收敛性\*

## A Reduced Difference Coefficient Algorithm and Its Global Convergence

简金宝  
Jian Jinbao

(广西大学数学与信息科学系 南宁市西乡塘路10号 530004)

(Dept. of Math. and Information Science, Guangxi University, 10 Xixiangtang Road, Nanning, 530004)

**摘要** 利用差商代替难以计算的精确导数,结合既约梯度法的思想建立新的算法;在目标函数一致凸的条件下证明了既约差商法的整体收敛性.

**关键词** 约束最优化 既约差商 差商 整体收敛性 一致凸

**Abstract** The difference coefficient was used to replace the exact derivative which is difficult to be computed, and a new algorithm was presented by using the idea of reduced gradient method. The reduced difference coefficient algorithm was shown to possess global convergence if the objective function is uniformly convex.

**Key words** constrained optimization, reduced difference coefficient, difference coefficient, global convergence, uniformly convex

自从 Wolfe<sup>[1]</sup> (1962) 提出既约梯度法以来,经过多年的实践表明该类方法的效果明显优于其它方法<sup>[2]</sup>. 该类方法在理论上也得到了广泛地研究,形成各种类型的既约梯度法. 但绝大多数可微优化算法的实现均依赖于导数的计算,而多数实际最优化的目标函数的精确导数难以计算,这给算法的应用带来了很大困难.

Dixon<sup>[3]</sup>和赵小平<sup>[4]</sup>提出了用差商代替导数的无约束优化变尺度法. 在此,我们借助既约梯度法降维的思想,以差商代替目标函数的精确导数,构造了线性约束最优化的一个既约差商法. 由于方法不需计算任何精确导数,故而具有较小的计算量和广泛的实用性.

### 1 既约差商算法

我们讨论如下非线性优化问题

$$(P) \quad \begin{aligned} & \min f(x) \\ & \text{s. t. } Ax = b \\ & \quad x \geq 0 \end{aligned}$$

其中  $A \in E^{m \times n}, b \in E^m, x \in E^n, f(x): E^n \rightarrow E^1$ .

对(P)作如下假设

(a) 可行集  $R = \{x \in E^n: Ax = b, x \geq 0\}$  是非退化的,即任意基可行解至少有  $m$  个正分量.

(b) 目标函数  $f(x)$  二阶连续可微,且存在常数  $M_1, M_2, 0 < M_1 < M_2$ , 使得  $\forall x, y \in E^n$  有

$$M_1 \|y\|^2 \leq y^T \nabla^2 f(x) y \leq M_2 \|y\|^2 \quad (1)$$

由(1)知  $f(x)$  为一致凸,从而(P)的最优解唯一,设(P)的最优解为  $x^*$ .

设  $a_j$  为  $A$  的第  $j$  个列向量,  $y \in E^n$ . 对于子集  $I \subset \{1, \dots, n\}$ , 记

$$A_I = (a_j, j \in I), \quad y_I = (y_j, j \in I).$$

如果  $|I| = m, A_I$  为非奇异,称  $I$  为(P)的基.

对于基  $I$ , 记  $J = \{1, \dots, n\} \setminus I$ . 则

$$Ax = b \Leftrightarrow x_I = A_I^{-1}b - A_I^{-1}A_J x_J \quad (2)$$

$$\begin{aligned} f(x) &= f(x_I, x_J) \\ &= f(A_I^{-1}b - A_I^{-1}A_J x_J, x_J) \triangleq \bar{f}(x_J) \end{aligned} \quad (3)$$

$$\nabla \bar{f}(x_J) = \nabla_J f(x) - (A_I^{-1}A_J)^T \nabla_I f(x) \quad (4)$$

$r(x) \triangleq \nabla \bar{f}(x_J)$  称为  $f(x)$  的既约梯度.

Guangxi Sciences, Vol. 2 No. 2, May 1995

1994-04-08 收稿.

1994-08-03 修回.

\* 广西大学青年科学基金资助项目.

对于  $h > 0$ , 定义

$$s_i = s_i(x, h) = \frac{f(x + he_i) - f(x)}{h} \quad (5)$$

$$s = (s_1, \dots, s_n)^T \in E^n.$$

其中  $e_i$  为  $E^n$  中第  $i$  个分量为 1, 其余分量为零的向量,  $i = 1, \dots, n$ .

称  $s$  为  $f(x)$  以  $h$  为步长的差商, 简称为  $f(x)$  的差商, 称  $\bar{r}(x)$  为  $f(x)$  的既约差商,  $\bar{r}(x)$  定义为

$$\begin{aligned} \bar{r}(x) &= \bar{r}(x, h) \\ &= s_j(x, h) - (A_I^{-1}A_j)^T s_j(x, h) \\ &= s_j - (A_I^{-1}A_j)^T s_j \end{aligned} \quad (7)$$

记  $\bar{f}(x_j)$  的差商为  $\bar{s} = (\bar{s}_j, j \in J)$ . 下面给出  $\nabla f(x), s, r(x), \bar{r}(x), \bar{s}$  之间的关系

**定理 1** 在假设 (b) 下, 有

$$\begin{aligned} 1) \nabla f(x) + \frac{h}{2} M_1 e \\ \leq s \leq \nabla f(x) + \frac{1}{2} h M_2 e \end{aligned} \quad (8)$$

$$e = (1, \dots, 1)^T \in E^n.$$

$$\begin{aligned} 2) r(x) + \frac{1}{2} h M_1 (1 + \xi) \bar{e} \\ \leq \bar{s} \leq r(x) + \frac{1}{2} h M_2 (1 + \eta) \bar{e}, \quad \bar{e} = \bar{e}_j \end{aligned} \quad (9)$$

$$\xi = \min\{\|A_I^{-1}a_j\|^2, j \in J\},$$

$$\eta = \max\{\|A_I^{-1}a_j\|^2, j \in J\}.$$

$$\begin{aligned} 3) \bar{s} + \frac{h}{2} [M_1 - M_2(1 + \eta + \sqrt{m\eta})] \bar{e} \\ \leq \bar{r}(x) \\ \leq \bar{s} + \frac{h}{2} [M_2(1 + \sqrt{m\eta}) - M_1(1 + \xi)] \bar{e} \end{aligned} \quad (10)$$

**证明** 1) 由中值定理有

$$\begin{aligned} s_j &= \frac{f(x + he_j) - f(x)}{h} \\ &= \nabla f(x)^T e_j + \frac{1}{2} h e_j^T \nabla^2 f(y_j) e_j \\ \text{记 } c_j &= e_j^T \nabla^2 f(y_j) e_j, \text{ 则有} \\ s &= \nabla f(x) + \frac{1}{2} h C, \quad M_1 \leq c_j \leq M_2 \end{aligned} \quad (11)$$

于是 1) 成立.

$$\begin{aligned} 2) \bar{s}_j &= \frac{\bar{f}(x_j + h\bar{e}_j) - \bar{f}(x_j)}{h} \\ &= \frac{f(x_j - A_I^{-1}A_j h\bar{e}_j, x_j + h\bar{e}_j) - f(x_j, x_j)}{h} \end{aligned}$$

利用中值定理及 (b) 易推知

$$h\bar{s}_j = \nabla_j f(x)^T (-hA_I^{-1}A_j\bar{e}_j) + h\nabla_j f(x)^T \bar{e}_j$$

广西科学 1998 年 5 月 第 2 卷第 2 期

$$+ \frac{1}{2} h^2 \begin{pmatrix} -A_I^{-1}A_j\bar{e}_j \\ \bar{e}_j \end{pmatrix}^T \nabla^2 f(z_j) \begin{pmatrix} -A_I^{-1}A_j\bar{e}_j \\ \bar{e}_j \end{pmatrix}$$

$$\begin{aligned} \text{其中 } \bar{e}_j &= (e_j)_J = (e_{j_i}, i \in J), e_{j_i} \text{ 为 } e_j \text{ 第 } i \text{ 个分量} \\ &M_1(1 + \|A_I^{-1}a_j\|^2) \\ &\leq \begin{pmatrix} -A_I^{-1}A_j\bar{e}_j \\ \bar{e}_j \end{pmatrix}^T \nabla^2 f(z_j) \begin{pmatrix} -A_I^{-1}A_j\bar{e}_j \\ \bar{e}_j \end{pmatrix} \\ &\leq M_2(1 + \|A_I^{-1}a_j\|^2) \end{aligned}$$

$$\text{令 } \xi = \min\{\|A_I^{-1}a_j\|^2, j \in J\},$$

$$\eta = \max\{\|A_I^{-1}a_j\|^2, j \in J\}$$

$$\begin{aligned} \text{则 } &M_1(1 + \xi) \\ &\leq \begin{pmatrix} -A_I^{-1}A_j\bar{e}_j \\ \bar{e}_j \end{pmatrix}^T \nabla^2 f(z_j) \begin{pmatrix} -A_I^{-1}A_j\bar{e}_j \\ \bar{e}_j \end{pmatrix} \\ &\leq M_2(1 + \eta). \end{aligned}$$

于是

$$\begin{aligned} \nabla_j f(x)^T \bar{e}_j - \nabla_j f(x)^T A_I^{-1}A_j\bar{e}_j + \frac{1}{2} h M_1 (1 + \xi) \\ \leq \bar{s}_j \leq \nabla_j f(x)^T \bar{e}_j - \nabla_j f(x)^T A_I^{-1}A_j\bar{e}_j \\ + \frac{1}{2} h M_2 (1 + \eta) \end{aligned}$$

$$\begin{aligned} r(x) + \frac{1}{2} h M_1 (1 + \xi) \bar{e} \\ \leq \bar{s} \leq r(x) + \frac{1}{2} h M_2 (1 + \eta) \bar{e} \end{aligned}$$

即 (9) 成立.

由 (7), (11) 有

$$\begin{aligned} \bar{r}(x) &= s_j - (A_I^{-1}A_j)^T s_j \\ &= \nabla_j f(x) + \frac{1}{2} h C_j - (A_I^{-1}A_j)^T (\nabla_j f(x) \\ &\quad + \frac{1}{2} h C_j) \end{aligned}$$

$$\bar{r}(x) = r(x) + \frac{1}{2} h C_j - \frac{1}{2} h (A_I^{-1}A_j)^T C_j \quad (12)$$

易见  $(A_I^{-1}A_j)^T C_j$  的分量  $(A_I^{-1}a_j)^T C_j$  满足

$$-\sqrt{m\eta}M_2 \leq (A_I^{-1}a_j)^T C_j \leq \sqrt{m\eta}M_2 \quad (12')$$

结合 (9), (12), (11) 有

$$\begin{aligned} \bar{s} + \frac{1}{2} h [M_1 - \sqrt{m\eta}M_2 - M_2(1 + \eta)] \bar{e} \\ \leq \bar{r}(x) \\ \leq \bar{s} + \frac{1}{2} h [M_2 + \sqrt{m\eta}M_2 - M_1(1 + \xi)] \bar{e} \end{aligned}$$

即 (10) 成立. 证毕

**既约差商法步骤:**

步 0. 选  $x^1 \in R$ , 基  $I_0, h_0 > 0, 0 < \rho < 1$ ,

$k = 1$ , 选一个十分小的终止参数  $\delta > 0$ .

步 1. 以  $I = I_{k-1}$  作以下转轴运算:

1.1) 计算  $x_i^k = \min\{x_i^k; i \in I\}$ ,  $T(I) = A_I^{-1}A, T_i^j$  为  $T(I)$  中位于  $r$  行和  $j$  列元素,  $j \in J$ .

1.2) 计算  $x_j^k = \max\{x_j^k; j \in J, T_i^j \neq 0\}$ .

1.3) 如  $x_i^k \geq \rho x_i^0$ , 令  $I_k = I, J_k = \{1, 2, \dots, n\} \setminus I_k$ ,  $h = h_{k-1}/2$ , 到步 2; 否则令  $I := I \cup \{\sigma\} \setminus \{r\}$ , 到 1.1).

步 2. 计算差商  $\bar{s} = \bar{s}(x^k, h)$ , 既约差商

$$\bar{r} = \bar{r}(x^k, h) = (\bar{r}_j, j \in J_k).$$

步 3. 计算搜索方向

$$d_j = \begin{cases} -\bar{r}_j, & \bar{r}_j \leq 0 \\ -x_j^k \bar{r}_j, & \bar{r}_j > 0 \end{cases}, \quad d_{J_k} = (d_j, j \in J_k). \quad (13)$$

$$d_{I_k} = -A_{I_k}^{-1} A_{J_k} d_{J_k}, \quad d = (d_{I_k}, d_{J_k}) \quad (14)$$

步 4. 作线搜索

$$f(x^k + \lambda d) = \min\{f(x^k + \lambda d) : x^k + \lambda d \in R\} \quad (15)$$

步 5. 如  $\bar{\lambda} = 0$ , 且  $h < \delta$ , 以  $x^k$  为近似解, 停; 如  $\bar{\lambda} = 0$ , 但  $h \geq \delta$ , 令  $h := \frac{1}{2}h$ , 转到步 2. 如  $\bar{\lambda} \neq 0$ , 置  $d^k = d, r^k = \bar{r}, \bar{s}^k = \bar{s}, h_k = h, \lambda_k = \bar{\lambda}, x^{k+1} = x^k + \lambda_k d^k, k := k + 1$ , 转回步 1.

算法的终止准则是以下面的定理 2 为理论基础.

## 2 算法的适定性和整体收敛性

为讨论算法的适定性和收敛性, 先建立以下基本结论.

引理 1<sup>[5]</sup> 对于  $x^k$ , 步 1 中的转轴运算可有限步终止; 如  $\lim_{k \in K} x^k = \tilde{x}$ , 则  $\min\{x_j^k, k \in K, j \in I_k\} \geq \epsilon_0 \rho$ , 其中  $\epsilon > 0$ ; 如  $\lim_{k \rightarrow \infty} x^k = \tilde{x}$ , 则当  $k$  充分大时,  $I_k$  固定不变, 即对于  $\{x^k\}$ , 转轴运算只需施行有限次.

引理 2 (13), (14) 确定的方向为  $(P)$  在  $x^k$  处的可行方向; 如  $r(x^k)^T d_{J_k} < 0$ , 则  $d$  为  $(P)$  的下降方向, 于是  $\bar{\lambda} \neq 0$ .

证明 首先由假设 (a) 及 [5] 可知  $R$  的任何点  $x$  至少有  $m$  个正分量, 因此当  $x_i^k \geq \rho x_i^0$  时, 不难推知  $x_j^k > 0, \forall j \in I_k$ . 另一方面, 对于  $x_j^k = 0, j \in J_k$ , 由 (13) 有  $d_j \geq 0$ . 再结合 (14) 可知  $d$  为可行方向. 由  $\nabla f(x^k)^T d = r(x^k)^T d_{J_k}$  可知后半部分成立.

引理 3<sup>[5]</sup>  $x^k$  为  $(P)$  的  $K-T$  点, 当且仅当

$$r(x^k) = r^k \geq 0, \quad x_{J_k}^T r^k = 0 \quad (15)$$

因  $(P)$  为凸规划, (15) 为  $x^k$  是唯一解  $x^*$  的充要条件.

定理 2 对于迭代点  $x^k$ , 如有正参数子列  $\{h_{k_j}\}_j$ ,  $\lim_{j \rightarrow \infty} h_{k_j} = 0$ , 使得步 5 中线搜索 (15) 的步长均为零, 其中  $d^{k_j} = d$  为 (13), (14) 确定的对应于参数  $h_{k_j}$  的方向. 则  $x^k$  为  $(P)$  的最优解  $x^*$ .

证明 因步 5 线搜索步长为零, 由引理 2 有

$$\begin{aligned} \nabla f(x^k)^T d_{J_k} &= r(x^k)^T d_{J_k}^j \geq 0, \text{ 而} \\ r(x^k)^T d_{J_k}^j &= \sum_{\bar{r}_i(h_{k_j}) \leq 0} -r_i(x^k) \bar{r}_i(h_{k_j}) + \sum_{\bar{r}_i(h_{k_j}) > 0} -x_i^k r_i(x^k) \bar{r}_i(h_{k_j}). \end{aligned}$$

由 (12), (12') 有

$$\begin{aligned} \bar{r}_i(h_{k_j}) - \frac{1}{2} h_{k_j} M_2 (1 + \sqrt{m\eta}) &\leq r_i(x^k) \\ &\leq \bar{r}_i(h_{k_j}) + \frac{1}{2} h_{k_j} (\sqrt{m\eta} M_2 - M_1) \end{aligned}$$

于是

$$\begin{aligned} &-\sum_{\bar{r}_i(h_{k_j}) \leq 0} [\bar{r}_i(h_{k_j})^2 + \frac{1}{2} h_{k_j} \bar{r}_i(h_{k_j}) (\sqrt{m\eta} M_2 - M_1)] \\ &-\sum_{\bar{r}_i(h_{k_j}) > 0} x_i^k \bar{r}_i(h_{k_j})^2 + \sum_{\bar{r}_i(h_{k_j}) > 0} x_i^k \bar{r}_i(h_{k_j}) h_{k_j} M_2 (1 + \sqrt{m\eta}) \\ &\geq r(x^k)^T d_{J_k}^j \geq 0 \end{aligned}$$

而  $h_{k_j} \rightarrow 0$ , 故  $\bar{r}_i(h_{k_j}) \rightarrow r_i(x^k)$ , 于是在上式中令  $j \rightarrow \infty$  有

$$-\sum_{r_i(x^k) \leq 0} r_i(x^k)^2 - \sum_{r_i(x^k) > 0} x_i^k r_i(x^k)^2 \geq 0$$

$$\text{从而 } \sum_{r_i(x^k) \leq 0} r_i(x^k)^2 + \sum_{r_i(x^k) > 0} x_i^k r_i(x^k)^2 = 0$$

由此可推知  $r(x^k) \geq 0, r(x^k)^T d_{J_k}^j = 0$ . 由引理 3 之 (15) 知  $x^k$  为  $(P)$  的最优解  $x^*$ , 证毕.

在下面收敛性讨论中, 不妨假设步 2 ~ 步 5 对每个  $x^k$  可有限步终止.

定理 3 设条件 (a), (b) 成立, 则  $\{x^k\}$  的任何极限点为  $(P)$  的  $K-T$  点, 从而等于最优解  $x^*$ .

证明 不妨设  $x^k \rightarrow \tilde{x}, k \in K$ , 且  $I_k \equiv I, J_k \equiv J, \forall k \in K$ . 利用中值定理有

$$\begin{aligned} f(x^k + h_k e_j) - f(x^k) &= h_k \nabla f(x^k)^T e_j + \frac{1}{2} h_k^2 e_j^T \nabla^2 f(x^k) e_j \end{aligned}$$

由条件 (b) 知

$$\begin{aligned} h_k \nabla f(x^k)^T e_j + \frac{1}{2} h_k^2 M_1 &\leq f(x^k + h_k e_j) - f(x^k) \\ &\leq h_k \nabla f(x^k)^T e_j + \frac{1}{2} h_k^2 M_2. \end{aligned}$$

故

$$\begin{aligned} \nabla f(x^k)^T e_j + \frac{1}{2} h_k M_1 &\leq s_j^k = \frac{f(x^k + h_k e_j) - f(x^k)}{h_k} \\ &\leq \nabla f(x^k)^T e_j + \frac{1}{2} h_k M_2. \end{aligned}$$

$$\text{由 } h_k \rightarrow 0, (k \rightarrow \infty), \text{ 有}$$

$$\lim_{k \in K} s_j^k = \nabla f(\tilde{x})^T e_j = \frac{\partial f(\tilde{x})}{\partial x_j}, j = 1 \sim n.$$

即  $\lim_{k \in K} s^k = \nabla f(\tilde{x})$ . 因此  $\lim_{k \in K} \bar{r}^k = \lim_{k \in K} \bar{r}(x^k, h_k)$

$$= \lim_{k \in K} [s_j^k - (A_j^{-1} A_j)^T r_j^k]$$

$$= \nabla_j f(\tilde{x}) - (A_j^{-1} A_j)^{-1} \nabla_j f(\tilde{x}) = r(\tilde{x}).$$

引进方向  $\bar{d}$ :

$$\bar{d}_j = \begin{cases} -r_j(\tilde{x}), r_j(\tilde{x}) \leq 0 \\ -\tilde{x}_j r_j(\tilde{x}), r_j(\tilde{x}) > 0 \end{cases}, j \in J.$$

$$\bar{d}_I = -A_I^{-1} A_I \bar{d}_J.$$

则  $d^k \rightarrow \bar{d}, k \in K$ . 下面假设  $\tilde{x}$  不是  $K-T$  点, 我们将导出矛盾.

首先由引理 1, 3 有

$$\begin{aligned} \nabla f(\tilde{x})^T \bar{d} &= r(\tilde{x})^T \bar{d}_J \\ &= -\sum_{r_j(\tilde{x}) \leq 0} r_j(\tilde{x})^2 - \sum_{r_j(\tilde{x}) > 0} \tilde{x}_j r_j(\tilde{x})^2 < 0. \end{aligned}$$

由  $x^k \rightarrow \tilde{x}, d^k \rightarrow \bar{d}, k \in K$  以及  $\nabla f(x)$  的一致连续性可推知: 存在  $\epsilon' > 0$ , 使得  $k \in K$  充分大时,

$$\nabla f(x^k + \lambda d^k)^T d^k < -\delta, \forall \lambda \in [0, \epsilon'], \quad (16)$$

$$\text{其中 } \delta = -\frac{1}{2} \nabla f(\tilde{x})^T \bar{d} > 0.$$

记

$$\epsilon_k = \begin{cases} \min \left\{ \frac{-x_i^k}{d_i^k}; d_i^k < 0 \right\} \\ +\infty, \text{ 如 } d_i^k \geq 0, j = 1 \sim n. \end{cases}$$

则  $x^k + \lambda d^k \in R, \lambda \in [0, \epsilon_k]$ .

其次我们证明:  $\epsilon = \inf \{\epsilon_k; k \in K\} > 0$ .

若不然, 可取子列  $K' \subset K$ , 使得

$$\epsilon_k = \frac{-x_i^k}{d_i^k} \rightarrow 0, d_i^k < 0, k \in K', t \text{ 与 } k \text{ 无关. 由于}$$

$x_i^k \rightarrow \tilde{x}_i, d_i^k \rightarrow \bar{d}_i$ , 故  $\tilde{x}_i = 0, t \in J$ , (引理 1). 结合 (14)

及  $d_i^k < 0$  可知  $d_i^k = -x_i^k r_i^k$ . 于是

$$\epsilon_k = \frac{-x_i^k}{d_i^k} = \frac{1}{r_i^k}.$$

但  $r_i^k \rightarrow r_i(\tilde{x})$ , 这与  $\epsilon_k \rightarrow 0$  矛盾. 即  $\epsilon > 0$ .

由于  $\epsilon_k \geq \epsilon > 0$ , 故

$$x^k + \lambda d^k \in R, \forall \lambda \in [0, \epsilon], k \in K \quad (17)$$

最后我们来导出矛盾.

令  $\bar{\epsilon} = \min \{\epsilon, \epsilon'\} > 0$ . 由中值定理及 (15), (17)

$$f(x^{k+1}) = f(x^k + \lambda_k d^k) \leq f(x^k + \bar{\epsilon} d^k)$$

$$= f(x^k) + \nabla f(x^k + \theta_k \bar{\epsilon} d^k)^T (\bar{\epsilon} d^k).$$

$$\theta_k \in [0, 1],$$

故  $\theta_k \bar{\epsilon} \in [0, \epsilon']$ , 由 (16) 有

$$f(x^{k+1}) \leq f(x^k) - \bar{\epsilon} \delta, k \in K.$$

由  $\{f(x^k)\}$  单调不增及  $f(x^k) \rightarrow f(\tilde{x}), k \in K$  有  $f(x^k) \rightarrow f(\tilde{x}) (k \rightarrow \infty)$ . 在上不等式中令  $k \rightarrow \infty, k \in K$  有  $\bar{\epsilon} \delta \leq 0$ . 这矛盾.

因此  $\tilde{x}$  为 (P) 的  $K-T$  点, 从而  $\tilde{x}$  等于凸规划 (P) 的唯一最优解  $x^*$ , 证毕.

**推论** 如  $\{x^k\}$  有界, 则  $x^k \rightarrow x^*, k \rightarrow \infty$ .

**算法的几点说明:**

1) 算法还可以采用别的终止准则, 如 " $r(x^k, h)^T d_{j_k} \geq 0, h < \delta$ ". 至于更为优秀的终止准则有待进一步研究和探索.

2) 为减少计算量, 可以考虑将精确线搜索 (15) 改为以下非精确线搜索. 收敛性仍成立.

取  $\bar{\lambda}$  为  $\{1, \frac{1}{2}, \frac{1}{4}, \frac{1}{8}, \dots, \frac{1}{2^j}, \dots, 0\}$  中满足式 (18) 的最大者

$$\begin{cases} f(x^k + \lambda d) \leq f(x^k) + \frac{1}{2} \bar{\lambda} r(x^k, h)^T d_{j_k} \\ f(x^k + \lambda d) \leq f(x^k) \end{cases} \quad (18)$$

如式 (18) 对非常大的  $j, \lambda = 2^{-j}$  仍不成立, 可取步长  $\bar{\lambda} = 0$ . (15) 中不要求  $\lambda \geq 0$  是为了尽快使  $\bar{\lambda} \neq 0$ . 结束一次迭代. 当有某个  $x_j^k = 0$ , 且  $r_j < 0$  时, 为使  $x^k + \lambda d \in R$ , 自然有  $\lambda \geq 0$ .

3) 利用本文思想, 类似于文献 [5] 可建立包含许多算法在内的一类既约差商法.

### 参考文献

- 1 Wolfe P. An Extended Simplex Method. Notices of the American Mathematical Society, 1962, 9: 4.
- 2 Laslon L S. Reduced Gradient Methods, Prented at NATO Advanced Research Institute on Non-Linear Optimization. Cambridge, England, July 1981, 13~14.
- 3 Dixon L C. On the Convergence of Variable Metric Method with Numerical Derivative and Effect of Noise in the Function Evaluation. In: Octtli V and Ritler K ed., Optimization and Operations Research, Springer-Verlong, 1976.
- 4 赵小平. 差商变尺度法的整体收敛性. 应用数学, 1994, 7 (1): 41~47.
- 5 越民义, 韩继业, 姚恩瑜. 可行方向法的一个统一探讨. 数学年刊, 1985, 6A (1): 1~12.

(责任编辑: 莫鼎新)