

非光滑优化的强次可行方向邻近点束求解方法*

A Proximal Bundle Method of Strongly Sub-feasible Directions for Nonsmooth Optimization

唐春明¹, 简金宝^{1,2}

TANG Chun-ming¹, JIAN Jin-bao^{1,2}

(1. 广西大学数学与信息科学学院, 广西南宁 530004; 2. 玉林师范学院数学与信息科学学院, 广西玉林 537000)

(1. College of Mathematics and Information Science, Guangxi University, Nanning, Guangxi, 530004, China; 2. College of Mathematics and Information Science, Yulin Normal University, Yulin, Guangxi, 537000, China)

摘要:通过引入新型邻近点参数修正策略及搜索方向子问题, 提出一个求解非光滑优化的强次可行方向邻近点束方法. 该方法稳定性好, 能保证迭代点的强次可行性, 且具备全局收敛性.

关键词:非光滑优化 邻近点 束方法 强次可行方向

中图分类号:O221.2 **文献标识码:**A **文章编号:**1005-9164(2014)03-0283-04

Abstract:By introducing a new updating strategy of proximal parameters and a new search direction finding subproblem, a proximal bundle method of strongly sub-feasible directions is proposed for solving nonsmooth optimization. The proposed method is stable, can preserve sub-feasibility of the iterations, and possesses global convergence.

Key words:nonsmooth optimization, proximal point, bundle method, strongly sub-feasible directions

考虑求解如下非线性不等式约束优化问题

$$\begin{aligned} & \min_{x \in R^n} f(x) \\ & \text{s. t. } c_i(x) \leq 0, i \in I \triangleq \{1, \dots, m\}, \end{aligned} \quad (0.1)$$

其中 $f: R^n \rightarrow R$ 为凸函数, 但不一定可微(即可能非光滑), $c_i (i \in I): R^n \rightarrow R$ 是连续可微的凸函数.

强次可行方向法^[1]是求解光滑约束优化的一类有效方法. 该类方法能接受不可行的初始迭代点, 并且能保持迭代点的强次可行性, 即对于当前迭代点满足可行性的约束函数, 在下一个迭代点仍然满足, 且同时避免在可行域外目标函数值增加过快, 一旦某个

迭代点落入可行域, 即自动变为可行方向法. 文献[2, 3]结合次梯度聚集技术、次梯度选取技术及广义割平面法的思想^[4], 将强次可行方向法推广到求解非光滑类型的问题(0.1). 本文将结合邻近点束方法的思想^[5], 对文献[2]的方法作进一步改进, 旨在提升算法的稳定性和计算效率. 文中提出一个带邻近点控制的产生搜索方向的二次规划子问题, 并给出一个新的邻近点参数更新策略, 最后证明算法的全局收敛性.

1 算法描述

假设 1.1 (i) 设 f 是凸函数但不一定可微, $c_i (i \in I)$ 是连续可微的凸函数;

(ii) 问题(0.1)满足 Slater 约束规格, 即存在一个向量 $\tilde{x} \in R^n$ 使得 $c_i(\tilde{x}) < 0, \forall i \in I$.

记问题(0.1)的可行集为 $F = \{x \in R^n : c_i(x) \leq 0, i \in I\}$. 定义符号

$$I_-(x) = \{i \in I : c_i(x) \leq 0\}, I_+(x) = \{i \in I : c_i(x) > 0\}, \varphi(x) = \max\{0, c_i(x), i \in I\}, \text{及惩罚函}$$

收稿日期:2013-09-30

修回日期:2013-12-11

作者简介:唐春明(1979-),男,博士,教授,主要从事最优化理论与算法的研究。

* 国家自然科学基金(11301095,11126341)和广西自然科学基金项目(2013GXNSFAA019013)资助。

数: $\delta(x): R^n \rightarrow [0, +\infty)$ 是连续函数, 且 $\delta(x) = 0$ 当且仅当 $x \in F$.

对 $\epsilon \geq 0$, 凸函数 f 在 $x \in R^n$ 处的 ϵ -次微分定义为

$$\partial_\epsilon f(x) = \{g \in R^n : f(y) \geq f(x) + g^T(y-x) - \epsilon, \forall y \in R^n\}.$$

特别地, $\partial_0 f(x) = \partial f(x)$ 为通常的次微分, $g \in \partial f(x)$ 称为一个次梯度.

设 $x^k \in R^n$ 是当前迭代点, $y^j, j \in J^k \subseteq \{1, \dots, k\}$ 为辅助迭代点, 对应次梯度 $g^j \in \partial f(y^j), j \in J^k$. 定义 f 在 y^j 处的线性化函数为

$$f_j(x) = f(y^j) + (g^j)^T(x - y^j), \forall x \in R^n, j \in J^k.$$

进而得到 f 的分片线性(下)近似函数

$$\hat{f}^k(x) = \max\{f_j(x) : j \in J^k\}.$$

令 $f_j^k = f_j(x^k)$ 得

$$f_j(x) = f_j^k + (g^j)^T(x - x^k), j \in J^k.$$

为了平衡目标函数的下降性和约束函数的可行性, 对于任意给定的 $y \in R^n$, 引入改进函数^[2]:

$$H_y(x) = \max\{f(x) - f(y) - \delta(y); c_i(x), i \in I_-(y); c_i(x) - \varphi(y), i \in I_+(y)\}.$$

以下引理给出了函数 H 的重要性质.

引理 1.1^[2] 若假设 1.1 成立, 则以下 3 个命题等价: (i) \bar{x} 是问题(0.1)的最优解; (ii) $\min\{H_{\bar{x}}(x) : x \in R^n\} = H_{\bar{x}}(\bar{x}) = 0$; (iii) $0 \in \partial H_{\bar{x}}(\bar{x})$.

由引理 1.1 可知, 求解原问题(0.1)等价于求改进函数 H 的“稳定点”. 为此, 在当前迭代点 x^k 处, 定义函数 $H_{x^k}(x)$ 的分片线性(下)近似函数:

$$\hat{H}_{x^k}(x) = \max\{\hat{f}^k(x) - f(x^k) - \delta^k; \hat{c}_i^k(x), i \in I_-^k; \hat{c}_i^k(x) - \varphi^k, i \in I_+^k\},$$

$$\text{其中 } \hat{c}_i^k(x) = c_i(x^k) + \nabla c_i(x^k)^T(x - x^k), I_-^k = I_-(x^k), I_+^k = I_+(x^k), \varphi^k = \varphi(x^k), \delta^k = \delta(x^k).$$

结合邻近点束方法思想^[5], 可选取如下新试探点

$$y^{k+1} = \operatorname{argmin}\{\hat{H}_{x^k}(x) + \frac{1}{2}\gamma^k \|x - x^k\|^2 : x \in R^n\},$$

其中 $\gamma^k > 0$ 是邻近点参数. 进一步引入次梯度聚集技术^[4], 并令 $d = x - x^k$, 则求解 y^{k+1} 可转化为求解如下寻找搜索方向子问题:

$$\begin{aligned} \min \quad & z + \frac{1}{2}\gamma^k \|d\|^2 \\ \text{s. t.} \quad & f_j^k - f(x^k) + (g^j)^T d \leq z + \delta^k, j \in J^k, \\ & f_p^k - f(x^k) + (p^{k-1})^T d \leq z + \delta^k, \\ & c_i(x^k) + \nabla c_i(x^k)^T d \leq z, i \in I_-^k, \\ & c_i(x^k) + \nabla c_i(x^k)^T d \leq z + \varphi^k, i \in I_+^k. \end{aligned} \quad (1.1)$$

其中 $z \in R$ 是一个辅助变量, f_p^k 和 p^{k-1} 分别是前 $k-1$

个函数值 $f_j^k, j=1, \dots, k-1$ 和次梯度 $g^j, j=1, \dots, k-1$ 的聚集(非负线性组合, 具体更新见下面算法).

由 f 和 c_i 的凸性可知, $(d, z) = (0, 0)$ 是子问题(1.1)的一个可行解. 设 (d^k, z^k) 是问题(1.1)的最优解, 其亦为问题(1.1)的 KKT 点, 即存在乘子 $\lambda_j^k, j \in J^k, \lambda_p^k, \mu_i^k, i \in I$ 使得

$$\begin{aligned} \gamma^k d^k + \sum_{j \in J^k} \lambda_j^k g^j + \lambda_p^k p^{k-1} + \sum_{i \in I} \mu_i^k \nabla c_i(x^k) &= 0, \\ \sum_{j \in J^k} \lambda_j^k + \lambda_p^k + \sum_{i \in I} \mu_i^k &= 1, \\ 0 \leq \lambda_j^k \perp (f_j^k - f(x^k) + (g^j)^T d^k - z^k - \delta^k) &\leq 0, j \in J^k, \\ 0 \leq \lambda_p^k \perp (f_p^k - f(x^k) + (p^{k-1})^T d^k - z^k - \delta^k) &\leq 0, \\ 0 \leq \mu_i^k \perp (c_i(x^k) + \nabla c_i(x^k)^T d^k - z^k) &\leq 0, i \in I_-^k, \\ 0 \leq \mu_i^k \perp (c_i(x^k) + \nabla c_i(x^k)^T d^k - z^k - \varphi^k) &\leq 0, i \in I_+^k. \end{aligned} \quad (1.2)$$

计算满足如下关系的聚集次梯度 p^k 和聚集函数值 \tilde{f}_p^k :

$$\theta^k(p^k, \tilde{f}_p^k) = \sum_{j \in J^k} \lambda_j^k (g^j, f_j^k) + \lambda_p^k (p^{k-1}, f_p^k), \quad (1.3)$$

$$\text{其中 } \theta^k = \sum_{j \in J^k} \lambda_j^k + \lambda_p^k.$$

以下引理给出了子问题(1.1)解的重要性质, 其证明类似于文献[2]的引理 2.2.

引理 1.2 设 (d^k, z^k) 是子问题(1.1)的最优解, 则

$$\begin{aligned} \text{(i)} \quad & z^k = -(\gamma^k \|d^k\|^2 + \tilde{\alpha}^k) \leq 0, \text{ 其中} \\ & \tilde{\alpha}^k = \theta^k (f(x^k) - \tilde{f}_p^k + \delta^k) - \sum_{i \in I_-^k} \mu_i^k c_i(x^k) - \sum_{i \in I_+^k} \mu_i^k (c_i(x^k) - \varphi^k); \end{aligned}$$

(ii) $-\gamma^k d^k$ 是函数 $H_{x^k}(\cdot)$ 在 x^k 处的 ϵ 次梯度, 即 $-\gamma^k d^k \in \partial_\epsilon H_{x^k}(x^k)$, 其中 $\epsilon = \tilde{\alpha}^k$;

(iii) 如果 $z^k = 0$, 则 $d^k = 0$ 且 x^k 是问题(0.1)的最优解.

算法 1.1

步骤 0 (初始化). 选取初始点 $x^1 \in R^n$, 次梯度 $g^1 \in \partial f(x^1)$, 及参数 $\beta \in (0, 1), \eta \in (0.5, 1), \gamma_{\min} > 0, \gamma^1 > 0$. 令 $y^1 = x^1, p^0 = g^1, f_p^1 = f_1^1 = f(x^1), J^1 = \{1\}$. 置 $k=1, l=0$ 及 $k(0)=1$.

步骤 1 (计算方向). 求解子问题(1.1)得到最优解 (d^k, z^k) 及乘子 $\lambda_j^k, j \in J^k, \lambda_p^k, \mu_i^k, i \in I$. 根据(1.3)式计算 p^k 及 \tilde{f}_p^k .

步骤 2 (终止准则). 令 $\omega^k = \frac{1}{2} \|\gamma^k d^k\|^2 +$

$\gamma^k \tilde{\alpha}^k$. 如果 $\omega^k = 0$, 终止; 否则转步骤 3.

步骤 3 (线搜索). 计算试探步长 t^k , 它是序列 $\{1, \beta, \beta^2, \dots\}$ 中第一个满足以下不等式的 t 值:

$$c_i(x^k + td^k) \leq \varphi^k + \eta tz^k, i \in I_+, \quad (1.4)$$

$$c_i(x^k + td^k) \leq \eta tz^k, i \in I^k. \quad (1.5)$$

如果

$$f(x^k + t^k d^k) \leq f(x^k) + \eta^k z^k + t^k \delta^k \quad (1.6)$$

成立, 则令 $t_L^k = t^k$ (有效步) 及辅助步长 $t_R^k = t^k$, 置 $k(l+1) = k+1, l := l+1$; 否则令 $t_L^k = 0$ (无效步) 及 $t_R^k = t^k$.

步骤 4 (更新). 令 $x^{k+1} = x^k + t_L^k d^k, y^{k+1} = x^k + t_R^k d^k$. 选取 $\hat{J}^k \subseteq J^k$, 并计算新的线性化函数值

$$f_j^{k+1} = f_j(x^{k+1}) = f_j^k + (g^j)^T (x^{k+1} - x^k), j \in \hat{J}^k,$$

$$f_p^{k+1} = \tilde{f}_p^k + (p^k)^T (x^{k+1} - x^k).$$

计算 $g^{k+1} \in \partial f(y^{k+1})$, 以及 $f^{k+1} = f(y^{k+1}) + (g^{k+1})^T (x^{k+1} - y^{k+1})$. 令 $J^{k+1} = \hat{J}^k \cup \{k+1\}$,

步骤 5 (邻近点参数修正). 令

$$\gamma^{k+1} = \begin{cases} \max\{u^{k+1}, \frac{\gamma^k}{10}, \gamma_{\min}\}, & \text{如果 } x^{k+1} \neq x^k; \\ \gamma^k, & \text{否则,} \end{cases}$$

其中 $u^{k+1} = 2\gamma^k (1 - \frac{H_{x^k}(x^{k+1})}{t^k z^k})$.

步骤 6 令 $k := k+1$, 返回步骤 1.

注 1 步骤 5 给出了一个新的邻近点参数修正策略, 其用意在于: 当 $x^{k+1} \neq x^k$ (有效步) 时, 当前的分片线性化近似模型较好, 从而在下次迭代可以适当加大步长, 因此需要减小邻近点参数 γ^k (见下面引理 2.1); 反之, 模型近似程度较差, 可保持邻近点参数不变或增大参数 (此处, 为简便描述, 我们保持邻近点参数不变, 若适当增加, 也不会影响下面的理论分析^[5]).

下面的引理给出了算法 1.1 的基本性质.

引理 1.3 (i) 算法 1.1 是适定的, 即线搜索 (1.4) 和 (1.5) 能在有限次计算后终止;

(ii) 算法 1.1 必定出现以下两种情形之一: (a) 存在指标 k_0 使得 $\varphi^{k_0} = 0$, 从而 $\varphi^k \equiv 0, \delta^k \equiv 0$ 及 $f(x^{k+1}) \leq f(x^k)$, 对所有 $k \geq k_0$ 成立; (b) $\varphi^k > 0, \varphi^{k+1} \leq \varphi^k, I^k \subseteq I^{k+1}, k=1, 2, 3, \dots$.

证明 (i) 根据引理 1.2, 若算法进入步骤 3, 则有 $z^k < 0$. 由 Taylor 展开, 及 (1.2) 可得

$$c_i(x^k + td^k) - \varphi^k - \eta^k z^k = c_i(x^k) - \varphi^k - \eta^k z^k + t \nabla c_i(x^k)^T d^k + o(t) \leq (1-t)(c_i(x^k) - \varphi^k) + (1-\eta)tz^k + o(t) \leq (1-\eta)tz^k + o(t), i \in I_+.$$

再结合 $z^k < 0, \eta \in (0.5, 1)$ 可知 (1.4) 式对 $t > 0$ 充分小成立. 另一方面, 根据

$$c_i(x^k + td^k) - \eta^k z^k = c_i(x^k) + t \nabla c_i(x^k)^T d^k - \eta^k z^k + o(t) \leq (1-t)c_i(x^k) + (1-\eta)tz^k + o(t) \leq (1-\eta)tz^k + o(t), i \in I^k,$$

知 (1.5) 式对 $t > 0$ 充分小成立, 故 (i) 得证.

由算法 1.1 的步骤 3 易知 (ii) 成立.

2 算法全局收敛性

若算法 1.1 有限步终止于 x^k 点, 则由步骤 2 可知 $\omega^k = 0$, 进而有 $z^k = 0$, 故根据引理 1.2(iii) 可得 x^k 是问题 (0.1) 的一个最优解. 现假设算法产生一个无限迭代序列 $\{x^k\}$, 以下将证明其任意一个聚点都是问题 (0.1) 的最优解.

引理 2.1 邻近点参数序列 $\{\gamma^k\}$ 单调不增, 且有正的下界.

证明 当 $x^{k+1} \neq x^k$ 时, 由线搜索 (1.4) ~ (1.6) 可知 $H_{x^k}(x^{k+1}) \leq \eta t^k z^k < 0$, 故结合 $\eta \in (0.5, 1)$ 得

$$u^{k+1} = 2\gamma^k (1 - \frac{H_{x^k}(x^{k+1})}{t^k z^k}) \leq 2\gamma^k (1 - \eta) < \gamma^k.$$

再结合算法 1.1 的步骤 5 可知引理 2.1 成立.

引理 2.2 设有无限指标集 $K \subseteq \{1, 2, \dots\}$ 及 $\bar{x} \in R^n$ 满足 $x^k \xrightarrow{K} \bar{x}$ 及 $\omega^k \xrightarrow{K} 0$, 则 \bar{x} 是问题 (0.1) 的最优解.

证明 由 $\omega^k \xrightarrow{K} 0$ 及引理 2.1 可得 $\gamma^k d^k \rightarrow 0, \tilde{\alpha}^k \rightarrow 0, k \in K$. 故由 $x^k \xrightarrow{K} \bar{x}$ 及引理 1.2(ii) 知 $0 \in \partial H_{\bar{x}}(\bar{x})$, 故再由引理 1.1 可得引理 2.2 成立.

以下分两种情形证明算法的全局收敛性. 首先分析算法产生无限多个有效步的情形. 类似文献 [2] 引理 3.3 的分析, 可得如下引理.

引理 2.3 设有无限指标集 $L \subseteq \{1, 2, \dots\}$ 和向量 $\bar{x} \in R^n$ 使得 $x^{k(l)} \rightarrow \bar{x}, l \rightarrow \infty, l \in L$, 则 \bar{x} 是问题 (0.1) 的一个最优解.

下面分析有限个有效步的情形, 即存在指标 \bar{k} 使得 $x^k = x^{\bar{k}}, k \geq \bar{k}$. 我们将证明 $x^{\bar{k}}$ 是问题 (0.1) 的最优解. 根据算法 1.1 步骤 5 可知, 存在常数 $\gamma > 0$, 使得 $\gamma^k \equiv \gamma, \forall k \geq \bar{k}$. 不失一般性, 在以下分析中我们将假设 $k \geq \bar{k}$.

引理 2.4 ω^k 是如下二次规划问题的最优值

$$\min \frac{1}{2} \left\| \sum_{j \in J^k} \lambda_j g^j + \lambda_p p^{k-1} + \sum_{i \in I} \mu_i \nabla c_i(x^k) \right\|^2 - \gamma^k \sum_{j \in J^k} \lambda_j (f_j^k - f(x^k) - \delta^k) - \gamma^k \lambda_p (f_p^k - f(x^k) - \delta^k) - \gamma^k \sum_{i \in I_-} \mu_i c_i(x^k) - \gamma^k \sum_{i \in I_+} \mu_i (c_i(x^k) - \varphi^k)$$

$$s. t. \lambda_j \geq 0, j \in J^k, \lambda_p \geq 0, \mu_i \geq 0, i \in I,$$

$$\sum_{j \in J^k} \lambda_j + \lambda_p + \sum_{i \in I} \mu_i = 1. \quad (2.1)$$

证明 由于问题(2.1)是子问题(1.1)的对偶问题,因此(1.1)的KKT乘子是问题(2.1)的最优解,再结合 w^k 的定义可得结论成立.

接下来,我们推广文献[4]的引理2.4.10的结果,得到如下引理.

引理 2.5 设 n 维向量 d, g ,及数 $\eta \in (0.5, 1)$, $\gamma > 0, C, w, z, \tilde{\alpha}$ 和 α 满足

$$w = \frac{1}{2} \|\gamma d\|^2 + \gamma \tilde{\alpha}, z = -(\gamma \|d\|^2 + \tilde{\alpha}), -\alpha +$$

$$g^T d \geq \gamma \tilde{\alpha}, C \geq \max\{\|\gamma d\|, \|g\|, \tilde{\alpha}, 1\}.$$

令 $\bar{w} = \min\{Q(v): v \in [0, 1]\}$,其中

$$Q(v) = \frac{1}{2} \|(1-v)(-\gamma d) + vg\|^2 + \gamma[(1-v)$$

$$v)\tilde{\alpha} + \alpha].$$

则 $\bar{w} \leq \phi_C(w)$,其中 $\phi_C(t) = t - (1-\eta)^2 t^2 / (8C^2)$.

引理 2.6 假设对某个 $k > 1$ 有 $t_k^{k-1} = 0$,令 $\alpha^k = f(x^k) - f_k^k$,则

$$(i) -(\alpha^k + \delta^{k-1}) + (g^k)^T d^{k-1} \geq \gamma \tilde{\alpha}^{k-1}; \quad (2.2)$$

$$(ii) w^k \leq \phi_C(w^{k-1}), \quad (2.3)$$

其中 C^k 满足 $C^k \geq \max\{\|\gamma d^{k-1}\|, \|g^k\|, \tilde{\alpha}^{k-1}, 1\}$.

证明 (i) 根据线搜索(1.6),该部分的证明与文献[2]的引理3.6(i)完全平行.

(ii) 对任意 $v \in [0, 1]$,定义乘子

$$\lambda_k(v) = v, \lambda_j(v) = 0, j \in J^k \setminus \{k\}, \lambda_p(v) = (1-v)\theta^{k-1}, \mu_i(v) = (1-v)\mu_i^{k-1}, i \in I, \quad (2.4)$$

其为问题(2.1)的一个可行解.此外,我们有

$$\sum_{j \in J^k} \lambda_j(v) g^j + \lambda_p(v) p^{k-1} + \sum_{i \in I} \mu_i(v) \nabla c_i(x^k) =$$

$$vg^k + (1-v)\theta^{k-1} p^{k-1} + (1-v) \sum_{i \in I} \mu_i^{k-1} \nabla c_i(x^{k-1}) =$$

$$vg^k + (1-v)(-\gamma d^{k-1}),$$

$$- \sum_{j \in J^k} \lambda_j (f_j^k - f(x^k) - \delta^k) - \lambda_p (f_p^k - f(x^k) -$$

$$\delta^k) - \sum_{i \in I_-} \mu_i c_i(x^k) - \sum_{i \in I_+} \mu_i (c_i(x^k) - \varphi^k) = -v(f_k^k -$$

$$f(x^k) - \delta^k) - (1-v)\theta^{k-1} (f_p^k - f(x^k) - \delta^k) - (1-$$

$$v) \sum_{i \in I_-} \mu_i^{k-1} c_i(x^k) - (1-v) \sum_{i \in I_+} \mu_i^{k-1} (c_i(x^k) -$$

$$\varphi^k) = v(\alpha^k + \delta^{k-1}) + (1-v)\tilde{\alpha}^{k-1}.$$

设 \bar{w} 为如下问题的最优值

$$\min \frac{1}{2} \|(1-v)(-\gamma d^{k-1}) + vg^k\|^2 + \gamma[(1-v)$$

$$v)\tilde{\alpha}^{k-1} + v(\alpha^k + \delta^{k-1})]$$

$$s. t. v \in [0, 1]. \quad (2.5)$$

则由引理2.4可知 $w^k \leq \bar{w}$.在引理2.5中令 $d = d^{k-1}$, $\tilde{\alpha} = \tilde{\alpha}^{k-1}$, $w = w^{k-1}$, $z = z^{k-1}$, $g = g^k$, $\alpha = \alpha^k + \delta^{k-1}$, γ 取为邻近点参数,并结合(2.2),可得 $w^k \leq \bar{w} \leq \phi_C(w^{k-1})$,故(ii)得证.

基于上述分析,可得全局收敛性定理.

定理 2.1 算法1.1或有限步终止于问题(0.1)的一个最优解,或产生一个无限迭代序列 $\{x^k\}$,使得其任意的聚点都是问题(0.1)的最优解.

证明 若算法1.1有限步终止于 x^k 点,则根据引理1.2(iii)可得 x^k 是问题(0.1)的一个最优解.现假设算法1.1产生一个无限迭代序列 $\{x^k\}$,且 x^* 为任一给定的聚点.下面分两种情形证明.

情形 I 有无限多个有效步.此时,必存在无限指标集 $L \subseteq \{1, 2, \dots\}$ 使得 $x^{k(l)} \rightarrow x^*$, $l \rightarrow \infty, l \in L$.因此,由引理2.3可知 x^* 是问题(0.1)的最优解.

情形 II 有限多个有效步.则存在指标 \bar{k} 使得 $x^k \equiv x^{\bar{k}} = x^*$, $\gamma^k \equiv \gamma, \forall k \geq \bar{k}$.此时,存在一个常数 $C > 0$ 使得

$$C \geq \max\{\|\gamma d^{k-1}\|, \|g^k\|, \tilde{\alpha}^{k-1}, 1\}, \forall k \geq \bar{k}.$$

结合(2.3)式,说明

$$w^k \leq \phi_C(w^{k-1}) = w^{k-1} - (1-\eta)^2 (w^{k-1})^2 / (8C^2),$$

进而有 $w^k \rightarrow 0, k \rightarrow \infty$.因此,由引理2.2可知 x^* 是问题(0.1)的一个最优解.

参考文献:

- [1] 简金宝.光滑约束优化快速算法——理论分析与数值试验[M].北京:科学出版社,2010.
Jian J B. Fast algorithms for smooth constrained optimization: theoretical analysis and numerical experiments [M]. Beijing, Science Press, 2010.
- [2] Tang C M, Jian J B. Strongly sub-feasible direction method for constrained optimization problems with non-smooth objective functions[J]. European Journal of Operational Research, 2012, 218: 28-37.
- [3] 唐春明,简金宝.基于次梯度选取的非光滑优化强次可行方向法[J].应用数学学报,2011,34(5):924-937.
Tang C M, Jian J B. Strongly sub-feasible direction method with subgradient selection for nonsmooth optimization [J]. Acta Mathematicae Applicatae Sinica, 2011, 34(5): 924-937.
- [4] Kiwiel K C. Methods of descent for nondifferentiable optimization[M]. [S. L.]: Lecture Notes in Mathematics 1133, Springer-Verlag, 1985.
- [5] Kiwiel K C. Proximity control in bundle methods for convex nondifferentiable minimization[J]. Mathematical Programming, 1990, 46: 105-122.

(责任编辑:尹 闯)