

基于非精确数据的非光滑优化强次可行方向法*

Strongly Sub-feasible Direction Method with Inexact Data for Nonsmooth Optimization

唐春明, 律金曼

TANG Chunming, LV Jinman

(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: 本研究针对一类目标函数非光滑优化问题, 提出一个基于非精确数据的强次可行方向法. 通过构造新的寻找搜索方向子问题和新型线搜索, 该算法能够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 强次可行方向法 非精确数据

中图分类号: C934 **文献标识码:** A **文章编号:** 1005-9164(2016)05-0404-05

Abstract: In this paper, a strongly sub-feasible direction method with inexact data is proposed for solving a class of optimization problems with nonsmooth objectives. By constructing a new search direction finding subproblem and a new line search, the strongly sub-feasibility of the iteration points is guaranteed, and the global convergence of the algorithm is proved.

Key words: nonsmooth optimization, strongly sub-feasible direction method, inexact data

0 引言

考虑如下非线性不等式约束优化问题

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

其中 $f: \mathbb{R}^n \rightarrow \mathbb{R}$ 是凸函数但不一定光滑, $c_i (i \in I): \mathbb{R}^n \rightarrow \mathbb{R}$ 是连续可微的凸函数.

在一些实际问题中, 有时很难精确计算 f 的函数值. 例如, f 是如下 \max -型函数

$$f(x) = \max\{F_u(x) : u \in U\}, \quad (0.2)$$

其中对任意给定的 $u \in U$, $F_u: \mathbb{R}^n \rightarrow \mathbb{R}$ 是凸函数, U 是

一个无限集, 此时无法计算 f 的精确值. 然而, 对于任意正数 ϵ , 可以在有限的时间内找出 $(0, 2)$ 的一个 ϵ -解, 即找出一个 $u_\epsilon \in U$ 满足 $F_{u_\epsilon}(x) \geq f(x) - \epsilon$, 从而得到 $f(x)$ 的近似值. 因此, 研究基于非精确数据的优化方法具有重要的意义^[1-3].

文献[4]基于精确数据, 提出一个求解问题(0.1)的强次可行方向法, 其优点在于能接受不可行的初始点, 且一旦产生一个可行迭代点, 即自动变为可行下降算法. 此外, 算法可保证迭代点的强次可行性, 同时能防止目标函数过度增大. 文献[2]中提出一种非精确数据的思想, 即假设对于给定的点 x 和误差限 $\epsilon \geq 0$, 能够计算得到近似的函数值 $f_\epsilon(x) \approx f(x)$ 和一个近似的次梯度 $g_\epsilon \approx g \in \partial f(x)$ 满足:

$$f_\epsilon(x) \in [f(x) - \epsilon, f(x) + \epsilon],$$

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

本研究旨在对文献[4]的方法进行改进, 结合文献[2]的思想, 提出一个基于非精确数据的非光滑优化强次可行方向法.

收稿日期: 2016-08-05

修回日期: 2016-09-20

作者简介: 唐春明(1979-), 男, 博士, 教授, 主要从事最优化理论、方法及其应用研究, E-mail: cmtang@gxu.edu.cn.

* 国家自然科学基金项目(11301095, 11271086)和广西自然科学基金项目(2013GXNSFAA019013, 2014GXNSFFA118001)资助.

1 算法

假设 $y^j, j=1, \dots, k$ 为试探点列, $\epsilon^j \geq 0$ 为相应的误差限, $f_{\epsilon^j}(y^j)$ 和 $g_{\epsilon^j}^j$ 分别为 y^j 处函数值和次梯度的近似, 满足 $f_{\epsilon^j}(y^j) \in [f(y^j) - \epsilon^j, f(y^j) + \epsilon^j]$ 及 $g_{\epsilon^j}^j \in \partial_{\epsilon^j} f(y^j)$. 记 $g^j = g_{\epsilon^j}^j$, 因此 f 在 y^j 处的近似线性化可定义为^[2]

$$f_j(x) = f_{\epsilon^j}(y^j) + \langle g^j, x - y^j \rangle - 2\epsilon^j. \quad (1.1)$$

由 $g^j \in \partial_{\epsilon^j} f(y^j)$ 和 $f(y^j) \geq f_{\epsilon^j}(y^j) - \epsilon^j$ 可知

$$f_j(x) \leq f(x), \forall x \in \mathbb{R}^n. \quad (1.2)$$

进而可定义 f 的近似割平面模型

$$\hat{f}^k(x) = \max\{f_j(x), j=1, \dots, k\}.$$

记问题(0.1)的可行集 $F = \{x \in \mathbb{R}^n : c_i(x) \leq 0, i \in I\}$. 定义指标集 $I_-(x) = \{i \in I : c_i(x) \leq 0\}$, $I_+(x) = \{i \in I : c_i(x) > 0\}$, 约束违反函数 $\varphi(x) = \max\{0, c_i(x), i \in I\}$. 引入改进函数^[4]:

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

其中 $\delta(x) : \mathbb{R}^n \rightarrow [0, +\infty)$ 连续, 并满足 $\delta(x) = 0$ 当且仅当 $x \in F$. 对于第 k 次迭代, 缩写 $I_-^k = I_-(x^k)$, $I_+^k = I_+(x^k)$, $\varphi^k = \varphi(x^k)$, $\delta^k = \delta(x^k)$.

下面给出改进函数的性质.

引理 1.1^[4] 若问题(0.1)满足 Slater 约束规格, 即存在一个向量 $x' \in \mathbb{R}^n$ 满足 $c_i(x') < 0, \forall i \in I$, 则以下 3 个命题等价: (i) \bar{x} 是问题(0.1)的最优解; (ii) $\min\{H(y; \bar{x}) : y \in \mathbb{R}^n\} = H(\bar{x}; \bar{x}) = 0$; (iii) $0 \in \partial H(\bar{x}; \bar{x})$.

基于引理 1.1, 并结合邻近点方法思想^[5], 选取新的试探点如下:

$$y^{k+1} = \arg \min\{H(y; x^k) + \frac{1}{2}\rho^k \|y - x^k\|^2 : y \in \mathbb{R}^n\}, \quad (1.3)$$

其中 $\rho^k > 0$ 是邻近参数, $x^k \in \{y^j\}_{j=1}^k$ 为邻近中心点. 然而, 问题(1.3)的求解较困难. 因此, 基于非精确数据, 并结合文献^[4]的思想, 本文提出如下寻找搜索方向子问题:

$$\begin{aligned} \min_{d \in \mathbb{R}^n, z \in \mathbb{R}} \quad & z + \frac{1}{2}\rho^k \|d\|^2, \\ \text{s. t.} \quad & -\alpha_j^k + \langle g^j, d \rangle \leq z + \delta^k, j \in J^k, \\ & -\alpha_s^k + \langle s^{k-1}, d \rangle \leq z + \delta^k, \\ & c_i(x^k) + \langle \nabla c_i(x^k), d \rangle \leq z, i \in I_-^k, \\ & c_i(x^k) + \langle \nabla c_i(x^k), d \rangle \leq z + \varphi^k, i \in I_+^k, \end{aligned} \quad (1.4)$$

其中 $z \in \mathbb{R}$ 是一个辅助变量, $J^k \subseteq \{1, \dots, k\}, \alpha_j^k = f_{\epsilon^j}(x^k) - f_j^k + \epsilon, \alpha_s^k = f_{\epsilon^s}(x^k) - f_s^k + \epsilon, f_j^k = f_j(x^k); s^{k-1}$

和 f_s^k 分别为过往的近似函数值和次梯度的聚集(具体将在算法中明确), 文献^[6]中证明存在 $\bar{\lambda}_j \geq 0, j=1, \dots, k-1$, 使得

$$(s^{k-1}, f_s^k) = \sum_{j=1}^{k-1} \bar{\lambda}_j (g^j, f_j^k), \sum_{j=1}^{k-1} \bar{\lambda}_j = 1. \quad (1.5)$$

设 (d^k, z^k) 是(1.4)式的最优解. 由于(1.4)式是一个带线性约束的凸规划, 故 (d^k, z^k) 亦为(1.4)式的 KKT 点, 即存在乘子 $\lambda_j^k, j \in J^k, \lambda_s^k, \mu_i^k, i \in I$, 使得

$$\begin{aligned} \rho^k d^k + \sum_{j \in J^k} \lambda_j^k g^j + \lambda_s^k s^{k-1} + \sum_{i \in I} \mu_i^k \nabla c_i(x^k) &= 0, \\ \sum_{j \in J^k} \lambda_j^k + \lambda_s^k + \sum_{i \in I} \mu_i^k &= 1, \\ 0 \leq \lambda_j^k \perp (-\alpha_j^k + \langle g^j, d^k \rangle - z^k - \delta^k) &\leq 0, j \in J^k, \\ 0 \leq \lambda_s^k \perp (-\alpha_s^k + \langle s^{k-1}, d^k \rangle - z^k - \delta^k) &\leq 0, \\ 0 \leq \mu_i^k \perp (c_i(x^k) + \langle \nabla c_i(x^k), d^k \rangle - z^k) &\leq 0, i \in I_-^k, \\ 0 \leq \mu_i^k \perp (c_i(x^k) + \langle \nabla c_i(x^k), d^k \rangle - z^k - \varphi^k) &\leq 0, i \in I_+^k. \end{aligned} \quad (1.6)$$

更新聚集次梯度如下:

$$(s^k, \tilde{f}_s^k) = \frac{1}{\theta^k} \left(\sum_{j \in J^k} \lambda_j^k (g^j, f_j^k) + \lambda_s^k (s^{k-1}, f_s^k) \right), \quad (1.7)$$

其中 $\theta^k = \sum_{j \in J^k} \lambda_j^k + \lambda_s^k$ (不失一般性假设 $\theta^k > 0$).

$$\text{记 } \tilde{\alpha}_s^k = f_{\epsilon^s}(x^k) - \tilde{f}_s^k + \epsilon, \text{ 有 } \sum_{j \in J^k} \lambda_j^k \alpha_j^k + \lambda_s^k \alpha_s^k = \theta^k \tilde{\alpha}_s^k.$$

以下引理给出子问题(1.4)的解的性质.

引理 1.2 设 (d^k, z^k) 是问题(1.4)的最优解, 则

$$(i) z^k = -(\rho^k \|d^k\|^2 + \tilde{\alpha}^k), \quad (1.8)$$

其中,

$$\tilde{\alpha}^k = \theta^k (\tilde{\alpha}_s^k + \delta^k) - \sum_{i \in I_-^k} \mu_i^k c_i(x^k) - \sum_{i \in I_+^k} \mu_i^k (c_i(x^k) - \varphi^k). \quad (1.9)$$

$$(ii) g^j \in \partial_{\epsilon^j} f(x^k), \epsilon = \alpha_j^k, j=1, \dots, k,$$

$$s^k \in \partial_{\epsilon^s} f(x^k), \epsilon = \tilde{\alpha}_s^k,$$

$$-\rho^k d^k \in \partial H(x^k; x^k), \epsilon = \tilde{\alpha}^k. \quad (1.10)$$

(iii) 如果 $z^k = 0$, 则 $d^k = 0$, 且 x^k 是问题(0.1)的一个最优解.

证明 (i) 由 KKT 条件(1.6)中的互补关系和(1.7)式有

$$\begin{aligned} z^k &= -\rho^k \|d^k\|^2 + \sum_{j \in J^k} \lambda_j^k (-\alpha_j^k - \delta^k) + \\ &\lambda_s^k (-\alpha_s^k - \delta^k) + \sum_{i \in I_-^k} \mu_i^k c_i(x^k) + \sum_{i \in I_+^k} \mu_i^k (c_i(x^k) - \end{aligned}$$

$$\varphi^k) = -\rho^k \|d^k\|^2 - \theta^k(\check{\alpha}_s^k + \delta^k) + \sum_{i \in I_+^k} \mu_i^k c_i(x^k) +$$

$$\sum_{i \in I_+^k} \mu_i^k (c_i(x^k) - \varphi^k) = -(\rho^k \|d^k\|^2 + \check{\alpha}_s^k).$$

故(1.8)式成立.

(ii) 由(1.2)式知,

$$\begin{aligned} f(x) &\geq f_j(x) = f_j^k + \langle g^j, x - x^k \rangle = f(x^k) - \\ f(x^k) &+ f_j^k + \langle g^j, x - x^k \rangle \geq f(x^k) + \langle g^j, x - \\ x^k \rangle &+ f_j^k - (f_\varepsilon(x^k) + \varepsilon) = f(x^k) + \langle g^j, x - x^k \rangle - \alpha_j^k, \end{aligned} \quad (1.11)$$

从而(1.10)式的第一个式子成立. 类似地, 根据(1.5)式知

$$f(x) \geq f(x^k) + \langle s^{k-1}, x - x^k \rangle - \alpha_s^k. \quad (1.12)$$

在(1.11)式和(1.12)式两边分别乘以 $\lambda_j^k, j \in J^k$ 和 λ_s^k 再进行求和, 有

$$f(x) \geq f(x^k) + \langle s^k, x - x^k \rangle - \check{\alpha}_s^k, \quad (1.13)$$

故(1.10)式的第二个式子成立.

根据 c_i 的凸性, 有

$$c_i(x) \geq c_i(x^k) + \langle \nabla c_i(x^k), x - x^k \rangle.$$

因此,

$$\sum_{i \in I} \mu_i^k c_i(x) \geq \sum_{i \in I} \mu_i^k (c_i(x^k) + \langle \nabla c_i(x^k), x - x^k \rangle).$$

此式结合(1.6)式, (1.13)式, $\theta^k \leq 1$ 及 $H(x^k; x^k) = 0$ 可得

$$\begin{aligned} H(x; x^k) &= \max\{f(x) - f(x^k) - \delta^k; c_i(x), i \in \\ I_+^k; &c_i(x) - \varphi^k, i \in I_+^k\} \geq \theta^k (f(x) - f(x^k) - \delta^k) + \\ \sum_{i \in I} &\mu_i^k c_i(x) - \sum_{i \in I_+^k} \mu_i^k \varphi^k \geq \theta^k (\langle s^k, x - x^k \rangle - \check{\alpha}_s^k - \delta^k) + \\ \sum_{i \in I} &\mu_i^k c_i(x^k) + \sum_{i \in I} \mu_i^k \langle \nabla c_i(x^k), x - x^k \rangle - \sum_{i \in I_+^k} \mu_i^k \varphi^k = \\ H(x^k; &x^k) + \langle -\rho^k d^k, x - x^k \rangle - (\theta^k(\check{\alpha}_s^k + \delta^k) - \\ \sum_{i \in I_+^k} &\mu_i^k c_i(x^k) - \sum_{i \in I_+^k} \mu_i^k (c_i(x^k) - \varphi^k)) = H(x^k; x^k) + \\ \langle -\rho^k &d^k, x - x^k \rangle - \check{\alpha}_s^k. \end{aligned}$$

由此证明(1.10)式的第三个式子.

(iii) 由于 $\check{\alpha}_s^k \geq 0$, 故由(1.8)式知, 当 $z^k = 0$ 时有 $\rho^k d^k = 0$ 和 $\check{\alpha}_s^k = 0$, 从而 $0 \in \partial H(x^k; x^k)$. 故根据引理 1.1(iii) 知 x^k 是问题(0.1)的一个最优解.

算法 1.1

步骤 0(初始化) 选取初始点 $x^1 \in \mathbf{R}^n$, 初始误差限 $\varepsilon^1 \geq 0$, 终止参数 $\varepsilon_{\text{tol}} \geq 0$, 线搜索参数 $\beta \in (0, 1)$, 邻近参数 $\rho_{\min} > 0, \rho^1 > \rho_{\min}$, 步长下界 $\underline{t} \in (0, 0.1]$. 选择两个线搜索参数 m_L 和 m_R 满足 $0 < m_L < m_R < 1$. 令 $y^1 = x^1, s^0 = g^1 \in \partial_{\varepsilon^1} f(x^1), f_s^1 = f^1 = f_{\varepsilon^1}(x^1), J^1 = \{1\}$. 置 $k = 1, l = 0$ 及 $k(0) = 1$.

步骤 1(寻找搜索方向) 令 $\varepsilon = \varepsilon^k$, 求解子问题(1.4) 得到最优解 (d^k, z^k) 和乘子 $\lambda_j^k, j \in J^k, \lambda_s^k, \mu_i^k, i \in I$. 根据(1.7)式计算 s^k, \check{f}_s^k 和 α_s^k .

步骤 2(误差限更新) 如果 $\varepsilon^k > -(m_R - m_L) \underline{t} z^k / 5$, 置 $\varepsilon^k = \varepsilon^k / 2$ 并返回步骤 1; 否则, 转步骤 3.

步骤 3(终止准则) 如果 $z^k \geq -\varepsilon_{\text{tol}}$, 算法终止; 否则, 转步骤 4.

步骤 4(线搜索) 计算试探步长 t^k , 它是序列 $\{1, \beta, \beta^2, \dots\}$ 中第一个满足下列不等式组的 t 值:

$$c_i(x^k + t d^k) \leq \varphi^k + m_L t z^k, i \in I_+^k, \quad (1.14)$$

$$c_i(x^k + t d^k) \leq 0, i \in I_-^k. \quad (1.15)$$

如果

$f_{\varepsilon^k}(x^k + t^k d^k) \leq f_{\varepsilon^k}(x^k) + m_L t^k z^k + t^k \delta^k - 2\varepsilon^k$, 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 $t_R^k = \max\{\underline{t}, t^k\}$.

步骤 5(更新) 令 $\varepsilon^{k+1} = \varepsilon^k, x^{k+1} = x^k + t_l^k d^k, y^{k+1} = x^k + t_R^k d^k$. 选取 $\hat{J}^k \subseteq J^k$ 并令 $J^{k+1} = \hat{J}^k \cup \{k+1\}$, 计算 $g^{k+1} \in \partial_{\varepsilon^{k+1}} f(y^{k+1})$ 及 $f_{k+1}^{k+1} = f_{\varepsilon^{k+1}}(y^{k+1}) + \langle g^{k+1}, x^{k+1} - y^{k+1} \rangle - 2\varepsilon^{k+1}$,

$$f_j^{k+1} = f_j^k + \langle g^j, x^{k+1} - x^k \rangle, j \in \hat{J}^k,$$

$$f_s^{k+1} = \check{f}_s^k + \langle s^k, x^{k+1} - x^k \rangle. \quad (1.16)$$

步骤 6(邻近参数选择) 如果 $x^{k+1} \neq x^k$, 取 $\rho^{k+1} \in [\rho_{\min}, \rho^k]$; 否则, $\rho^{k+1} = \rho^k$.

步骤 7 令 $k := k+1$, 返回步骤 1.

引理 1.3^[4] 算法 1.1 是适定的, 即线搜索(1.14)和(1.15)能在有限次计算后终止.

引理 1.4 算法 1.1 必定出现以下两种情形之一.

(i) 存在一个指标 k_0 使得 $\varphi^{k_0} = 0$, 从而 $\varphi^k \equiv 0, \delta^k \equiv 0$ 和 $f(x^{k+1}) \leq f(x^k)$, 对于所有的 $k \geq k_0$ 成立;

(ii) 对任意的 k , 有 $\varphi^k > 0, \varphi^{k+1} \leq \varphi^k, I_-^k \subseteq I_-^{k+1}$.

证明 (i) 由步骤 4 可知, $\varphi^k \equiv 0$ 及 $\delta^k \equiv 0$ 对 $k \geq k_0$ 成立. 现证明 $f(x^{k+1}) \leq f(x^k)$. 根据步骤 4, 如果是一个有效步, 由 $z^k < 0$ 可得

$$f(x^{k+1}) \leq f_{\varepsilon^k}(x^{k+1}) + \varepsilon^k \leq f_{\varepsilon^k}(x^k) + m_L t_l^k z^k - \varepsilon^k \leq f(x^k) + m_L t_l^k z^k \leq f(x^k).$$

若是一个无效步, 则有 $f(x^{k+1}) = f(x^k)$.

(ii) 根据线搜索(1.14)和(1.15)易证.

2 算法的收敛性

在以下收敛分析中取 $\varepsilon_{\text{tol}} = 0$. 若算法有限步终止于 x^k 点, 则由步骤 3 可知 $z^k = 0$, 因此由引理 1.2(iii) 得 x^k 是问题(0.1)的一个最优解. 假设算法

产生一个无限迭代点列, 以下将证明该序列的任一聚点都是问题(0.1)的一个最优解. 根据引理 1.4, 在下面的分析中不妨假设 $I_-^k \equiv I_-$, $I_+^k \equiv I_+$.

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

证明 根据步骤 6, 显然 $\{\rho^k\}$ 单调不增, 且 $\rho^k \geq \rho_{\min} > 0$.

引理 2.2 假设存在无限指标集 $K \subseteq \{1, 2, \dots\}$ 和一个点 $\bar{x} \in \mathbf{R}^n$ 满足 $x^k \xrightarrow{K} \bar{x}$ 及 $z^k \xrightarrow{K} 0$, 则 \bar{x} 是问题(0.1)的一个最优解.

证明 由 $z^k \xrightarrow{K} 0$ 和(1.8)式知 $\rho^k d^k \rightarrow 0, \check{\alpha}^k \rightarrow 0, k \in K$. 故由 $x^k \xrightarrow{K} \bar{x}$ 及引理 1.2 知 $0 \in \partial H(\bar{x}; \bar{x})$, 因此 \bar{x} 是问题(0.1)的一个最优解.

分两种情形证明. 首先考虑有无限个有效步的情形. 类似文献[7], 有如下引理.

引理 2.3 假设存在一个无限指标集 $L \subseteq \{1, 2, \dots\}$ 和一个点 $\bar{x} \in \mathbf{R}^n$ 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.

接下来考虑有效步有限的情形, 即存在一个指标 \bar{k} 使得 $x^k = x^{\bar{k}}, k \geq \bar{k}$. 下面证明 $x^{\bar{k}}$ 是问题(0.1)的一个最优解.

引理 2.4 令 $\omega^k = \frac{1}{2} \|\rho^k d^k\|^2 + \rho^k \check{\alpha}^k$, 则 ω^k 是以下问题的最优值

$$\begin{aligned} \min \quad & \frac{1}{2} \left\| \sum_{j \in J^k} \lambda_j g^j + \lambda_s s^{k-1} + \sum_{i \in I} \mu_i \nabla c_i(x^k) \right\|^2 - \rho^k \left[\sum_{j \in J^k} \lambda_j (-\alpha_j^k - \delta^k) - \lambda_s (-\alpha_s^k - \delta^k) - \sum_{i \in I_-} \mu_i c_i(x^k) - \sum_{i \in I_+} \mu_i (c_i(x^k) - \varphi^k) \right] \\ \text{s. t.} \quad & \lambda_j \geq 0, j \in J^k, \lambda_s \geq 0, \mu_i \geq 0, i \in I, \\ & \sum_{j \in J^k} \lambda_j + \lambda_s + \sum_{i \in I} \mu_i = 1. \end{aligned} \quad (2.1)$$

证明 由于问题(2.1)是问题(1.4)的对偶问题, 故问题(2.1)的最优解即为问题(1.4)的KKT乘子. 因此, 由(1.6)式, (1.9)式及 ω^k 的定义可得结论成立.

引理 2.5^[6] 设 n 维向量 d, g 及数 $\eta \in (0, 1), \rho > 0, C, \omega, z, \check{\alpha}$ 和 α 满足

$$\begin{aligned} \omega &= \frac{1}{2} \|\rho d\|^2 + \rho \check{\alpha}, z = -(\rho \|d\|^2 + \check{\alpha}), \\ -\alpha + \langle g, d \rangle &\geq \eta z, C \geq \max\{\|\rho d\|, \|g\|, \check{\alpha}, 1\}. \end{aligned}$$

令 $\bar{\omega} = \min\{Q(v) : v \in [0, 1]\}$, 其中 $Q(v) = \frac{1}{2} \|(1-v)(-\rho d) + v g\|^2 + \rho[(1-v)\check{\alpha} + \alpha]$, 则 $\bar{\omega} \leq \omega - \rho^2(1-\eta)^2 \omega^2 / 8C^2$.

基于引理 2.5, 得到以下一个重要的结论.

引理 2.6 假设对于某个 $k > 1$ 有 $t_L^k = 0$ 及 $\epsilon^{k-1} = \epsilon^k$, 则

$$(i) -(\alpha_k^k + \delta^{k-1}) + \langle g^k, d^{k-1} \rangle \geq m_R z^{k-1}, \quad (2.2)$$

其中 $\epsilon_k^k = f_{\epsilon^k}(x^k) - f_k^k + \epsilon^k$;

$$(ii) \omega^k \leq \omega^{k-1} - (\rho^{k-1})^2 (1 - m_R)^2 (\omega^{k-1})^2 / 8(C^k)^2, \quad (2.3)$$

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

证明 (i) 由算法 1.1 中步骤 4 知当 $t_L^{k-1} = 0, \epsilon^{k-1} = \epsilon^k$ 时, $x^k = x^{k-1}, y^k = x^{k-1} + t_R^{k-1} d^{k-1}$, 且有

$$f_{\epsilon^k}(y^k) > f_{\epsilon^k}(x^{k-1}) + m_L t_R^{k-1} z^{k-1} + t_R^{k-1} \delta^{k-1} - 2\epsilon^k. \quad (2.4)$$

因此, 由(1.1)式和(2.4)式有

$$\begin{aligned} -(\alpha_k^k + \delta^{k-1}) &= -(f_{\epsilon^k}(x^k) - f_k^k + \epsilon^k) - \delta^{k-1} = \\ &= -(f_{\epsilon^k}(x^k) - f_{\epsilon^k}(y^k) - \langle g^k, x^k - y^k \rangle + 3\epsilon^k) - \\ &\delta^{k-1} = -(f_{\epsilon^k}(x^{k-1}) - f_{\epsilon^k}(y^k) - \langle g^k, x^{k-1} - y^k \rangle + \\ &3\epsilon^k) - \delta^{k-1} = f_{\epsilon^k}(y^k) - t_R^{k-1} \langle g^k, d^{k-1} \rangle - f_{\epsilon^k}(x^{k-1}) - \\ &\delta^{k-1} - 3\epsilon^k \geq m_L t_R^{k-1} z^{k-1} - t_R^{k-1} \langle g^k, d^{k-1} \rangle + (1 - \\ &t_R^{k-1}) \delta^{k-1} - 5\epsilon^k. \end{aligned} \quad (2.5)$$

由 $\epsilon_k^k = f_{\epsilon^k}(x^k) - f_k^k + \epsilon^k \geq f(x^k) - f_k^k \geq 0$ 知 $\epsilon_k^k = f_{\epsilon^k}(x^{k-1}) - f_{\epsilon^k}(y^k) + t_R^{k-1} \langle g^k, d^{k-1} \rangle + 3\epsilon^k \geq 0$,

因此根据(2.4)式可得

$$\langle g^k, d^{k-1} \rangle \geq m_L z^{k-1} + \delta^{k-1} - 5\epsilon^k / t_R^{k-1}. \quad (2.6)$$

结合(2.5)式, (2.6)式和 $t_R^{k-1} \in [\underline{t}, 1]$ 得

$$\begin{aligned} -(\alpha_k^k + \delta^{k-1}) + \langle g^k, d^{k-1} \rangle &\geq m_L t_R^{k-1} z^{k-1} + (1 - \\ &t_R^{k-1})(\langle g^k, d^{k-1} \rangle - \delta^{k-1}) - 5\epsilon^k \geq m_L t_R^{k-1} z^{k-1} + (1 - \\ &t_R^{k-1})(m_L z^{k-1} - 3\epsilon^k / t_R^{k-1}) - 5\epsilon^k = m_L z^{k-1} - 5\epsilon^k / t_R^{k-1} \geq \\ &m_L z^{k-1} - 5\epsilon^k / \underline{t}. \end{aligned}$$

由步骤 2 知 $5\epsilon^k / \underline{t} = 5\epsilon^{k-1} / \underline{t} > -(m_R - m_L) z^{k-1}$, 从而得到

$$-(\alpha_k^k + \delta^{k-1}) + \langle g^k, d^{k-1} \rangle \geq m_R z^{k-1}.$$

(ii) 对任意的 $v \in [0, 1]$, 定义问题(2.1)的可行解

$$\begin{aligned} \lambda_k(v) &= v, \lambda_j(v) = 0, j \in J^k \setminus \{k\}, \\ \lambda_s(v) &= (1-v)\theta^{k-1}, \mu_i(v) = (1-v)\mu_i^{k-1}, i \in I. \end{aligned}$$

由(1.16)式和 $x^{k-1} = x^k$ 可得

$$\alpha_s^k = f_{\epsilon^k}(x^k) - f_s^k + \epsilon^k = f_{\epsilon^k}(x^{k-1}) - \check{f}_s^{k-1} + \epsilon^k = \check{\alpha}_s^{k-1}, \quad (2.7)$$

因此

$$\begin{aligned} \sum_{j \in J^k} \lambda_j(v) g^j + \lambda_s(v) s^{k-1} + \sum_{i \in I} \mu_i(v) \nabla c_i(x^k) &= \\ v g^k + (1-v)\theta^{k-1} s^{k-1} + (1-v) \sum_{i \in I} \mu_i^{k-1} \nabla c_i(x^{k-1}) &= \end{aligned}$$

$vg^k + (1-\nu)(-\rho^{k-1}d^{k-1})$.

此外,根据(2.7)式有

$$\begin{aligned} & - \sum_{j \in J^k} \lambda_j (-\alpha_j^k - \delta^k) - \lambda_s (-\alpha_s^k - \delta^k) - \\ & \sum_{i \in L_-} \mu_i c_i(x^k) - \sum_{i \in L_+} \mu_i (c_i(x^k) - \varphi^k) = -\nu(-\alpha_k^k - \delta^k) - \\ & (1-\nu)\theta^{k-1}(-\alpha_s^k - \delta^k) - (1-\nu) \sum_{i \in L_-} \mu_i^{k-1} c_i(x^k) - (1-\nu) \\ & \sum_{i \in L_+} \mu_i^{k-1} (c_i(x^k) - \varphi^k) = \nu(\alpha_k^k + \delta^{k-1}) + (1-\nu) \\ & (\theta^{k-1}(\alpha_s^{k-1} + \delta^{k-1}) - \sum_{i \in L_-} \mu_i^{k-1} c_i(x^{k-1}) - \\ & \sum_{i \in L_+} \mu_i^{k-1} (c_i(x^{k-1}) - \varphi^{k-1})) = \nu(\alpha_k^k + \delta^{k-1}) + (1-\nu) \\ & \alpha^{k-1}. \end{aligned}$$

令 $\bar{\omega}$ 是如下问题的最优值

$$\begin{aligned} \min \quad & \frac{1}{2} \|(1-\nu)(-\rho^{k-1}d^{k-1}) + \nu g^k\|^2 + \\ & \rho^{k-1}[(1-\nu)\alpha^{k-1} + \nu(\alpha_k^k + \delta^{k-1})], \\ \text{s. t.} \quad & \nu \in [0, 1]. \end{aligned}$$

则由引理 2.4 知 $\omega^k \leq \bar{\omega}$. 在定理 2.5 中令 $d = d^{k-1}$, $g = g^k$, $\eta = m_R$, $\rho = \rho^{k-1}$, $\omega = \omega^{k-1}$, $z = z^{k-1}$, $\alpha = \alpha^{k-1}$, $\alpha = \alpha_k^k + \delta^{k-1}$, 并结合(2.2)式, 我们有 $\omega^k \leq \bar{\omega} \leq \omega^{k-1} - (\rho^{k-1})^2(1-m_R)^2(\omega^{k-1})^2/8(C^k)^2$.

定理 2.1 (i) 如果算法 1.1 有限步终止于第 k 次迭代, 则 x^k 是问题(0.1)的一个最优解; (ii) 如果算法 1.1 在第 k 次迭代时无限次在步骤 1 与步骤 2 之间循环, 则 x^k 是问题(0.1)的一个最优解; (iii) 如果算法 1.1 产生一个无限迭代序列 $\{x^k\}$, 则其任一聚点 x^* 都是问题(0.1)的一个最优解.

证明 (i) 如果算法 1.1 有限次终止于点 x^k , 则 $z^k = 0$. 根据引理 1.2 知 x^k 是问题(0.1)的一个最优解.

(ii) 如果算法在第 k 次迭代时于步骤 1 与步骤 2 之间无限次循环, 此时因为每次在步骤 2 中 ϵ^k 减半, $(m_R - m_L) \underline{t} > 0$, $-z^k = \rho^k \|d^k\|^2 + \epsilon^k \geq 0$, 所以 $\epsilon^k \rightarrow 0, z^k \rightarrow 0$. 由引理 2.2 知 x^k 是问题(0.1)的一个最优解.

(iii) 现在假设算法 1.1 产生一个无限迭代序列 $\{x^k\}$, 且 x^* 是其任一聚点. 则分两种情况证明 x^* 是问题(0.1)的一个最优解.

情形 1 有无限多个有效步. 此时, 必然存在无

限指标集 $L \subseteq \{1, 2, \dots\}$ 使得 $x^{k(l)} \rightarrow x^*, l \rightarrow \infty, l \in L$. 因此, 根据引理 2.3 知 x^* 是问题(0.1)的一个最优解.

情形 2 有效步有限. 则存在一个指标 \bar{k} 使得 $x^k \equiv x^{\bar{k}} = x^*$ 且有 $\rho^k \equiv \rho$. 如果 $\epsilon^k \rightarrow 0$, 类似与(ii)的证明, 知 x^* 是问题(0.1)的一个最优解. 设对于任意的 $k \geq \bar{k}$ 有 $\epsilon^k \equiv \epsilon > 0$, 此时存在一个常数 $C > 0$ 使得 $C \geq \max\{\|\rho d^{k-1}\|, \|g^k\|, \alpha^{k-1}, 1\}, \forall k \geq \bar{k}$. 结合(2.3)式, 有

$$\omega^k \leq \omega^{k-1} - \rho^2(1-m_R)^2(\omega^{k-1})^2/8C^2,$$

由此可得 $\omega^k \rightarrow 0, k \rightarrow \infty$, 从而 $z^k \rightarrow 0, k \rightarrow \infty$. 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] KIWIEL K C. An alternating linearization bundle method for convex optimization and nonlinear multicommodity flow problems[J]. Mathematical Programming, 2011, 130(1):59-84.
- [2] KIWIEL K C. An algorithm for nonsmooth convex minimization with errors[J]. Mathematics of Computation, 1985, 171(45):173-180.
- [3] KIWIEL K C. A method of centers with approximate subgradient linearizations for nonsmooth convex optimization[J]. SIAM Journal on Optimization, 2007, 18(4): 1467-1489.
- [4] TANG C M, JIAN J B. Strongly sub-feasible direction method for constrained optimization problems with nonsmooth objective functions[J]. European Journal of Operational Research, 2012, 218(1):28-37.
- [5] KIWIEL K C. Proximity control in bundle methods for convex nondifferentiable minimization[J]. Mathematical Programming, 1990, 46(1/2/3):105-122.
- [6] KIWIEL K C. Methods of Descent for Nondifferentiable Optimization[M]. Berlin Heidelberg: Springer-Verlag, 1985.
- [7] 唐春明, 简金宝. 非光滑优化的强次可行方向邻近点束求解方法[J]. 广西科学, 2014, 21(3):283-286. TANG C M, JIAN J B. A proximal bundle method of strongly sub-feasible directions for nonsmooth optimization[J]. Guangxi Sciences, 2014, 21(3):283-286.

(责任编辑:米慧芝)