

带 1 - 范数约束的分裂可行问题的投影算法

畅含笑, 屈 虹
(曲阜师范大学管理学院, 山东 日照 276826)

摘要: 本文主要研究带 1 - 范数约束的分裂可行问题的求解算法. 用一种交替投影算法, 求得了问题的解, 提出松弛交替投影算法, 改进了直接往闭凸集上投影这一不足, 并证明了该算法的收敛性.

关键词: 分裂可行问题; 1 - 范数约束; 交替投影; 松弛

MR(2010) 主题分类号: 90C25; 65K05 中图分类号: O221.2

文献标识码: A 文章编号: 0255-7797(2017)06-1234-11

1 引言

由于社会的发展和生产实践的需求, 最优化问题在金融、医学、药学以及手工农业等领域受到越来越多的重视, 分裂可行问题就是其中之一. 1994 年, Censor 和 Elfving 依据医学中有关放射治疗的实践经验和理论提出了分裂可行问题^[1], 问题形式如下

$$\text{求 } x \in C \text{ s.t. } Ax \in Q, \quad (1.1)$$

其中 C, Q 分别为 R^N 和 R^M 中的非空闭凸集, A 为一个 $M \times N$ 的实矩阵.

随后, 分裂可行问题的拓展形式被学者们相继提出. 本文主要研究的是带 1 - 范数约束的分裂可行问题的解, 问题形式如下

$$\text{求 } x \in C, Ax \in Q \text{ s.t. } \|x\|_1 \leq s, \quad (1.2)$$

其中 $\|\cdot\|_1$ 代表 1 - 范数, $s > 0$ 为一个给定的常数.

目前, 大多数关于求解分裂可行问题及其拓展问题的算法, 要么牵涉到往闭凸集上的投影, 而这一投影在实际操作中难以实现; 要么在求解合适的步长过程中需要估算相关矩阵的最大特征值、Lipschitz 系数或进行线搜索, 而这些操作往往需要大量的计算. 关于求解分裂可行问题的 1 - 范数解问题已有学者在研究^[14,15]. 在文献 [14] 中, 作者将分裂可行问题的 1 - 范数解问题转化为变分不等式问题进行求解, 但在其给出的算法中需要估算矩阵的最大特征值.

在文献 [2] 中, 对于多集分裂可行问题

$$x \in \bigcap_{i=1}^t C_i \text{ s.t. } Ax \in \bigcap_{j=1}^r Q_j, \quad (1.3)$$

其中 C_i ($i = 1, 2, \dots, t$) 和 Q_j ($j = 1, 2, \dots, r$) 分别为 R^N 和 R^M 中的非空闭凸集.

*收稿日期: 2016-03-11 接收日期: 2016-06-28

基金项目: 国家自然科学基金 (11271226); 山东省优秀中青年科学家科研奖励基金 (BS2012SF027).

作者简介: 畅含笑 (1990-), 女, 河南开封, 硕士, 主要研究方向: 非线性规划.

作者提出了一种序列投影算法

$$x^{k+1} = P_{C_t} P_{C_{t-1}} \cdots P_1(x^k + \omega_k r_k d_k),$$

其中 $d_j^k = P_{Q_j}(Ax_k) - Ax_k, j = 1, 2, \dots, r, d_k = \sum_{j=1}^r A^T d_j^k, r_k = \frac{\sum_{j=1}^r \|d_j^k\|^2}{\|d_k\|^2}, 0 < \underline{\omega} \leq \omega_k \leq \bar{\omega} < 2, k = 1, 2, \dots$

显然, 序列投影算法有可以直接计算的步长, 从而避免了在求解步长时进行大量的计算. 受到文献 [2] 的启发, 将问题 (1.2) 转化为如下形式

$$\text{求 } x \in C \cap D \text{ s.t. } Ax \in Q, \quad (1.4)$$

其中 $D = \{x \mid \|x\|_1 \leq s\}$.

序列投影算法虽有可以直接计算的步长, 但却牵涉到往闭凸集上的投影. 首先, 本文在序列投影的基础上, 提出交替投影算法求解了问题 (1.4). 其次, 考虑到在实际操作中往闭凸集上的投影是难以实现的, 文章后半部分构造包含 C, D, Q 的半空间, 利用到半空间上的投影来代替到闭凸集上的投影, 从而使投影得到了顺利实现.

2 预备知识

定义 1 ^[3,4] 设 $\Omega \subset R^N$ 为非空闭凸集, 对任意的 $x \in R^N$, 定义

$$P_\Omega(x) = \arg \min \{ \|x - y\| \mid y \in \Omega \}.$$

并称其为 x 到 Ω 上的投影. 显然, 若 $x \in \Omega$, 则 $x = P_\Omega(x)$.

注 1 由投影的定义, 可以得出问题 (1.2) 等价于如下带约束的最小化问题

$$\begin{aligned} & \min \frac{1}{2} \|Ax - P_Q(Ax)\|^2, \\ & \text{s.t. } x \in C \cap D. \end{aligned}$$

定义 2 ^[3] 给定正常凸函数 $f : R^N \rightarrow (-\infty, +\infty]$, 对任意一点 $x \in \text{dom}f$, 若向量 $\xi \in R^N$ 满足

$$f(y) - f(x) \geq \langle \xi, y - x \rangle, y \in R^N, \quad (2.1)$$

则称 ξ 为凸函数 f 在点 x 处的次梯度. 将满足式 (2.1) 的向量 ξ 的全体构成的集合记为 $\partial f(x)$, 并称之为 f 在 x 处的次微分.

注 2 $\text{dom}f$ 表示 f 的有效域, 即 $\text{dom}f = \{x \in R^N \mid f(x) < +\infty\}$. 若 f 在 x 处可微, 则满足 (2.1) 式的 ξ 存在且唯一, 并且易知该向量即梯度 $\nabla f(x)$.

由次梯度的定义, 简单计算可得 $f(x) = \|x\|_1$ 在 $x \in R^N$ 的次梯度 t , 其分量为

$$t_j = \begin{cases} 1, & x_j > 0; \\ [-1, 1], & x_j = 0; \\ -1, & x_j < 0. \end{cases}$$

引理 2.1 [9] 设 Ω 为 R^N 中的非空闭凸集, 则对于投影算子 $P_\Omega(\cdot)$, 下述结论成立.

- (a) $\langle P_\Omega(x) - x, z - P_\Omega(x) \rangle \geq 0, \forall x \in R^N, z \in \Omega;$
- (b) $\|P_\Omega(x) - P_\Omega(y)\| \leq \|x - y\|, \forall x, y \in R^N;$
- (c) $\|P_\Omega(x) - z\|^2 \leq \|x - z\|^2 - \|P_\Omega(x) - x\|^2, \forall x \in R^N, z \in \Omega;$
- (d) $\|P_\Omega(x) - P_\Omega(y)\|^2 \leq \|x - y\|^2 - \|P_\Omega(x) - x + y - P_\Omega(y)\|^2, \forall x, y \in R^N.$

引理 2.2 [3] 假设 $f : R^N \rightarrow R$ 为凸函数, 则 f 在 R^N 上处处次可微且次微分在 R^N 的任意有界子集上一致有界.

引理 2.3 [4] 设 $a \in R^N, b \in R$, 则 $u \in R^N$ 到半空间 $\{x \in R^N | a^T x \geq b\}$ 上的投影为

$$P(u) = u + \frac{\max\{0, b - a^T u\}}{\|a\|^2} a.$$

引理 2.4 [16] 设 $f : R^N \rightarrow (-\infty, +\infty]$ 为闭正常凸函数. 给定满足 $x^k \rightarrow x$ 的点列 $\{x^k\} \subseteq R^N$, 若 $\xi^k \in \partial f(x^k)$ 且 $\xi^k \rightarrow \xi$, 则有 $\xi \in \partial f(x)$.

3 算法及收敛性分析

此部分给出问题 (1.4) 的求解算法.

3.1 交替投影算法

本文采用可以直接计算的步长, 避免了在求合适步长时, 进行大量的计算. 在该算法中, 假设到闭凸集上的投影是可以直接计算的, 且问题 (1.4) 的解集非空.

算法 3.1

步骤 1 任取 $x^0 \in R^N$, 选取 $0 \leq \omega \leq \omega_k \leq \bar{\omega} < 2, k = 0, 1, 2, \dots$;

步骤 2 令 $\bar{d}_k = P_Q(Ax_k) - Ax_k, d_k = A^T \bar{d}_k, r_k = \frac{\|\bar{d}_k\|^2}{\|d_k\|^2};$

步骤 3 计算 $x^{k+1} = P_D P_C(x^k + \omega_k r_k d_k).$

引理 3.1 设 x^* 为问题 (1.4) 的任意解, $\{x^k\}$ 为算法 3.1 产生的点列, 则数列 $\{\|x^k - x^*\|\}$ 收敛.

定理 3.1 设 $\{x^k\}$ 为算法 3.1 产生的点列, 则 $\{x^k\}$ 收敛到问题 (1.4) 的一个解.

注 3 算法 3.1 可以看成 [2] 中序列投影算法的特例, 引理 3.1、定理 3.1 的证明过程可分别参看文献 [2] 中引理 2.2、定理 2.1.

3.2 松弛交替投影算法

由于算法 3.1 牵涉到往闭凸集上的投影, 所以针对这一不足对算法 3.1 进行改进. 这里, 寻找包含集合 C, D, Q 的半空间, 利用到半空间上的投影来代替到闭凸集上的投影, 从而使投影简单可行.

在该部分, 将集合 $D = \{x \in R^N | \|x\|_1 \leq s\}$ 记为 $D = \{x \in R^N | f(x) \leq 0\}$, 其中 $f(x) = \|x\|_1 - s$.

假设 C, Q 满足如下条件:

(H1) $C = \{x \in R^N | c(x) \leq 0\}$, 其中 $c : R^N \rightarrow R$ 是凸函数 (不需要可微的) 且 C 是非空的. $Q = \{y \in R^M | q(y) \leq 0\}$, 其中 $q : R^M \rightarrow R$ 是凸函数 (不需要可微的) 且 Q 是非空的.

(H2) 对于任意的 $x \in R^N$, 至少有一个次梯度 $\varsigma \in \partial c(x)$ 是可以计算的, 其中 $\partial c(x) = \{\varsigma \in R^N | c(z) \geq c(x) + \langle \varsigma, z - x \rangle, \forall z \in R^N\}$.

对于任意的 $y \in R^M$, 至少有一个次梯度 $\eta \in \partial q(y)$ 是可以计算的, 其中 $\partial q(y) = \{\eta \in R^M | q(u) \geq q(y) + \langle \eta, u - y \rangle, \forall u \in R^M\}$. 并且构造包含 C, D, Q 的半空间 C_k, D_k, Q_k 如下

$$\begin{aligned} C_k &= \{x \in R^N | c(x^k) + \langle \varsigma^k, x - x^k \rangle \leq 0\}, \text{ 其中 } \varsigma^k \in \partial c(x^k). \\ D_k &= \{x \in R^N | f(x^k) + \langle \phi^k, x - x^k \rangle \leq 0\}, \text{ 其中 } \phi^k \in \partial f(x^k). \\ Q_k &= \{y \in R^M | q(Ax^k) + \langle \eta^k, y - Ax^k \rangle \leq 0\}, \text{ 其中 } \eta^k \in \partial q(Ax^k). \end{aligned}$$

注 4 由次梯度的定义, 容易得出 $\forall k \in N$, 有 $C \subset C_k, D \subset D_k, Q \subset Q_k$.

算法 3.2

步骤 1 任取 $x^0 \in R^N$, 选取 $0 < \underline{w} \leq w_k \leq \bar{w} < 2, k = 0, 1, 2, \dots$;

步骤 2 令 $\bar{d}_k = P_{Q_k}(Ax_k) - Ax_k, d_k = A^T \bar{d}_k, r_k = \frac{\|\bar{d}_k\|^2}{\|d_k\|^2}$;

步骤 3 计算 $x^{k+1} = P_{D_k} P_{C_k}(x^k + w_k r_k d_k)$.

其中 C_k, D_k, Q_k 如上文所述.

注 5 在实际计算中,

$$\begin{aligned} \bar{d}_k &= P_{Q_k}(Ax_k) - Ax_k = \frac{\max\{0, q(Ax^k)\}}{\|\eta^k\|^2}(-\eta^k), \\ r_k &= \frac{\|\bar{d}_k\|^2}{\|d_k\|^2} = \frac{\|P_{Q_k}(Ax_k) - Ax_k\|^2}{\|A^T(P_{Q_k}(Ax_k) - Ax_k)\|^2} = \frac{\|\frac{\max\{0, q(Ax^k)\}}{\|\eta^k\|^2}\eta^k\|^2}{\|A^T(\frac{\max\{0, q(Ax^k)\}}{\|\eta^k\|^2}\eta^k)\|^2}, \\ x^{k+1} &= P_{D_k} P_{C_k}(x^k + w_k r_k d_k) = P_{D_k}(x^k + \omega_k r_k d_k + \frac{\max\{0, c(x^k) + (\varsigma^k)^T(\omega_k r_k d_k)\}}{\|\varsigma^k\|^2}(-\varsigma^k)). \end{aligned}$$

令

$$y = x^k + \omega_k r_k d_k + \frac{\max\{0, c(x^k) + (\varsigma^k)^T(\omega_k r_k d_k)\}}{\|\varsigma^k\|^2}(-\varsigma^k),$$

则

$$x^{k+1} = P_{D_k} P_{C_k}(x^k + w_k r_k d_k) = P_{D_k}(y) = y + \frac{\max\{0, f(x^k) - (\phi^k)^T x^k + (\phi^k)^T y\}}{\|\phi^k\|^2}(-\phi^k).$$

对任意的 $\tilde{x} \in R^N$, 记

$$C(\tilde{x}) = \{x \in R^N | c(\tilde{x}) + \langle \tilde{\varsigma}, x - \tilde{x} \rangle \leq 0\}, \quad (3.1)$$

其中 $\tilde{\varsigma} \in \partial c(\tilde{x})$.

注 6 由 (3.1) 式及 C_k 的定义, 显然 $C_k = C(x^k)$. 在式 (3.1) 中, 可以取满足如下条件的 $\tilde{x}, \tilde{\varsigma} : \lim_{k \rightarrow \infty} x^k = \tilde{x}, \lim_{k \rightarrow \infty} \varsigma^k = \tilde{\varsigma}$. 由引理 2.4 知 $\tilde{\varsigma} \in \partial c(\tilde{x})$.

引理 3.2 若点列 $\{x^k\}$ 收敛到 \tilde{x} , $\{y^k\}$ 收敛到 \tilde{y} , 则 $\lim_{k \rightarrow \infty} P_{C_k}(y^k) = P_{C(\tilde{x})}(\tilde{y})$, 其中 $C(\tilde{x})$ 中 $\tilde{\varsigma}$ 满足 $\lim_{k \rightarrow \infty} \varsigma^k = \tilde{\varsigma}$.

证 由引理 2.3 得

$$P_{C_k}(y^k) = y^k + \frac{\max \left\{ 0, (\zeta^k)^T x^k - c(x^k) - (\zeta^k)^T y^k \right\}}{\|\zeta^k\|^2} \zeta^k, \quad (3.2)$$

$$P_{C(\tilde{x})}(\tilde{y}) = \tilde{y} + \frac{\max \left\{ 0, (\tilde{\zeta})^T \tilde{x} - c(\tilde{x}) - (\tilde{\zeta})^T \tilde{y} \right\}}{\|\tilde{\zeta}\|^2} \tilde{\zeta}. \quad (3.3)$$

因为点列 $\{x^k\}$ 收敛到 \tilde{x} , $\{y^k\}$ 收敛到 \tilde{y} 及 $\lim_{k \rightarrow \infty} \zeta^k = \tilde{\zeta}$, 所以

$$\begin{aligned} \lim_{k \rightarrow \infty} P_{C_k}(y^k) &= \lim_{k \rightarrow \infty} y^k + \lim_{k \rightarrow \infty} \frac{\max \left\{ 0, (\zeta^k)^T x^k - c(x^k) - (\zeta^k)^T y^k \right\}}{\|\zeta^k\|^2} \zeta^k \\ &= \tilde{y} + \frac{\max \left\{ 0, (\tilde{\zeta})^T \tilde{x} - c(\tilde{x}) - (\tilde{\zeta})^T \tilde{y} \right\}}{\|\tilde{\zeta}\|^2} \tilde{\zeta} \\ &= P_{C(\tilde{x})}(\tilde{y}). \end{aligned}$$

证毕.

引理 3.3 设 x^* 为问题 (1.4) 的任意解, $\{x^k\}$ 为算法 3.2 产生的点列, 则数列 $\{\|x^k - x^*\|\}$ 收敛.

证 因为 x^* 为问题 (1.4) 的任意解, 所以 $x^* \in C \cap D$, $Ax^* \in Q$, 由引理 2.1(a) 得

$$\begin{aligned} \langle x^* - x^k, d_k \rangle &= \langle x^* - x^k, A^T \overline{d_k} \rangle \\ &= \langle Ax^* - Ax^k, \overline{d_k} \rangle \\ &= \langle A x^* + P_Q(Ax^k) - P_Q(Ax^k) - Ax^k, \overline{d_k} \rangle \\ &= \|\overline{d_k}\|^2 + \langle Ax^* - P_Q(Ax^k), P_Q(Ax^k) - Ax^k \rangle \\ &\geq \|\overline{d_k}\|^2. \end{aligned}$$

又因为 $x^* \in C \subset C_k$, $x^* \in D \subset D_k$, 所以

$$\begin{aligned} \|x^{k+1} - x^*\|^2 &= \|P_{D_k} P_{C_k}(x^k + w_k r_k d_k) - x^*\|^2 \\ &\leq \|P_{C_k}(x^k + w_k r_k d_k) - x^*\|^2 \\ &\leq \|x^k + w_k r_k d_k - x^*\|^2 \\ &= \|x^k - x^*\|^2 - 2w_k r_k \langle x^* - x^k, d_k \rangle + w_k^2 r_k^2 \|d_k\|^2 \\ &\leq \|x^k - x^*\|^2 - 2w_k r_k \|\overline{d_k}\|^2 + w_k^2 r_k^2 \|d_k\|^2. \end{aligned} \quad (3.4)$$

由于 $0 < \underline{w} \leq w_k \leq \bar{w} < 2$, $k = 0, 1, 2, \dots$, 故

$$\|x^{k+1} - x^*\|^2 \leq \|x^k - x^*\|^2 - \underline{w} r_k^2 \|d_k\|^2 (2 - \bar{w}). \quad (3.5)$$

从而数列 $\{\|x^k - x^*\|\}$ 收敛. 证毕.

注 7 由 (3.4) 式的最后一步可以得出, 当 $r_k = \frac{\|\overline{d_k}\|^2}{\|d_k\|^2}$ 时, $\|x^k - x^*\|$ 取得最小值, 也即 x^k 最接近 x^* .

定理 3.2 设 $\{x^k\}$ 为算法 3.2 产生的点列, 若问题 (1.4) 的解集非空, 则 $\{x^k\}$ 收敛到问题 (1.4) 的一个解.

证 设 x^* 为问题 (1.4) 的任意解, 由引理 3.2 知数列 $\{\|x^k - x^*\|\}$ 收敛, 同时序列 $\{x^k\}, \{d_k\}$ 有界. 更进一步, 由 (3.5) 式得 $\lim_{k \rightarrow \infty} r_k^2 \|d_k\|^2 = 0$. 又因为 $\{d_k\}$ 有界, 所以 $\lim_{k \rightarrow \infty} r_k^2 \|d_k\|^4 = 0$, 即

$$\lim_{k \rightarrow \infty} \|\bar{d}_k\|^2 = 0.$$

也就是

$$\lim_{k \rightarrow \infty} \|P_{Q_k}(Ax^k) - Ax^k\|^2 = 0. \quad (3.6)$$

设 \bar{x} 是 $\{x^k\}$ 的任意聚点, 则一定存在 $\{x^k\}$ 的子列 $\{x^{k_l}\}$, 使得 $\lim_{k_l \rightarrow \infty} x^{k_l} = \bar{x}$. 下证 \bar{x} 为问题 (1.4) 的一个解.

首先证明 $A\bar{x} \in Q$. 由 (3.6) 式得 $\lim_{k_l \rightarrow \infty} \|P_{Q_{k_l}}(Ax^{k_l}) - Ax^{k_l}\|^2 = 0$. 显然 $P_{Q_{k_l}}(Ax^{k_l}) \in Q_{k_l}$. 由 Q_{k_l} 的定义得

$$q(Ax^{k_l}) + \langle \eta^{k_l}, P_{Q_{k_l}}(Ax^{k_l}) - Ax^{k_l} \rangle \leq 0. \quad (3.7)$$

由引理 2.2 可知 $\{\eta^{k_l}\}$ 有界. 对 (3.7) 式取极限得 $q(A\bar{x}) \leq 0$. 即 $A\bar{x} \in Q$.

接下来证明 $\bar{x} \in C \cap D$.

由引理 2.1(b), (c) 可得

$$\begin{aligned} \|x^{k+1} - x^*\|^2 &= \|P_{D_k} P_{C_k}(x^k + w_k r_k d_k) - x^*\|^2 \\ &\leq \|P_{C_k}(x^k + w_k r_k d_k) - x^*\|^2 - \|x^{k+1} - P_{C_k}(x^k + w_k r_k d_k)\|^2 \\ &\leq \|x^k + w_k r_k d_k - x^*\|^2 - \|x^{k+1} - P_{C_k}(x^k + w_k r_k d_k)\|^2. \end{aligned} \quad (3.8)$$

令 $\lim_{k \rightarrow \infty} \|x^k - x^*\|^2 = a (a \geq 0)$, 结合 $\lim_{k \rightarrow \infty} r_k^2 \|d_k\|^2 = 0$, 对 (3.8) 式取极限得

$$\lim_{k \rightarrow \infty} \|x^{k+1} - P_{C_k}(x^k + w_k r_k d_k)\|^2 = 0,$$

从而

$$\lim_{k_l \rightarrow \infty} \|x^{k_l+1} - P_{C_{k_l}}(x^{k_l} + w_{k_l} r_{k_l} d_{k_l})\|^2 = 0. \quad (3.9)$$

下证 $x^{k_l+1} \rightarrow \bar{x} (k_l \rightarrow \infty)$.

由于 $\{x^k\}$ 有界, 故 $\{x^{k_l+1}\}$ 有界. 设 \bar{x} 为 $\{x^{k_l+1}\}$ 的任意聚点, 易知 \bar{x} 也为 $\{x^k\}$ 的任意聚点, 则存在 $\{x^{k_l+1}\}$ 的子列 $\{x^{k_{l_i}+1}\}$, 使得 $\lim_{k_{l_i} \rightarrow \infty} x^{k_{l_i}+1} = \bar{x}$, 且 $\lim_{k_{l_i} \rightarrow \infty} x^{k_{l_i}} = \bar{x}$.

由 (3.9) 式得

$$\lim_{k_{l_i} \rightarrow \infty} \|x^{k_{l_i}+1} - P_{C_{k_{l_i}}}(x^{k_{l_i}} + w_{k_{l_i}} r_{k_{l_i}} d_{k_{l_i}})\|^2 = 0. \quad (3.10)$$

由引理 3.2, 对 (3.10) 式取极限得

$$\bar{x} = P_{C(\bar{x})}(\bar{x}), \quad (3.11)$$

其中 $C(\bar{x}) = \{x \in R^N | c(\bar{x}) + \langle \bar{\varsigma}, x - \bar{x} \rangle \leq 0\}$, $\bar{\varsigma} \in \partial c(\bar{x})$, 且 $\bar{\varsigma}$ 满足 $\lim_{k_{l_i} \rightarrow \infty} \varsigma^{k_{l_i}} = \bar{\varsigma}$.

因为 $x^* \in C_{k_{l_i}} = \{x \in R^N | c(x^{k_{l_i}}) + \langle \varsigma^{k_{l_i}}, x - x^{k_{l_i}} \rangle \leq 0\}$, $\varsigma^{k_{l_i}} \in \partial c(x^{k_{l_i}})$, 所以

$$c(x^{k_{l_i}}) + \langle \varsigma^{k_{l_i}}, x^* - x^{k_{l_i}} \rangle \leq 0. \quad (3.12)$$

对 (3.12) 式取极限得 $c(\bar{x}) + \langle \bar{\varsigma}, x^* - \bar{x} \rangle \leq 0$, 从而 $x^* \in C(\bar{x})$. 由引理 2.1(c), 结合 (3.11) 式, 得

$$\|\bar{x} - x^*\|^2 \leq \|\bar{x} - \bar{x}\|^2 - \|\bar{x} - \bar{x}\|^2. \quad (3.13)$$

又因为 $\|\bar{x} - x^*\|^2 = \|\bar{x} - \bar{x}\|^2$, 所以 $\bar{x} = \bar{x}$. 从而有界子列 $\{x^{k_{l_i+1}}\}$ 有唯一聚点 \bar{x} .

由 (3.11) 式知 $\bar{x} = \bar{x} = P_{C(\bar{x})}(\bar{x})$, 从而 $\bar{x} \in C(\bar{x})$. 由 $C(\bar{x})$ 的定义得

$$c(\bar{x}) + \langle \bar{\varsigma}, \bar{x} - \bar{x} \rangle \leq 0.$$

从而 $c(\bar{x}) \leq 0$, 即 $\bar{x} \in C$. 由于 D_k 为非空闭凸集, 且 $\{x^k\} \subset D_k$, 故 $\bar{x} \in D_k$, 再由 D_k 的构造得

$$f(x^{k_l}) + \langle \phi^{k_l}, \bar{x} - x^{k_l} \rangle \leq 0. \quad (3.14)$$

由引理 2.2 知 $\{\phi^{k_l}\}$ 有界, 对 (3.14) 式取极限得 $f(\bar{x}) \leq 0$, 即 $\bar{x} \in D$.

综上所述, 可以得到 \bar{x} 是问题 (1.4) 的一个解. 所以, 可以用 \bar{x} 来代替上述证明过程中的 x^* . 又 $\{\|x^k - \bar{x}\|\}$ 收敛, 而其子列 $\{\|x^{k_l} - \bar{x}\|\}$ 收敛到零, 故 $\{x^k\}$ 收敛到 \bar{x} .

证毕.

4 数值实验

为了验证本文所给算法 3.2 的可行性, 给出如下几个例子. 下面的例 1–6 取 $s = 1.2, s = 3$ 两种情况来验证. 首先给出的例 1–4, 集合 C 与 Q 都是由可微凸函数的水平集来定义的; 其次给出的例 5–6, 集合 C 与 Q 为不可微凸函数的水平集来定义的. 最后给出的例 7 选取高维的水平集和随机的矩阵. 在实际计算中选取参数 $\omega_k = 1$.

例 1 设 $C = \{x \in R^3 | x_1^2 - x_2 \leq 0\}$, $Q = \{x \in R^3 | x_1^2 + x_2^2 + x_3^2 \leq 0\}$, $A = I$.

求 $x \in C, Ax \in Q$ s.t. $\|x\|_1 \leq s$.

例 2 设 $C = \{x \in R^3 | x_1^2 + x_2^2 - 1 \leq 0\}$, $Q = \{x \in R^3 | x_2^2 + x_3^2 - 1 \leq 0\}$, $A = \begin{bmatrix} 2 & 1 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 2 \end{bmatrix}$.

求 $x \in C, Ax \in Q$ s.t. $\|x\|_1 \leq s$.

例 3 设 $C = \{x \in R^3 | x_2^2 + x_3^2 - 4 \leq 0\}$, $Q = \{x \in R^3 | x_3 - x_1^2 - 1 \leq 0\}$, $A = I$.

求 $x \in C, Ax \in Q$ s.t. $\|x\|_1 \leq s$.

例 4 设 $C = \{x \in R^3 | x_1 + x_2^2 + 2x_3 \leq 0\}$, $Q = \{x \in R^3 | x_1^3 + x_2 - x_3 \leq 0\}$, $A = \begin{bmatrix} 1 & 1 & 0 \\ 0 & 1 & 1 \\ 2 & 0 & 1 \end{bmatrix}$.

求 $x \in C, Ax \in Q$ s.t. $\|x\|_1 \leq s$.

例 5 设 $C = \{x \in R^3 | x_1^2 - |x_2| \leq 0\}$, $Q = \{x \in R^3 | x_1^2 + x_2^2 + x_3^2 \leq 0\}$, $A = I$.

求 $x \in C, Ax \in Q$ s.t. $\|x\|_1 \leq s$.

例 6 设 $C = \{x \in R^3 | x_1 + x_2^2 + 2|x_3| \leq 0\}$, $Q = \{x \in R^3 | x_1^3 + |x_2| - x_3 \leq 0\}$, $A = \begin{bmatrix} 1 & 1 & 0 \\ 0 & 1 & 1 \\ 2 & 0 & 1 \end{bmatrix}$.

求 $x \in C, Ax \in Q$ s.t. $\|x\|_1 \leq s$.

例 7 设 $C = \{x \in R^N | \|x\|_2 \leq 0.25\}$, $Q = \{y \in R^M | 0.6 \leq y_j \leq 1, j = 1, 2, \dots, M\}$, $A = (a_{ij})_{M \times N}$ 且 $a_{ij} \in (0, 50)$ 为随机选取的.

求 $x \in C, Ax \in Q$ s.t. $\|x\|_1 \leq s$.

例 1-6 的数值结果如下表 1.1-6.2. 在表 1.1-7.1 中, x^0 代表初始点, Iter 代表迭代步数, cpu 代表计算时间 (单位为秒), x^* 代表近似解 (以下这些结果都是运用 MATLAB 计算得到的).

表 1.1: 例 1 ($s = 1.2$) 的数值结果

x^0	CPU	Iter	x^*
$(1, 1, 1)^T$	0.095	2	(0.4000, 0.4000, 0.4000)
$(1, 2, 3)^T$	0.091	3	(-0.0543, 0.3118, 0.8338)
$(10, 10, 10)^T$	0.093	2	(0.4000, 0.4000, 0.4000)
$(1, 10, 100)^T$	0.086	9	(-0.2168, 0.0685, 0.8695)

表 1.2: 例 1 ($s = 3$) 的数值结果

x^0	CPU	Iter	x^*
$(1, 1, 1)^T$	0.14	5	(0.5773, 0.5773, 0.5773)
$(1, 2, 3)^T$	0.095	6	(0.2455, 0.5289, 0.8123)
$(10, 10, 10)^T$	0.084	6	(0.5773, 0.5773, 0.5773)
$(1, 10, 100)^T$	0.087	9	(-0.1327, 0.2424, 0.9610)

表 2.1: 例 2 ($s = 1.2$) 的数值结果

x^0	CPU	Iter	x^*
$(1, 1, 1)^T$	0.090	2	(0.5323, 0.4147, 0.2529)
$(1, 2, 3)^T$	0.087	6	(0.0148, 0.4113, 0.4557)
$(10, 10, 10)^T$	0.134	5	(0.9999, 0.0030, -0.1676)
$(1, 10, 100)^T$	0.089	5	(-0.5335, 0.3244, 0.3420)

表 2.2: 例 2 ($s = 3$) 的数值结果

x^0	CPU	Iter	x^*
$(1, 1, 1)^T$	0.086	5	(0.7822, 0.6227, 0.3912)
$(1, 2, 3)^T$	0.086	7	(0.5692, 0.7318, 0.3407)
$(10, 10, 10)^T$	0.095	6	(0.9634, 0.2677, 0.4029)
$(1, 10, 100)^T$	0.088	10	(0.5564, 0.7109, 0.3516)

表 3.1: 例 3 ($s = 1.2$) 的数值结果

x^0	CPU	Iter	x^*
$(1, 2, 3)^T$	0.081	2	$(0.2333, 0.2333, 0.7333)$
$(1, 10, 100)^T$	0.094	5	$(-0.0769, -0.9647, 0.1583)$
$(5, 5, 5)^T$	0.104	15	$(1.2, 0, 0)$

表 3.2: 例 3 ($s = 3$) 的数值结果

x^0	CPU	Iter	x^*
$(1, 2, 3)^T$	0.089	2	$(0.8333, 0.8333, 1.3333)$
$(1, 10, 100)^T$	0.087	7	$(-0.2595, -1.9975, 0.0991)$
$(5, 5, 5)^T$	0.089	2	$(2.5333, 0.2333, 0.2333)$

表 4.1: 例 4 ($s = 1.2$) 的数值结果

x^0	CPU	Iter	x^*
$(1, 1, 1)^T$	0.082	4	$(0.2336, -0.0644, -0.1189)$
$(-10, -10, -10)^T$	0.094	6	$(0.0563, 0.0676, -1.0760)$
$(10, 10, 10)^T$	0.106	14	$(-0.0296, -0.0691, 0.0124)$
$(1, 10, 100)^T$	0.109	19	$(-0.0301, -0.0705, 0.0126)$

表 4.2: 例 4 ($s = 3$) 的数值结果

x^0	CPU	Iter	x^*
$(1, 1, 1)^T$	0.086	4	$(0.2336, -0.0644, -0.1189)$
$(-10, -10, -10)^T$	0.085	6	$(0.0725, 0.0202, -2.9072)$
$(10, 10, 10)^T$	0.084	15	$(-0.0231, -0.0520, 0.0102)$
$(1, 10, 100)^T$	0.087	20	$(-0.0251, -0.0569, 0.0109)$

表 5.1: 例 5 ($s = 1.2$) 的数值结果

x^0	CPU	Iter	x^*
$(1, 1, 1)^T$	0.045	2	$(0.3216, 0.4392, 0.4392)$
$(1, 2, 3)^T$	0.055	3	$(-0.1691, 0.2588, 0.7720)$
$(10, 10, 10)^T$	0.048	3	$(-0.2178, -0.5879, 0.3943)$
$(1, 10, 100)^T$	0.049	9	$(0.0043, -0.1591, 0.9873)$

表 5.2: 例 5 ($s = 3$) 的数值结果

x^0	CPU	Iter	x^*
$(1, 1, 1)^T$	0.045	5	$(0.5504, 0.6455, 0.6455)$
$(1, 2, 3)^T$	0.054	6	$(0.2224, 0.5427, 0, 8338)$
$(10, 10, 10)^T$	0.048	6	$(-0.6430, 0.8498, 0.7373)$
$(1, 10, 100)^T$	0.068	11	$(0.2309, 0.0533, 0.9924)$

表 6.1: 例 6 ($s = 1.2$) 的数值结果

x^0	CPU	Iter	x^*
$(1, 1, 1)^T$	0.051	183	$(0.0000, -0.0000, 0.0000)$
$(-10, -10, -10)^T$	0.061	413	$(-0.5280, -0.6720, 0.0000)$
$(10, 10, 10)^T$	0.067	264	$(-0.5014, -0.6772, 0.0214)$
$(1, 10, 100)^T$	0.068	267	$(-0.5014, -0.6672, 0.0214)$

表 6.2: 例 6 ($s = 3$) 的数值结果

x^0	CPU	Iter	x^*
$(1, 1, 1)^T$	0.057	183	$(0.0000, -0.0000, 0.0000)$
$(-10, -10, -10)^T$	0.048	5	$(-1.9821, 0.0386, -0.0978)$
$(10, 10, 10)^T$	0.047	7	$(-0.9367, -0.3765, 0.3975)$
$(1, 10, 100)^T$	0.052	10	$(-1.8112, -0.1148, 0.8990)$

例 7 的数值结果如下表, 由于选取的水平集为高维的、矩阵是随机的, 所以给出的计算结果中不显示近似解.

表 7.1: 例 7 ($s = 0.12$) 的数值结果

x^0	M=50, N=55		M=100, N=100		M=150, N=200	
	CPU	Iter	CPU	Iter	CPU	Iter
$(0, 0, \dots, 0)^T$	0.045; 4		0.068; 5		0.056; 5	
$100e_1$	0.058; 140		0.081; 172		0.126; 429	
$\text{rand}(N, 1)$	0.075; 78		0.079; 97		0.067; 97	
$-100 * \text{rand}(N, 1)$	0.059; 151		0.069; 133		0.083; 143	

从例 1-7 的数值实验结果可以看出, 所有的计算时间都在 0.1 秒左右完成, 甚至大多数的计算时间都在 0.1 秒以内. 由此可见松弛交替投影算法具有较强的可行性和实用性.

5 本文小结

本文主要对带 1 - 范数约束的分裂可行问题进行了求解. 首先, 在算法上取了可以直接计算的步长, 避免了在求合适的步长时进行大量的计算. 其次, 又寻找包含闭凸集的半空间, 用往半空间上的投影来代替往闭凸集上的投影, 从而提出松弛交替投影算法, 使得投影容易计算. 并给出几个实例来验证松弛交替投影算法的可行性. 数值实验表明本文的算法具有较强的可行性和实用性.

参 考 文 献

- [1] Censor Y, Elfving T. A multiprojection algorithm using Bregman projection in a product space[J]. Numer. Alg., 1994, 8(2): 221–239.
- [2] Liu B, Qu B. A successive projection scheme for solving the multiple-sets split feasibility problem[J]. Numer. Funct. Anal. Optim., 2014, 35(11): 1459–1466.

- [3] Rockafellar R T. Convex analysis[M]. Vol. 28, Princeton: Princeton Math. Ser., 1970.
- [4] 王宣举, 修乃华. 非线性最优化理论与方法 [M]. 北京: 北京科学出版社, 2012.
- [5] Qu B, Xiu N. A note on the CQ algorithm for the split feasibility problem[J]. Inverse Prob., 2005, 21: 1655–1665.
- [6] Censor Y, Elfving T, Kopf N, et al. The multiple-sets split feasibility problem and its applications for inverse problems[J]. Inverse Prob., 2005, 21: 2071–2084.
- [7] Yang Q. The relaxed CQ algorithm solving the split feasibility problem [J]. Inverse Prob., 2004, 20(4): 1261–1266.
- [8] Zhang H, Wang Y. A new CQ method for solving split feasibility problem [J]. Front. Math. China, 2005, 5(1): 37–46.
- [9] Facchinei F, Pang J S. Finite-dimensional variational inequalities and complementarity problems[M]. Vols. I and II, Berlin: Springer Verlag, 2003.
- [10] Qu Biao, Liu Bing-hua and Zhengna. On the computation of the step-size for the CQ-like algorithms for the split feasibility problem[J]. Appl. Math. Comp., 2015, 262: 218–223.
- [11] Carmi A, Censor Y and Gurfil P, Convex feasibility modeling and projection methods for sparse signal recovery[J]. J. Comp. Appl. Math., 2012, 236(17): 4318–4335.
- [12] Amir Beck, Yonina C Eldar. Sparsity constrained nonlinear optimization conditions and algorithms[J]. SIAM Optim., 2012, 23(3): 1480–1509.
- [13] Fukushima M. An outer approximation algorithm for solving general convex programs[J]. Oper. Res., 1983, 31: 101–113.
- [14] He H, Ling C, Xu H. An implementable splitting algorithm for the 1-norm regularized split feasibility problem[J]. J. Sci. Comput., 2016, 67: 281–289.
- [15] He S, Zhu W. A note on approximating curve with 1-norm regularization method for the split feasibility problem[J]. J. Appl. Math., 2012, 16: 3800–3844.
- [16] Massao Fukushima. 非线性最优化基础 [M]. 北京: 科学出版社, 2011.
- [17] 兰晓坚, 曲彪. 求解分裂可行问题的一种半空间投影算法 [J]. 数学杂志, 2011, 31(3): 547–553.
- [18] 房明磊, 朱志斌, 陈凤华, 张聪. 互补约束规划问题的一个广义梯度投影算法 [J]. 数学杂志, 2011, 31(4): 685–694.

PROJECTION ALGORITHMS FOR THE SOLUTION OF SPLIT FEASIBILITY PROBLEM WITH 1-NORM CONSTRAINTS

CHANG Han-xiao, QU Biao

(School of Management, Qufu Normal University, Rizhao 276826, China)

Abstract: In this paper, we mainly study the solution algorithm of the split feasibility problem subject to 1-norm constraints. By using the alternating projections algorithm, we solve the problem successfully and propose a relaxed alternating projections algorithm which improves the shortage of projecting directly onto the closed convex set. And we obtain the convergence of this algorithm.

Keywords: split feasible problem; 1-norm constraints; alternating projections; relaxed

2010 MR Subject Classification: 90C25; 65K05