

一些典型凸优化问题的分裂收缩算法

基于变分不等式和邻近点算法的统一框架

南师大数科院系列讲座 2022年元月4-9日

何炳生

Homepage: maths.nju.edu.cn/~hebma

四. 交替方向法(ADMM)及其线性化方法的收敛性证明

我们讨论求解两个可分离块凸优化问题

$$\min \{\theta_1(x) + \theta_2(y) \mid Ax + By = b, x \in \mathcal{X}, y \in \mathcal{Y}\}. \quad (0.1)$$

的交替方向法. 由于变动目标函数中的常数项对问题的解没有影响, 乘子交替方向法的第 k 次迭代可以表述成从 (y^k, λ^k) 开始:

$$\text{(ADMM)} \begin{cases} x^{k+1} \in \operatorname{argmin} \{ \theta_1(x) - x^T A^T \lambda^k + \frac{\beta}{2} \|Ax + By^k - b\|^2 \mid x \in \mathcal{X} \} & (0.2a) \\ y^{k+1} \in \operatorname{argmin} \{ \theta_2(y) - y^T B^T \lambda^k + \frac{\beta}{2} \|Ax^{k+1} + By - b\|^2 \mid y \in \mathcal{Y} \}, & (0.2b) \\ \lambda^{k+1} = \lambda^k - \beta(Ax^{k+1} + By^{k+1} - b). & (0.2c) \end{cases}$$

1 ADMM 的收敛性分析

子问题 (0.2a) 和 (0.2b) 分别等价于需要求解的子问题的具体形式是

$$x^{k+1} = \operatorname{argmin} \{ \theta_1(x) + \frac{\beta}{2} \| (Ax + By^k - b) - \frac{1}{\beta} \lambda^k \|^2 \mid x \in \mathcal{X} \} \quad (1.1a)$$

和

$$y^{k+1} \in \operatorname{argmin} \{ \theta_2(y) + \frac{\beta}{2} \| (Ax^{k+1} + By - b) - \frac{1}{\beta} \lambda^k \|^2 \mid y \in \mathcal{Y} \}. \quad (1.1b)$$

我们假设这类问题在方法中是容易求解的.

前面的分析已经告诉我们, 问题(0.1)的一阶最优性条件可以表示成一个单调的变分不等式

$$w^* \in \Omega, \quad \theta(w) - \theta(w^*) + (w - w^*)^T F(w^*) \geq 0, \quad \forall w \in \Omega. \quad (1.2a)$$

其中

$$u = \begin{pmatrix} x \\ y \end{pmatrix}, \quad w = \begin{pmatrix} x \\ y \\ \lambda \end{pmatrix}, \quad F(w) = \begin{pmatrix} -A^T \lambda \\ -B^T \lambda \\ Ax + By - b \end{pmatrix} \quad (1.2b)$$

和

$$\theta(u) = \theta_1(x) + \theta_2(y), \quad \Omega = \mathcal{X} \times \mathcal{Y} \times \mathfrak{R}^m. \quad (1.2c)$$

我们注意到这样定义的 F 满足关系式

$$(w - \tilde{w})^T (F(w) - F(\tilde{w})) \equiv 0, \quad \forall w, \tilde{w}. \quad (1.3)$$

还是用 Ω^* 表示变分不等式 (1.2) 的解集.

分析 利用关于最优性的引理, 子问题(0.2a)和(0.2b)的解分别满足

$$\begin{aligned} x^{k+1} \in \mathcal{X}, \quad & \theta_1(x) - \theta_1(x^{k+1}) \\ & + (x - x^{k+1})^T \{-A^T \lambda^k + \beta A^T (Ax^{k+1} + By^k - b)\} \geq 0, \quad \forall x \in \mathcal{X} \end{aligned} \quad (1.4a)$$

和

$$\begin{aligned} y^{k+1} \in \mathcal{Y}, \quad & \theta_2(y) - \theta_2(y^{k+1}) \\ & + (y - y^{k+1})^T \{-B^T \lambda^k + \beta B^T (Ax^{k+1} + By^{k+1} - b)\} \geq 0, \quad \forall y \in \mathcal{Y}. \end{aligned} \quad (1.4b)$$

将 λ^{k+1} (参见(0.2c)) 代入(1.4) (消去其中的 λ^k), 我们得到

$$\begin{aligned} x^{k+1} \in \mathcal{X}, \quad & \theta_1(x) - \theta_1(x^{k+1}) \\ & + (x - x^{k+1})^T \{-A^T \lambda^{k+1} + \beta A^T B(y^k - y^{k+1})\} \geq 0, \quad \forall x \in \mathcal{X}, \end{aligned} \quad (1.5a)$$

和

$$y^{k+1} \in \mathcal{Y}, \quad \theta_2(y) - \theta_2(y^{k+1}) + (y - y^{k+1})^T \{-B^T \lambda^{k+1}\} \geq 0, \quad \forall y \in \mathcal{Y}. \quad (1.5b)$$

我们可将变分不等式 (1.5) 写成一个比较紧凑的形式: $u^{k+1} = (x^{k+1}, y^{k+1}) \in \mathcal{X} \times \mathcal{Y}$, 并且对所有的 $(x, y) \in \mathcal{X} \times \mathcal{Y}$, 都有

$$\theta(u) - \theta(u^{k+1}) + \begin{pmatrix} x - x^{k+1} \\ y - y^{k+1} \end{pmatrix}^T \left\{ \begin{pmatrix} -A^T \lambda^{k+1} \\ -B^T \lambda^{k+1} \end{pmatrix} + \beta \begin{pmatrix} A^T \\ 0 \end{pmatrix} B(y^k - y^{k+1}) \right\} \geq 0. \quad (1.6)$$

再把上述变分不等式写成我们需要的格式: $u^{k+1} = (x^{k+1}, y^{k+1}) \in \mathcal{X} \times \mathcal{Y}$, 使得

$$\begin{aligned} \theta(u) - \theta(u^{k+1}) + \begin{pmatrix} x - x^{k+1} \\ y - y^{k+1} \end{pmatrix}^T \left\{ \begin{pmatrix} -A^T \lambda^{k+1} \\ -B^T \lambda^{k+1} \end{pmatrix} + \beta \begin{pmatrix} A^T \\ B^T \end{pmatrix} B(y^k - y^{k+1}) \right. \\ \left. + \begin{pmatrix} 0 & 0 \\ 0 & \beta B^T B \end{pmatrix} \begin{pmatrix} x^{k+1} - x^k \\ y^{k+1} - y^k \end{pmatrix} \right\} \geq 0, \quad \forall (x, y) \in \mathcal{X} \times \mathcal{Y}. \end{aligned} \quad (1.7)$$

再把等式 (0.2c) 写成等价的

$$(\lambda - \lambda^{k+1}) \{(Ax^{k+1} + By^{k+1} - b) + \frac{1}{\beta}(\lambda^{k+1} - \lambda^k)\} \geq 0, \quad \forall \lambda \in \mathfrak{R}^m. \quad (1.8)$$

将 (1.7) 和 (1.8) 加到一起, 我们有 $w^{k+1} \in \Omega$ 并且

$$\begin{aligned} \theta(u) - \theta(u^{k+1}) + \begin{pmatrix} x - x^{k+1} \\ y - y^{k+1} \\ \lambda - \lambda^{k+1} \end{pmatrix}^T \left\{ \begin{pmatrix} -A^T \lambda^{k+1} \\ -B^T \lambda^{k+1} \\ Ax^{k+1} + By^{k+1} - b \end{pmatrix} + \beta \begin{pmatrix} A^T \\ B^T \\ 0 \end{pmatrix} B(y^k - y^{k+1}) \right. \\ \left. + \begin{pmatrix} 0 & 0 \\ \beta B^T B & 0 \\ 0 & \frac{1}{\beta} I_m \end{pmatrix} \begin{pmatrix} y^{k+1} - y^k \\ \lambda^{k+1} - \lambda^k \end{pmatrix} \right\} \geq 0, \quad \forall w \in \Omega. \end{aligned} \quad (1.9)$$

为方便讨论, 我们定义如下的记号:

$$v = \begin{pmatrix} y \\ \lambda \end{pmatrix}, \quad \mathcal{V}^* = \{(y^*, \lambda^*) \mid (x^*, y^*, \lambda^*) \in \Omega^*\}.$$

和

$$H = \begin{pmatrix} \beta B^T B & 0 \\ 0 & \frac{1}{\beta} I_m \end{pmatrix}. \quad (1.10)$$

利用 (1.2) 和上述记号, 从 (1.9) 我们直接得到如下的引理:

引理 1.1 求解结构型变分不等式 (1.2). 设 $w^{k+1} = (x^{k+1}, y^{k+1}, \lambda^{k+1}) \in \Omega$ 是由算法 (0.2) 生成的新的迭代点, 则有

$$\begin{aligned} \theta(u) - \theta(u^{k+1}) + (w - w^{k+1})^T F(w^{k+1}) \\ \geq \beta \begin{pmatrix} x - x^{k+1} \\ y - y^{k+1} \end{pmatrix}^T \begin{pmatrix} A^T \\ B^T \end{pmatrix} B(y^{k+1} - y^k) \\ + (v - v^{k+1})^T H(v^k - v^{k+1}), \quad \forall w \in \Omega. \end{aligned} \quad (1.11)$$

下面的引理可以由引理 1.1 的结论直接推出.

引理 1.2 求解结构型变分不等式 (1.2). 设 $w^{k+1} = (x^{k+1}, y^{k+1}, \lambda^{k+1}) \in \Omega$ 是由算法 (0.2) 生成的新的迭代点, 则有

$$\begin{aligned} (v^{k+1} - v^*)^T H(v^k - v^{k+1}) \\ \geq \beta \begin{pmatrix} x^{k+1} - x^* \\ y^{k+1} - y^* \end{pmatrix}^T \begin{pmatrix} A^T \\ B^T \end{pmatrix} B(y^k - y^{k+1}), \quad \forall w^* \in \Omega^*, \end{aligned} \quad (1.12)$$

证明. 在变分不等式 (1.11) 中令 $w = w^*$, 并利用 H 的表达式, 我们得到

$$\begin{aligned} (v^{k+1} - v^*)^T H(v^k - v^{k+1}) \\ \geq \theta(u^{k+1}) - \theta(u^*) + (w^{k+1} - w^*)^T F(w^{k+1}) \\ + \beta \begin{pmatrix} x^{k+1} - x^* \\ y^{k+1} - y^* \end{pmatrix}^T \begin{pmatrix} A^T \\ B^T \end{pmatrix} B(y^k - y^{k+1}), \quad \forall w^* \in \Omega^*. \end{aligned} \quad (1.13)$$

由于 F 是单调的, 并且 w^* 是最优解, 则

$$\theta(u^{k+1}) - \theta(u^*) + (w^{k+1} - w^*)^T F(w^{k+1}) \geq 0.$$

利用上述不等式, 结论(1.12) 可从(1.13) 直接得到. \square

引理 1.3 求解结构型变分不等式 (1.2). 设 $w^{k+1} = (x^{k+1}, y^{k+1}, \lambda^{k+1}) \in \Omega$ 是由算法 (0.2) 生成的新的迭代点, 则有

$$\beta \begin{pmatrix} x^{k+1} - x^* \\ y^{k+1} - y^* \end{pmatrix}^T \begin{pmatrix} A^T \\ B^T \end{pmatrix} B(y^k - y^{k+1}) \geq 0, \quad \forall w^* \in \Omega^*. \quad (1.14)$$

证明. 利用 $Ax^* + By^* = b$, 我们有

$$\begin{aligned} & \beta \begin{pmatrix} x^{k+1} - x^* \\ y^{k+1} - y^* \end{pmatrix}^T \begin{pmatrix} A^T \\ B^T \end{pmatrix} B(y^k - y^{k+1}) \\ &= \beta \{(Ax^{k+1} + By^{k+1}) - (Ax^* + By^*)\}^T B(y^k - y^{k+1}) \\ &= \beta (Ax^{k+1} + By^{k+1} - b)^T B(y^k - y^{k+1}) \\ &= (\lambda^k - \lambda^{k+1})^T B(y^k - y^{k+1}). \end{aligned} \quad (1.15)$$

上面最后一个等式是用了 (0.2c). 因为 (1.5b) 对第 k 次及前一次迭代均成立, 因此有

$$\theta_2(y) - \theta_2(y^{k+1}) + (y - y^{k+1})^T \{-B^T \lambda^{k+1}\} \geq 0, \quad \forall y \in \mathcal{Y}, \quad (1.16)$$

和

$$\theta_2(y) - \theta_2(y^k) + (y - y^k)^T \{-B^T \lambda^k\} \geq 0, \quad \forall y \in \mathcal{Y}, \quad (1.17)$$

我们在(1.16) 令 $y = y^k$ 并且在(1.17)中令 $y = y^{k+1}$, 然后将得到的变分不等式相加得到

$$(\lambda^k - \lambda^{k+1})^T B(y^k - y^{k+1}) \geq 0. \quad (1.18)$$

将(1.18) 代入到(1.15)中, 我们得到结论(1.14). \square

将不等式 (1.14) 的结论代入不等式 (1.12), 我们有

$$(v^{k+1} - v^*)^T H(v^k - v^{k+1}) \geq 0, \quad \forall v^* \in \mathcal{V}^*. \quad (1.19)$$

根据上述不等式和预备知识中提到的简单引理, 我们直接得到下面的定理.

定理 1.1 求解结构型变分不等式 (1.2). 设 $w^{k+1} = (x^{k+1}, y^{k+1}, \lambda^{k+1}) \in \Omega$ 是由算法 (0.2) 生成的新的迭代点, 则有

$$\|v^{k+1} - v^*\|_H^2 \leq \|v^k - v^*\|_H^2 - \|v^k - v^{k+1}\|_H^2, \quad \forall v^* \in \mathcal{V}^*. \quad (1.20)$$

定理 1.1 提供了 ADMM 算法收敛性证明的关键不等式.

如何选取参数 β . ADMM 算法的效率严重依赖于 (0.2) 中参数 β 的值. 我们接下来讨论在实际计算当中如何选择适当的参数 β .

注意到如果 $\beta A^T B(y^k - y^{k+1}) = 0$, 则利用 (1.6) 就得到

$$\theta(u) - \theta(u^{k+1}) + \begin{pmatrix} x - x^{k+1} \\ y - y^{k+1} \end{pmatrix}^T \begin{pmatrix} -A^T \lambda^{k+1} \\ -B^T \lambda^{k+1} \end{pmatrix} \geq 0, \quad \forall (x, y) \in \mathcal{X} \times \mathcal{Y}. \quad (1.21)$$

在这种情况下, 如果 $Ax^{k+1} + By^{k+1} - b = 0$ 也成立, 则我们得到

$$\begin{cases} \theta_1(x) - \theta_1(x^{k+1}) + (x - x^{k+1})^T (-A^T \lambda^{k+1}) \geq 0, & \forall x \in \mathcal{X} \\ \theta_2(y) - \theta_2(y^{k+1}) + (y - y^{k+1})^T (-B^T \lambda^{k+1}) \geq 0, & \forall y \in \mathcal{Y} \\ (\lambda - \lambda^{k+1})^T (Ax^{k+1} + By^{k+1} - b) \geq 0, & \forall \lambda \in \mathbb{R}^m \end{cases}$$

因此 $(x^{k+1}, y^{k+1}, \lambda^{k+1})$ 是变分不等式(1.2)的一个最优解. 换句话说, 如果

$$\beta A^T B(y^k - y^{k+1}) \neq 0 \quad \text{和/或} \quad Ax^{k+1} + By^{k+1} - b \neq 0,$$

则 $(x^{k+1}, y^{k+1}, \lambda^{k+1})$ 不是变分不等式(1.2)的解. 我们称

$$\|\beta A^T B(y^k - y^{k+1})\| \quad \text{和} \quad \|Ax^{k+1} + By^{k+1} - b\|$$

分别为原始残差和对偶残差. 通过上述分析而知, 我们应该在迭代过程中动态的平衡原始残差和对偶残差. 如果

$$\mu \|\beta A^T B(y^k - y^{k+1})\| < \|Ax^{k+1} + By^{k+1} - b\| \quad \text{其中} \quad \mu > 1,$$

这意味着对偶残差过大, 我们应该增大增广Lagrange函数中参数 β 的值. 倒过来, 我们应该减小 β 的值.

下面我们介绍一种简单而有效的调整参数 β 的格式(参见, e.g., [7]):

$$\beta_{k+1} = \begin{cases} \beta_k * \tau, & \text{如果 } \mu \|\beta A^T B(y^k - y^{k+1})\| < \|Ax^{k+1} + By^{k+1} - b\|; \\ \beta_k / \tau, & \text{如果 } \|\beta A^T B(y^k - y^{k+1})\| > \mu \|Ax^{k+1} + By^{k+1} - b\|; \\ \beta_k, & \text{其它.} \end{cases}$$

其中参数 $\mu > 1, \tau > 1$. 一种典型的参数选择为 $\mu = 10$ 和 $\tau = 2$. 这种参数更新方式的背后的想法是通过因子 τ 来控制原始残差和对偶残差的范数, 使得两者达到动态均衡并收敛到0. 这种自调比方式已经被用于S. Boyd的科研组[1]以及他们的凸优化求解器当中[5].

2 线性化的交替方向法

常用的ADMM方法(0.2)中, 每步迭代的主要工作是相当于对给定的 p^k 和 q^k , 分别求解(1.1)这样的子问题. 在一些实际应用中, 由于矩阵 A 或 B 的结构, 其中会有一个子问题难解. 我们总设其中比较难解的问题是(0.2b).

由于变动目标函数中的常数项对问题的解没有影响, 我们考察 ADMM 中的子问题 (0.2b),

$$\begin{aligned} y^{k+1} &= \arg \min \{ \mathcal{L}_\beta^{[2]}(x^{k+1}, y, \lambda^k) \mid y \in \mathcal{Y} \} \\ &= \arg \min \{ \theta_2(y) - y^T B^T \lambda^k + \frac{\beta}{2} \|Ax^{k+1} + By - b\|^2 \mid y \in \mathcal{Y} \} \\ &= \arg \min \left\{ \begin{array}{l} \theta_2(y) - y^T B^T [\lambda^k - \beta(Ax^{k+1} + By^k - b)] \\ + \frac{\beta}{2} \|B(y - y^k)\|^2 \end{array} \mid y \in \mathcal{Y} \right\}. \end{aligned}$$

因此, 困难在于目标函数中既有 $\theta_2(y)$, 又有二次项 $\frac{\beta}{2} \|B(y - y^k)\|^2$. 所谓线性化的 ADMM, 就是用简单的二次函数

$$\frac{s}{2} \|y - y^k\|^2 \quad \text{去代替} \quad \frac{\beta}{2} \|B(y - y^k)\|^2.$$

换句话说, 就是将 (0.2b) 中的

$$\mathcal{L}_\beta^{[2]}(x^{k+1}, y, \lambda^k) \quad \text{换成} \quad \mathcal{L}_\beta^{[2]}(x^{k+1}, y, \lambda^k) + \frac{s}{2} \|y - y^k\|^2 - \frac{\beta}{2} \|B(y - y^k)\|^2.$$

因此, 对照 ADMM 公式 (0.2), 线性化的 ADMM 的迭代公式可以表述成:

(L-ADMM)	$\begin{cases} x^{k+1} = \arg \min \{ \mathcal{L}_\beta(x, y^k, \lambda^k) \mid x \in \mathcal{X} \}, & (2.1a) \\ y^{k+1} = \arg \min \{ \mathcal{L}_\beta(x^{k+1}, y, \lambda^k) + \frac{1}{2} \ y - y^k\ _{D_B}^2 \mid y \in \mathcal{Y} \}, & (2.1b) \\ \lambda^{k+1} = \lambda^k - \beta(Ax^{k+1} + By^{k+1} - b), & (2.1c) \end{cases}$	
其中	$D_B = sI - \beta B^T B. \quad (2.2)$	

经过这种“线性化”以后, 子问题 (2.1b) 中的 y^{k+1} 就是

$$\begin{aligned} y^{k+1} &= \arg \min \{ \mathcal{L}_\beta^{[2]}(x^{k+1}, y, \lambda^k) + \frac{1}{2} \|y - y^k\|_{D_B}^2 \mid y \in \mathcal{Y} \} \\ &= \arg \min \left\{ \begin{array}{l} \theta_2(y) - y^T B^T \lambda^k + \beta y^T B^T (Ax^{k+1} + By^k - b) \\ + \frac{s}{2} \|y - y^k\|^2 \end{array} \mid y \in \mathcal{Y} \right\} \\ &= \arg \min \left\{ \theta_2(y) + \frac{s}{2} \|y - d^k\|^2 \mid y \in \mathcal{Y} \right\}, \end{aligned} \quad (2.3)$$

其中

$$d^k = y^k - \frac{1}{s} B^T [\beta(Ax^{k+1} + By^k - b) - \lambda^k].$$

为了理论上保证收敛, 对于固定(不能随意变小)的 β , 人们要求 (2.2) 中的参数 [12, 13]

$$s \geq \beta \|B^T B\|. \quad (2.4)$$

大家同时知道, 过大的 $s > 0$, 会影响收敛速度.

我们先根据迭代 (2.1) 中子问题的最优性条件, 给出下面的基本引理.

引理 2.1 用线性化乘子交替方向法 (2.1) 求解结构型变分不等式 (1.2). 设 w^{k+1} 是由给定的 $v^k = (y^k, \lambda^k)$ 所产生的新的迭代点, 那么有

$$\begin{aligned} w^{k+1} \in \Omega, \quad & \theta(w) - \theta(w^{k+1}) + (w - w^{k+1})^T F(w^{k+1}) + \beta(x - x^{k+1})^T A^T (By^k - By^{k+1}) \\ & \geq (y - y^{k+1})^T D_B (y^k - y^{k+1}) \\ & \quad + \frac{1}{\beta} (\lambda - \lambda^{k+1})^T (\lambda^k - \lambda^{k+1}), \quad \forall w \in \Omega. \end{aligned} \quad (2.5)$$

证明 对 L-ADMM 算法的 x -子问题 (2.1a), 有

$$\begin{aligned} x^{k+1} \in \mathcal{X}, \quad & \theta_1(x) - \theta_1(x^{k+1}) \\ & + (x - x^{k+1})^T \{-A^T \lambda^k + \beta A^T (Ax^{k+1} + By^k - b)\} \geq 0, \quad \forall x \in \mathcal{X}. \end{aligned}$$

利用 (2.1) 中的乘子校正公式 $\lambda^{k+1} = \lambda^k - \beta(Ax^{k+1} + By^{k+1} - b)$, 上式可以写成

$$\begin{aligned} x^{k+1} \in \mathcal{X}, \quad & \theta_1(x) - \theta_1(x^{k+1}) \\ & + (x - x^{k+1})^T \{-A^T \lambda^{k+1} + \beta A^T B(y^k - y^{k+1})\} \geq 0, \quad \forall x \in \mathcal{X}. \end{aligned} \quad (2.6)$$

对 L-ADMM 算法的 y -子问题 (2.1b), 有

$$\begin{aligned} y^{k+1} \in \mathcal{Y}, \quad & \theta_2(y) - \theta_2(y^{k+1}) + (y - y^{k+1})^T \{-B^T \lambda^k + \beta B^T (Ax^{k+1} + By^{k+1} - b)\} \\ & + (y - y^{k+1})^T D_B (y^{k+1} - y^k) \geq 0, \quad \forall y \in \mathcal{Y}. \end{aligned}$$

利用乘子校正公式 $\lambda^{k+1} = \lambda^k - \beta(Ax^{k+1} + By^{k+1} - b)$, 上式可以写成

$$y^{k+1} \in \mathcal{Y}, \quad \theta_2(y) - \theta_2(y^{k+1}) + (y - y^{k+1})^T \{-B^T \lambda^{k+1} + D_B (y^{k+1} - y^k)\} \geq 0, \quad \forall y \in \mathcal{Y}. \quad (2.7)$$

注意到乘子校正公式 $\lambda^{k+1} = \lambda^k - \beta(Ax^{k+1} + By^{k+1} - b)$ 本身可以写成

$$\lambda^{k+1} \in \mathfrak{R}^m, \quad (\lambda - \lambda^{k+1})^T \{(Ax^{k+1} + By^{k+1} - b) + \frac{1}{\beta} (\lambda^{k+1} - \lambda^k)\} \geq 0, \quad \forall \lambda \in \mathfrak{R}^m. \quad (2.8)$$

将 (2.6), (2.7) 和 (2.8) 加在一起, 注意到其中下划线的部分组合在一起就是 $F(w^{k+1})$. 利用 (1.2) 中的记号, 我们得到

$$\begin{aligned} w^{k+1} \in \Omega, \quad & \theta(w) - \theta(w^{k+1}) + (w - w^{k+1})^T F(w^{k+1}) + \beta(x - x^{k+1})^T A^T B(y^k - y^{k+1}) \\ & \geq (y - y^{k+1})^T D_B (y^k - y^{k+1}) \\ & \quad + \frac{1}{\beta} (\lambda - \lambda^{k+1})^T (\lambda^k - \lambda^{k+1}), \quad \forall w \in \Omega. \end{aligned} \quad (2.9)$$

对 (2.9) 式左端中的 $(w - w^{k+1})^T F(w^{k+1})$ 利用 (1.3), 有

$$(w - w^{k+1})^T F(w^{k+1}) = (w - w^{k+1})^T F(w).$$

这就证明了该引理的结论 (2.5). \square

这个基本引理, 是我们证明方法收敛性质的重要基础. 下面我们证明算法产生的迭代序列 $\{w^k\}$ 具有收缩性质. 对任意的 $v^* \in \mathcal{V}^*$, 序列 $\{\|v^k - v^*\|_G + \|y^{k-1} - y^k\|_{D_B}^2\}$ 是单调下降的. 为此, 我们先证明几个引理.

引理 2.2 用线性化乘子交替方向法 (2.1) 求解结构型变分不等式 (1.2). 设 w^{k+1} 是由给定的 $v^k = (y^k, \lambda^k)$ 所产生的新的迭代点, 那么有

$$\begin{aligned} w^{k+1} \in \Omega, \quad & \theta(w) - \theta(w^{k+1}) + (w - w^{k+1})^T F(w^{k+1}) \\ & + \beta \begin{pmatrix} x - x^{k+1} \\ y - y^{k+1} \end{pmatrix}^T \begin{pmatrix} A^T \\ B^T \end{pmatrix} B(y^k - y^{k+1}) \\ & \geq (v - v^{k+1})^T G(v^k - v^{k+1}), \quad \forall w \in \Omega, \end{aligned} \quad (2.10)$$

其中

$$G = \begin{pmatrix} D_B + \beta B^T B & 0 \\ 0 & \frac{1}{\beta} I \end{pmatrix}. \quad (2.11)$$

证明. 对引理 2.1 中 (2.5) 的两端加上 $(y - y^{k+1})^T \beta B^T B(y^k - y^{k+1})$, 并利用矩阵 G 的结构就马上得到 (2.10), 引理得证. \square

引理 2.3 用线性化乘子交替方向法 (2.1) 求解结构型变分不等式 (1.2). 设 w^{k+1} 是由给定的 $v^k = (y^k, \lambda^k)$ 所产生的新的迭代点, 那么有

$$(v^{k+1} - v^*)^T G(v^k - v^{k+1}) \geq (\lambda^k - \lambda^{k+1})^T B(y^k - y^{k+1}), \quad \forall w^* \in \Omega^*. \quad (2.12)$$

证明. 将 (2.10) 的 $w \in \Omega$ 设为任意的 $w^* \in \Omega^*$, 我们有

$$\begin{aligned} & (v^{k+1} - v^*)^T G(v^k - v^{k+1}) \\ & \geq \beta \begin{pmatrix} x^{k+1} - x^* \\ y^{k+1} - y^* \end{pmatrix}^T \begin{pmatrix} A^T \\ B^T \end{pmatrix} B(y^k - y^{k+1}) \\ & \quad + \{\theta(u^{k+1}) - \theta(u^*) + (w^{k+1} - w^*)^T F(w^{k+1})\}. \end{aligned} \quad (2.13)$$

利用 $Ax^* + By^* = b$ 和 $\lambda^k - \lambda^{k+1} = \beta(Ax^{k+1} + By^{k+1} - b)$ (see (2.1c)) 处理(2.13) 右端的第一部分, 就有

$$\begin{aligned} & \beta \begin{pmatrix} x^{k+1} - x^* \\ y^{k+1} - y^* \end{pmatrix}^T \begin{pmatrix} A^T \\ B^T \end{pmatrix} B(y^k - y^{k+1}) \\ & = \beta[(Ax^{k+1} - Ax^*) + (By^{k+1} - By^*)]^T B(y^k - y^{k+1}) \\ & = (\lambda^k - \lambda^{k+1})^T B(y^k - y^{k+1}). \end{aligned}$$

根据 (1.3) 和最优性条件, (2.13) 右端的第二部分

$$\begin{aligned} & \theta(u^{k+1}) - \theta(u^*) + (w^{k+1} - w^*)^T F(w^{k+1}) \\ & = \theta(u^{k+1}) - \theta(u^*) + (w^{k+1} - w^*)^T F(w^*) \geq 0. \end{aligned}$$

综合这两条, 引理得证. \square

引理 2.4 用线性化乘子交替方向法 (2.1) 求解结构型变分不等式 (1.2). 设 w^{k+1} 是由给定的 $v^k = (y^k, \lambda^k)$ 所产生的新的迭代点, 那么有

$$(\lambda^k - \lambda^{k+1})^T B(y^k - y^{k+1}) \geq \frac{1}{2} \|y^k - y^{k+1}\|_{D_B}^2 - \frac{1}{2} \|y^{k-1} - y^k\|_{D_B}^2. \quad (2.14)$$

证明. 首先, (2.7) 式表示 $y^{k+1} \in \mathcal{Y}$ 并且

$$\theta_2(y) - \theta_2(y^{k+1}) + (y - y^{k+1})^T \{-B^T \lambda^{k+1} + D_B(y^{k+1} - y^k)\} \geq 0, \quad \forall y \in \mathcal{Y}. \quad (2.15)$$

以 $k-1$ 置换 (2.15) 中的 k , 就有 $y^k \in \mathcal{Y}$ 并且

$$\theta_2(y) - \theta_2(y^k) + (y - y^k)^T \{-B^T \lambda^k + D_B(y^k - y^{k-1})\} \geq 0, \quad \forall y \in \mathcal{Y}. \quad (2.16)$$

将 (2.15) 和 (2.16) 中的任意的 $y \in \mathcal{Y}$ 分别设成 y^k 和 y^{k+1} , 然后将两式相加, 有

$$(y^k - y^{k+1})^T \{B^T(\lambda^k - \lambda^{k+1}) + D_B[(y^{k+1} - y^k) - (y^k - y^{k-1})]\} \geq 0.$$

由上式得到

$$(y^k - y^{k+1})^T B^T(\lambda^k - \lambda^{k+1}) \geq (y^k - y^{k+1})^T D_B[(y^k - y^{k+1}) - (y^{k-1} - y^k)].$$

由于 D_B 矩阵正定, 对上式右端使用

$$\|a\|_{D_B}^2 - a^T(D_B)b \geq \frac{1}{2}\|a\|_{D_B}^2 - \frac{1}{2}\|b\|_{D_B}^2$$

这样的不等式就得到 (2.14). \square

根据引理 2.3 和引理 2.4 我们可以直接证明下面的定理.

定理 2.1 用线性化乘子交替方向法 (2.1) 求解结构型变分不等式 (1.2). 设 w^{k+1} 是由给定的 $v^k = (y^k, \lambda^k)$ 所产生的新的迭代点, 那么有

$$\begin{aligned} & (\|v^{k+1} - v^*\|_G^2 + \|y^k - y^{k+1}\|_{D_B}^2) \\ & \leq (\|v^k - v^*\|_G^2 + \|y^{k-1} - y^k\|_{D_B}^2) - \|v^k - v^{k+1}\|_G^2, \quad \forall w^* \in \Omega^*, \end{aligned} \quad (2.17)$$

其中 G 由 (2.11) 给出.

证明. 由引理 2.3 和引理 2.4, 有

$$(v^{k+1} - v^*)^T G(v^k - v^{k+1}) \geq \frac{1}{2} \|y^k - y^{k+1}\|_{D_B}^2 - \frac{1}{2} \|y^{k-1} - y^k\|_{D_B}^2, \quad \forall w^* \in \Omega^*.$$

利用上式, 对任意的 $w^* \in \Omega^*$, 都有

$$\begin{aligned} \|v^k - v^*\|_G^2 &= \|(v^{k+1} - v^*) + (v^k - v^{k+1})\|_G^2 \\ &\geq \|v^{k+1} - v^*\|_G^2 + \|v^k - v^{k+1}\|_G^2 + 2(v^{k+1} - v^*)^T G(v^k - v^{k+1}) \\ &\geq \|v^{k+1} - v^*\|_G^2 + \|v^k - v^{k+1}\|_G^2 + \|y^k - y^{k+1}\|_{D_B}^2 - \|y^{k-1} - y^k\|_{D_B}^2. \end{aligned}$$

这就证明了定理 2.1 的结论. \square

3 ADMM 算法的收敛性证明

在线性化 ADMM 的收敛性质定理 2.1 中取 $D_B = 0$, 这时其中的矩阵 G 就等同于 (1.10) 中的矩阵 H , 得到了 ADMM 收敛性质的定理 1.1. 因此, 我们只要对线性化的 ADMM 证明算法的收敛定理. 其证明思路和 PPA 算法收敛性定理相同.

定理 3.1 设 $\{w^k$ 是用线性化乘子交替方向法 (2.1) 求解结构型变分不等式 (1.2) 产生的序列. 那么相应的序列 $\{v^k\}$ 收敛于属于 \mathcal{V}^* 的一点 v^∞ .

Proof. 首先, 根据定理 2.1 的结论 (2.17), 有

$$\begin{aligned} \|v^k - v^{k+1}\|_G^2 \leq & (\|v^k - v^*\|_G^2 + \|y^{k-1} - y^k\|_{D_B}^2) \\ & - (\|v^{k+1} - v^*\|_G^2 + \|y^k - y^{k+1}\|_{D_B}^2). \end{aligned} \quad (3.1)$$

将上式对 $k = 1, 2, \dots$, 累加, 得到

$$\sum_{k=1}^{\infty} \|v^k - v^{k+1}\|_G^2 \leq \|v^1 - v^*\|_G^2 + \|y^0 - y^1\|_{D_B}^2. \quad (3.2)$$

由于矩阵 G 是正定的, 由上面的不等式得到

$$\lim_{k \rightarrow \infty} \|v^k - v^{k+1}\| = 0. \quad (3.3)$$

对任意确定的 $v^* \in \mathcal{V}^*$, 不等式 (2.17) 告诉我们, 对任意的 $k \geq 1$, 都有

$$\begin{aligned} \|v^{k+1} - v^*\|_G^2 & \leq \|v^k - v^*\|_G^2 + \|y^{k-1} - y^k\|_{D_B}^2 \\ & \leq \|v^1 - v^*\|_G^2 + \|y^0 - y^1\|_{D_B}^2, \end{aligned} \quad (3.4)$$

因此序列 $\{v^k\}$ 是有界的. 设 $\{v^{k_j}\}$ 是 $\{v^k\}$ 的收敛于 v^∞ 的子序列, x^∞ 是与 $(y^\infty, \lambda^\infty)$ 相应的中间变量. 那么, 由 (2.5) 和 (3.3) 得到

$$w^\infty \in \Omega, \quad \theta(w) - \theta(w^\infty) + (w - w^\infty)^T F(w^\infty) \geq 0, \quad \forall w \in \Omega,$$

这说明 w^∞ 是 (1.2) 的解并且其核心部分 $v^\infty \in \mathcal{V}^*$. 因为 $v^\infty \in \mathcal{V}^*$, 从 (3.4) 中有

$$\|v^{k+1} - v^\infty\|_G^2 \leq \|v^k - v^\infty\|_G^2 + \|y^{k-1} - y^k\|_{D_B}^2. \quad (3.5)$$

结合 (3.3), 上式说明 $\{v^k\}$ 不可能有多于一个聚点. 所以序列 $\{v^k\}$ 收敛于 v^∞ . \square

参考文献

- [1] S. Boyd, N. Parikh, E. Chu, B. Peleato and J. Eckstein, Distributed Optimization and Statistical Learning via the Alternating Direction Method of Multipliers, Foundations and Trends in Machine Learning Vol. 3, No. 1 (2010) 1 - 122.

- [2] X.J. Cai, G.Y. Gu, B.S. He and X.M. Yuan, A proximal point algorithms revisit on the alternating direction method of multipliers, *Science China Mathematics*, 56 (2013), 2179-2186.
- [3] R. Glowinski, *Numerical Methods for Nonlinear Variational Problems*, Springer-Verlag, New York, Berlin, Heidelberg, Tokyo, 1984.
- [4] Gu G Y, He B S and Yuan X M. Customized proximal point algorithms for linearly constrained convex minimization and saddle-point problems: a unified approach. *Comput. Optim. Appl.*, 2014, 59: 135-161.
- [5] D. Hallac, Ch. Wong, S. Diamond, A. Sharang, R. Sosič, S. Boyd and J. Leskovec, SnapVX: A Network-Based Convex Optimization Solver, *Journal of Machine Learning Research* 18 (2017) 1-5.
- [6] B. S. He, PPA-like contraction methods for convex optimization: a framework using variational inequality approach. *J. Oper. Res. Soc. China* **3** (2015) 391 - 420.
- [7] B.S. He, H. Yang, and S.L. Wang, Alternating directions method with self-adaptive penalty parameters for monotone variational inequalities, *JOTA* **23**(2000), 349-368.
- [8] B. S. He, M. Tao and X.M. Yuan, Alternating direction method with Gaussian back substitution for separable convex programming, *SIAM Journal on Optimization* **22**(2012), 313-340.
- [9] B.S. He and X. M. Yuan, Convergence analysis of primal-dual algorithms for a saddle-point problem: From contraction perspective, *SIAM Journal on Imaging Science*, **5**, 119-149, 2012.
- [10] M. R. Hestenes, Multiplier and gradient methods, *JOTA* **4**, 303-320, 1969.
- [11] M. J. D. Powell, A method for nonlinear constraints in minimization problems, in *Optimization*, R. Fletcher, ed., Academic Press, New York, NY, pp. 283-298, 1969.
- [12] Yang J F and Yuan X M. Linearized augmented Lagrangian and alternating direction methods for nuclear norm minimization *Mathematics of Computation*, 2013, 82: 301-329
- [13] Zhang X. Q, Burger M and Osher S. A unified primal-dual algorithm framework based on Bregman iteration, *J. Sci. Comput.*, 2010, 46: 20 - 46.
- [14] 何炳生. 从变分不等式的统一收缩算法到凸优化的分裂收缩算法, *高等学校计算数学学报*, 2016, 38: 74-96.
- [15] 何炳生. 凸优化的一阶分裂算法-变分不等式为工具的统一框架, 见 <http://maths.nju.edu.cn/~hebma> 中的《My Talk》.
- [16] 何炳生. 凸优化和单调变分不等式的收缩算法, 见 <http://maths.nju.edu.cn/~hebma> 中的系列讲义.