

# 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](http://maths.nju.edu.cn/~hebma)

## 八. 三个可分离块的凸优化问题

这一章考虑三块可分离凸优化问题

$$\min\{\theta_1(x) + \theta_2(y) + \theta_3(z) \mid Ax + By + Cz = b, x \in \mathcal{X}, y \in \mathcal{Y}, z \in \mathcal{Z}\} \quad (0.1)$$

的求解方法. 这个问题的拉格朗日函数是

$$L(x, y, z, \lambda) = \theta_1(x) + \theta_2(y) + \theta_3(z) - \lambda^T (Ax + By + Cz - b).$$

问题 (0.1) 同样可以归结为变分不等式问题

$$w^* \in \Omega, \quad \theta(u) - \theta(u^*) + (w - w^*)^T F(w^*) \geq 0, \quad \forall w \in \Omega, \quad (0.2a)$$

其中

$$w = \begin{pmatrix} x \\ y \\ z \\ \lambda \end{pmatrix}, \quad u = \begin{pmatrix} x \\ y \\ z \end{pmatrix}, \quad F(w) = \begin{pmatrix} -A^T \lambda \\ -B^T \lambda \\ -C^T \lambda \\ Ax + By + Cz - b \end{pmatrix}, \quad (0.2b)$$

和

$$\theta(u) = \theta_1(x) + \theta_2(y) + \theta_3(z), \quad \Omega = \mathcal{X} \times \mathcal{Y} \times \mathcal{Z} \times \mathfrak{R}^m. \quad (0.2c)$$

相应的增广拉格朗日函数记为(与两个算子的符号有区别)

$$\begin{aligned} \mathcal{L}_\beta^{[3]}(x, y, z, \lambda) = & \theta_1(x) + \theta_2(y) + \theta_3(z) - \lambda^T (Ax + By + Cz - b) \\ & + \frac{\beta}{2} \|Ax + By + Cz - b\|^2. \end{aligned} \quad (0.3)$$

## 1 直接推广的 ADMM 求解三块可分离问题不保证收敛

对三个可分离块的凸优化问题, 采用直接推广的乘子交替方向法, 第  $k$  步迭代是从给定的  $v^k = (y^k, z^k, \lambda^k)$  出发, 通过

$$\begin{cases} x^{k+1} = \arg \min \{ \mathcal{L}_\beta^{[3]}(x, y^k, z^k, \lambda^k) \mid x \in \mathcal{X} \}, \\ y^{k+1} = \arg \min \{ \mathcal{L}_\beta^{[3]}(x^{k+1}, y, z^k, \lambda^k) \mid y \in \mathcal{Y} \}, \\ z^{k+1} = \arg \min \{ \mathcal{L}_\beta^{[3]}(x^{k+1}, y^{k+1}, z, \lambda^k) \mid z \in \mathcal{Z} \}, \\ \lambda^{k+1} = \lambda^k - \beta(Ax^{k+1} + By^{k+1} + Cz^{k+1} - b), \end{cases} \quad (1.1)$$

求得新的迭代点  $w^{k+1} = (x^{k+1}, y^{k+1}, z^{k+1}, \lambda^{k+1})$ . 当矩阵  $A, B, C$  中有两个是互相正交的时候, 用方法 (1.1) 求解问题 (0.1) 是收敛的. 因为这种三块的可分离问题, 实际上相当于两块可分离的问题. 对一般的三块可分离问题, 是不能保证收敛的[1].

### 值得继续研究的问题和猜想

譬如说, 三个算子的实际问题中, 线性约束矩阵

$$A = [A, B, C] \quad \text{中, 往往至少有一个是单位矩阵. 即, } A = [A, B, I].$$

直接推广的 ADMM 处理这种更贴近实际的三个算子的问题, 既没有证明收敛, 也没有举出反例, 这仍然是一个有趣又特别有意义的问题! 举个简单的例子来说吧:

- 经典的乘子交替方向法处理问题

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

- 将等式约束换成不等式约束, 问题就变成

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

- 再化成三个算子的等式约束问题就是

$$\min\{\theta_1(x) + \theta_2(y) + 0 \mid Ax + By + z = b, x \in \mathcal{X}, y \in \mathcal{Y}, z \geq 0\}.$$

- 直接推广的乘子交替方向法 (1.1) 处理上面这种问题, 我们猜想是收敛的, 但是至今没有证明收敛性. 仍然是一个遗留的挑战性问题!

在对直接推广的 ADMM (1.1) 证明不了收敛性的时候, 我们就着手对三块可分离的问题提出一些修正算法. 修正方法的原则是尽量对 ADMM 少做改动, 保持它原来的好品性. 特别是对问题不加(诸如目标函数强凸等)任何额外条件, 对经典 ADMM 中需要调比选取的大于零的  $\beta$ , 仍然让它可以自由选取.

这一章的后面几节, 除了对已经发表的一些算法分别用统一框架去验证收敛性, 也介绍一些最近根据统一框架构造的方法.

## 2 部分平行分裂的 ADMM 预测校正方法

这一节的方法源自 2009 年发表的[5], 还是把  $x$  当成中间变量, 迭代从  $v^k = (y^k, z^k, \lambda^k)$  到  $v^{k+1} = (y^{k+1}, z^{k+1}, \lambda^{k+1})$ , 只是平行处理  $y$  和  $z$ -子问题, 再更新  $\lambda$ . 换句话说, 把

$$\begin{cases} x^{k+1} = \arg \min \{ \mathcal{L}_\beta^{[3]}(x, y^k, z^k, \lambda^k) \mid x \in \mathcal{X} \}, \\ y^{k+1} = \arg \min \{ \mathcal{L}_\beta^{[3]}(x^{k+1}, y, z^k, \lambda^k) \mid y \in \mathcal{Y} \}, \\ z^{k+1} = \arg \min \{ \mathcal{L}_\beta^{[3]}(x^{k+1}, y^k, z, \lambda^k) \mid z \in \mathcal{Z} \}, \\ \lambda^{k+1} = \lambda^k - \beta(Ax^{k+1} + By^{k+1} + Cz^{k+1} - b) \end{cases} \quad (2.1)$$

生成的点  $(x^{k+1}, y^{k+1}, z^{k+1}, \lambda^{k+1})$  当成预测点. 再把核心变量往回拉一点. 原因是  $y, z$  子问题平行处理, 包括据此更新的  $\lambda$ , 都太自由, 需要校正. 校正公式是

$$v^{k+1} := v^k - \alpha(v^k - v^{k+1}), \quad \alpha \in (0, 2 - \sqrt{2}). \quad (2.2)$$

譬如说, 我们可以取  $\alpha = 0.55$ . 注意到 (2.2) 右端的  $v^{k+1} = (y^{k+1}, z^{k+1}, \lambda^{k+1})$  是由 (2.1) 提供的.

我们用统一框架来验证这个部分平行分裂的预测校正方法的收敛性. 先把由 (2.1) 生成的  $(x^{k+1}, y^{k+1}, z^{k+1})$  视为  $(\tilde{x}^k, \tilde{y}^k, \tilde{z}^k)$ , 并定义

$$\tilde{\lambda}^k = \lambda^k - \beta(A\tilde{x}^k + B\tilde{y}^k + C\tilde{z}^k - b). \quad (2.3)$$

这样, 预测点  $(\tilde{x}^k, \tilde{y}^k, \tilde{z}^k, \tilde{\lambda}^k)$  就可以看成由下式生成:

$$\begin{cases} \tilde{x}^k = \arg \min \{ \mathcal{L}_\beta^{[3]}(x, y^k, z^k, \lambda^k) \mid x \in \mathcal{X} \}, & (2.4a) \\ \tilde{y}^k = \arg \min \{ \mathcal{L}_\beta^{[3]}(\tilde{x}^k, y, z^k, \lambda^k) \mid y \in \mathcal{Y} \}, & (2.4b) \\ \tilde{z}^k = \arg \min \{ \mathcal{L}_\beta^{[3]}(\tilde{x}^k, y^k, z, \lambda^k) \mid z \in \mathcal{Z} \}, & (2.4c) \\ \tilde{\lambda}^k = \lambda^k - \beta(A\tilde{x}^k + B\tilde{y}^k + C\tilde{z}^k - b). & (2.4d) \end{cases}$$

利用增广拉格朗日函数 (0.3), 子问题 (2.4a) 相当于

$$\tilde{x}^k = \operatorname{argmin}\{\theta_1(x) - x^T A^T \lambda^k + \frac{1}{2}\beta\|Ax + By^k + Cz^k - b\|^2 \mid x \in \mathcal{X}\},$$

根据最优性引理,  $\tilde{x}^k \in \mathcal{X}$ ,

$$\theta_1(x) - \theta_1(\tilde{x}^k) + (x - \tilde{x}^k)^T \{-A^T \lambda^k + \beta A^T (A\tilde{x}^k + B\tilde{y}^k - b)\} \geq 0, \quad \forall x \in \mathcal{X}.$$

再根据 (2.4d), 就有

$$\tilde{x}^k \in \mathcal{X}, \quad \theta_1(x) - \theta_1(\tilde{x}^k) + (x - \tilde{x}^k)^T \{-A^T \tilde{\lambda}^k\} \geq 0, \quad \forall x \in \mathcal{X}. \quad (2.5a)$$

子问题 (2.4b) 相当于

$$\tilde{y}^k = \operatorname{argmin}\{\theta_2(y) - y^T B^T \lambda^k + \frac{1}{2}\beta\|A\tilde{x}^k + By + Cz^k - b\|^2 \mid y \in \mathcal{Y}\},$$

同样根据最优性条件引理, 有  $\tilde{y}^k \in \mathcal{Y}$ ,

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

再根据 (2.4d), 就有

$$\tilde{y}^k \in \mathcal{Y}, \quad \theta_2(y) - \theta_2(\tilde{y}^k) + (y - \tilde{y}^k)^T \left\{ \frac{-B^T \tilde{\lambda}^k}{\beta} + \beta B^T B (\tilde{y}^k - y^k) \right\} \geq 0, \quad \forall y \in \mathcal{Y}. \quad (2.5b)$$

同理, 对子问题 (2.4c) 有

$$\tilde{z}^k \in \mathcal{Z}, \quad \theta_3(z) - \theta_3(\tilde{z}^k) + (z - \tilde{z}^k)^T \left\{ \frac{-C^T \tilde{\lambda}^k}{\beta} + \beta C^T C (\tilde{z}^k - z^k) \right\} \geq 0, \quad \forall z \in \mathcal{Z}. \quad (2.5c)$$

注意到 (2.4d) 可以写成

$$\underline{(A\tilde{x}^k + B\tilde{y}^k + C\tilde{z}^k - b)} - B(\tilde{y}^k - y^k) - C(\tilde{z}^k - z^k) + (1/\beta)(\tilde{\lambda}^k - \lambda^k) = 0. \quad (2.5d)$$

把 (2.6) 中的公式组合在一起, 可以写成统一框架中的预测形式:

$$\tilde{w}^k \in \Omega, \quad \theta(w) - \theta(\tilde{w}^k) + (w - \tilde{w}^k)^T F(\tilde{w}^k) \geq (v - \tilde{v}^k)^T Q(v^k - \tilde{v}^k), \quad \forall w \in \Omega, \quad (2.6a)$$

其中

$$Q = \begin{pmatrix} \beta B^T B & 0 & 0 \\ 0 & \beta C^T C & 0 \\ -B & -C & \frac{1}{\beta} I \end{pmatrix}. \quad (2.6b)$$

回头来看方法 (2.1)-(2.2) 在统一框架中的校正该怎么表示. 由于

$$y^{k+1} = \tilde{y}^k, \quad z^{k+1} = \tilde{z}^k, \quad \text{和} \quad \lambda^{k+1} = \tilde{\lambda}^k + \beta B(y^k - \tilde{y}^k) + \beta C(z^k - \tilde{z}^k).$$

把 (2.4) 的输出作为预测点时, 校正公式 (2.2) 就可以表示成

$$\begin{pmatrix} y^{k+1} \\ z^{k+1} \\ \lambda^{k+1} \end{pmatrix} = \begin{pmatrix} y^k \\ z^k \\ \lambda^k \end{pmatrix} - \alpha \begin{pmatrix} I & 0 & 0 \\ 0 & I & 0 \\ -\beta B & -\beta C & I \end{pmatrix} \begin{pmatrix} y^k - \tilde{y}^k \\ z^k - \tilde{z}^k \\ \lambda^k - \tilde{\lambda}^k \end{pmatrix}.$$

也就是说, 利用了统一框架中 (2.6) 这样的预测表达式, 方法 (2.1)-(2.2) 的校正公式是

$$v^{k+1} = v^k - \alpha(v^k - \tilde{v}^k), \quad (2.7a)$$

其中

$$M = \begin{pmatrix} I & 0 & 0 \\ 0 & I & 0 \\ -\beta B & -\beta C & I \end{pmatrix}. \quad (2.7b)$$

对这样的  $Q$  和  $M$ , 设

$$H = \begin{pmatrix} \beta B^T B & 0 & 0 \\ 0 & \beta C^T C & 0 \\ 0 & 0 & \frac{1}{\beta} I \end{pmatrix},$$

就有  $HM = Q$ , 说明收敛性条件满足.

根据统一框架, 要找出一个  $\alpha > 0$ , 使得条件

$$G = (Q^T + Q) - \alpha M^T H M \succ 0$$

满足. 简单的矩阵运算得到

$$\begin{aligned} G &= (Q^T + Q) - \alpha M^T H M = (Q^T + Q) - \alpha M^T Q \\ &= \begin{pmatrix} \sqrt{\beta} B^T & 0 & 0 \\ 0 & \sqrt{\beta} C^T & 0 \\ 0 & 0 & \frac{1}{\sqrt{\beta}} I \end{pmatrix} \begin{pmatrix} 2(1-\alpha)I & -\alpha I & -(1-\alpha)I \\ -\alpha I & 2(1-\alpha)I & -(1-\alpha)I \\ -(1-\alpha)I & -(1-\alpha)I & (2-\alpha)I \end{pmatrix} \\ &\quad \begin{pmatrix} \sqrt{\beta} B & 0 & 0 \\ 0 & \sqrt{\beta} C & 0 \\ 0 & 0 & \frac{1}{\sqrt{\beta}} I \end{pmatrix}. \end{aligned}$$

容易验证, 对所有的  $\alpha \in (0, 2 - \sqrt{2})$ , 矩阵

$$\begin{pmatrix} 2(1-\alpha) & -\alpha & -(1-\alpha) \\ -\alpha & 2(1-\alpha) & -(1-\alpha) \\ -(1-\alpha) & -(1-\alpha) & (2-\alpha) \end{pmatrix} \succ 0.$$

收敛性条件满足.

### 3 带高斯回代的 ADMM 方法

带高斯回代的 ADMM 方法 [6] 是 2012 年发表的. 直接推广的乘子交替方向法 (1.1) 对三个算子的问题不能保证收敛, 是因为它们处理有关核心变量的  $y$  和  $z$ -子问题不公平. 采取补救的办法是将 (1.1) 提供的  $(y^{k+1}, z^{k+1}, \lambda^{k+1})$  当成预测点, 校正公式为

$$\begin{pmatrix} y^{k+1} \\ z^{k+1} \\ \lambda^{k+1} \end{pmatrix} := \begin{pmatrix} y^k \\ z^k \\ \lambda^k \end{pmatrix} - \nu \begin{pmatrix} I & -(B^T B)^{-1} B^T C & 0 \\ 0 & I & 0 \\ 0 & 0 & I \end{pmatrix} \begin{pmatrix} y^k - y^{k+1} \\ z^k - z^{k+1} \\ \lambda^k - \lambda^{k+1} \end{pmatrix}. \quad (3.1)$$

其中  $\nu \in (0, 1)$ , 右端的  $(y^{k+1}, z^{k+1}, \lambda^{k+1})$  是由 (1.1) 提供的. 这个方法发表在 [6]. 想法是不公平, 就要做找补, 调整. 事实上, 也可以就用 (1.1) 提供的  $\lambda^{k+1}$ , 只通过

$$\begin{pmatrix} y^{k+1} \\ z^{k+1} \end{pmatrix} := \begin{pmatrix} y^k \\ z^k \end{pmatrix} - \nu \begin{pmatrix} I & -(B^T B)^{-1} B^T C \\ 0 & I \end{pmatrix} \begin{pmatrix} y^k - y^{k+1} \\ z^k - z^{k+1} \end{pmatrix}. \quad (3.2)$$

校正  $y$  和  $z$  (无需校正  $\lambda$ ). 由于为下一步迭代只需要准备  $(By^{k+1}, Cz^{k+1}, \lambda^{k+1})$ , 我们只要做比(3.2)更简单的

$$\begin{pmatrix} By^{k+1} \\ Cz^{k+1} \end{pmatrix} := \begin{pmatrix} By^k \\ Cz^k \end{pmatrix} - \nu \begin{pmatrix} I & -I \\ 0 & I \end{pmatrix} \begin{pmatrix} By^k - By^{k+1} \\ Cz^k - Cz^{k+1} \end{pmatrix}. \quad (3.3)$$

上式中这个从下到上的过程我们把它叫做高斯回代.

求解三个可分离块凸优化 (0.1), [6] 中介绍了带高斯回代的 ADMM 方法. 把由直接推广的 (1.1) 生成的  $x^{k+1}, y^{k+1}, z^{k+1}$  分别视为  $\tilde{x}^k, \tilde{y}^k, \tilde{z}^k$ , 并定义

$$\tilde{\lambda}^k = \lambda^k - \beta(A\tilde{x}^k + B\tilde{y}^k + C\tilde{z}^k - b).$$

把  $\tilde{w}^k = (\tilde{x}^k, \tilde{y}^k, \tilde{z}^k, \tilde{\lambda}^k)$  看做预测点, 它由下面的公式

$$\begin{cases} \tilde{x}^k = \operatorname{argmin}\{\theta_1(x) - (\lambda^k)^T Ax + \frac{\beta}{2}\|Ax + By^k + Cz^k - b\|^2 | x \in \mathcal{X}\}, \\ \tilde{y}^k = \operatorname{argmin}\{\theta_2(y) - (\lambda^k)^T By + \frac{\beta}{2}\|A\tilde{x}^k + By + Cz^k - b\|^2 | y \in \mathcal{Y}\}, \\ \tilde{z}^k = \operatorname{argmin}\{\theta_3(z) - (\lambda^k)^T Cz + \frac{\beta}{2}\|A\tilde{x}^k + B\tilde{y}^k + Cz - b\|^2 | z \in \mathcal{Z}\}, \\ \tilde{\lambda}^k = \lambda^k - \beta(A\tilde{x}^k + B\tilde{y}^k + C\tilde{z}^k - b). \end{cases}$$

这样, 利用最优性引理把最优性条件写出来, 利用变分不等式 (0.2) 的形式, 就可以写成统一框架中预测的形式:

$$\tilde{w}^k \in \Omega, \quad \theta(u) - \theta(\tilde{w}^k) + (w - \tilde{w}^k)^T F(\tilde{w}^k) \geq (v - \tilde{v}^k)^T Q(v^k - \tilde{v}^k), \forall w \in \Omega, \quad (3.4a)$$

其中

$$Q = \begin{pmatrix} \beta B^T B & 0 & 0 \\ \beta C^T B & \beta C^T C & 0 \\ -B & -C & \frac{1}{\beta} I \end{pmatrix}. \quad (3.4b)$$

利用这样的预测点, 只校正  $y$  和  $z$  的公式 (3.2) (注意  $\lambda^{k+1}$  和  $\tilde{\lambda}^k$  的关系) 就可以写成

$$\begin{pmatrix} y^{k+1} \\ z^{k+1} \\ \lambda^{k+1} \end{pmatrix} = \begin{pmatrix} y^k \\ z^k \\ \lambda^k \end{pmatrix} - \begin{pmatrix} \nu I & -\nu(B^T B)^{-1} B^T C & 0 \\ 0 & \nu I & 0 \\ -\beta B & -\beta C & I \end{pmatrix} \begin{pmatrix} y^k - \tilde{y}^k \\ z^k - \tilde{z}^k \\ \lambda^k - \tilde{\lambda}^k \end{pmatrix}.$$

也就是说, 在统一框架的校正公式中

$$M = \begin{pmatrix} \nu I & -\nu(B^T B)^{-1} B^T C & 0 \\ 0 & \nu I & 0 \\ -\beta B & -\beta C & I \end{pmatrix}. \quad (3.5)$$

对于矩阵

$$H = \begin{pmatrix} \frac{1}{\nu} \beta B^T B & \frac{1}{\nu} \beta B^T C & 0 \\ \frac{1}{\nu} \beta C^T B & \frac{1}{\nu} \beta [C^T C + C^T B (B^T B)^{-1} B^T C] & 0 \\ 0 & 0 & \frac{1}{\beta} I \end{pmatrix} \quad (3.6)$$

可以验证  $H$  正定并有  $HM = Q$ . 此外,

$$\begin{aligned} G &= (Q^T + Q) - M^T H M = (Q^T + Q) - M^T Q \\ &= \begin{pmatrix} 2\beta B^T B & \beta B^T C & -B^T \\ \beta C^T B & 2\beta C^T C & -C^T \\ -B & -C & \frac{2}{\beta} I \end{pmatrix} - \begin{pmatrix} (1+\nu)\beta B^T B & \beta B^T C & -B^T \\ \beta C^T B & (1+\nu)\beta C^T C & -C^T \\ -B & -C & \frac{1}{\beta} I \end{pmatrix} \\ &= \begin{pmatrix} (1-\nu)\beta B^T B & 0 & 0 \\ 0 & (1-\nu)\beta C^T C & 0 \\ 0 & 0 & \frac{1}{\beta} I \end{pmatrix}. \end{aligned}$$

由于  $\nu \in (0, 1)$ , 矩阵  $G$  正定, 收敛性条件满足.

事实上, 从 (3.4) 得到了

$$\begin{pmatrix} B\tilde{y}^k - By^* \\ Cz^k - Cz^* \\ \tilde{\lambda}^k - \lambda^* \end{pmatrix}^T \begin{pmatrix} \beta I & 0 & 0 \\ \beta I & \beta I & 0 \\ -I & -I & \frac{1}{\beta} I \end{pmatrix} \begin{pmatrix} B(y^k - \tilde{y}^k) \\ C(z^k - \tilde{z}^k) \\ \lambda^k - \tilde{\lambda}^k \end{pmatrix} \geq 0.$$

若令

$$\xi = \begin{pmatrix} By \\ Cz \\ \lambda \end{pmatrix} \quad \text{和} \quad \mathcal{Q} = \begin{pmatrix} \beta I & 0 & 0 \\ \beta I & \beta I & 0 \\ -I & -I & \frac{1}{\beta} I \end{pmatrix}, \quad (3.7)$$

就有

$$(\tilde{\xi}^k - \xi^*)^T \mathcal{Q}(\xi^k - \tilde{\xi}^k) \geq 0,$$

和因此得到的

$$(\xi^k - \xi^*)^T \mathcal{Q}(\xi^k - \tilde{\xi}^k) \geq (\xi^k - \tilde{\xi}^k)^T \mathcal{Q}(\xi^k - \tilde{\xi}^k). \quad (3.8)$$

回代公式 (3.3) 就可以写成

$$\xi^{k+1} = \xi^k - \mathcal{M}(\xi^k - \tilde{\xi}^k) \quad \text{其中} \quad \mathcal{M} = \begin{pmatrix} \nu I & -\nu I & 0 \\ 0 & \nu I & 0 \\ -\beta I & -\beta I & I \end{pmatrix}. \quad (3.9)$$

对于

$$\mathcal{H} = \begin{pmatrix} \frac{1}{\nu}\beta I & \frac{1}{\nu}\beta I & 0 \\ \frac{1}{\nu}\beta I & \frac{2}{\nu}\beta I & 0 \\ 0 & 0 & \frac{1}{\beta} I \end{pmatrix}, \quad \text{我们有} \quad \mathcal{H}\mathcal{M} = \mathcal{Q}.$$

利用 (3.8) 和  $\mathcal{H}\mathcal{M} = \mathcal{Q}$ , 我们得到

$$\begin{aligned} &\|\xi^k - \xi^*\|_{\mathcal{H}}^2 - \|\xi^{k+1} - \xi^*\|_{\mathcal{H}}^2 \\ &= \|\xi^k - \xi^*\|_{\mathcal{H}}^2 - \|(\xi^k - \xi^*) - \mathcal{M}(\xi^k - \tilde{\xi}^k)\|_{\mathcal{H}}^2 \\ &= 2(\xi^k - \xi^*)^T \mathcal{H}\mathcal{M}(\xi^k - \tilde{\xi}^k) - \|\mathcal{M}(\xi^k - \tilde{\xi}^k)\|_{\mathcal{H}}^2 \\ &\geq 2(\xi^k - \tilde{\xi}^k)^T \mathcal{Q}(\xi^k - \tilde{\xi}^k) - \|\xi^k - \tilde{\xi}^k\|_{(\mathcal{M}^T \mathcal{H} \mathcal{M})}^2 \\ &= (\xi^k - \tilde{\xi}^k)[\mathcal{Q}^T + \mathcal{Q} - \mathcal{M}^T \mathcal{H} \mathcal{M}](\xi^k - \tilde{\xi}^k). \end{aligned} \quad (3.10)$$

由于

$$\begin{aligned} \mathcal{G} &= \mathcal{Q}^T + \mathcal{Q} - \mathcal{M}^T \mathcal{H} \mathcal{M} = \mathcal{Q}^T + \mathcal{Q} - \mathcal{Q}^T \mathcal{M} \\ &= \begin{pmatrix} 2\beta I & \beta I & -I \\ \beta I & 2\beta I & -I \\ -I & -I & \frac{2}{\beta} I \end{pmatrix} - \begin{pmatrix} \beta I & \beta I & -I \\ 0 & \beta I & -I \\ 0 & 0 & \frac{1}{\beta} I \end{pmatrix} \begin{pmatrix} \nu I & -\nu I & 0 \\ 0 & \nu I & 0 \\ -\beta I & -\beta I & I \end{pmatrix} \\ &= \begin{pmatrix} (1-\nu)\beta I & 0 & 0 \\ 0 & (1-\nu)\beta I & 0 \\ 0 & 0 & \frac{1}{\beta} I \end{pmatrix} \succ 0, \end{aligned}$$

所以

$$\|\xi^{k+1} - \xi^*\|_{\mathcal{H}}^2 \leq \|\xi^k - \xi^*\|_{\mathcal{H}}^2 - \|\xi^k - \tilde{\xi}^k\|_{\mathcal{G}}^2.$$

从另一个角度证明了方法的收敛性.

## 4 部分平行并加正则项的 ADMM 方法

下面的方法与 §2 中方法相同的是平行求解  $y$ ,  $z$ -子问题, 不同的是不做后处理, 而是给这两个子问题预先都加个正则项. 方法写起来就是

$$\begin{cases} x^{k+1} = \arg \min \{ \mathcal{L}_{\beta}^{[3]}(x, y^k, z^k, \lambda^k) \mid x \in \mathcal{X} \}, \\ y^{k+1} = \arg \min \{ \mathcal{L}_{\beta}^{[3]}(x^{k+1}, y, z^k, \lambda^k) + \frac{\nu}{2}\beta \|B(y - y^k)\|^2 \mid y \in \mathcal{Y} \}, \\ z^{k+1} = \arg \min \{ \mathcal{L}_{\beta}^{[3]}(x^{k+1}, y^k, z, \lambda^k) + \frac{\nu}{2}\beta \|C(z - z^k)\|^2 \mid z \in \mathcal{Z} \}, \\ \lambda^{k+1} = \lambda^k - \beta(Ax^{k+1} + By^{k+1} + Cz^{k+1} - b), \end{cases}$$

其中  $\nu > 1$ . 上述做法相当于

$$\begin{cases} x^{k+1} = \operatorname{argmin} \{ \theta_1(x) + \frac{\beta}{2} \|Ax + By^k + Cz^k - b - \frac{1}{\beta} \lambda^k\|^2 \mid x \in \mathcal{X} \}, \\ \lambda^{k+\frac{1}{2}} = \lambda^k - \beta(Ax^{k+1} + By^k + Cz^k - b) \\ y^{k+1} = \operatorname{argmin} \{ \theta_2(y) - y^T B^T \lambda^{k+\frac{1}{2}} + \frac{\mu\beta}{2} \|B(y - y^k)\|^2 \mid y \in \mathcal{Y} \}, \\ z^{k+1} = \operatorname{argmin} \{ \theta_3(z) - z^T C^T \lambda^{k+\frac{1}{2}} + \frac{\mu\beta}{2} \|C(z - z^k)\|^2 \mid z \in \mathcal{Z} \}, \\ \lambda^{k+1} = \lambda^k - \beta(Ax^{k+1} + By^{k+1} + Cz^{k+1} - b), \end{cases} \quad (4.1)$$

其中  $\mu = \nu + 1$ . 例如, 可以取  $\mu = 2.01$ . 这类发表在 [7, 8] 的算法思想是: 让  $y$  和  $z$  各自独立, 又不准备校正, 那就预先加正则项让它们不致走得太远. [7] 中的方法被 UCLA Osher 教授的课题组成功用来求解图像降维问题 [2].

把由 (4.1) 生成的  $(x^{k+1}, y^{k+1}, z^{k+1}, \lambda^{k+\frac{1}{2}})$  视为预测点  $(\tilde{x}^k, \tilde{y}^k, \tilde{z}^k, \tilde{\lambda}^k)$ , 这个预测公式就成为

$$\begin{cases} \tilde{x}^k = \operatorname{argmin} \{ \theta_1(x) - x^T A^T \lambda^k + \frac{\beta}{2} \|Ax + By^k + Cz^k - b\|^2 \mid x \in \mathcal{X} \}, \\ \tilde{y}^k = \operatorname{argmin} \{ \theta_2(y) - y^T B^T \tilde{\lambda}^k + \frac{\mu\beta}{2} \|B(y - y^k)\|^2 \mid y \in \mathcal{Y} \}, \\ \tilde{z}^k = \operatorname{argmin} \{ \theta_3(z) - z^T C^T \tilde{\lambda}^k + \frac{\mu\beta}{2} \|C(z - z^k)\|^2 \mid z \in \mathcal{Z} \}, \\ \tilde{\lambda}^k = \lambda^k - \beta(A\tilde{x}^k + B\tilde{y}^k + C\tilde{z}^k - b). \end{cases} \quad (4.2)$$



这样, 利用最优性引理和变分不等式 (0.2) 的形式, 预测就可以写成统一框架中的形式:

$$\tilde{w}^k \in \Omega, \quad \theta(u) - \theta(\tilde{u}^k) + (w - \tilde{w}^k)^T F(\tilde{w}^k) \geq (v - \tilde{v}^k)^T Q(v^k - \tilde{v}^k), \forall w \in \Omega, \quad (4.3a)$$

其中

$$Q = \begin{pmatrix} \mu\beta B^T B & 0 & 0 \\ 0 & \mu\beta C^T C & 0 \\ -B & -C & \frac{1}{\beta} I \end{pmatrix}. \quad (4.3b)$$

利用这样的预测点, 校正  $y$  和  $z$  的公式 (注意  $\lambda^{k+1}$  和  $\tilde{\lambda}^k$  的关系) 就可以写成

$$\begin{pmatrix} y^{k+1} \\ z^{k+1} \\ \lambda^{k+1} \end{pmatrix} = \begin{pmatrix} y^k \\ z^k \\ \lambda^k \end{pmatrix} - \begin{pmatrix} I & 0 & 0 \\ 0 & I & 0 \\ -\beta B & -\beta C & I \end{pmatrix} \begin{pmatrix} y^k - \tilde{y}^k \\ z^k - \tilde{z}^k \\ \lambda^k - \tilde{\lambda}^k \end{pmatrix}.$$

也就是说, 在统一框架的校正公式中

$$M = \begin{pmatrix} I & 0 & 0 \\ 0 & I & 0 \\ -\beta B & -\beta C & I \end{pmatrix}. \quad (4.4)$$

对于矩阵

$$H = \begin{pmatrix} \mu\beta B^T B & 0 & 0 \\ 0 & \mu\beta C^T C & 0 \\ 0 & 0 & \frac{1}{\beta} I \end{pmatrix},$$

可以验证  $H$  正定并有  $HM = Q$ . 此外,

$$\begin{aligned} G &= (Q^T + Q) - M^T H M = (Q^T + Q) - M^T Q \\ &= \begin{pmatrix} 2\mu\beta B^T B & 0 & -B^T \\ 0 & 2\mu\beta C^T C & -C^T \\ -B & -C & \frac{2}{\beta} I \end{pmatrix} - \begin{pmatrix} (1+\mu)\beta B^T B & \beta B^T C & -B^T \\ \beta C^T B & (1+\mu)\beta C^T C & -C^T \\ -B & -C & \frac{1}{\beta} I \end{pmatrix} \\ &= \begin{pmatrix} (\mu-1)\beta B^T B & -\beta B^T C & 0 \\ -\beta C^T B & (\mu-1)\beta C^T C & 0 \\ 0 & 0 & \frac{1}{\beta} I \end{pmatrix}. \end{aligned}$$

由于  $\mu > 2$ , 矩阵  $G$  正定, 收敛性条件满足. 方法的收敛性得到证明.

## 参考文献

- [1] C. H. Chen, B. S. He, Y. Y. Ye and X. M. Yuan, The direct extension of ADMM for multi-block convex minimization problems is not necessarily convergent, *Mathematical Programming, Series A*, 155 (2016) 57-79.

- [2] E. Esser, M. Möller, S. Osher, G. Sapiro and J. Xin, A convex model for non-negative matrix factorization and dimensionality reduction on physical space, *IEEE Trans. Imag. Process.*, 21(7), 3239-3252, 2012.
- [3] R. Glowinski, *Numerical Methods for Nonlinear Variational Problems*, Springer-Verlag, New York, Berlin, Heidelberg, Tokyo, 1984.
- [4] 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.
- [5] B. S. He, Parallel splitting augmented Lagrangian methods for monotone structured variational inequalities, *Computational Optimization and Applications* **42**(2009), 195–212.
- [6] 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.
- [7] B.S. He, M. Tao and X.M. Yuan, A splitting method for separable convex programming, *IMA Journal of Numerical Analysis*, **31**, 394-426, 2015.
- [8] Tao M and Yuan X M. Recovering low-rank and sparse components of matrices from incomplete and noisy observations *SIAM Journal on Optimization*, 2011, 21: 57-81.
- [9] B.S. He, My 20 years research on alternating directions method of multipliers (in Chinese). *Oper. Res. Trans.*, 2018, 22: 1-31.
- [10] 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.
- [11] 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》.
- [12] 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.