

# 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)

## 七. 均困的增广拉格朗日乘子法

这一章继续介绍如何用第统一框架来构造求解凸优化问题

$$\min\{\theta(x) \mid Ax = b \text{ (or } \geq b), x \in \mathcal{X}\}. \quad (0.1)$$

问题

$$L(x, \lambda) = \theta(x) - \lambda^T(Ax - b). \quad (0.2)$$

相应的变分不等式是

$$w^* \in \Omega, \quad \theta(x) - \theta(x^*) + (w - w^*)^T F(w^*) \geq 0, \quad \forall w \in \Omega, \quad (0.3a)$$

其中

$$w = \begin{pmatrix} x \\ \lambda \end{pmatrix}, \quad F(w) = \begin{pmatrix} -A^T \lambda \\ Ax - b \end{pmatrix}, \quad \Omega = \mathcal{X} \times \Lambda. \quad (0.3b)$$

注意到, 对等式约束  $Ax = b$  和不等式约束  $Ax \geq b$ ,  $\Lambda$  分别为  $\Re^m$  和  $\Re_+^m$ . 这一章的方法中, 我们需要定义一个  $m \times m$  矩阵

$$H_0 = \frac{1}{r} AA^T + \delta I_m. \quad (0.4)$$

对任意的  $\delta > 0$ , 矩阵  $H$  是正定的.

### 1 均困平衡的增广拉格朗日乘子法

我们从增广拉格朗日乘子法 [8, 9, 10] 谈起, 许多有效算法 (例如交替方向法 (ADMM)) 起源于 ALM. 用 ALM, 求解等式约束问题 (0.1), 迭代公式是

$$\begin{cases} x^{k+1} \in \arg \min \{L(x, \lambda^k) + \frac{r}{2} \|Ax - b\|^2 \mid x \in \mathcal{X}\}, & (1.1a) \\ \lambda^{k+1} = \arg \max \{L(x^{k+1}, \lambda) - \frac{1}{2r} \|\lambda - \lambda^k\|^2 \mid \lambda \in \Re^m\}. & (1.1b) \end{cases}$$

把 ALM 中  $x$ -子问题 (1.1a) 中目标函数里的常数项做调整, ALM 可以通过

$$x^{k+1} \in \operatorname{argmin}\{\theta(x) + rx^T A^T (Ax^k - b) + \frac{r}{2} \|A(x - x^k)\|^2 \mid x \in \mathcal{X}\},$$

实现. ALM 的  $x$ -子问题 (1.1a) 中既有非线性凸函数  $\theta(x)$ , 又有形如  $\frac{r}{2} \|A(x - x^k)\|^2$  的二次项. 这两项加在一起, 会给求解带来一定的困难. ALM 中通过 (1.1b) 更新对偶变量  $\lambda^{k+1}$ , 这非常简单. 前面介绍的求解等式和不等式约束的凸优化问题 ALM 类算法, 它们的  $x$ -子问题的目标函数中同样既包含非线性函数  $\theta(x)$ , 还包含二次项  $\|A(x - x^k)\|^2$ .

我们试图利用统一框架构造新的算法, 通过

$$\begin{cases} x^{k+1} \in \operatorname{argmin}\{L(x, \lambda^k) + \frac{r}{2} \|x - x^k\|^2 \mid x \in \mathcal{X}\}, & (1.2a) \\ \lambda^{k+1} = \operatorname{argmax}\{L(x^{k+1}, \lambda) - \frac{1}{2} \|\lambda - \lambda^k\|_{H_0}^2 \mid \lambda \in \mathfrak{R}^m\}. & (1.2b) \end{cases}$$

得出预测点  $w^{k+1} = (x^{k+1}, \lambda^{k+1})$ , 其中矩阵  $H_0$  由 (0.4) 给出. 比起 (1.1), (1.2) 中的  $x$ -子问题简化了, 但是增加了求得  $\lambda^{k+1}$  的难度. (1.2b) 中的  $\lambda^{k+1}$  是一个并不难解的线性方程组

$$\left(\frac{1}{r} AA^T + \delta I_m\right)(\lambda - \lambda^k) + (Ax^{k+1} - b) = 0$$

的解. 虽然由 (1.2) 的最优性条件的变分不等式形式和预备知识一章中的 PPA 格式不匹配, 后面我们就会看到, 在统一框架的指导下, 一个单位上三角矩阵的校正就能保证迭代序列收敛.

用 Chambolle 和 Pock 的可以解释成 PPA 的原始-对偶混合梯度法 [3, 4, 7], 我们把它称为求解等式约束问题 (0.1), 迭代公式是

$$(CP\text{-PPA}) \quad \begin{cases} x^{k+1} = \operatorname{argmin}\{L(x, \lambda^k) + \frac{r}{2} \|x - x^k\|^2 \mid x \in \mathcal{X}\}, & (1.3a) \\ \lambda^{k+1} = \operatorname{argmax}\{L([2x^{k+1} - x^k], \lambda) - \frac{s}{2} \|\lambda - \lambda^k\|^2\}. & (1.3b) \end{cases}$$

这里的  $r, s > 0$  是迫使新的  $x^{k+1}$  和  $\lambda^{k+1}$  分别离原来的  $x^k$  和  $\lambda^k$  不要太远. CP-PPA 方法中  $x$ -子问题的二次项简单, 求解也相对容易. 然而, 为了保证收敛, 要求参数

$$rs > \|A^T A\|. \quad (1.4)$$

从 (1.3) 可以看出, 过大的  $r$  和  $s$ , 分别迫使  $x^{k+1}$  离  $x^k$ ,  $\lambda^{k+1}$  离  $\lambda^k$  很近, 相当于迭代中步长受限, 影响整体收敛速度. CP-PPA 方法在图像处理中的确取得了比较好的效果, 是得益于其中用到的全变差矩阵的  $\|A^T A\| \leq 8$ .

把 (1.3b) 中的二次项

$$\frac{s}{2} \|\lambda - \lambda^k\|^2 \quad \text{换成} \quad \frac{1}{2} \|\lambda - \lambda^k\|_{H_0}^2.$$

这里的参数  $r > 0$  子问题 (1.3a) 中已经确定了. 任意的  $\delta > 0$  只是为了保证某种正定性. 这样, Balanced ALM 的迭代公式是

$$\begin{cases} x^{k+1} = \arg \min \{L(x, \lambda^k) + \frac{r}{2} \|x - x^k\|^2 \mid x \in \mathcal{X}\}, & (1.5a) \\ \lambda^{k+1} = \arg \max \{L([2x^{k+1} - x^k], \lambda) - \frac{1}{2} \|\lambda - \lambda^k\|_{(\frac{1}{r}AA^T + \delta I_m)}^2\}. & (1.5b) \end{cases}$$

就像 ALM 方法一样, Balanced ALM 中只有一个参数  $r$  需要根据具体问题而选择. Balanced ALM 方法迭代公式的等价形式是

$$\begin{cases} x^{k+1} = \arg \min \{\theta(x) + \frac{r}{2} \|x - [x^k + \frac{1}{r}A^T\lambda^k]\|^2 \mid x \in \mathcal{X}\}. & (1.6a) \\ \lambda^{k+1} = \arg \min \{\frac{1}{2} \|\lambda - \lambda^k\|_{(\frac{1}{r}AA^T + \delta I_m)}^2 + \lambda^T(A[2x^{k+1} - x^k] - b)\}. & (1.6b) \end{cases}$$

这里的  $x$ -子问题 (1.6a) 和 CP-PPA 的  $x$ -子问题 (1.3a) 形式完全一样, (1.6b) 中的  $\lambda^{k+1}$  是线性方程组

$$\left(\frac{1}{r}AA^T + \delta I_m\right)(\lambda - \lambda^k) + (A[2x^{k+1} - x^k] - b) = 0 \quad (1.7)$$

的解. 注意到上述线性方程组的系数矩阵是对称正定的, 在整个迭代过程中我们只要做一次正定矩阵

$$\left(\frac{1}{r}AA^T + \delta I_m\right). \quad (1.8)$$

的 Cholesky 分解. 矩阵计算 [5, 11] 里有非常成熟的方法求解这类线性方程组.

对应于不等式约束问题

$$\min\{\theta(x) \mid Ax \geq b, x \in \mathcal{X}\},$$

Balanced PPA 只要将 (1.6) 中的  $\lambda$ -子问题 (1.6b) 改成

$$\lambda^{k+1} = \arg \min \left\{ \begin{array}{l} \frac{1}{2}(\lambda - \lambda^k)^T \left(\frac{1}{r}AA^T + \delta I_m\right)(\lambda - \lambda^k) \\ + \lambda^T(A[2x^{k+1} - x^k] - b) \end{array} \mid \lambda \geq 0 \right\}.$$

这是一个带非负约束的凸二次规划, 尽管迭代中不能一劳永逸, 但求解也是比较容易的.

## 2 统一框架下非平凡校正的算法

这一节介绍需要用统一框架中非平凡校正的均困 ALM 类算法. 通常是把一个不确定是否收敛的方法的输出当做预测点, 然后再在统一框架的指引下选择简单的校正.

### 2.1 Primal-Dual 顺序产生预测点

从给定的  $w^k = (x^k, \lambda^k)$  出发, 把 (1.2) 的输出当成预测点, 公式就是

$$\begin{cases} \tilde{x}^k = \arg \min \{\theta(x) - x^T A^T \lambda^k + \frac{r}{2} \|x - x^k\|^2 \mid x \in \mathcal{X}\}, & (2.1a) \\ \tilde{\lambda}^k = \arg \min \{\frac{1}{2}(\lambda - \lambda^k)^T \left(\frac{1}{r}AA^T + \delta I_m\right)(\lambda - \lambda^k) + \lambda^T(A\tilde{x}^k - b) \mid \lambda \in \Lambda\} & (2.1b) \end{cases}$$

根据最优性条件就有

$$\begin{cases} \tilde{x}^k \in \mathcal{X}, & \theta(x) - \theta(\tilde{x}^k) + (x - \tilde{x}^k)^T \{-A^T \lambda^k + r(\tilde{x}^k - x^k)\} \geq 0, \quad \forall x \in \mathcal{X}, \\ \tilde{\lambda}^k \in \Lambda, & (\lambda - \tilde{\lambda}^k)^T \{(\frac{1}{r}AA^T + \delta I_m)(\tilde{\lambda}^k - \lambda^k) + (A\tilde{x}^k - b)\} \geq 0, \quad \forall \lambda \in \Lambda. \end{cases}$$

我们把上式改写成

$$\begin{cases} \theta(x) - \theta(\tilde{x}^k) + \underline{(x - \tilde{x}^k)^T \{-A^T \tilde{\lambda}^k + r(\tilde{x}^k - x^k) + A^T(\tilde{\lambda}^k - \lambda^k)\}} \geq 0, \quad \forall x \in \mathcal{X}, \\ \underline{(\lambda - \tilde{\lambda}^k)^T \{(A\tilde{x}^k - b) + (\frac{1}{r}AA^T + \delta I_m)(\tilde{\lambda}^k - \lambda^k)\}} \geq 0, \quad \forall \lambda \in \Lambda. \end{cases}$$

其中带下划线的部分组合在一起就是  $F(\tilde{w}^k)$ . 利用变分不等式 (0.3) 的表达式, 上式中下划线部分放在一起就是  $F(\tilde{w}^k)$ . 因此, 求得的预测点  $\tilde{w}^k$  满足

$$\tilde{w}^k \in \Omega, \quad \theta(x) - \theta(\tilde{x}^k) + (w - \tilde{w}^k)^T \{F(\tilde{w}^k) + Q(\tilde{w}^k - w^k)\} \geq 0, \quad \forall w \in \Omega, \quad (2.2a)$$

其中

$$Q = \begin{pmatrix} rI_n & A^T \\ 0 & \frac{1}{r}AA^T + \delta I_m \end{pmatrix}, \quad \delta > 0. \quad (2.2b)$$

上面的矩阵  $Q^T + Q$  是正定的.

对由 (2.1) 生成的预测点, 我们采用步长  $\alpha = 1$  的非平凡校正

$$w^{k+1} = w^k - M(w^k - \tilde{w}^k), \quad (2.3a)$$

生成新的迭代点, 其中

$$M = \begin{pmatrix} I_n & \frac{1}{r}A^T \\ 0 & I_m \end{pmatrix} \quad (2.3b)$$

是单位上三角矩阵. 下面我们用统一框架中的收敛条件去验证收敛性, 注意到

$$\begin{aligned} H &= QM^{-1} = \begin{pmatrix} rI_n & A^T \\ 0 & \frac{1}{r}AA^T + \delta I_m \end{pmatrix} \begin{pmatrix} I_n & -\frac{1}{r}A^T \\ 0 & I_m \end{pmatrix} \\ &= \begin{pmatrix} rI_n & 0 \\ 0 & \frac{1}{\beta}I_m \end{pmatrix}. \end{aligned}$$

和

$$\begin{aligned} G &= Q^T + Q - M^T H M = Q^T + Q - Q^T M \\ &= \begin{pmatrix} 2rI_n & A^T \\ A & 2(\frac{1}{r}AA^T + \delta I_m) \end{pmatrix} - \begin{pmatrix} rI_n & 0 \\ A & \frac{1}{r}AA^T + \delta I_m \end{pmatrix} \begin{pmatrix} I_n & \frac{1}{r}A^T \\ 0 & I_m \end{pmatrix} \\ &= \begin{pmatrix} rI_n & 0 \\ 0 & \delta I_m \end{pmatrix}. \end{aligned}$$

矩阵  $H$  和  $G$  都正定. 分别用 (2.1) 做预测和 (2.3) 做校正, 产生新的迭代点  $w^{k+1}$  满足

$$\|w^{k+1} - w^*\|_H^2 \leq \|w^k - w^*\|_H^2 - \|w^k - \tilde{w}^k\|_G^2, \quad \forall w^* \in \Omega^*.$$

我们就得到一个求解(与优化问题 (0.1) 对应的)变分不等式 (0.3) 的收敛算法.

## 2.2 Dual-Primal 顺序产生预测点

考虑和 (2.1) 不同的 Dual-Primal 顺序预测,  $k$ -次迭代从就通过

$$\begin{cases} \tilde{\lambda}^k = \operatorname{argmin}\left\{\frac{1}{2}(\lambda - \lambda^k)^T\left(\frac{1}{r}AA^T + \delta I_m\right)(\lambda - \lambda^k) + \lambda^T(Ax^k - b) \mid \lambda \in \Lambda\right\}, & (2.4a) \\ \tilde{x}^k = \operatorname{argmin}\left\{\theta(x) - x^T A^T \tilde{\lambda}^k + \frac{r}{2}\|x - x^k\|^2 \mid x \in \mathcal{X}\right\} & (2.4b) \end{cases}$$

得到预测点  $\tilde{w}^k$ . 根据最优性条件就有

$$\begin{cases} \tilde{\lambda}^k \in \Lambda, & (\lambda - \tilde{\lambda}^k)^T\{(Ax^k - b) + (\frac{1}{r}AA^T + \delta I_m)(\tilde{\lambda}^k - \lambda^k)\} \geq 0, \quad \forall \lambda \in \Lambda, \\ \tilde{x}^k \in \mathcal{X}, & \theta(x) - \theta(\tilde{x}^k) + (x - \tilde{x}^k)^T\{-A^T \tilde{\lambda}^k + r(\tilde{x}^k - x^k)\} \geq 0, \quad \forall x \in \mathcal{X}. \end{cases}$$

我们把上式改写成

$$\begin{cases} \theta(x) - \theta(\tilde{x}^k) + (x - \tilde{x}^k)^T\{-A^T \tilde{\lambda}^k + r(\tilde{x}^k - x^k)\} \geq 0, & \forall x \in \mathcal{X}, \\ (\lambda - \tilde{\lambda}^k)^T\{\underline{A\tilde{x}^k - b} - A(\tilde{x}^k - x^k) + (\frac{1}{r}AA^T + \delta I_m)(\tilde{\lambda}^k - \lambda^k)\} \geq 0, & \forall \lambda \in \Lambda. \end{cases}$$

其中带下划线的部分组合在一起就是  $F(\tilde{w}^k)$ . 利用变分不等式 (0.3) 的表达式, 上式中下划线部分放在一起就是  $F(\tilde{w}^k)$ . 因此, 求得的预测点  $\tilde{w}^k$  满足

$$\tilde{w}^k \in \Omega, \quad \theta(x) - \theta(\tilde{x}^k) + (w - \tilde{w}^k)^T\{F(\tilde{w}^k) + Q(\tilde{w}^k - w^k)\} \geq 0, \quad \forall w \in \Omega, \quad (2.5a)$$

其中

$$Q = \begin{pmatrix} rI_n & 0 \\ -A & (\frac{1}{r}AA^T + \delta I_m) \end{pmatrix}, \quad \delta > 0. \quad (2.5b)$$

当  $A$  列满秩时上面的矩时  $Q^T + Q$  是正定的.

对由 (2.4) 生成的预测点, 我们采用步长  $\alpha = 1$  的非平凡校正

$$w^{k+1} = w^k - M(w^k - \tilde{w}^k), \quad (2.6a)$$

生成新的迭代点, 其中

$$M = \begin{pmatrix} I_n & \frac{1}{r}A^T \\ 0 & I_m \end{pmatrix}. \quad (2.6b)$$

剩下就是用统一框架中的收敛条件去验证收敛性, 注意到

$$\begin{aligned} H &= QM^{-1} = \begin{pmatrix} rI_n & 0 \\ -A & \frac{1}{r}AA^T + \delta I_m \end{pmatrix} \begin{pmatrix} I_n & -\frac{1}{r}A^T \\ 0 & I_m \end{pmatrix} \\ &= \begin{pmatrix} rI_n & -A^T \\ -A & \frac{2}{r}AA^T + \delta I_m \end{pmatrix}. \end{aligned}$$

和

$$\begin{aligned}
G &= Q^T + Q - M^T H M = Q^T + Q - Q^T M \\
&= \begin{pmatrix} 2rI_n & -A^T \\ -A & \frac{2}{r}AA^T + 2\delta I_m \end{pmatrix} - \begin{pmatrix} rI_n & -A^T \\ 0 & \frac{1}{r}AA^T + \delta I_m \end{pmatrix} \begin{pmatrix} I_n & \frac{1}{r}A^T \\ 0 & I_m \end{pmatrix} \\
&= \begin{pmatrix} rI_n & -A^T \\ -A & \frac{1}{r}AA^T + \delta I_m \end{pmatrix}.
\end{aligned}$$

矩阵  $H$  和  $G$  都正定. 分别用 (2.4) 做预测和 (2.6) 做校正, 产生新的迭代点  $w^{k+1}$  满足

$$\|w^{k+1} - w^*\|_H^2 \leq \|w^k - w^*\|_H^2 - \|w^k - \tilde{w}^k\|_G^2, \quad \forall w^* \in \Omega^*.$$

我们就得到一个求解(与优化问题 (0.1) 对应的)变分不等式 (0.3) 的收敛算法.

### 3 统一框架下平凡松弛校正的 PPA 算法

跟前一节不同, 这一节根据统一框架中 PPA 的要求, 先设计个符合条件的正定矩阵, 再去构造相应的算法实施.

#### 3.1 Primal-Dual 顺序产生预测点

求解(与不等式约束凸优化问题(0.1)对应的)变分不等式(0.3), 我们根据第五章的统一框架设计一个预测-校正方法, 迭代从给定的  $w^k = (x^k, \lambda^k)$  开始, 求得的预测点  $\tilde{w}^k$  满足

$$\tilde{w}^k \in \Omega, \quad \theta(x) - \theta(\tilde{x}^k) + (w - \tilde{w}^k)^T \{F(\tilde{w}^k) + H(\tilde{w}^k - w^k)\} \geq 0, \quad \forall w \in \Omega, \quad (3.1a)$$

其中

$$H = \begin{pmatrix} rI_n & A^T \\ A & \frac{1}{r}AA^T + \delta I_m \end{pmatrix}, \quad r, \delta > 0. \quad (3.1b)$$

对于任何的  $r, \delta > 0$ , 这个预测公式中的矩阵  $H$  是正定的. 这样就能用平凡松弛的校正(??)直接产生新迭代点  $w^{k+1}$ . 问题归结为求满足 (3.1) 的预测点  $\tilde{w}^k$ . 将预测 (3.1) 按  $F$  和  $H$  的结构分拆开来, 可以写成  $\tilde{w}^k = (\tilde{x}^k, \tilde{\lambda}^k) \in \Omega$ ,

$$\begin{cases} \theta(x) - \theta(\tilde{x}^k) + (x - \tilde{x}^k)^T \{-A^T \tilde{\lambda}^k + r(\tilde{x}^k - x^k) + A^T(\tilde{\lambda}^k - \lambda^k)\} \geq 0, & \forall x \in \mathcal{X}, \\ (\lambda - \tilde{\lambda}^k)^T \{(A\tilde{x}^k - b) \\ + A(\tilde{x}^k - x^k) + (\frac{1}{r}AA^T + \delta I_m)(\tilde{\lambda}^k - \lambda^k)\} \geq 0, & \forall \lambda \in \Lambda, \end{cases}$$

其中带下划线的部分组合在一起就是  $F(\tilde{w}^k)$ . 归并简化后的形式是  $\tilde{w}^k = (\tilde{x}^k, \tilde{\lambda}^k) \in \Omega$ ,

$$\begin{cases} \theta(x) - \theta(\tilde{x}^k) + (x - \tilde{x}^k)^T \{-A^T \lambda^k + r(\tilde{x}^k - x^k)\} \geq 0, & \forall x \in \mathcal{X}, \end{cases} \quad (3.2a)$$

$$\begin{cases} (\lambda - \tilde{\lambda}^k)^T \{(A(2\tilde{x}^k - x^k) - b) + (\frac{1}{r}AA^T + \delta I_m)(\tilde{\lambda}^k - \lambda^k)\} \geq 0, & \forall \lambda \in \Lambda. \end{cases} \quad (3.2b)$$

注意到 (3.2a) 中只有需要预测的  $\tilde{x}^k$ , 而 (3.2b) 中有了  $\tilde{x}^k$  才能开展. 所以我们只能先实现 (3.2a) 再实现 (3.2b). 根据最优性引理, (3.2a) 中的  $\tilde{x}^k$  可以通过求解子问题

$$\min\{\theta(x) - x^T A^T \lambda^k + \frac{r}{2} \|x - x^k\|^2 \mid x \in \mathcal{X}\}$$

得到. 而有了  $\tilde{x}^k$ , (3.2b) 中的  $\tilde{\lambda}^k$  则是

$$\min\left\{\frac{1}{2}(\lambda - \lambda^k)^T \left(\frac{1}{r} A A^T + \delta I_m\right) (\lambda - \lambda^k) + \lambda^T [A(2\tilde{x}^k - x^k) - b] \mid \lambda \in \Lambda\right\}$$

的解. 所以, 满足 (3.1) 的预测点由

$$\begin{cases} \tilde{x}^k = \arg \min\{\theta(x) - x^T A^T \lambda^k + \frac{r}{2} \|x - x^k\|^2 \mid x \in \mathcal{X}\}, \\ \tilde{\lambda}^k = \arg \min\left\{\frac{1}{2}(\lambda - \lambda^k)^T \left(\frac{1}{r} A A^T + \delta I_m\right) (\lambda - \lambda^k) + \lambda^T [A(2\tilde{x}^k - x^k) - b] \mid \lambda \in \Lambda\right\} \end{cases} \quad (3.3a)$$

$$\begin{cases} \tilde{\lambda}^k = \arg \min\left\{\frac{1}{2}(\lambda - \lambda^k)^T \left(\frac{1}{r} A A^T + \delta I_m\right) (\lambda - \lambda^k) + \lambda^T [A(2\tilde{x}^k - x^k) - b] \mid \lambda \in \Lambda\right\} \end{cases} \quad (3.3b)$$

提供, 按照先  $\tilde{x}^k$ , 后  $\tilde{\lambda}^k$  的(primal-dual)顺序实现. 再用

$$w^{k+1} = w^k - \alpha(w^k - \tilde{w}^k), \quad \alpha \in (0, 2)$$

这样平凡的松弛校正, 迭代序列  $\{w^k\}$  满足

$$\|w^{k+1} - w^*\|_H^2 \leq \|w^k - w^*\|_H^2 - \alpha(2 - \alpha) \|w^k - \tilde{w}^k\|_H^2, \quad \forall w^* \in \Omega^*.$$

### 3.2 Dual-Primal 顺序产生预测点

如果把预测满足的变分不等式 (3.1) 换成

$$\tilde{w}^k \in \Omega, \quad \theta(x) - \theta(\tilde{x}^k) + (w - \tilde{w}^k)^T \{F(\tilde{w}^k) + H(\tilde{w}^k - w^k)\} \geq 0, \quad \forall w \in \Omega, \quad (3.4a)$$

其中

$$H = \begin{pmatrix} rI_n & -A^T \\ -A & \frac{1}{r} A A^T + \delta I_m \end{pmatrix}, \quad \delta > 0. \quad (3.4b)$$

上面的矩阵  $H$  是正定的. 对应于统一框架中的预测,  $v = w$ . 再用松弛校正(??)直接产生新迭代点  $w^{k+1}$  的算法是能保证收敛的. 问题归结为求满足 (3.4) 的预测点  $\tilde{w}^k$ . 将预测 (3.4) 按  $F$  和  $H$  的结构分拆开来, 可以写成  $\tilde{w}^k = (\tilde{x}^k, \tilde{\lambda}^k) \in \Omega$ ,

$$\begin{cases} \theta(x) - \theta(\tilde{x}^k) + (x - \tilde{x}^k)^T \{-A^T \tilde{\lambda}^k + s(\tilde{x}^k - x^k) - A^T(\tilde{\lambda}^k - \lambda^k)\} \geq 0, & \forall x \in \mathcal{X}, \\ (\lambda - \tilde{\lambda}^k)^T \{A \tilde{x}^k - b\} - A(\tilde{x}^k - x^k) + \left(\frac{1}{r} A A^T + \delta I_m\right) (\tilde{\lambda}^k - \lambda^k) \geq 0, & \forall \lambda \in \Lambda. \end{cases}$$

其中带下划线的部分组合在一起就是  $F(\tilde{w}^k)$ . 归并简化后的形式是  $\tilde{w}^k = (\tilde{x}^k, \tilde{\lambda}^k) \in \Omega$ ,

$$\begin{cases} \theta(x) - \theta(\tilde{x}^k) + (x - \tilde{x}^k)^T \{r(\tilde{x}^k - x^k) - A^T(2\tilde{\lambda}^k - \lambda^k)\} \geq 0, & \forall x \in \mathcal{X}, \\ (\lambda - \tilde{\lambda}^k)^T \{A \tilde{x}^k - b\} + \left(\frac{1}{r} A A^T + \delta I_m\right) (\tilde{\lambda}^k - \lambda^k) \geq 0, & \forall \lambda \in \Lambda. \end{cases} \quad (3.5a)$$

$$\begin{cases} (\lambda - \tilde{\lambda}^k)^T \{A \tilde{x}^k - b\} + \left(\frac{1}{r} A A^T + \delta I_m\right) (\tilde{\lambda}^k - \lambda^k) \geq 0, & \forall \lambda \in \Lambda. \end{cases} \quad (3.5b)$$

注意到 (3.5b) 中预测  $\tilde{\lambda}^k$  只需要给定的  $w^k$ , 而 (3.5a) 中预测  $\tilde{x}^k$  需要  $\tilde{\lambda}^k$  在手. 所以我们只能先实现 (3.5b) 再实现 (3.5a). 根据最优性条件引理, (3.5b) 中的  $\tilde{\lambda}^k$  是

$$\min\left\{\frac{1}{2}(\lambda - \lambda^k)^T\left(\frac{1}{r}AA^T + \delta I_m\right)(\lambda - \lambda^k) + \lambda^T(Ax^k - b) \mid \lambda \in \Lambda\right\}$$

的解. 而 (3.5a) 中的  $\tilde{x}^k$  可以通过求解子问题

$$\min\left\{\theta(x) - x^T A^T(2\tilde{\lambda}^k - \lambda^k) + \frac{r}{2}\|x - x^k\|^2 \mid x \in \mathcal{X}\right\}$$

得到. 所以, 满足 (3.4) 的预测点由

$$\begin{cases} \tilde{\lambda}^k = \operatorname{argmin}\left\{\frac{1}{2}(\lambda - \lambda^k)^T\left(\frac{1}{r}AA^T + \delta I_m\right)(\lambda - \lambda^k) + \lambda^T(Ax^k - b) \mid \lambda \in \Lambda\right\}, & (3.6a) \\ \tilde{x}^k = \operatorname{argmin}\left\{\theta(x) - x^T A^T(2\tilde{\lambda}^k - \lambda^k) + \frac{r}{2}\|x - x^k\|^2 \mid x \in \mathcal{X}\right\} & (3.6b) \end{cases}$$

提供, 按照先  $\tilde{\lambda}^k$ , 后  $\tilde{x}^k$  的(dual-primal)顺序实现. 同样, 再用

$$w^{k+1} = w^k - \alpha(w^k - \tilde{w}^k), \quad \alpha \in (0, 2)$$

这样平凡的松弛校正, 迭代序列  $\{w^k\}$  满足

$$\|w^{k+1} - w^*\|_H^2 \leq \|w^k - w^*\|_H^2 - \alpha(2 - \alpha)\|w^k - \tilde{w}^k\|_H^2, \quad \forall w^* \in \Omega^*.$$

## 4 平行处理子问题的均困方法

均困平衡的 ALM 类算法, 把困难均分了, 平行处理子问题变得更有意义. 从给定的  $w^k = (x^k, \lambda^k)$  出发, 如果由下面的公式

$$\begin{cases} \tilde{x}^k = \operatorname{argmin}\left\{\theta(x) - x^T A^T \lambda^k + \frac{r}{2}\|x - x^k\|^2 \mid x \in \mathcal{X}\right\}, & (4.1a) \\ \tilde{\lambda}^k = \operatorname{argmin}\left\{\frac{1}{2}(\lambda - \lambda^k)^T\left(\frac{1}{r}AA^T + \delta I_m\right)(\lambda - \lambda^k) + \lambda^T(Ax^k - b) \mid \lambda \in \Lambda\right\} & (4.1b) \end{cases}$$

产生预测点, 是可以平行处理的. 根据最优性条件就有

$$\begin{cases} \tilde{x}^k \in \mathcal{X}, & \theta(x) - \theta(\tilde{x}^k) + (x - \tilde{x}^k)^T \{-A^T \lambda^k + r(\tilde{x}^k - x^k)\} \geq 0, \quad \forall x \in \mathcal{X}, \\ \tilde{\lambda}^k \in \Lambda, & (\lambda - \tilde{\lambda}^k)^T \left\{ \left(\frac{1}{r}AA^T + \delta I_m\right)(\tilde{\lambda}^k - \lambda^k) + (Ax^k - b) \right\} \geq 0, \quad \forall \lambda \in \Lambda. \end{cases}$$

我们把上式改写成

$$\begin{cases} \theta(x) - \theta(\tilde{x}^k) + (x - \tilde{x}^k)^T \{ \underline{-A^T \tilde{\lambda}^k} + r(\tilde{x}^k - x^k) + A^T(\tilde{\lambda}^k - \lambda^k) \} \geq 0, \quad \forall x \in \mathcal{X}, \\ (\lambda - \tilde{\lambda}^k)^T \{ \underline{A\tilde{x}^k - b} - A(\tilde{x}^k - x^k) + \left(\frac{1}{r}AA^T + \delta I_m\right)(\tilde{\lambda}^k - \lambda^k) \} \geq 0, \quad \forall \lambda \in \Lambda. \end{cases}$$

其中带下划线的部分组合在一起就是  $F(\tilde{w}^k)$ . 利用变分不等式 (0.3) 的表达式, 上式中下划线部分放在一起就是  $F(\tilde{w}^k)$ . 因此, 求得的预测点  $\tilde{w}^k$  满足

$$\tilde{w}^k \in \Omega, \quad \theta(x) - \theta(\tilde{x}^k) + (w - \tilde{w}^k)^T \{ F(\tilde{w}^k) + Q(\tilde{w}^k - w^k) \} \geq 0, \quad \forall w \in \Omega, \quad (4.2a)$$



其中

$$Q = \begin{pmatrix} rI_n & A^T \\ -A & \frac{1}{r}AA^T + \delta I_m \end{pmatrix}, \quad \delta > 0. \quad (4.2b)$$

上面的矩阵  $Q^T + Q$  是正定的.

对由 (4.1) 生成的预测点, 我们采用步长  $\alpha = 1$  的非平凡校正

$$w^{k+1} = w^k - M(w^k - \tilde{w}^k), \quad (4.3a)$$

生成新的迭代点, 其中

$$M = \begin{pmatrix} I_n & \frac{1}{r}A^T \\ -(\frac{1}{r}AA^T + \delta I_m)^{-1}A & I_m \end{pmatrix}. \quad (4.3b)$$

取正定矩阵

$$H = \begin{pmatrix} rI_n & 0 \\ 0 & \frac{1}{r}AA^T + \delta I_m \end{pmatrix}, \quad (4.4)$$

用统一框架去验证收敛性条件, 注意到

$$\begin{aligned} HM &= \begin{pmatrix} rI_n & \\ & \frac{1}{r}AA^T + \delta I_m \end{pmatrix} \begin{pmatrix} I_n & \frac{1}{r}A^T \\ -(\frac{1}{r}AA^T + \delta I_m)^{-1}A & I_m \end{pmatrix} \\ &= \begin{pmatrix} rI_n & A^T \\ -A & \frac{1}{r}AA^T + \delta I_m \end{pmatrix}, \end{aligned}$$

的确有  $HM = Q$ . 此外

$$\begin{aligned} G &= Q^T + Q - M^T H M = Q^T + Q - Q^T M \\ &= \begin{pmatrix} 2rI_n & 0 \\ 0 & 2(\frac{1}{r}AA^T + \delta I_m) \end{pmatrix} \\ &\quad - \begin{pmatrix} rI_n & -A^T \\ A & \frac{1}{r}AA^T + \delta I_m \end{pmatrix} \begin{pmatrix} I_n & \frac{1}{r}A^T \\ -(\frac{1}{r}AA^T + \delta I_m)^{-1}A & I_m \end{pmatrix} \\ &= \begin{pmatrix} rI_n - A^T(\frac{1}{r}AA^T + \delta I_m)^{-1}A & 0 \\ 0 & \delta I_m \end{pmatrix}. \end{aligned}$$

矩阵  $H$  和  $G$  都正定. 分别用 (2.1) 做预测和 (2.3) 做校正, 产生新的迭代点  $w^{k+1}$  满足

$$\|w^{k+1} - w^*\|_H^2 \leq \|w^k - w^*\|_H^2 - \|w^k - \tilde{w}^k\|_G^2, \quad \forall w^* \in \Omega^*.$$

我们就得到一个求解(与优化问题 (0.1) 对应的)变分不等式 (0.3) 的收敛算法.

校正 (4.3) 的具体实现就是

$$\begin{cases} x^{k+1} = \tilde{x}^k - \frac{1}{r}A^T(\lambda^k - \tilde{\lambda}^k), \end{cases} \quad (4.5a)$$

$$\begin{cases} \lambda^{k+1} = \tilde{\lambda}^k + (\frac{1}{r}AA^T + \delta I)^{-1}(x^k - \tilde{x}^k). \end{cases} \quad (4.5b)$$

(4.5b) 中的  $\lambda^{k+1}$  是线性方程组

$$\left(\frac{1}{r}AA^T + \delta I\right)(\lambda - \tilde{\lambda}^k) - (x^k - \tilde{x}^k) = 0$$

的解. 为了这个校正, 在整个迭代过程的校正中, 需要做一次  $(\frac{1}{r}AA^T + \delta I)$  的 Cholesky 分解. 对等式约束的问题, 做预测 (4.1b) 本来就要做一次这样的 Cholesky 分解的.

## 参考文献

- [1] A. Beck, First-Order Methods in convex optimization, MOS-SIAM Series on Optimization.
- [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] A. Chambolle, T. Pock, A first-order primal-dual algorithms for convex problem with applications to imaging, *J. Math. Imaging Vison*, 40, 120-145, 2011.
- [4] Chambolle A and Pock T. On the ergodic convergence rates of a first-order primal-dual algorithm, *Mathematical Programming*, 2016, 159: 253–287.
- [5] G. Golub and C. F. Van Loan, Matrix Computations, The Johns Hopkins University Press, The Fourth Edition, 2013.
- [6] 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.
- [7] 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.
- [8] M. R. Hestenes, Multiplier and gradient methods, *JOTA* 4, 303-320, 1969.
- [9] J. Stoer and R. Bulirsch, Introduction to Numerical Analysis, Second Edition, Text in Applied Mathematics 12, Springer-Verlag, 1991.