

带非正定临近项的乘子交替方向法的收敛速率^①王逸云¹, 欧小庆², 李高西³

1. 西南大学 数学与统计学院, 重庆 400715; 2. 重庆人文科技学院 管理学院, 重庆 合川 401524;
3. 重庆工商大学 数学与统计学院, 重庆 400067

摘要: 研究了带非正定临近正则项的乘子交替方向法(ADMM)的收敛速度. 通过引入松弛因子改进拉格朗日乘子的迭代步长, 并在适当的参数条件下建立了带非正定临近正则项的 ADMM 在遍历意义下的收敛速率.

关键词: 凸规划问题; 交替方向法; 非正定临近项; 收敛速率

中图分类号: O224

文献标志码: A

文章编号: 1673-9868(2018)03-0101-08

本文考虑解决以下的一类线性约束凸优化问题

$$\min\{\theta_1(\mathbf{x}) + \theta_2(\mathbf{y}) \mid \mathbf{Ax} + \mathbf{By} = \mathbf{b}, \mathbf{x} \in \mathcal{X}, \mathbf{y} \in \mathcal{Y}\} \quad (1)$$

其中: $\theta_1(\mathbf{x}): \mathbb{R}^{n_1} \rightarrow \mathbb{R}$, $\theta_2(\mathbf{y}): \mathbb{R}^{n_2} \rightarrow \mathbb{R}$ 是凸函数(但不一定光滑); 矩阵 $\mathbf{A} \in \mathbb{R}^{m \times n_1}$, $\mathbf{B} \in \mathbb{R}^{m \times n_2}$; 向量 $\mathbf{b} \in \mathbb{R}^m$; $\mathcal{X} \subset \mathbb{R}^{n_1}$ 与 $\mathcal{Y} \subset \mathbb{R}^{n_2}$ 是给定的闭凸集. 在本文中, 假设问题(1)的解集是非空的. 将问题(1)的增广 Lagrange 函数定义为

$$L_{\beta}^2(\mathbf{x}, \mathbf{y}, \boldsymbol{\lambda}) = \theta_1(\mathbf{x}) + \theta_2(\mathbf{y}) - \boldsymbol{\lambda}^T(\mathbf{Ax} + \mathbf{By} - \mathbf{b}) + \frac{\beta}{2} \|\mathbf{Ax} + \mathbf{By} - \mathbf{b}\|^2$$

其中: $\boldsymbol{\lambda} \in \mathbb{R}^m$ 为 Lagrange 乘子, $\beta > 0$ 为罚因子.

经典的乘子交替方向法(ADMM)主要是为了解决带约束的凸优化问题, 最先在 20 世纪 70 年代中期由文献[1-2]提出. ADMM 被广泛地应用于各个领域, 如机器学习、图像处理、统计学习、无线网络等方面. 原始的 ADMM 形式如下:

$$(\text{ADMM}) \begin{cases} \mathbf{x}^{k+1} = \operatorname{argmin}\{L_{\beta}^2(\mathbf{x}, \mathbf{y}^k, \boldsymbol{\lambda}^k) \mid \mathbf{x} \in \mathcal{X}\} \\ \mathbf{y}^{k+1} = \operatorname{argmin}\{L_{\beta}^2(\mathbf{x}^{k+1}, \mathbf{y}, \boldsymbol{\lambda}^k) \mid \mathbf{y} \in \mathcal{Y}\} \\ \boldsymbol{\lambda}^{k+1} = \boldsymbol{\lambda}^k - \beta(\mathbf{Ax}^{k+1} + \mathbf{By}^{k+1} - \mathbf{b}) \end{cases} \quad (2)$$

运行 ADMM(2) 时, 为了能够求得唯一的点 $(\mathbf{x}^{k+1}, \mathbf{y}^{k+1})$, 通常通过增加一个平方临近项来正则化(2)式的子问题. 不失一般性, 可以只讨论正则化 ADMM(2) 第二步子问题的情形. 文献[3-4]将算法进一步改进成下面的形式:

$$(\text{PD-ADMM}) \begin{cases} \mathbf{x}^{k+1} = \operatorname{argmin}\{L_{\beta}^2(\mathbf{x}, \mathbf{y}^k, \boldsymbol{\lambda}^k) \mid \mathbf{x} \in \mathcal{X}\} \\ \mathbf{y}^{k+1} = \operatorname{argmin}\{L_{\beta}^2(\mathbf{x}^{k+1}, \mathbf{y}, \boldsymbol{\lambda}^k) + \frac{1}{2} \|\mathbf{y} - \mathbf{y}^k\|_{\mathbf{D}}^2 \mid \mathbf{y} \in \mathcal{Y}\} \\ \boldsymbol{\lambda}^{k+1} = \boldsymbol{\lambda}^k - \beta(\mathbf{Ax}^{k+1} + \mathbf{By}^{k+1} - \mathbf{b}) \end{cases} \quad (3)$$

① 收稿日期: 2017-05-30

基金项目: 重庆市基础与前沿研究项目(cstc2016jcyjA0239).

作者简介: 王逸云(1993-), 女, 湖北洪湖人, 硕士研究生, 主要从事最优化理论、算法及应用的研究.

其中 $\mathbf{D} \in \mathbb{R}^{n_2 \times n_2}$ 为正定矩阵. 通常, 在很多文献中都会要求矩阵 $\mathbf{D}$ 必须要满足正定性, 在(3)式中, $\frac{1}{2} \|\mathbf{y} - \mathbf{y}^k\|_{\mathbf{D}}^2$ 就是添加的平方临近项. 另外, 也可以考虑对 ADMM(2) 的第一、二步都进行正则化的情形, 可以参考文献[5]. 进一步, 文献[6] 提出, PD-ADMM(3) 中的矩阵 $\mathbf{D}$ 可以不满足正定性, 若取 $\mathbf{D} = \tau\gamma\mathbf{I}_{n_2} - \beta\mathbf{B}^T\mathbf{B}$, 其中 $\gamma > \beta\|\mathbf{B}^T\mathbf{B}\|$, $\tau \in (0, 1)$, 显然 $\mathbf{D}$ 此时不一定正定. 此时, 平方正则项 $\frac{1}{2} \|\mathbf{y} - \mathbf{y}^k\|_{\mathbf{D}}^2$ 在目标函数中所占比重减少, $\mathbf{y}$ 的迭代步长变大. 特别地, 文献[6] 说明了当取 $\tau = 0.8$ 时为最佳值, 并且证明了 $\tau = 0.8$ 时算法的收敛性及其在遍历意义下的收敛速率. 另一方面, 文献[7] 对原始的增广拉格朗日算法(ALM)进行了一些改进, 扩大了生成 Lagrange 乘子 $\boldsymbol{\lambda}$ 的步长, 从而加快收敛速度. 与文献[6] 类似, 文献[7] 中还提出了平方临近项中的矩阵 $\mathbf{D}$ 可以为非正定的矩阵, 即把原始的 ALM 改进为

$$(\text{PIDP-ALM}) \begin{cases} \mathbf{x}^{k+1} = \operatorname{argmin}\{L(\mathbf{x}, \boldsymbol{\lambda}^k) + \frac{1}{2} \|\mathbf{x} - \mathbf{x}^k\|_{\mathbf{D}_0}^2 \mid \mathbf{x} \in \mathcal{X}\} \\ \boldsymbol{\lambda}^{k+1} = \boldsymbol{\lambda}^k - \gamma\beta(\mathbf{A}\mathbf{x}^{k+1} - \mathbf{b}), \gamma \in (0, 2) \end{cases} \quad (4)$$

其中: $\mathbf{D}_0 = \mathbf{D} - (1 - \tau)\beta\mathbf{A}^T\mathbf{A}$, $\tau \in (0, 1)$, $\mathbf{D} \in \mathbb{R}^l$ 是任意给定的正定矩阵; Lagrange 函数 $L(\mathbf{x}, \boldsymbol{\lambda}) = \theta(\mathbf{x}) - \boldsymbol{\lambda}^T(\mathbf{A}\mathbf{x} - \mathbf{b})$. 文献[1] 中确定当系数 τ 和 γ 满足数量关系 $\tau > \frac{2 + \gamma}{4}$ 时, 算法 PIDP-ALM(4) 仍然保持收敛性.

受文献[6-7] 的启发, 本文考虑将文献[6] 中带有非正定正则项的 ADMM 算法进行改进, 引入松弛变量 γ , 对生成 Lagrange 乘子 $\boldsymbol{\lambda}$ 的子问题步长进行调整. 本文将讨论如下算法 1:

$$\begin{cases} \mathbf{x}^{k+1} = \operatorname{argmin}\{L_{\beta}^2(\mathbf{x}, \mathbf{y}^k, \boldsymbol{\lambda}^k) \mid \mathbf{x} \in \mathcal{X}\} \\ \boldsymbol{\lambda}^{k+1} = \boldsymbol{\lambda}^k - \gamma\beta(\mathbf{A}\mathbf{x}^{k+1} + \mathbf{B}\mathbf{y}^k - \mathbf{b}) \\ \mathbf{y}^{k+1} = \operatorname{argmin}\{L_{\beta}^2(\mathbf{x}^{k+1}, \mathbf{y}, \boldsymbol{\lambda}^{k+1}) + \frac{1}{2} \|\mathbf{y} - \mathbf{y}^k\|_{\mathbf{D}_0}^2 \mid \mathbf{y} \in \mathcal{Y}\} \end{cases} \quad (5)$$

其中: $\mathbf{D}_0 = \mathbf{D} - (1 - \tau)\beta\mathbf{B}^T\mathbf{B}$, $\mathbf{D} \in \mathbb{R}^l$ 是任意给定的正定矩阵, $\tau \in \left[\frac{1 + \beta}{2\beta}, 1\right)$; 松弛变量 $\gamma \in \left(0, \frac{2}{1 + \beta}\right]$.

另外在本文中设罚参数 $\beta > 1$ 且为一固定值. 相对于文献[6], 本文中对生成 Lagrange 乘子 $\boldsymbol{\lambda}$ 的子问题引入松弛变量 γ , 使得对偶变量的迭代步长范围变大, 更具有一般性, 在理论上有更好的计算性能, 并且非正定矩阵 $\mathbf{D}_0$ 中的系数 τ , 松弛变量 γ 与罚参数 β 之间产生了相互约束的作用.

1 预备知识

本节将回顾一些本文所涉及的主要理论基础知识.

在 $\mathcal{X} \times \mathcal{Y} \times \mathbb{R}^m$ 上定义问题(1) 的 Lagrange 函数

$$L(\mathbf{x}, \mathbf{y}, \boldsymbol{\lambda}) = \theta_1(\mathbf{x}) + \theta_2(\mathbf{y}) - \boldsymbol{\lambda}^T(\mathbf{A}\mathbf{x} + \mathbf{B}\mathbf{y} - \mathbf{b})$$

其中 $\boldsymbol{\lambda} \in \mathbb{R}^m$ 为 Lagrange 乘子. 点 $((\mathbf{x}^*, \mathbf{y}^*), \boldsymbol{\lambda}^*)$ 若满足

$$L_{\boldsymbol{\lambda} \in \mathbb{R}^m}(\mathbf{x}^*, \mathbf{y}^*, \boldsymbol{\lambda}) \leq L(\mathbf{x}^*, \mathbf{y}^*, \boldsymbol{\lambda}^*) \leq L_{\mathbf{x} \in \mathcal{X}, \mathbf{y} \in \mathcal{Y}}(\mathbf{x}, \mathbf{y}, \boldsymbol{\lambda}^*)$$

则被称为 Lagrange 函数的鞍点. 鞍点问题等价于下面的变分不等式组:

$$\begin{cases} \mathbf{x}^* \in \mathcal{X}, \theta_1(\mathbf{x}) - \theta_1(\mathbf{x}^*) + (\mathbf{x} - \mathbf{x}^*)^T(-\mathbf{A}^T\boldsymbol{\lambda}^*) \geq 0 & \forall \mathbf{x} \in \mathcal{X} \\ \mathbf{y}^* \in \mathcal{Y}, \theta_2(\mathbf{y}) - \theta_2(\mathbf{y}^*) + (\mathbf{y} - \mathbf{y}^*)^T(\mathbf{B}^T\boldsymbol{\lambda}^*) \geq 0 & \forall \mathbf{y} \in \mathcal{Y} \\ \boldsymbol{\lambda}^* \in \mathbb{R}^m, (\boldsymbol{\lambda} - \boldsymbol{\lambda}^*)^T(\mathbf{A}\mathbf{x}^* + \mathbf{B}\mathbf{y}^* - \mathbf{b}) \geq 0 & \forall \boldsymbol{\lambda} \in \mathbb{R}^m \end{cases} \quad (6)$$

如果记

$$\Omega = \mathcal{X} \times \mathcal{Y} \times \mathbb{R}^m$$

以及

$$u = \begin{pmatrix} x \\ y \end{pmatrix} \quad \theta(u) = \theta_1(x) + \theta_2(y), \quad \omega = \begin{pmatrix} x \\ y \\ \lambda \end{pmatrix} \quad F(\omega) = \begin{pmatrix} -A^T \lambda \\ -B^T \lambda \\ Ax + By - b \end{pmatrix} \quad (7)$$

问题(6) 可以写成变分不等式

$$\omega^* \in \Omega, \theta(u) - \theta(u^*) + (\omega - \omega^*)^T F(\omega^*) \geq 0 \quad \forall \omega \in \Omega \quad (8)$$

将问题(8) 的解集记作 Ω^* . 定义在(7) 式中的算子 F 是一个带有斜对称矩阵的仿射单调算子, 并且对于任意的 $\omega, \bar{\omega} \in \Omega$ 有

$$\begin{aligned} (\omega - \bar{\omega})^T (F(\omega) - F(\bar{\omega})) &= \\ (\omega - \bar{\omega})^T \begin{pmatrix} -A^T(\lambda - \bar{\lambda}) \\ -B^T(\lambda - \bar{\lambda}) \\ A(x - \bar{x}) + B(y - \bar{y}) \end{pmatrix} &= \begin{pmatrix} x - \bar{x} \\ y - \bar{y} \\ \lambda - \bar{\lambda} \end{pmatrix}^T \begin{pmatrix} -A^T(\lambda - \bar{\lambda}) \\ -B^T(\lambda - \bar{\lambda}) \\ A(x - \bar{x}) + B(y - \bar{y}) \end{pmatrix} = \\ &= -(x - \bar{x})^T A^T(\lambda - \bar{\lambda}) - (y - \bar{y})^T B^T(\lambda - \bar{\lambda}) + (\lambda - \bar{\lambda})^T A(x - \bar{x}) + (\lambda - \bar{\lambda})^T B(y - \bar{y}) = 0 \end{aligned}$$

引理 1^[6] 设 $\mathcal{X} \subset \mathbb{R}^n$ 是一个闭凸集合, $\theta(x)$ 和 $f(x)$ 是定义在 $\mathcal{X}$ 上的凸函数. 若函数 f 是可微的, 且问题 $\min\{\theta(x) + f(x) \mid x \in \mathcal{X}\}$ 的解集是非空的. 则有

$$x^* \in \operatorname{argmin}\{\theta(x) + f(x) \mid x \in \mathcal{X}\}$$

当且仅当存在 $x^* \in \mathcal{X}$, $\theta(x) - \theta(x^*) + (x - x^*)^T \nabla f(x^*) \geq 0, \forall x \in \mathcal{X}$.

2 算法 1 的预估校正形式

本节将用预估校正方法解释算法 1, 这样的形式有助于在后文中对算法的收敛速率进行分析. 首先定义

$$v = \begin{pmatrix} y \\ \lambda \end{pmatrix}, \quad \mathcal{V} = \mathcal{Y} \times \mathbb{R}^m, \quad \mathcal{V}^* = \{(y^*, \lambda^*) \mid (x^*, y^*, \lambda^*) \in \Omega^*\}$$

由引理 1 知算法 1 的子问题可以分别写作

$$x^{k+1} \in \mathcal{X}$$

$$\theta_1(x) - \theta_1(x^{k+1}) + (x - x^{k+1})^T [-A^T \lambda^k + \beta A^T (Ax^{k+1} + By^k - b)] \geq 0, \quad \forall x \in \mathcal{X} \quad (9)$$

和

$$y^{k+1} \in \mathcal{Y}$$

$$\theta_2(y) - \theta_2(y^{k+1}) + (y - y^{k+1})^T [-B^T(\lambda^{k+1} - \beta(Ax^{k+1} + By^{k+1} - b)) + D_0(y^{k+1} - y^k)] \geq 0, \quad \forall y \in \mathcal{Y} \quad (10)$$

对于给定的 (y^k, λ^k) 算法 1 生成了 (x^{k+1}, y^{k+1}) , 分别定义 $\tilde{x}^k = x^{k+1}$, $\tilde{y}^k = y^{k+1}$, 以及辅助变量

$$\tilde{\lambda}^k := \lambda^k - \beta(Ax^{k+1} + By^k - b) \quad (11)$$

因此不等式(9) 可以写作

$$\tilde{x}^k \in \mathcal{X}, \theta_1(x) - \theta_1(\tilde{x}^k) + (x - \tilde{x}^k)^T (-A^T \tilde{\lambda}^k) \geq 0, \quad \forall x \in \mathcal{X} \quad (12)$$

另外, 由 λ^{k+1} , $\tilde{\lambda}^k$ 和 y^{k+1} 的定义, 有

$$\begin{aligned} \lambda^{k+1} - \beta(Ax^{k+1} + By^{k+1} - b) &= \\ \lambda^k - \gamma\beta(Ax^{k+1} + By^k - b) - \beta(Ax^{k+1} + By^k - b) - \beta B(y^{k+1} - y^k) &= \\ \lambda^k - \beta(Ax^{k+1} + By^k - b) - \gamma(\lambda^k - \tilde{\lambda}^k) - \beta B(\tilde{y}^k - y^k) &= \end{aligned}$$

$$\tilde{\lambda}^k - \gamma(\lambda^k - \tilde{\lambda}^k) - \beta \mathbf{B}(\tilde{\mathbf{y}}^k - \mathbf{y}^k)$$

则不等式(10) 可以写为

$$\tilde{\mathbf{y}}^k \in \mathcal{Y}$$

$$\theta_2(\mathbf{y}) - \theta_2(\tilde{\mathbf{y}}^k) + (\mathbf{y} - \tilde{\mathbf{y}}^k)^T [-\mathbf{B}^T \tilde{\lambda}^k + \gamma \mathbf{B}^T (\lambda^k - \tilde{\lambda}^k) + (\beta \mathbf{B}^T \mathbf{B} + \mathbf{D}_0)(\tilde{\mathbf{y}}^k - \mathbf{y}^k)] \geq 0, \forall \mathbf{y} \in \mathcal{Y} \quad (13)$$

由 $\tilde{\lambda}^k$ 的定义, 有

$$(\mathbf{A}\tilde{\mathbf{x}}^k + \mathbf{B}\tilde{\mathbf{y}}^k - \mathbf{b}) - \mathbf{B}(\tilde{\mathbf{y}}^k - \mathbf{y}^k) + \frac{1}{\beta}(\tilde{\lambda}^k - \lambda^k) = 0 \quad (14)$$

联立(12) – (14) 式, 可以得到:

$$\begin{aligned} \theta(\mathbf{u}) - \theta(\tilde{\mathbf{u}}^k) + \begin{pmatrix} \mathbf{x} - \tilde{\mathbf{x}}^k \\ \mathbf{y} - \tilde{\mathbf{y}}^k \\ \lambda - \tilde{\lambda}^k \end{pmatrix}^T \left\{ \begin{pmatrix} -\mathbf{A}^T \tilde{\lambda}^k \\ -\mathbf{B}^T \tilde{\lambda}^k \\ \mathbf{A}\tilde{\mathbf{x}}^k + \mathbf{B}\tilde{\mathbf{y}}^k - \mathbf{b} \end{pmatrix} \right. \\ \left. - \begin{pmatrix} (\beta \mathbf{B}^T \mathbf{B} + \mathbf{D}_0)(\mathbf{y}^k - \tilde{\mathbf{y}}^k) - \gamma \mathbf{B}^T (\lambda^k - \tilde{\lambda}^k) \\ -\mathbf{B}(\mathbf{y}^k - \tilde{\mathbf{y}}^k) + \frac{1}{\beta}(\lambda^k - \tilde{\lambda}^k) \end{pmatrix} \right\} \geq 0 \quad \forall \boldsymbol{\omega} \in \Omega \end{aligned} \quad (15)$$

由(7) 式中的定义, (15) 式等价于变分不等式

$$\tilde{\boldsymbol{\omega}}^k \in \Omega, \theta(\mathbf{u}) - \theta(\tilde{\mathbf{u}}^k) + (\boldsymbol{\omega} - \tilde{\boldsymbol{\omega}}^k)^T F(\tilde{\boldsymbol{\omega}}^k) \geq (\mathbf{v} - \tilde{\mathbf{v}}^k)^T \mathbf{Q}(\mathbf{v}^k - \tilde{\mathbf{v}}^k) \quad \forall \boldsymbol{\omega} \in \Omega \quad (16)$$

其中

$$\mathbf{Q} = \begin{pmatrix} \beta \mathbf{B}^T \mathbf{B} + \mathbf{D}_0 & -\gamma \mathbf{B}^T \\ -\mathbf{B} & \frac{1}{\beta} \mathbf{I}_m \end{pmatrix} = \begin{pmatrix} \tau \beta \mathbf{B}^T \mathbf{B} + \mathbf{D} & -\gamma \mathbf{B}^T \\ -\mathbf{B} & \frac{1}{\beta} \mathbf{I}_m \end{pmatrix} \quad (17)$$

另一方面, 由 $\lambda^{k+1}, \tilde{\lambda}^k$ 和 $\mathbf{y}^{k+1}$ 的定义, 有

$$\begin{aligned} \mathbf{y}^{k+1} &= \mathbf{y}^k - (\mathbf{y}^k - \tilde{\mathbf{y}}^k) \\ \lambda^{k+1} &= \lambda^k - \gamma(\mathbf{A}\mathbf{x}^{k+1} + \mathbf{B}\mathbf{y}^k - \mathbf{b}) = \lambda^k - \gamma(\lambda^k - \tilde{\lambda}^k) \end{aligned}$$

因此, 有

$$\mathbf{v}^{k+1} = \mathbf{v}^k - \mathbf{M}(\mathbf{v}^k - \tilde{\mathbf{v}}^k) \quad (18)$$

其中

$$\mathbf{M} = \begin{pmatrix} \mathbf{I}_{n_2} & 0 \\ 0 & \gamma \mathbf{I}_m \end{pmatrix} \quad (19)$$

由上面的内容可知, 算法 1 从理论上可以看作是分为两个阶段的. 第一步由变分不等式(16) 生成一个预测点 $(\tilde{\mathbf{y}}^k, \tilde{\lambda}^k)$; 第二步再通过(18) 式对 $(\tilde{\mathbf{y}}^k, \tilde{\lambda}^k)$ 进行校正, 生成新的迭代点 $(\mathbf{y}^{k+1}, \lambda^{k+1})$.

3 遍历意义下的收敛速率

本节将分析算法 1 在遍历意义下的收敛速率. 首先给出以下的几个引理:

引理 2 设定义在(1) 式中的矩阵 $\mathbf{B}$ 是列满秩的, 罚参数 $\beta > 1$. 定义矩阵

$$\mathbf{H} = \begin{pmatrix} \tau \beta \mathbf{B}^T \mathbf{B} + \mathbf{D} & -\mathbf{B}^T \\ -\mathbf{B} & \frac{1}{\gamma \beta} \mathbf{I}_m \end{pmatrix}$$

则

$$\mathbf{H}\mathbf{M} = \mathbf{Q} \quad (20)$$

另外, 当 $\tau \in \left[\frac{1+\beta}{2\beta}, 1\right)$, $\gamma \in \left(0, \frac{2}{1+\beta}\right]$ 时, 有 $\mathbf{H} > \mathbf{0}$.

证 由(17)式和(19)式, 有

$$\begin{aligned} \mathbf{H}\mathbf{M} &= \begin{pmatrix} \tau\beta\mathbf{B}^T\mathbf{B} + \mathbf{D} & -\mathbf{B}^T \\ -\mathbf{B} & \frac{1}{\gamma\beta}\mathbf{I}_m \end{pmatrix} \begin{pmatrix} \mathbf{I}_{n_2} & \mathbf{0} \\ \mathbf{0} & \gamma\mathbf{I}_m \end{pmatrix} = \\ &= \begin{pmatrix} \tau\beta\mathbf{B}^T\mathbf{B} + \mathbf{D} & -\gamma\mathbf{B}^T \\ -\mathbf{B} & \frac{1}{\beta}\mathbf{I}_m \end{pmatrix} = \mathbf{Q} \end{aligned}$$

等式(20)立即证得.

另一方面,

$$\mathbf{H} = \begin{pmatrix} \tau\beta\mathbf{B}^T\mathbf{B} + \mathbf{D} & -\mathbf{B}^T \\ -\mathbf{B} & \frac{1}{\gamma\beta}\mathbf{I}_m \end{pmatrix} = \begin{pmatrix} \tau\beta\mathbf{B}^T\mathbf{B} & -\mathbf{B}^T \\ -\mathbf{B} & \frac{1}{\gamma\beta}\mathbf{I}_m \end{pmatrix} + \begin{pmatrix} \mathbf{D} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} \end{pmatrix}$$

并且 $\mathbf{D}$ 为正定矩阵. 因此, 若矩阵 $\begin{pmatrix} \tau\beta\mathbf{B}^T\mathbf{B} & -\mathbf{B}^T \\ -\mathbf{B} & \frac{1}{\gamma\beta}\mathbf{I}_m \end{pmatrix}$ 为正定矩阵, 则 $\mathbf{H}$ 一定正定. 矩阵

$$\begin{pmatrix} \tau\beta\mathbf{B}^T\mathbf{B} & -\mathbf{B}^T \\ -\mathbf{B} & \frac{1}{\gamma\beta}\mathbf{I}_m \end{pmatrix} = \begin{pmatrix} \mathbf{B}^T & \mathbf{0} \\ \mathbf{0} & \mathbf{I}_m \end{pmatrix} \begin{pmatrix} \tau\beta\mathbf{I}_m & -\mathbf{I}_m \\ -\mathbf{I}_m & \frac{1}{\gamma\beta}\mathbf{I}_m \end{pmatrix} \begin{pmatrix} \mathbf{B} & \mathbf{0} \\ \mathbf{0} & \mathbf{I}_m \end{pmatrix}$$

由假设矩阵 $\mathbf{B}$ 是列满秩的, 因此只需

$$\begin{pmatrix} \tau\beta\mathbf{I}_m & -\mathbf{I}_m \\ -\mathbf{I}_m & \frac{1}{\gamma\beta}\mathbf{I}_m \end{pmatrix} > \mathbf{0}$$

即

$$\frac{1}{\gamma}(\tau - \gamma) > 0$$

由于 $\gamma \in \left(0, \frac{2}{1+\beta}\right]$, 只需 $\tau > \gamma$. 对于任意固定的罚参数 $\beta > 1$, 当 $\tau \in \left[\frac{1+\beta}{2\beta}, 1\right)$, $\gamma \in \left(0, \frac{2}{1+\beta}\right]$ 时, 一定有 $\tau > \gamma$, 因此有 $\mathbf{H} > \mathbf{0}$.

定义对称矩阵 $\mathbf{G} = \mathbf{Q}^T + \mathbf{Q} - \mathbf{M}^T\mathbf{H}\mathbf{M}$, 因为 $\mathbf{H}\mathbf{M} = \mathbf{Q}$, $\mathbf{M}^T\mathbf{H}\mathbf{M} = \mathbf{M}^T\mathbf{Q}$, 有

$$\mathbf{M}^T\mathbf{H}\mathbf{M} = \begin{pmatrix} \mathbf{I}_{n_2} & \mathbf{0} \\ \mathbf{0} & \gamma\mathbf{I}_m \end{pmatrix} \begin{pmatrix} \tau\beta\mathbf{B}^T\mathbf{B} + \mathbf{D} & -\gamma\mathbf{B}^T \\ -\mathbf{B} & \frac{1}{\beta}\mathbf{I}_m \end{pmatrix} = \begin{pmatrix} \tau\beta\mathbf{B}^T\mathbf{B} + \mathbf{D} & -\gamma\mathbf{B}^T \\ -\gamma\mathbf{B} & \frac{\gamma}{\beta}\mathbf{I}_m \end{pmatrix}$$

所以

$$\begin{aligned} \mathbf{G} &= \mathbf{Q}^T + \mathbf{Q} - \mathbf{M}^T\mathbf{H}\mathbf{M} = \\ &= \begin{pmatrix} 2(\tau\beta\mathbf{B}^T\mathbf{B} + \mathbf{D}) & -\mathbf{B}^T - \gamma\mathbf{B}^T \\ -\mathbf{B} - \gamma\mathbf{B} & \frac{2}{\beta}\mathbf{I}_m \end{pmatrix} - \begin{pmatrix} \tau\beta\mathbf{B}^T\mathbf{B} + \mathbf{D} & -\gamma\mathbf{B}^T \\ -\gamma\mathbf{B} & \frac{\gamma}{\beta}\mathbf{I}_m \end{pmatrix} = \\ &= \begin{pmatrix} \tau\beta\mathbf{B}^T\mathbf{B} + \mathbf{D} & -\mathbf{B}^T \\ -\mathbf{B} & \frac{2-\gamma}{\beta}\mathbf{I}_m \end{pmatrix} \end{aligned} \quad (21)$$

引理 3 设 (ω^k) 为算法 1 所生成的序列, $\tilde{\omega}^k$ 由(11) 式定义, 则有 $\tilde{\omega}^k \in \Omega$ 以及

$$\theta(u) - \theta(\tilde{u}^k) + (\omega - \tilde{\omega}^k)^T F(\omega) \geq \frac{1}{2}(\|v - v^{k+1}\|_H^2 - \|v - v^k\|_H^2) + \frac{1}{2}(v^k - \tilde{v}^k)^T G(v^k - \tilde{v}^k) \quad \forall \omega \in \Omega \quad (22)$$

其中 G 在(21) 式中被定义.

由于证明过程与文献[6] 中的引理 2 类似, 故而省略.

如果矩阵 G 是正定的, 则由(22) 式很容易推导出算法 1 的收敛性以及遍历意义下的收敛速率. 本文需要处理的难点在于定义在(21) 式中的矩阵 G 不一定是正定的, 为了解决这个问题, 考虑寻找 $(v^k - \tilde{v}^k)^T G(v^k - \tilde{v}^k)$ 的一个下界.

引理 4 设 (ω^k) 为算法 1 所生成的序列, $\tilde{\omega}^k$ 由(11) 式定义, 则有

$$(v^k - \tilde{v}^k)^T G(v^k - \tilde{v}^k) \geq \|y^k - y^{k+1}\|_B^2 + (\tau\beta - \frac{1}{\gamma}) \|B(y^k - y^{k+1})\|^2 + \left(\frac{2-\gamma}{\gamma^2\beta} - \frac{1}{\gamma}\right) \|\lambda^k - \lambda^{k+1}\|^2 \quad (23)$$

证 由(21) 式 G 的定义和 $\tilde{y}^k = y^{k+1}$, 有

$$(v^k - \tilde{v}^k)^T G(v^k - \tilde{v}^k) = \tau\beta \|B(y^k - y^{k+1})\|^2 + \|y^k - y^{k+1}\|_B^2 + \frac{2-\gamma}{\beta} \|\lambda^k - \tilde{\lambda}^k\|^2 - 2(\lambda^k - \tilde{\lambda}^k)^T B(y^k - y^{k+1}) \quad (24)$$

而从

$$\tilde{\lambda}^k = \lambda^k - \beta(Ax^{k+1} + By^k - b), \lambda^{k+1} = \lambda^k - \gamma\beta(Ax^{k+1} + By^k - b)$$

有

$$\lambda^k - \tilde{\lambda}^k = \beta(Ax^{k+1} + By^k - b) = \frac{1}{\gamma}(\lambda^k - \lambda^{k+1})$$

所以

$$\frac{2-\gamma}{\beta} \|\lambda^k - \tilde{\lambda}^k\|^2 = \frac{2-\gamma}{\gamma^2\beta} \|\lambda^k - \lambda^{k+1}\|^2 \quad (25)$$

和

$$(\lambda^k - \tilde{\lambda}^k)^T B(y^k - y^{k+1}) = \frac{1}{\gamma}(\lambda^k - \lambda^{k+1})^T B(y^k - y^{k+1}) \quad (26)$$

将(25) 式和(26) 式代入(24) 式中, 有

$$(v^k - \tilde{v}^k)^T G(v^k - \tilde{v}^k) = \tau\beta \|B(y^k - y^{k+1})\|^2 + \|y^k - y^{k+1}\|_B^2 + \frac{2-\gamma}{\gamma^2\beta} \|\lambda^k - \lambda^{k+1}\|^2 - \frac{2}{\gamma}(\lambda^k - \lambda^{k+1})^T B(y^k - y^{k+1}) \quad (27)$$

接下来处理(27) 式右边的交叉项, 由 Cauchy-Schwarz 不等式以及 $\gamma \in (0, 1)$ 知

$$-\frac{2}{\gamma}(\lambda^k - \lambda^{k+1})^T B(y^k - y^{k+1}) \geq -\frac{1}{\gamma} \|\lambda^k - \lambda^{k+1}\|^2 - \frac{1}{\gamma} \|B(y^k - y^{k+1})\|^2 \quad (28)$$

结合(27) 式和(28) 式, 即可得到(23) 式.

由引理 3 和引理 4 可以得到下面的引理:

引理 5 设 (ω^k) 为算法 1 所生成的序列, $\tilde{\omega}^k$ 由(11) 式定义, 罚参数 $\beta > 1$, 则对任意的 $\tau \in$

$\left[\frac{1+\beta}{2\beta}, 1\right)$, $\gamma \in \left(0, \frac{2}{1+\beta}\right]$ 有

$$\begin{aligned} \theta(\mathbf{u}) - \theta(\tilde{\mathbf{u}}^k) + (\boldsymbol{\omega} - \tilde{\boldsymbol{\omega}}^k)^\top F(\boldsymbol{\omega}) \geqslant \\ \frac{1}{2}(\|\mathbf{v} - \mathbf{v}^{k+1}\|_{\mathbf{H}}^2 - \|\mathbf{v} - \mathbf{v}^k\|_{\mathbf{H}}^2) + \frac{1}{2}\|\mathbf{y}^k - \mathbf{y}^{k+1}\|_{\mathbf{D}}^2 + \frac{1}{2}(\tau\beta - \frac{1}{\gamma})\|\mathbf{B}(\mathbf{y}^k - \mathbf{y}^{k+1})\|^2 + \\ \frac{1}{2}\left(\frac{2-\gamma}{\gamma^2\beta} - \frac{1}{\gamma}\right)\|\boldsymbol{\lambda}^k - \boldsymbol{\lambda}^{k+1}\|^2 \quad \forall \boldsymbol{\omega} \in \Omega \end{aligned} \quad (29)$$

证 (29)式可直接由(22)式和(23)式得到.

由(29)式,结合文献[6]中第6部分中关于IP-LADMM的收敛性证明过程,可类似推出算法1的收敛性成立,故此处省略.

下面分析算法1在遍历意义下的收敛速率.

定理1 设 $(\boldsymbol{\omega}^k)$ 为算法1所生成的序列, $\tilde{\boldsymbol{\omega}}^k$ 定义在(11)式中,罚参数 $\beta > 1$,则对任意的 $\tau \in \left[\frac{1+\beta}{2\beta}, 1\right)$, $\gamma \in \left(0, \frac{2}{1+\beta}\right]$ 以及迭代次数 t 有

$$\theta(\tilde{\mathbf{u}}_t) - \theta(\mathbf{u}) + (\tilde{\boldsymbol{\omega}}_t - \boldsymbol{\omega})^\top F(\boldsymbol{\omega}) \leqslant \frac{1}{2t}\|\mathbf{v} - \mathbf{v}^1\|_{\mathbf{H}}^2 \quad (30)$$

其中

$$\tilde{\boldsymbol{\omega}}_t = \frac{1}{t}\left(\sum_{k=1}^t \tilde{\boldsymbol{\omega}}^k\right)$$

证 由(29)式,且其中 $\varphi(\mathbf{v}^k, \mathbf{v}^{k+1})$ 为非负函数,有

$$\theta(\mathbf{u}) - \theta(\tilde{\mathbf{u}}^k) + (\boldsymbol{\omega} - \tilde{\boldsymbol{\omega}}^k)^\top F(\boldsymbol{\omega}) \geqslant \frac{1}{2}\|\mathbf{v} - \mathbf{v}^{k+1}\|_{\mathbf{H}}^2 - \frac{1}{2}\|\mathbf{v} - \mathbf{v}^k\|_{\mathbf{H}}^2 \quad (31)$$

从 $k=1, 2, \dots, t$ 对(31)式进行求和,有

$$\sum_{k=1}^t \theta(\tilde{\mathbf{u}}^k) - t\theta(\mathbf{u}) + \left(\sum_{k=1}^t \tilde{\boldsymbol{\omega}}^k - t\boldsymbol{\omega}\right)^\top F(\boldsymbol{\omega}) \leqslant \frac{1}{2}\|\mathbf{v} - \mathbf{v}^1\|_{\mathbf{H}}^2 \quad (32)$$

因为 $\theta(\cdot)$ 是凸函数,并且

$$\tilde{\mathbf{u}}_t = \frac{1}{t}\left(\sum_{k=1}^t \tilde{\mathbf{u}}^k\right)$$

所以有

$$\theta(\tilde{\mathbf{u}}_t) = \frac{1}{t}\left(\sum_{k=1}^t \theta(\tilde{\mathbf{u}}^k)\right)$$

结合(31)式,即可得到(30)式.

参考文献:

- [1] GLOWINSKI R, MARROCCO A. Sur l'approximation, Paréléments Finis D'ordre 1, et la Résolution, par Pénalisation Dualité d'une Classe de Problèmes de Dirichlet non Linéaires [J]. Journal of Equine Veterinary Science, 1975, 2(R-2): 41-76.
- [2] GABAY D, MERCIER B. A Dual Algorithm for the Solution of Nonlinear Variational Problems Via Finite Element Approximation [J]. Comput Math Appl, 1976, 2(1): 17-40.
- [3] YANG J F, YUAN X M. Linearized Augmented Lagrangian and Alternating Direction Methods for Nuclear Norm Minimization [J]. Math Comp, 2013, 82(281): 301-329.
- [4] ZHANG X Q, BURGER M, OSHER S. A Unified Primal-Dual Algorithm Framework Based on Bergman Iteration [J]. J Sci Comput, 2011, 46(1): 20-46.
- [5] HE B S, LIAO L Z, HAN D, et al. A New Inexact Alternating Directions Method for Monotone Variational Inequalities

- [J]. Math Program, 2002, 92(1): 103–118.
- [6] HE B S, MA F, YUAN X M. Linearized Alternating Direction Method of Multipliers Via Positive-Indefinite Proximal Regularization for Convex Programming [DB/OL]. (2016–7–31)[2017–5–20]. http://www.optimization-online.org/DB_HTML/2016/07/5569.html.
- [7] HE B S, MA F, YUAN X M. Positive-Indefinite Proximal Augmented Lagrangian Method and its Application to Full Jacobian Splitting for Multi-Block Separable Convex Minimization Problems [DB/OL]. (2016–9–15) [2017–5–20]. http://www.optimization-online.org/DB_HTML/2016/09/5631.html.

On the Convergence Rate of ADMM with a Positive-Indefinite Proximal Term

WANG Yi-yun¹, OU Xiao-qing², LI Gao-xi³

1. School of Mathematics and Statistics, Southwest University, Chongqing 400715, China;

2. School of Management, Chongqing College of Humanities, Science & Technology, Hechuan Chongqing 401524, China;

3. School of Mathematics and Statistics, Chongqing Technology and Business University, Chongqing 400067, China

Abstract: In this paper, we mainly investigate the convergence rate of ADMM with a positive-indefinite proximal term. We improve the iterative step size of the Lagrangian multiplier by introducing a relaxation factor, and establish the convergence rate of ADMM with a positive-indefinite proximal term in the ergodic sense under suitable assumptions on parameters.

Key words: convex programming problem; alternating direction method of multipliers; positive-indefinite proximal term; convergence rate

责任编辑 张 枸

