

# 原始-对偶混合梯度算法

Zaiwen Wen

*Beijing International Center For Mathematical Research*

<http://bicmr.pku.edu.cn/~wenzw/opt-2020-fall.html>

1 原始-对偶混合梯度算法

2 应用举例

3 收敛性分析

## 鞍点问题

令 $f, h$ 是适当的闭凸函数。考虑原始问题：

$$\min_x f(x) + h(Ax),$$

- 由于 $h$ 有自共轭性，我们将问题变形为

$$(\text{LPD}) \quad \min_x \max_z \psi_{PD}(x, z) \stackrel{\text{def}}{=} f(x) - h^*(z) + z^T Ax. \quad (1)$$

可以看到此时问题变成了一个极小-极大问题，即关于变量 $x$ 求极小，关于变量 $z$ 求极大，这是一个典型的鞍点问题。

- 另一种常用的鞍点问题定义方式构造拉格朗日函数。问题

$$\min_{x \in \mathbb{R}^n, y \in \mathbb{R}^m} f(x) + h(y), \quad \text{s.t.} \quad y = Ax.$$

相应的鞍点问题形式如下：

$$(\text{LP}) \quad \min_{x, y} \max_z f(x) + h(y) + z^T (Ax - y). \quad (2)$$

# PDHG 算法

- PDHG 算法的思想就是分别对两类变量应用近似点梯度算法.
- 以求解问题(1) 为例, PDHG 算法交替更新原始变量以及对偶变量, 其迭代格式如下:

$$\begin{aligned}z^{k+1} &= \operatorname{argmax}_z \left\{ -h^*(z) + \langle Ax^k, z - z^k \rangle - \frac{1}{2\delta_k} \|z - z^k\|_2^2 \right\} \\ &= \operatorname{prox}_{\delta_k h^*}(z^k + \delta_k Ax^k), \\ x^{k+1} &= \operatorname{argmin}_x \left\{ f(x) + (z^{k+1})^T A(x - x^k) + \frac{1}{2\alpha_k} \|x - x^k\|_2^2 \right\} \\ &= \operatorname{prox}_{\alpha_k f}(x^k - \alpha_k A^T z^{k+1}),\end{aligned}\tag{3}$$

其中  $\alpha_k, \delta_k$  分别为原始变量和对偶变量的更新步长.

- 它在第一步固定原始变量  $x^k$  针对对偶变量做梯度上升, 在第二步固定更新后的对偶变量  $z^{k+1}$  针对原始变量做梯度下降. 在这里注意, 原始变量和对偶变量的更新顺序是无关紧要的, 若先更新原始变量, 其等价于在另一初值下先更新对偶变量.

# Chambolle-Pock 算法

- PDHG 算法的收敛性需要比较强的条件，有些情形下未必收敛。
- Chambolle-Pock 算法与 PDHG 算法的区别在于多了一个外推步
- 具体的迭代格式如下：

$$\begin{aligned}z^{k+1} &= \text{prox}_{\delta_k h^*}(z^k + \delta_k A y^k), \\x^{k+1} &= \text{prox}_{\alpha_k f}(x^k - \alpha_k A^T z^{k+1}), \\y^{k+1} &= 2x^{k+1} - x^k.\end{aligned}\tag{4}$$

## 三项函数拆分

考虑

$$\min_x f_1(x) + f_2(Bx) + f_3(x),$$

其中 $f_1, f_2, f_3$ 是三个下半连续的凸函数，且 $f_1$ 具有Lipschitz连续常数 $\frac{1}{\beta}$ ， $\beta \in [0, \infty)$ ， $B \in \mathbb{R}^{m \times n}$ 。

Saddle point 问题形式：

$$\min_x \max_z f_1(x) + \langle z, Bx \rangle - f_2^*(z) + f_3(x)$$

PDFP算法更新如下：

$$\begin{cases} y_{k+1} = \mathbf{prox}_{\gamma f_3}(x_k - \gamma \nabla f_1(x_k) - \lambda B^T z_k), \\ z_{k+1} = (I - \mathbf{prox}_{\frac{\gamma}{\lambda} f_2})(By_{k+1} + z_k), \\ x_{k+1} = \mathbf{prox}_{\gamma f_3}(x_k - \gamma \nabla f_1(x_k) - \lambda B^T z_{k+1}). \end{cases}$$

其中 $0 < \lambda < \frac{1}{\lambda_{\max}(BB^T)}$ ， $0 < \gamma < 2\beta$ 。

1 原始-对偶混合梯度算法

2 应用举例

3 收敛性分析

# LASSO问题求解

考虑LASSO问题

$$\min_{x \in \mathbb{R}^n} \psi(x) \stackrel{\text{def}}{=} \mu \|x\|_1 + \frac{1}{2} \|Ax - b\|_2^2.$$

取 $f(x) = \mu \|x\|_1$  和  $h(z) = \frac{1}{2} \|z - b\|_2^2$ , 相应的鞍点问题:

$$\min_{x \in \mathbb{R}^n} \max_{z \in \mathbb{R}^m} f(x) - h^*(z) + z^T Ax.$$

根据共轭函数的定义,

$$h^*(z) = \sup_{y \in \mathbb{R}^m} \left\{ y^T z - \frac{1}{2} \|y - b\|_2^2 \right\} = \frac{1}{2} \|z\|_2^2 + b^T z.$$

应用PDHG算法,  $x^{k+1}$  和  $z^{k+1}$  的更新格式分别为

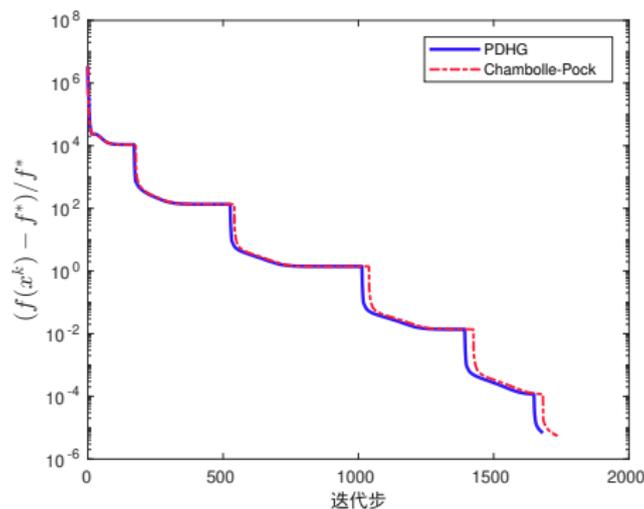
$$\begin{aligned} z^{k+1} &= \text{prox}_{\delta_k h^*}(z^k + \delta_k Ax^k) = \frac{1}{\delta_k + 1} (z^k + \delta_k Ax^k - \delta_k b), \\ x^{k+1} &= \text{prox}_{\alpha_k \mu \|\cdot\|_1}(x^k - \alpha_k A^T z^{k+1}). \end{aligned}$$

这里 $\delta_k, \alpha_k$  为步长.

# LASSO问题求解

Chambolle-Pock算法格式为

$$\begin{aligned}z^{k+1} &= \frac{1}{\delta_k + 1} (z^k + \delta_k A y^k - \delta_k b), \\x^{k+1} &= \text{prox}_{\alpha_k \mu \|\cdot\|_1} (x^k - \alpha_k A^T z^{k+1}), \\y^{k+1} &= 2x^{k+1} - x^k.\end{aligned}$$



# TV- $L^1$ 模型

考虑去噪情形下的TV- $L^1$ 模型（即 $\mathcal{A}$ 为矩阵空间的恒等算子）：

$$\min_{U \in \mathbb{R}^{n \times n}} \|U\|_{TV} + \lambda \|U - B\|_1,$$

其中 $\|U\|_{TV}$ 为全变差，即可以用离散的梯度（线性）算子 $D: \mathbb{R}^{n \times n} \rightarrow \mathbb{R}^{n \times n \times 2}$ 表示为

$$\|U\|_{TV} = \sum_{1 \leq i, j \leq n} \|(DU)_{ij}\|_2.$$

对任意的 $W, V \in \mathbb{R}^{n \times n \times 2}$ ，记

$$\|W\| = \sum_{1 \leq i, j \leq n} \|w_{ij}\|_2, \quad \langle W, V \rangle = \sum_{1 \leq i, j \leq n, 1 \leq k \leq 2} w_{i,j,k} v_{i,j,k},$$

其中 $w_{ij} \in \mathbb{R}^2$ 且 $\|\cdot\|$ 定义了 $\mathbb{R}^{n \times n \times 2}$ 上的一种范数。利用 $\|\cdot\|$ 的定义，有

$$\|U\|_{TV} = \|DU\|.$$

# TV- $L^1$ 模型

我们取 $D$ 为相应的线性算子，并取

$$f(U) = \lambda \|U - B\|_1, U \in \mathbb{R}^{n \times n}, \quad h(W) = \|W\|, \quad W \in \mathbb{R}^{n \times n \times 2}.$$

相应的鞍点问题(1)如下：

$$(\text{LPD}) \quad \min_{U \in \mathbb{R}^{n \times n}} \max_{V \in \mathbb{R}^{n \times n \times 2}} f(U) - h^*(V) + \langle V, DU \rangle.$$

根据共轭函数的定义，

$$h^*(V) = \sup_{U \in \mathbb{R}^{n \times n \times 2}} \{ \langle U, V \rangle - \|U\| \} = \begin{cases} 0, & \max_{ij} \|v_{ij}\|_2 \leq 1, \\ +\infty, & \text{其他.} \end{cases}$$

记 $\mathcal{V} = \{V \in \mathbb{R}^{n \times n \times 2} : \max_{ij} \|v_{ij}\|_2 \leq 1\}$ ，其示性函数记为 $I_{\mathcal{V}}(V)$ ，则问题(LPD)可以整理为

$$\min_U \max_V f(U) + \langle V, DU \rangle - I_{\mathcal{V}}(V).$$

# TV- $L^1$ 模型

应用PDHG算法，则 $V^{k+1}$ 的更新为

$$V^{k+1} = \text{prox}_{sI_{\mathcal{V}}}(V^k + sDU^k) = \mathcal{P}_{\mathcal{V}}(V^k + sDU^k), \quad (5)$$

即 $V^k + sDU^k$ 在 $\mathcal{V}$ 上的投影，而 $U^{k+1}$ 的更新如下：

$$\begin{aligned} U^{k+1} &= \text{prox}_{tf}(U^k + tGV^{k+1}) \\ &= \underset{U}{\text{argmin}} \left\{ \lambda \|U - B\|_1 + \langle V^{k+1}, DU \rangle + \frac{1}{2t} \|U - U^k\|_F^2 \right\} \end{aligned}$$

其中 $G: \mathbb{R}^{n \times n \times 2} \rightarrow \mathbb{R}^{n \times n}$ 为离散的散度算子，其满足

$$\langle V, DU \rangle = -\langle GV, U \rangle, \quad \forall U \in \mathbb{R}^{n \times n}, V \in \mathbb{R}^{n \times n \times 2}.$$

若应用Chambolle-Pock算法，那么 $U^{k+1}$ 的更新保持不变，仅需调整 $V^{k+1}$ 的更新为 $V^k + sD(2U^{k+1} - U^k)$ 在 $\mathcal{V}$ 上的投影。

## 图像填充模型

考虑问题

$$\min_{U \in \mathbb{R}^{n \times n}} \|U\|_{TV} + \frac{\lambda}{2} \|U - B\|_F^2.$$

类似于上一个例子中的分析，我们取 $D$ 为相应的线性算子，并取

$$f(U) = \frac{\lambda}{2} \|U - B\|_F^2, \quad U \in \mathbb{R}^{n \times n}, \quad h(W) = \|W\|, \quad W \in \mathbb{R}^{n \times n \times 2}.$$

一般的鞍点问题叙述如下：

$$(\text{LPD}) \quad \min_U \max_V f(U) + \langle V, DU \rangle - I_{\mathcal{V}}(V),$$

其中 $\mathcal{V}$ 与TV- $L^1$ 模型中的定义一致。应用PDHG算法，则 $V^{k+1}$ 的更新为(5)式。引入离散的散度算子 $G$ ， $U^{k+1}$ 的更新如下：

$$\begin{aligned} U^{k+1} &= \text{prox}_{f, G}(U^k + tGV^{k+1}) \\ &= \underset{U}{\text{argmin}} \left\{ \frac{\lambda}{2} \|U - B\|_F^2 + \langle V^{k+1}, DU \rangle + \frac{1}{2t} \|U - U^k\|_F^2 \right\}. \end{aligned}$$

同样地，Chambolle-Pock算法的更新表达式也可类似地推出。

# 图像反卷积模型

考虑问题

$$\min_{U \in \mathbb{R}^{n \times n}} \|U\|_{TV} + \frac{\lambda}{2} \|AU - B\|_F^2,$$

其中  $AU = K_A * U$  为卷积算子，且  $K_A$  是  $\mathcal{A}$  的卷积核对应的矩阵。  
类似于 TV- $L^1$  模型中的分析，取  $D$  为相应的线性算子，并取

$$f(U) = \frac{\lambda}{2} \|AU - B\|_F^2, \quad U \in \mathbb{R}^{n \times n}, \quad h(W) = \|W\|, \quad W \in \mathbb{R}^{n \times n \times 2}.$$

类似地，一般的鞍点问题叙述如下：

$$(\text{LPD}) \quad \min_U \max_V \quad f(U) + \langle V, DU \rangle - I_{\mathcal{V}}(V),$$

其中  $\mathcal{V}$  与 TV- $L^1$  模型中的定义一致。

# 图像反卷积模型

应用PDHG算法, 则 $V^{k+1}$ 的更新仍为(5)式, 而 $U^{k+1}$ 的更新为:

$$\begin{aligned} U^{k+1} &= \operatorname{prox}_{\mathcal{A}^*} (U^k + tGV^{k+1}) \\ &= \operatorname{argmin}_U \left\{ \frac{\lambda}{2} \|\mathcal{A}U - B\|_F^2 + \frac{1}{2t} \|U - (U^k + tGV^{k+1})\|_F^2 \right\}, \end{aligned}$$

其中 $G$ 为离散的散度算子. 可知 $U^{k+1}$ 满足如下方程:

$$\lambda \mathcal{A}^*(\mathcal{A}U^{k+1} - B) + \frac{1}{t}(U^{k+1} - (U^k + tGV^{k+1})) = 0,$$

其中 $\mathcal{A}^*$ 是 $\mathcal{A}$ 的共轭算子, 且其卷积核对应的矩阵为 $K_{\mathcal{A}^*}$ . 由于 $\mathcal{A}U = K_{\mathcal{A}} * U$ 具有卷积的形式, 我们可以利用快速傅里叶变换 $\mathcal{F}$ 和其逆变换 $\mathcal{F}^{-1}$ 来快速求解上面的线性方程组.

# 图像反卷积模型

根据

$$\mathcal{F}(\mathcal{A}U) = \mathcal{F}(K_{\mathcal{A}} * U) = \mathcal{F}(K_{\mathcal{A}}) \odot \mathcal{F}(U),$$

其中 $\odot$ 表示逐分量相乘, 我们有

$$\begin{aligned} & \mathcal{F}(K_{\mathcal{A}^*}) \odot \left( \mathcal{F}(K_{\mathcal{A}}) \odot \mathcal{F}(U^{k+1}) - \mathcal{F}(B) \right) + \\ & \frac{1}{t\lambda} \mathcal{F}(U^{k+1} - (U^k + tGV^{k+1})) = 0. \end{aligned}$$

利用关系式 $\mathcal{F}(K_{\mathcal{A}^*}) = \overline{\mathcal{F}(K_{\mathcal{A}})}$ , 可得 $U^{k+1}$ 的显式表达式

$$U^{k+1} = \mathcal{F}^{-1} \left( \frac{\mathcal{F}(U^k + tGV^{k+1}) + t\lambda \mathcal{F}(B) \odot \overline{\mathcal{F}(K_{\mathcal{A}})}}{1 + t\lambda |\mathcal{F}(K_{\mathcal{A}})|^2} \right),$$

以上表达式中除 $\mathcal{F}, \mathcal{F}^{-1}, G$ 外, 其余均为逐分量的运算

## 三项函数拆分例子

- Fused Lasso:

$$\min_x \frac{1}{2} \|Ax - b\|^2 + \mu_1 \|Bx\|_1 + \mu_2 \|x\|_1$$

即  $f_1(x) = \frac{1}{2} \|Ax - b\|^2$ ,  $f_2 = \mu_1 \|\cdot\|_1$ ,  $f_3 = \mu_2 \|\cdot\|_1$ 。

- 图像恢复:

$$\min_{x \in C} \frac{1}{2} \|Ax - b\|^2 + \mu \|Dx\|_1$$

即  $f_1(x) = \frac{1}{2} \|Ax - b\|^2$ ,  $f_2 = \mu \|\cdot\|_1$ ,  $f_3 = 1_C(\cdot)$ . 在医学核磁共振图像重建问题中,  $A = (A_1^T, \dots, A_N^T)$ , 其中  $A_j$  由一个对角下采样算子  $D$ , 傅里叶变换  $F$ , 对角的圈灵敏度映射  $S_j$  构成, 即  $A_j = DFS_j$ , 通常  $S_j$  是事先估计好的。

# Outline

- 1 原始-对偶混合梯度算法
- 2 应用举例
- 3 收敛性分析

# Chambolle-Pock 算法的收敛性

- 设 $X, Z$ 分别为变量 $x, z$ 的取值空间, 若点 $(\hat{x}, \hat{z})$ 满足

$$\psi_{\text{PD}}(x, \hat{z}) \geq \psi_{\text{PD}}(\hat{x}, \hat{z}) \geq \psi_{\text{PD}}(\hat{x}, z), \quad \forall x \in X, z \in Z,$$

称 $(\hat{x}, \hat{z})$ 是问题(1)的一个鞍点, 其中 $\psi_{\text{PD}}$ 的定义见该问题.

- 对任意子集 $B_1 \times B_2 \subset X \times Z$ , 定义部分原始-对偶间隙为

$$\mathcal{G}_{B_1 \times B_2}(x, z) = \max_{z' \in B_2} \psi_{\text{PD}}(x, z') - \min_{x' \in B_1} \psi_{\text{PD}}(x', z). \quad (6)$$

不难验证, 只要鞍点 $(\hat{x}, \hat{z}) \in B_1 \times B_2$ , 就有

$$\begin{aligned} \mathcal{G}_{B_1 \times B_2}(x, z) &\geq \psi_{\text{PD}}(x, \hat{z}) - \psi_{\text{PD}}(\hat{x}, z) \\ &= (\psi_{\text{PD}}(x, \hat{z}) - \psi_{\text{PD}}(\hat{x}, \hat{z})) + (\psi_{\text{PD}}(\hat{x}, \hat{z}) - \psi_{\text{PD}}(\hat{x}, z)) \geq 0, \end{aligned}$$

并且在鞍点处 $\mathcal{G}_{B_1 \times B_2}(\hat{x}, \hat{z}) = 0$ . 此外, 容易验证当点 $(\hat{x}, \hat{z}) \in \text{int}(B_1 \times B_2)$ 且满足 $\mathcal{G}_{B_1 \times B_2}(\hat{x}, \hat{z}) = 0$ 时,  $(\hat{x}, \hat{z})$ 是一个鞍点.

# Chambolle-Pock 算法的收敛性

设 $f, h$ 为闭凸函数, 原问题存在鞍点 $(\hat{x}, \hat{z})$ . 在迭代格式(4)中取步长 $\alpha_k = t, \delta_k = s$ , 且满足 $st < \frac{1}{L}$  ( $L = \|A\|_2^2$ ), 则序列 $\{(x^k, z^k)\}$ 具有:

(a) 令常数 $C \leq (1 - Lst)^{-1}$ .  $\forall k$ ,  $(x^k, z^k)$ 有界, 且满足

$$\frac{\|x^k - \hat{x}\|^2}{2t} + \frac{\|z^k - \hat{z}\|^2}{2s} \leq C \left( \frac{\|x^0 - \hat{x}\|^2}{2t} + \frac{\|z^0 - \hat{z}\|^2}{2s} \right), \quad (7)$$

(b) 记 $\bar{x}_N = \frac{1}{N} \sum_{k=1}^N x^k$ ,  $\bar{z}_N = \frac{1}{N} \sum_{k=1}^N z^k$ , 则对 $B_1 \times B_2 \subset X \times Z$ , 有

$$\mathcal{G}_{B_1 \times B_2}(\bar{x}_N, \bar{z}_N) \leq \frac{D(B_1, B_2)}{N}, \quad (8)$$

其中 $D(B_1, B_2) = \sup_{(x, z) \in B_1 \times B_2} \left\{ \frac{\|x - x^0\|^2}{2t} + \frac{\|z - z^0\|^2}{2s} \right\}$ ;

进一步地, 序列 $\{(\bar{x}_N, \bar{z}_N)\}_{N=1}^{\infty}$ 的聚点为问题(1)的一个鞍点;

(c) 存在问题(1)一个鞍点 $(x^*, z^*)$ 使得 $x^k \rightarrow x^*, z^k \rightarrow z^*$ .

## 收敛性分析

为了方便推导，首先考虑算法的一般格式：

$$\begin{aligned}z^{k+1} &= \text{prox}_{sh^*}(z^k + sA\bar{x}), \\x^{k+1} &= \text{prox}_{tf}(x^k - tA^T\bar{z}).\end{aligned}\tag{9}$$

这里和算法(4)不同的是，我们使用 $\bar{x}, \bar{z}$ 来表示更新 $x, z$ 时的参考点。当它们取特定值时，以上格式可以为PDHG算法或Chambolle-Pock算法。根据邻近算子的性质，

$$\begin{aligned}-A^T\bar{z} + \frac{x^k - x^{k+1}}{t} &\in \partial f(x^{k+1}), \\A\bar{x} + \frac{z^k - z^{k+1}}{s} &\in \partial h^*(z^{k+1}).\end{aligned}$$

根据次梯度的定义，对于任意的 $(x, z) \in X \times Z$ 有

$$\begin{aligned}f(x) &\geq f(x^{k+1}) + \frac{1}{t}(x - x^{k+1})^T(x^k - x^{k+1}) - (x - x^{k+1})^T A^T \bar{z}, \\h^*(z) &\geq h^*(z^{k+1}) + \frac{1}{s}(z - z^{k+1})^T(z^k - z^{k+1}) + (z - z^{k+1})^T A \bar{x}.\end{aligned}\tag{10}$$

## 收敛性分析

将上述两个不等式相加，并引入二次项可整理得到

$$\begin{aligned} & \frac{\|x - x^k\|^2}{2t} + \frac{\|z - z^k\|^2}{2s} - \frac{\|x - x^{k+1}\|^2}{2t} - \frac{\|z - z^{k+1}\|^2}{2s} \\ & \geq [f(x^{k+1}) - h^*(z) + (x^{k+1})^T A^T z] - [f(x) - h^*(z^{k+1}) + x^T A^T z^{k+1}] \\ & \quad + \frac{\|x^k - x^{k+1}\|^2}{2t} + \frac{\|z^k - z^{k+1}\|^2}{2s} \\ & \quad + (x^{k+1} - \bar{x})^T A^T (z^{k+1} - z) - (x^{k+1} - x)^T A^T (z^{k+1} - \bar{z}). \end{aligned} \tag{11}$$

将式(4)代入(11)，即取 $\bar{x} = 2x^k - x^{k-1}$ ， $\bar{z} = z^{k+1}$ ，那么上式最后两项：

$$\begin{aligned} & (x^{k+1} - \bar{x})^T A^T (z^{k+1} - z) - (x^{k+1} - x)^T A^T (z^{k+1} - \bar{z}) \\ & = (x^{k+1} - x^k - (x^k - x^{k-1}))^T A^T (z^{k+1} - z) \\ & = (x^{k+1} - x^k)^T A^T (z^{k+1} - z) - (x^k - x^{k-1})^T A^T (z^k - z) \\ & \quad - (x^k - x^{k-1})^T A^T (z^{k+1} - z^k) \\ & \geq (x^{k+1} - x^k)^T A^T (z^{k+1} - z) - (x^k - x^{k-1})^T A^T (z^k - z) \\ & \quad - \sqrt{L} \|x^k - x^{k-1}\| \|z^{k+1} - z^k\|, \end{aligned} \tag{12}$$

应用柯西不等式即得到最后的不等号

## 收敛性分析

又利用  $2ab \leq \alpha a^2 + \frac{b^2}{\alpha}$  对任意的  $\alpha > 0$  均成立, 有

$$\begin{aligned} & \sqrt{L} \|x^k - x^{k-1}\| \|z^{k+1} - z^k\| \\ & \leq \frac{\sqrt{L}\alpha t}{2t} \|x^k - x^{k-1}\|^2 + \frac{\sqrt{L}s}{2\alpha s} \|z^{k+1} - z^k\|^2, \end{aligned} \quad (13)$$

取  $\alpha = \sqrt{\frac{s}{t}}$ , 则

$$\sqrt{L}\alpha t = \sqrt{L} \frac{s}{\alpha} = \sqrt{Lst} < 1,$$

从而合并(11)式和(12)式得到, 对于任意的  $(x, z) \in X \times Z$ ,

$$\begin{aligned} & \frac{\|x - x^k\|^2}{2t} + \frac{\|z - z^k\|^2}{2s} - \frac{\|x - x^{k+1}\|^2}{2t} - \frac{\|z - z^{k+1}\|^2}{2s} \\ & \geq [f(x^{k+1}) - h^*(z) + (x^{k+1})^T A^T z] - [f(x) - h^*(z^{k+1}) + x^T A^T z^{k+1}] \\ & \quad + (1 - \sqrt{Lst}) \frac{\|z^k - z^{k+1}\|^2}{2s} + \frac{\|x^k - x^{k+1}\|^2}{2t} - \sqrt{Lst} \frac{\|x^{k-1} - x^k\|^2}{2t} \\ & \quad + (x^{k+1} - x^k)^T A^T (z^{k+1} - z) - (x^k - x^{k-1})^T A^T (z^k - z). \end{aligned} \quad (14)$$

## 收敛性分析

将上述不等式中的 $k$ 从0遍历至 $N-1$ 并求和, 消掉不等式两边共同项后有

$$\begin{aligned} & \sum_{k=1}^N \{ [f(x^k) - h^*(z) + (x^k)^T A^T z] - [f(x) - h^*(z^k) + x^T A^T z^k] \} \\ & + \frac{\|x - x^N\|^2}{2t} + \frac{\|z - z^N\|^2}{2s} + (1 - \sqrt{Lst}) \sum_{k=1}^N \frac{\|z^k - z^{k-1}\|^2}{2s} \\ & + (1 - \sqrt{Lst}) \sum_{k=1}^{N-1} \frac{\|x^k - x^{k-1}\|^2}{2t} + \frac{\|x^N - x^{N-1}\|^2}{2t} \\ & \leq \frac{\|x - x^0\|^2}{2t} + \frac{\|z - z^0\|^2}{2s} + (x^N - x^{N-1})^T A^T (z^N - z), \end{aligned} \quad (15)$$

其中约定 $x^{-1} = x^0$ . 再一次应用柯西不等式, 以及 $2ab \leq \alpha a^2 + \frac{b^2}{\alpha}$ 对任意的 $\alpha > 0$ 均成立, 可以得到

$$\begin{aligned} (x^N - x^{N-1})^T A^T (z^N - z) & \leq \|x^N - x^{N-1}\| (\sqrt{L} \|z^N - z\|) \\ & \leq \frac{\|x^N - x^{N-1}\|^2}{2t} + \frac{Lst \|z - z^N\|^2}{2s}. \end{aligned}$$

## 收敛性分析

不等式(15)可进一步整理为

$$\begin{aligned} & \sum_{k=1}^N \{ [f(x^k) - h^*(z) + (x^k)^T A^T z] - [f(x) - h^*(z^k) + x^T A^T z^k] \} \\ & + \frac{\|x - x^N\|^2}{2t} + (1 - Lst) \frac{\|z - z^N\|^2}{2s} + (1 - \sqrt{Lst}) \sum_{k=1}^N \frac{\|z^k - z^{k-1}\|^2}{2s} \\ & + (1 - \sqrt{Lst}) \sum_{k=1}^{N-1} \frac{\|x^k - x^{k-1}\|^2}{2t} \\ & \leq \frac{\|x - x^0\|^2}{2t} + \frac{\|z - z^0\|^2}{2s}. \end{aligned} \tag{16}$$

若取  $(x, z) = (\hat{x}, \hat{z})$ , 则由鞍点性质可知

$$[f(x^k) - h^*(\hat{z}) + (x^k)^T A^T \hat{z}] - [f(\hat{x}) - h^*(z^k) + \hat{x}^T A^T z^k] \geq 0.$$

进而(16)左边每一项都是正的, 结论(a)成立.

## 收敛性分析

从(16)出发, 利用 $f, h^*$ 的凸性, 以及 $\bar{x}_N, \bar{z}_N$ 的定义, 有

$$\begin{aligned} & [f(\bar{x}_N) - h^*(z) + (\bar{x}_N)^T A^T z] - [f(x) - h^*(\bar{z}_N) + x^T A^T \bar{z}_N] \\ & \leq \frac{1}{N} \sum_{k=1}^N \{ [f(x^k) - h^*(z) + (x^k)^T A^T z] - [f(x) - h^*(z^k) + x^T A^T z^k] \} \quad (17) \\ & \leq \frac{1}{N} \left( \frac{\|x - x^0\|^2}{2t} + \frac{\|z - z^0\|^2}{2s} \right). \end{aligned}$$

从而结论(b)中(8)式成立. 由(1)知 $\{(x^k, z^k)\}$ 是有界序列, 因此其均值列 $\{(\bar{x}_N, \bar{z}_N)\}$ 也为有界序列. 记 $(x^\#, z^\#)$ 为序列 $\{(\bar{x}_N, \bar{z}_N)\}$ 的聚点, 利用 $f, h^*$ 的凸性以及闭性(下半连续性), 对(17)式左右同时取下极限, 可知对任意的 $(x, z) \in X \times Z$ ,

$$[f(x^\#) - h^*(z) + (x^\#)^T A^T z] - [f(x) - h^*(z^\#) + x^T A^T z^\#] \leq 0. \quad (18)$$

从而 $(x^\#, z^\#)$ 也是问题(1)的一个鞍点.

## 收敛性分析

为了证明 $\{(x^k, z^k)\}$ 全序列收敛到问题(1)的鞍点, 我们采用的大致思路为: 先说明其子列收敛, 然后再利用(14)式估计序列中其他点到子列极限点的误差(进而证明全序列收敛), 最后说明该极限点是鞍点.

根据结论(1),  $\{(x^k, z^k)\}$ 是有界点列, 因此存在子列 $\{(x^{k_l}, z^{k_l})\}$ 收敛于 $(x^*, z^*)$ . 在(14)式中令 $(x, z) = (x^*, z^*)$ , 并将 $k$ 从 $k_l$ 取至 $N-1, N > k_l$ 并求和, 有

$$\begin{aligned} & \frac{\|x^* - x^N\|^2}{2t} + \frac{\|z^* - z^N\|^2}{2s} \\ & + (1 - \sqrt{Lst}) \sum_{k=k_l+1}^N \frac{\|z^k - z^{k-1}\|^2}{2s} - \frac{\|x^{k_l} - x^{k_l-1}\|^2}{2t} \\ & + (1 - \sqrt{Lst}) \sum_{k=k_l}^{N-1} \frac{\|x^k - x^{k-1}\|^2}{2t} + \frac{\|x^N - x^{N-1}\|^2}{2t} \\ & + (x^N - x^{N-1})^T A^T (z^N - z^*) - (x^{k_l} - x^{k_l-1})^T A^T (z^{k_l} - z^*) \\ & \leq \frac{\|x^* - x^{k_l}\|^2}{2t} + \frac{\|z^* - z^{k_l}\|^2}{2s}. \end{aligned}$$

# 收敛性分析

去掉上式中不等式左边的求和项（正项），我们有如下估计：

$$\begin{aligned} & \frac{\|x^* - x^N\|^2}{2t} + \frac{\|z^* - z^N\|^2}{2s} \\ \leq & \frac{\|x^* - x^{k_l}\|^2}{2t} + \frac{\|z^* - z^{k_l}\|^2}{2s} + \frac{\|x^{k_l} - x^{k_l-1}\|^2}{2t} - \frac{\|x^N - x^{N-1}\|^2}{2t} \\ & + (x^{k_l} - x^{k_l-1})^T A^T (z^{k_l} - z^*) - (x^N - x^{N-1})^T A^T (z^N - z^*). \end{aligned}$$

注意到

$$\begin{aligned} x^{k_l} &\rightarrow x^*, && (x^{k_l} \text{ 的定义}) \\ x^N - x^{N-1} &\rightarrow 0, && (\text{由(16) 式推出}) \\ \{z^k\} &\text{有界}, && (\text{本定理中(a) 的结论}) \end{aligned}$$

所以当  $N \rightarrow \infty$  时有， $x^N \rightarrow x^*$ ， $z^N \rightarrow z^*$ ，全序列收敛性得证。最后，由全序列收敛可知均值  $(\bar{x}_N, \bar{z}_N)$  也收敛到  $(x^*, z^*)$ ，根据(a)的结论和极限的唯一性立即得到  $(x^\#, z^\#) = (x^*, z^*)$ ，即收敛到问题(1)的一个鞍点