

附表 1

附表 1

算法一 次梯度法求解带非负约束的数值算法

算法一伪代码：

- 输入：观测数据矩阵 X ， Y ；正则化参数 λ 。
- 输出：系数矩阵 A ；非负矩阵 B 。
- 初始化： B 为非负矩阵，根据 SVD 对 A 进行初始化。
- 迭代过程（直到式（1）收敛）：
 - 固定 B ，使用 SVD 求解 A ，如式（2）所示。
 - 当 B 未收敛时：
 - 对每个 i ，根据式（5）更新 B^i 。
 - 检查 B 是否已收敛。
 - 检查目标函数是否已收敛。

附表 2

附表 2

算法二 非负约束的稳健降秩回归算法

算法二伪代码：

- 输入：矩阵 X, Y ，初始矩阵 $C^{(0)}$ 和 $B^{(0)}$ （确保 $B^{(0)} \geq 0$ ），阈值函数 Θ ，计数器 $t = 0$ ，
- 重复，
- $t \leftarrow t + 1$ 。
 - $C^{(t+1)} \leftarrow \bar{\Theta}(Y - XB^{(t)}; \lambda)$
 - 根据估计结果式（12）， $\hat{r}^{(t+1)} \leftarrow R(X, Y - C^{(t+1)}, r)$ 。
- 直到收敛。

附表 3

附表 3

算法三 ADMM 算法

算法三伪代码：

(1) 初始化参数：主变量 A, D, Z 和 W 初始化为零矩阵, $A \geq 0$; 对偶变量 B_D, B_Z 和 B_W 初始化为零矩阵; 常数 $\rho > 0$ 和 $\delta > 0$ 。

(2) 迭代直至满足停止准则 $\frac{\|a_j^t - a_j^{t-1}\|_2^2}{\|a_j^{t-1}\|_2^2} \leq \varepsilon$, 对于所有的 $j=1, \dots, q$, a_j^t 是系数矩阵 A 的第 j 列在第 t 次迭代后的值。

(a) 更新: A, Z, W, D ;

(i) 更新 A 并确保其非负:

$$A = \max \left\{ 0, \left(\tilde{X}^T \tilde{X} \right)^{-1} \tilde{X}^T (\eta + B) \right\},$$

(ii) $Z = S(A - B_Z, \lambda\gamma/\rho)$ 。其中, S 表示软阈值操作符, 对矩阵逐元素应用。

$$S(A_{ij}, b) = \text{sign}(A_{ij}) \max(|A_{ij}| - b, 0)。$$

(iii) $W = \sum_j \max(\omega_j - \lambda/\rho, 0) a_j b_j^T$, 其中 $\sum_j \omega_j a_j b_j^T$ 是 $A - B_W$ 的奇异值分解。

(iv) $C = XA - B_D$ 。令,

$$D_{ij} = \begin{cases} \frac{Y_{ij} + n\rho C_{ij}}{1 + n\rho}, & |n\rho(Y_{ij} - C_{ij})/(1 + n\rho)| \leq \tau \\ Y_{ij} - S(Y_{ij} - C_{ij}, \tau/n\rho), & \text{其它} \end{cases}$$

(b) 更新 B_D, B_Z, B_W :

(i) $B_D = B_D + D - XA$;

(ii) $B_Z = B_Z + Z - A$;

(iii) $B_W = B_W + W - A$ 。

附录 1:

定义 1 与定义 2 的详细说明

定义 1 (阈值函数) 阈值函数 $\Theta(t; \lambda)$ 是一个实值函数，定义在 $-\infty < t < \infty$ 和 $0 \leq \lambda < \infty$ 范围内，使得：

$$(1) \Theta(-t; \lambda) = -\Theta(t; \lambda);$$

$$(2) \text{对于 } t \leq t', \text{ 有 } \Theta(t; \lambda) \leq \Theta(t'; \lambda);$$

$$(3) \lim_{t \rightarrow \infty} \Theta(t; \lambda) = \infty;$$

$$(4) \text{对于 } 0 \leq t < \infty, \text{ 有 } 0 \leq \Theta(t; \lambda) \leq t.$$

定义 2 (多元阈值函数) 给定阈值函数 Θ 和任意向量 $\mathbf{d} \in \mathbb{R}^m$ 。多元阈值函数 $\bar{\Theta}(\mathbf{d}; \lambda)$ 定义为：当 $\mathbf{d} \neq \mathbf{0}$ 时， $\bar{\Theta}(\mathbf{d}; \lambda) = \mathbf{d} \Theta(\|\mathbf{d}\|_2; \lambda) / \|\mathbf{d}\|_2$ ；当 $\mathbf{d} = \mathbf{0}$ 时， $\bar{\Theta}(\mathbf{d}; \lambda) = \mathbf{0}$ 。对于任意矩阵：

$$\mathbf{D} = (\mathbf{d}_1 \dots \mathbf{d}_n)^T \in \mathbb{R}^{n \times m}, \text{ 定义 } \bar{\Theta}(\mathbf{D}; \lambda) = \{\bar{\Theta}(\mathbf{d}_1; \lambda) \dots \bar{\Theta}(\mathbf{d}_n; \lambda)\}^T.$$

附录 2:

定理一的证明推导说明

首先介绍证明中出现的一些主要符号。

我们通过求解式 (13) 研究令 $\mathbf{A} = (\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_q)$ 的估计值 $\hat{\mathbf{A}} = (\hat{\mathbf{a}}_1, \hat{\mathbf{a}}_2, \dots, \hat{\mathbf{a}}_q)$ 的理论性质。

其中, $\mathbf{a}_i, \hat{\mathbf{a}}_i$ 为列向量, $i = 1, 2, \dots, q$, $\mathbf{A} \in \mathbb{R}^{p \times q}, \hat{\mathbf{A}} \in \mathbb{R}^{p \times q}$ 。令 $V_{p,q} = \{U \in \mathbb{R}^{p \times q} : U^T U = I_q\}$ 表

示 $p \times q$ 正交矩阵的 Stiefel 流形。在整个理论分析中, 假设 $\hat{\mathbf{A}}$ 可以分解为

$$\hat{\mathbf{A}} = \hat{U} \hat{\Lambda} (\hat{V})^T = \sum_{k=1}^r \hat{\lambda}_k \hat{\mathbf{u}}_k (\hat{\mathbf{v}}_k)^T, \text{ 其中 } \hat{U} \in V_{p,r}, \hat{V} \in V_{q,r}, \max_k \|\hat{\mathbf{u}}_k\|_0 \leq s_u, \text{ 以及 } \max_k \|\hat{\mathbf{v}}_k\|_0 \leq s_v,$$

$s_v, s_v \leq n, r \leq n$, 并且 $rs_u s_v \leq n$, s_u 是行稀疏, s_v 是列稀疏。因此 $\hat{\mathbf{A}}$ 是稀疏且低秩的。令

$S = \text{supp}(\hat{\mathbf{A}})$ 为 $\hat{\mathbf{A}}$ 的支持集, 其基数为 $|S| = s$, 即 S 包含 $\hat{\mathbf{A}}$ 中非零元素的索引。同时, $s \leq rs_u s_v$ 。

对于任意向量 $\mathbf{u} = (u_1, \dots, u_p)^T \in \mathbb{R}^p$ 且 $q \geq 1$, 定义 $\|\mathbf{u}\|_q = \left(\sum_{j=1}^p |u_j|^q \right)^{1/q}$ 为 ℓ_q 范数。

$\|\mathbf{u}\|_0 = \sum_{j=1}^p 1(u_j \neq 0)$ 表示 $\mathbf{u}$ 中非零元素的个数, $\|\mathbf{u}\|_\infty = \max_{1 \leq j \leq p} |u_j|$ 。对于任意两个向量 $\mathbf{u}, \mathbf{v} \in \mathbb{R}^p$ 的

内积记为 $\langle \mathbf{u}, \mathbf{v} \rangle = \mathbf{u}^T \mathbf{v}$ 。设 $\mathbf{M}$ 为 $m \times n$ 实矩阵, q 阶范数 $\|\mathbf{M}\|_q = \max_{\mathbf{u} \in \mathbb{R}^n} \frac{\|\mathbf{M}\mathbf{u}\|_q}{\|\mathbf{u}\|_q}$, 核范数

$\|\mathbf{M}\|_* = \sum_{k=1}^{\min\{m,n\}} \lambda_k$, Frobenius 范数 $\|\mathbf{M}\|_F = \sqrt{\sum_{i=1}^m \sum_{j=1}^n M_{ij}^2}$, 将矩阵 $\mathbf{M}$ 的列逐一堆叠, 即可得

到向量化形式 $\text{vec}(\mathbf{M})$ 。

回顾优化问题的形式:

$$\min_{\mathbf{A} \geq 0} \left\{ L_\tau(\mathbf{A}) + \lambda (\|\mathbf{A}\|_* + \gamma \|\mathbf{A}\|_{1,1}) \right\}$$

其中, $L_\tau(\mathbf{A}) = \frac{1}{n} \sum_{i=1}^n \sum_{k=1}^q \ell_\tau(Y_{ik} - \mathbf{X}_{i\cdot}^T \mathbf{A}_k)$, 以方便在证明中使用。令 $\mathbf{A} \in \mathbb{R}^{p \times q}$ 是一个秩为 r 的

非负矩阵, 具有奇异值分解 $\mathbf{U} \mathbf{\hat{u}} \mathbf{V}^T$, 其中 $\mathbf{U} \in \mathbb{R}^{p \times r}, \mathbf{V} \in \mathbb{R}^{q \times r}, \mathbf{\hat{u}} \in \mathbb{R}^{r \times r}$ 。核范数的次微分由下式给出:

$$\partial \|\mathbf{A}\|_* = \{ \mathbf{U} \mathbf{V}^T + \mathbf{W} : \mathbf{W} \in \mathbb{R}^{p \times q}, \mathbf{U}^T \mathbf{W} = \mathbf{0}, \mathbf{W} \mathbf{V} = \mathbf{0}, \|\mathbf{W}\|_2 \leq 1 \}$$

设 $F(r) = \{ \mathbf{A} \in \mathbb{R}^{p \times q} : \text{rank}(\mathbf{A}) \leq r \}$ 是一个代数多样性, 其包含了所有秩至多为 r 的矩阵。与

$F(r)$ 相关的切空间在 $\mathbf{A}$ 处可以表示为:

$$T(\mathbf{A}) = \left\{ \mathbf{U}\mathbf{W}_1^T + \mathbf{W}_2\mathbf{V}^T : \mathbf{W}_1 \in \mathbb{R}^{q \times r}, \mathbf{W}_2 \in \mathbb{R}^{p \times r} \right\}$$

其中, $T(\mathbf{A})$ 可以解释为 $\mathbb{R}^{p \times q}$ 中的一个子空间。令 $\mathbf{P}_{T(\mathbf{A})}$ 表示到 $T(\mathbf{A})$ 的投影算子。则以下关系成立:

$$\tilde{\mathbf{N}} \in \partial \|\mathbf{A}\|_*, \text{ 当且仅当, } \mathbf{P}_{T(\mathbf{A})}(\tilde{\mathbf{N}}) = \mathbf{U}\mathbf{V}^T \text{ 且 } \|\mathbf{P}_{T(\mathbf{A})^\perp} \tilde{\mathbf{N}}\|_2 \leq 1.$$

此外, 定义了一些将在证明中使用的量。

对于任何凸损失函数 $L_\tau(\cdot)$, $\hat{\mathbf{A}}$ 和 $\mathbf{A}$ 之间的非对称 Bregman 散度为:

$$D_L(\hat{\mathbf{A}}, \mathbf{A}) = L_\tau(\hat{\mathbf{A}}) - L_\tau(\mathbf{A}) - \langle \nabla L_\tau(\mathbf{A}), \hat{\mathbf{A}} - \mathbf{A} \rangle \geq 0$$

定义对称 Bregman 散度为:

$$D_L^S(\hat{\mathbf{A}}, \mathbf{A}) = D_L(\hat{\mathbf{A}}, \mathbf{A}) + D_L(\mathbf{A}, \hat{\mathbf{A}}) = \langle \nabla L_\tau(\hat{\mathbf{A}}) - \nabla L_\tau(\mathbf{A}), \hat{\mathbf{A}} - \mathbf{A} \rangle \geq 0$$

该证明涉及对称 Bregman 散度的上界和下界。为此, 我们陈述了一些将在证明中使用的条件与技术性引理。

定义 4 (矩阵的受限特征值) 设 $\xi > 1$ 。给定矩阵 $\mathbf{S}$, 其最小与最大 (ξ, m) -受限特征值分别定义为

$$\rho_-(\mathbf{S}, \xi, m) = \inf_{\mathbf{U}} \left\{ \frac{\text{tr}(\mathbf{U}^T \mathbf{S} \mathbf{U})}{\|\mathbf{U}\|_{1,2}^2} : \mathbf{U} \in \mathbb{R}^{p \times q}, \mathbf{U} \neq \mathbf{0}, \mathbf{S} \subseteq J, |J| \leq m, \|\mathbf{U}_{J^c}\|_{1,1} \leq \xi \|\mathbf{U}_J\|_{1,1} \right\}$$

$$\rho_+(\mathbf{S}, \xi, m) = \sup_{\mathbf{U}} \left\{ \frac{\text{tr}(\mathbf{U}^T \mathbf{S} \mathbf{U})}{\|\mathbf{U}\|_{1,2}^2} : \mathbf{U} \in \mathbb{R}^{p \times q}, \mathbf{U} \neq \mathbf{0}, \mathbf{S} \subseteq J, |J| \leq m, \|\mathbf{U}_{J^c}\|_{1,1} \leq \xi \|\mathbf{U}_J\|_{1,1} \right\}$$

其中, $\|\mathbf{U}\|_{2,2}^2 = \sum_{i,j} \mathbf{U}_{i,j}^2$ 表示 Frobenius 范数平方, $\mathbf{U}_J$ 是 $\mathbf{U}$ 在列指标集 J 上的子矩阵。

条件 3 存在常数 $0 < K_{\text{lower}} \leq K_{\text{upper}} < \infty$, 使得 $\mathbf{S}$ 的受限特征值满足

$$K_{\text{lower}} \leq \rho_-(\mathbf{S}, \xi, m) \leq \rho_+(\mathbf{S}, \xi, m) \leq K_{\text{upper}}$$

引理 1 设矩阵 $\mathbf{A}^* \in \mathbb{C}(m, \xi, \eta)$, 其中

$$\mathbb{C}(m, \xi, \eta) = \left\{ (\mathbf{A}^*, \mathbf{U}) \in \mathbb{R}^{p \times q} \times \mathbb{R}^{p \times q} : \mathbf{U} \neq \mathbf{0}, \mathbf{S} \subseteq J, |J| \leq m, \|\mathbf{U}_{S^c}\|_{1,1} \leq \xi \|\mathbf{U}_S\|_{1,1}, \|\mathbf{A}^* - \mathbf{A}\|_{1,1} \leq \eta \right\}$$

取 $\tau \geq \max \left\{ 8\eta, C \cdot (m\nu_\delta)^{1/(1+\delta)} \right\}$, $n > C'm^2 \log(pq)$, $C, C' > 0$ 为充分大的常数。条件 1 与条件 3

成立的前提下, 存在常数 K_{lower} 与 K_{upper} , 使得矩阵 $\mathbf{H}_\tau(\mathbf{A}^*)$ 的局部受限特征值满足

$$0 < \frac{K_{\text{lower}}}{2} \leq K_-(\mathbf{H}_\tau(\mathbf{A}^*), \xi, \eta) \leq K_+(\mathbf{H}_\tau(\mathbf{A}^*), \xi, \eta) \leq K_{\text{upper}} < \infty$$

且以至少 $1 - (pq)^{-1}$ 的概率成立。

引理 2 (梯度无穷范数边界) 假设协变量标准化, 使得 $\max_{i,j} |\mathbf{X}_{ij}| = 1$, 且 E_{ik} 满足

$\nu_\delta = \mathbb{E} \left(|E_{ik}|^{1+\delta} \right) < \infty$ 。令 $\mathbf{A} = (\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_q)$, $\hat{\mathbf{A}} = (\hat{\mathbf{a}}_1, \hat{\mathbf{a}}_2, \dots, \hat{\mathbf{a}}_q)$ 为估计值, $\mathbf{a}_i, \hat{\mathbf{a}}_i$ 为列向量,

$i = 1, 2, \dots, q$ 。选择 $\tau \geq C_1 \left\{ n\nu_\delta / \log(pq) \right\}^{\min\{1/2, 1/(1+\delta)\}}$, 则有

$$\|\nabla L_{\tau}(\mathbf{A})\|_{\infty, \infty} \leq C_2 v_{\delta}^{1/\min(1+\delta, 2)} \left(\frac{\log(pq)}{n} \right)^{\min\{1/2, \delta/(1+\delta)\}}$$

的概率为 $1 - (pq)^{-1}$ ，其中 C_1 和 C_2 是常数。

引理 3 ($\ell_{1,1}$ -锥约束性质) 假设 $\|\nabla L_{\tau}(\mathbf{A})\|_{\infty, \infty} \leq \frac{\lambda}{2}$ ， $\gamma > 3/2$ 。设 $\hat{\mathbf{A}}$ 是式(12)的一个解， $\mathbf{A} = (\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_q)$ ，其估计 $\hat{\mathbf{A}} = (\hat{\mathbf{a}}_1, \hat{\mathbf{a}}_2, \dots, \hat{\mathbf{a}}_q)$ ， $\mathbf{A} \in \mathbb{R}_+^{p \times q}$ ， $\hat{\mathbf{A}} \in \mathbb{R}_+^{p \times q}$ 那么有 $\hat{\mathbf{A}}$ 落在以下 $\ell_{1,1}$ -锥中，

$$\left\| (\hat{\mathbf{A}} - \mathbf{A})_{S^c} \right\|_{1,1} \leq \frac{2\gamma + 3}{2\gamma - 3} \left\| (\hat{\mathbf{A}} - \mathbf{A})_S \right\|_{1,1}$$

引理 3 的证明

$$D_{\mathbf{L}}^s(\hat{\mathbf{A}}, \mathbf{A}) = \langle \nabla L_{\tau}(\mathbf{A}), \mathbf{A} - \hat{\mathbf{A}} \rangle + \lambda \langle \tilde{\mathbf{N}}, \mathbf{A} - \hat{\mathbf{A}} \rangle + \lambda \gamma \langle \tilde{\mathbf{s}}, \mathbf{A} - \hat{\mathbf{A}} \rangle + \langle \Pi, \mathbf{A} - \hat{\mathbf{A}} \rangle \leq 0$$

接下来分解并计算各组成部分的上界。

$$\text{令: } \mathbf{I}_1 = \langle \nabla L_{\tau}(\mathbf{A}), \mathbf{A} - \hat{\mathbf{A}} \rangle, \quad \mathbf{I}_2 = \lambda \langle \tilde{\mathbf{N}}, \mathbf{A} - \hat{\mathbf{A}} \rangle, \quad \mathbf{I}_3 = \lambda \gamma \langle \tilde{\mathbf{s}}, \mathbf{A} - \hat{\mathbf{A}} \rangle, \quad \mathbf{I}_4 = \langle \Pi, \mathbf{A} - \hat{\mathbf{A}} \rangle.$$

记 $\Delta = \hat{\mathbf{A}} - \mathbf{A}$ ，则

$$\mathbf{I}_1 = \langle \nabla L_{\tau}(\mathbf{A}), \Delta \rangle, \quad \mathbf{I}_2 = \lambda \langle \tilde{\mathbf{N}}, \Delta \rangle, \quad \mathbf{I}_3 = \lambda \gamma \langle \tilde{\mathbf{s}}, \Delta \rangle, \quad \mathbf{I}_4 = \langle \Pi, \Delta \rangle$$

$$\text{记, } S = \text{supp}(\mathbf{A}), \quad s_0 := \|\Delta_S\|_{1,1}, \quad s_1 := \|\Delta_{S^c}\|_{1,1}, \quad \text{则}$$

$$\mathbf{I}_1 = \langle \nabla L_{\tau}(\mathbf{A}), \Delta \rangle \geq -\|\nabla L_{\tau}(\mathbf{A})\|_{\infty, \infty} \|\Delta\|_{1,1} \geq -\frac{\lambda}{2} \|\Delta\|_{1,1} = -\frac{\lambda}{2} (s_0 + s_1)$$

$$\mathbf{I}_2 = \lambda \langle \tilde{\mathbf{N}}, \Delta \rangle \geq -\lambda \|\tilde{\mathbf{N}}\|_{\infty, \infty} \|\Delta\|_{1,1} \geq -\lambda (s_0 + s_1)$$

$$\text{其中, 取 } \tilde{\mathbf{N}} = \mathbf{U}\mathbf{V}^T, \quad \text{令 } \mathbf{W} = \mathbf{0}, \quad \text{在分解 } \tilde{\mathbf{N}} = \mathbf{U}\mathbf{V}^T + \mathbf{W} \text{ 中, 则 } \|\tilde{\mathbf{N}}\|_{\infty, \infty} \leq 1$$

$$\begin{aligned} \mathbf{I}_3 &= \lambda \gamma \langle \tilde{\mathbf{s}}, \Delta \rangle \\ &\geq \lambda \gamma \langle \tilde{\mathbf{s}}_S, \Delta_S \rangle + \lambda \gamma \langle \tilde{\mathbf{s}}_{S^c}, \Delta_{S^c} \rangle \\ &\geq -\lambda \gamma \|\Delta_S\|_{1,1} + \lambda \gamma \|\Delta_{S^c}\|_{1,1} \\ &= -\lambda \gamma s_0 + \lambda \gamma s_1 \end{aligned}$$

$$\text{其中, } \|\tilde{\mathbf{s}}_S\|_{\infty, \infty} \leq 1$$

$$\mathbf{I}_4 = \langle \Pi, \Delta \rangle \geq 0$$

将上述结果代入下式

$$D_{\mathbf{L}}^s(\hat{\mathbf{A}}, \mathbf{A}) = \langle \nabla L_{\tau}(\mathbf{A}), \mathbf{A} - \hat{\mathbf{A}} \rangle + \lambda \langle \tilde{\mathbf{N}}, \mathbf{A} - \hat{\mathbf{A}} \rangle + \lambda \gamma \langle \tilde{\mathbf{s}}, \mathbf{A} - \hat{\mathbf{A}} \rangle + \langle \Pi, \mathbf{A} - \hat{\mathbf{A}} \rangle \leq 0$$

得到

$$-\frac{\lambda}{2} (s_0 + s_1) - \lambda (s_0 + s_1) - \lambda \gamma s_0 + \lambda \gamma s_1 \leq 0$$

$$\begin{aligned} \left(\gamma - \frac{3}{2}\right)s_1 &\leq \left(\gamma + \frac{3}{2}\right)s_0 \\ \frac{s_1}{s_0} &= \frac{2\gamma + 3}{2\gamma - 3} \\ \text{即 } \left\|(\hat{A} - A)_{S^c}\right\|_{1,1} &\leq \frac{2\gamma + 3}{2\gamma - 3} \left\|(\hat{A} - A)_S\right\|_{1,1}. \end{aligned}$$

引理 4 (限制强凸性) 对于矩阵 $(A^*, U) \in C(m, \xi, \eta)$, $A = (a_1, a_2, \dots, a_q)$, $a_i, \hat{a}_i$ 为列向量, $A^* = (a_1^*, a_2^*, \dots, a_q^*)$,

$$C(m, \xi, \eta) = \left\{ (A^*, U) \in \begin{matrix} p \times q \\ p \times q \end{matrix} : U \neq \mathbf{0}, S \subseteq J, |J| \leq m, \|U_{S^c}\|_{1,1} \leq \xi \|U_S\|_{1,1}, \|A^* - A\|_{1,1} \leq \eta \right\}$$

在和引理 1 相同的条件下有:

$$D_L^s(A^*, A) \geq \frac{K_{\text{lower}}}{2} \|A^* - A\|_F^2 \text{ 的概率至少为 } 1 - (pq)^{-1}.$$

引理 1, 引理 2 与引理 4 的证明详见 Tan 等 (2023) 的引理 1, 引理 2 与引理 5。

证明定理 1:

首先, 定义一阶优化条件

存在 $\tilde{N} \in \partial \|\hat{A}\|_*$, $\tilde{\mathcal{S}} \in \partial \|\hat{A}\|_{1,1}$, $\Pi \in \mathbb{R}_+^{p \times q}$, 对 $\hat{A}$ 有

$$\nabla L_\tau(\hat{A}) + \lambda(\tilde{N} + \gamma \tilde{\mathcal{S}}) - \Pi = \mathbf{0}$$

$$\Pi \hat{A} = \mathbf{0}, \Pi \geq \mathbf{0}$$

其中, Π 为非负拉格朗日乘子。互补条件 $\Pi \hat{A} = \mathbf{0}$, 确保 $\hat{A}_{ij} = 0$ 时 $\Pi_{ij} \geq 0$, 而 $\hat{A}_{ij} > 0$ 时 $\Pi_{ij} = 0$ 。

定义对称 Bregman 散度:

$$D_L^s(\hat{A}, A) = \langle -\lambda \tilde{N} - \lambda \gamma \tilde{\mathcal{S}} - \nabla L_\tau(A) + \Pi, \hat{A} - A \rangle$$

进一步

$$D_L^s(\hat{A}, A) = \langle \nabla L_\tau(A), A - \hat{A} \rangle + \lambda \langle \tilde{N}, A - \hat{A} \rangle + \lambda \gamma \langle \tilde{\mathcal{S}}, A - \hat{A} \rangle + \langle \Pi, A - \hat{A} \rangle$$

接下来分解并计算各组成部分的上界。

$$\text{令: } I_1 = \langle \nabla L_\tau(A), A - \hat{A} \rangle, I_2 = \lambda \langle \tilde{N}, A - \hat{A} \rangle, I_3 = \lambda \gamma \langle \tilde{\mathcal{S}}, A - \hat{A} \rangle, I_4 = \langle \Pi, A - \hat{A} \rangle.$$

根据 Holder 不等式,

对 I_1 的上界估计:

$$\begin{aligned} I_1 &\leq \|\nabla L_\tau(A)\|_{\infty, \infty} \|\hat{A} - A\|_{1,1} \\ &\leq \frac{\lambda}{2} \|\hat{A} - A\|_{1,1} \\ &\leq \frac{\lambda}{2} \left(\left\|(\hat{A} - A)_S\right\|_{1,1} + \left\|(\hat{A} - A)_{S^c}\right\|_{1,1} \right) \\ &\leq \frac{2\lambda\gamma}{2\gamma - 3} \left\|(\hat{A} - A)_S\right\|_{1,1} \end{aligned}$$

对 I_2 的上界估计:

$$\begin{aligned}
I_2 &\leq \lambda \|\tilde{N}\|_{\infty, \infty} \|\hat{A} - A\|_{1,1} \\
&\leq \lambda \|\hat{A} - A\|_{1,1} \\
&\leq \frac{4\lambda\gamma}{2\gamma-3} \|(\hat{A} - A)_s\|_{1,1}
\end{aligned}$$

其中, $\|\tilde{N}\|_{\infty, \infty} \leq 1$

对 I_3 的上界估计:

$$\begin{aligned}
I_3 &\leq \lambda\gamma \|\tilde{s}\|_{\infty, \infty} \|\hat{A} - A\|_{1,1} \\
&\leq \lambda\gamma \|\hat{A} - A\|_{1,1} \\
&\leq \frac{4\lambda\gamma^2}{2\gamma-3} \|(\hat{A} - A)_s\|_{1,1}
\end{aligned}$$

其中, $\|\tilde{s}\|_{\infty, \infty} \leq 1$

对 I_4 的上界估计:

$$\begin{aligned}
I_4 &= \langle \Pi, A - \hat{A} \rangle \\
&\leq \|\Pi\|_{\infty, \infty} \|\hat{A} - A\|_{1,1} \\
&\leq \frac{\lambda(4\gamma^2 + 8\gamma)}{2\gamma-3} \|(\hat{A} - A)_s\|_{1,1}
\end{aligned}$$

其中, $\|\Pi\|_{\infty, \infty} \leq \lambda(\gamma + 2)$

接着将 I_1 、 I_2 、 I_3 和 I_4 的上界代入到 $D_L^s(\hat{A}, A)$ 的计算中, 得到:

$$\begin{aligned}
D_L^s(\hat{A}, A) &\leq \frac{8\gamma^2 + 14\gamma}{2\gamma-3} \lambda \|(\hat{A} - A)_s\|_{1,1} \\
&\leq \frac{8\gamma^2 + 14\gamma}{2\gamma-3} \lambda \sqrt{s} \|(\hat{A} - A)_s\|_F
\end{aligned}$$

其中, $s \leq rs_u s_v$ 是 A 的稀疏性参数, $\|(\hat{A} - A)_s\|_{1,1} \leq \sqrt{s} \|(\hat{A} - A)_s\|_F$, $s = |\text{supp}(A)|$ 。

接下来, 利用引理 4 来获得对称 Bregman 散度的下界。引理 4 要求向量 A^* 在 $C(m, \xi, \eta)$ 中。因此构造向量 $\hat{A}_\eta = A + \zeta(\hat{A} - A)$, 对于 $\eta > 0$, 有 $\|\hat{A}_\eta - \hat{A}\|_{1,1} \leq \eta$ 。如果 $\|\hat{A} - A\|_{1,1} \leq \eta$, 则设 $\zeta = 1$, 则 $\hat{A}_\eta = \hat{A}$ 。否则取 $\zeta \in (0, 1)$, 使得 $\|\hat{A}_\eta - \hat{A}\|_{1,1} \leq \eta$ 。因此, 根据引理 3 可以证明 $\hat{A}_\eta$ 落在一个 ℓ_1 锥中, 因此 $\hat{A}_\eta \in C(m, \xi, \eta)$, 并且有

$$\|(\hat{A}_\eta - A)_{s^c}\|_{1,1} \leq \frac{2\gamma+3}{2\gamma-3} \|(\hat{A}_\eta - A)_s\|_{1,1} \quad \text{和} \quad \|\hat{A}_\eta - A\|_{1,1} \leq \eta \quad (17)$$

再通过引理 4 有:

$$D_L^s(\hat{A}_\eta, A) \geq \frac{K_{\text{lower}}}{2} \|\hat{A}_\eta - A\|_F^2 \quad (18)$$

根据 Sun 等 (2020) 的引理 A.1 有:

$$D_L^s(\hat{A}_\eta, A) \leq \zeta D_L^s(\hat{A}, A) \quad (19)$$

结合上述(18)式和(19)式, 得到:

$$\|\hat{\mathbf{A}}_\eta - \mathbf{A}\|_F^2 \leq \zeta K_{\text{lower}}^{-1} \frac{16\gamma^2 + 28\gamma}{2\gamma - 3} \lambda \left\| (\hat{\mathbf{A}} - \mathbf{A})_s \right\|_{1,1}$$

由于 $\left\| (\hat{\mathbf{A}} - \mathbf{A})_s \right\|_{1,1} \leq \sqrt{s} \left\| (\hat{\mathbf{A}} - \mathbf{A})_s \right\|_F$, 因此

$$\|\hat{\mathbf{A}}_\eta - \mathbf{A}\|_F^2 \leq \zeta K_{\text{lower}}^{-1} \frac{16\gamma^2 + 28\gamma}{2\gamma - 3} \lambda \sqrt{s} \|\hat{\mathbf{A}} - \mathbf{A}\|_F$$

由于 $\hat{\mathbf{A}} - \mathbf{A} = \zeta^{-1} (\hat{\mathbf{A}}_\eta - \mathbf{A})$, 则

$$\|\hat{\mathbf{A}}_\eta - \mathbf{A}\|_F \leq K_{\text{lower}}^{-1} \frac{16\gamma^2 + 28\gamma}{2\gamma - 3} \lambda \sqrt{s}$$

根据式(17), 当 $n > Cs^2 \log(pq)$ 时, C 是某个足够大的常数。则有,

$$\begin{aligned} \|\hat{\mathbf{A}}_\eta - \mathbf{A}\|_{1,1} &\leq \frac{4\gamma}{2\gamma - 3} \left\| (\hat{\mathbf{A}}_\eta - \mathbf{A})_s \right\|_{1,1} \\ &\leq \frac{4\gamma\sqrt{s}}{2\gamma - 3} \left\| (\hat{\mathbf{A}}_\eta - \mathbf{A})_s \right\|_F \\ &\leq K_{\text{lower}}^{-1} \frac{4\gamma}{2\gamma - 3} \frac{16\gamma^2 + 28\gamma}{2\gamma - 3} \lambda s \\ &< \eta \end{aligned}$$

由于, $\|\hat{\mathbf{A}}_\eta - \mathbf{A}\|_{1,1} < \eta$, 则 $\hat{\mathbf{A}}_\eta = \hat{\mathbf{A}}$, 因此

$$\|\hat{\mathbf{A}} - \mathbf{A}\|_F \leq K_{\text{lower}}^{-1} \frac{16\gamma^2 + 28\gamma}{2\gamma - 3} \lambda \sqrt{s}$$

由于 $\hat{\mathbf{A}} = (\hat{\mathbf{a}}_1, \hat{\mathbf{a}}_2, \dots, \hat{\mathbf{a}}_q)$, $\mathbf{A} = (\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_q)$, $\mathbf{a}_i, \hat{\mathbf{a}}_i$ 为列向量, $i = 1, 2, \dots, q$ 。则对于每个向量 $\hat{\mathbf{a}}_i$

$$\|\hat{\mathbf{A}} - \mathbf{A}\|_F^2 = \sum_{i=1}^q \|\hat{\mathbf{a}}_i - \mathbf{a}_i\|_2^2$$

于是对于任意 i 都有,

$$\|\hat{\mathbf{a}}_i - \mathbf{a}_i\|_2 \leq \|\hat{\mathbf{A}} - \mathbf{A}\|_F$$

则

$$\|\hat{\mathbf{a}}_i - \mathbf{a}_i\|_2 \leq \|\hat{\mathbf{A}} - \mathbf{A}\|_F \leq K_{\text{lower}}^{-1} \frac{16\gamma^2 + 28\gamma}{2\gamma - 3} \lambda \sqrt{s}$$

进一步得到


$$\|\hat{\mathbf{a}}_i - \mathbf{a}_i\|_2 \leq K_{\text{lower}}^{-1} \frac{16\gamma^2 + 28\gamma}{2\gamma - 3} \lambda \sqrt{s_i}, \quad i = 1, 2, \dots, q$$

综上, 定理 1 得证。

参考文献

- [1] Sun Q, Zhou WX, Fan J. Adaptive Huber Regression [J]. Journal of the American Statistical Association, 2020, 115(529): 254-265.

附图 1



附图 1 $r = 1$ 和 $r = 2$ 时的最小交叉验证误差轨迹图