

文章编号: 1672 - 058X(2009)06 - 0517 - 05

# 有约束的多元线性回归模型的 Minimax 估计

王理峰<sup>1</sup>, 朱道元<sup>2\*</sup>

(1. 南京铁道职业技术学院 社科部, 南京 210015; 2. 东南大学 数学系, 南京 210096)

**摘要:** 在损失函数  $\text{tr}(\hat{B} - B)^T A (\hat{B} - B)$  下给出  $B$  在线性估计类中的 Minimax 估计, 研究了其性质. 在一些特殊的情形下, 该估计包括了多元功效岭回归估计 (Ridge regression estimation), 多元 Stein 估计等.

**关键词:** 多元线性回归模型; 多元线性 Minimax 估计; 多元岭回归估计

中图分类号: O212.1

文献标志码: A

为了以下计算方便, 先介绍几个符号: 符号  $a \wedge b = \min(a, b)$ ,  $a \vee b = \max(a, b)$ ,  $x_+ = \max(x, 0)$ .

若  $A$  为  $n \times n$  阶对称矩阵, 有谱分解  $A = P D P^T$ , 其中  $P$  为  $n \times n$  阶正交阵,  $D$  为对角阵, 其对角元记为  $d_i$ ,  $i = 1, 2, \dots, n$ . 定义:  $D_+ = \text{diag}((d_1 \vee 0), (d_2 \vee 0), \dots, (d_i \vee 0), \dots, (d_n \vee 0))$ . 考虑多元线性回归模型:

$$\begin{cases} Y = X\hat{B} + E \\ \text{vec}(E) \sim (0, W \otimes I) \end{cases} \quad (1)$$

其中  $Y$  为  $n \times q$  阶观测矩阵,  $X$  为  $n \times p$  设计矩阵,  $\text{rk}(X) = p$ ,  $E = (e_1, e_2, \dots, e_q)$  为  $n \times q$  阶误差矩阵,  $W = (w_{ij})$  为已知的  $q$  阶非零非负定阵.  $B$  为  $p \times q$  阶未知参数矩阵, 满足  $\text{tr}(B^T X F X B) > 0$ , 其中  $F$  为  $n \times n$  阶非负定阵. 记  $L = \{\hat{B} \mid \text{tr}(\hat{B}^T X F X B) > 0\}$ . 式 (1) 的最小二乘估计为  $\hat{B}_{LS} = (X^T X)^{-1} X^T Y$ , 此处采用的损失函数为:  $L$  中的  $\hat{B}$  为  $\text{tr}(\hat{B}^T B - B^T B)$ ,  $B$  为  $p \times p$  阶正定阵, 其相应的风险函数为  $EL(\hat{B}, B, A)$ .

**定义 1**  $\hat{B}^*$  为约束条件下  $B$  的线性 Minimax 估计, 若  $\inf_{\hat{B} \in L} \sup_B EL(\hat{B}, B, A) = \sup_B EL(\hat{B}^*, B, A)$ , 其中  $L$  为  $B$  的线性估计类, 记  $L = \{\hat{B} : \hat{B} = CY, C \text{ 为 } p \times n \text{ 阶矩阵}\}$ .

线性回归的许多问题, 包括 Minimax 估计问题, 在典则形式下很容易理解.

对  $X$  进行奇异值分解:  $X = UDV^T$ ,  $U, V$  分别为  $n \times n, p \times p$  阶正交阵,  $D$  为  $n \times p$  阶矩阵.  $D$  的  $(i, i)$  元为  $d_i$  ( $d_1 \geq d_2 \geq \dots \geq d_p > 0$ ), 其余位置为 0, 则  $X^T X = VD^2V^T = VD^2V$ . 其中  $D = \text{diag}(d_1, d_2, \dots, d_p)$ ,  $d_i = \sqrt{d_i}$ ,  $i$  为  $X^T X$  的非零特征根, 其中  $d_1 \geq d_2 \geq \dots \geq d_p > 0$ .

令  $Z = U^T Y, D = U^T X V, R = V^T B, E = U^T E, u = XB, \hat{u} = EZ = U^T E = (u_1, u_2, \dots, u_q)$ , 其中,  $u_i = (z_{1i}, z_{2i}, \dots, z_{pi}), 0, \dots, 0)$ , 则模型 (1) 可化为:

$$\begin{cases} Z = DR + \\ \text{vec}(E) \sim (0, W \otimes I_n) \end{cases} \quad (2)$$

式 (2) 的最小二乘估计为  $\hat{R}_{LS} = (\tilde{D}^T \tilde{D})^{-1} \tilde{D}^T Z$ . 记  $Z = (z_{ij}) = (z_{11}, z_{12}, \dots, z_{1q}) = (\tilde{Z}^*)$ , 其中  $\tilde{Z} = (\tilde{z}_1, \tilde{z}_2, \dots, \tilde{z}_q)$ ,  $\tilde{z}_i = (z_{1i}, z_{2i}, \dots, z_{pi})$ ,  $\tilde{D}$  为  $Z$  上面  $p \times q$  阶子块组成的矩阵. 记  $R = (r_{ij}) = (r_{11}, r_{12}, \dots, r_{1q}) = (R^*)$ , 其中

收稿日期: 2009-08-30; 修回日期: 2009-09-20.

作者简介: 王理峰 (1981-), 女, 河南平顶山人, 硕士, 从事多元统计分析及其应用研究.

\* 通讯作者: 朱道元 (1947-), 男, 东南大学数学系教授, 从事多元统计分析与数学建模研究. e-mail: zhudy@seu.edu.cn

$= (r_{11}, r_{12}, \dots, r_{1q}), \quad i = (r_{ii}, r_{i2}, \dots, r_{ip})$ , 为上面  $p \times q$  阶子块组成的矩阵. 记  $R = (r_{ij}) = (r_1, r_2, \dots, r_q)$ , 则

$$\begin{cases} \tilde{Z} = DR + \\ \text{vec}(\tilde{Z}) \sim (0, W \otimes I_p) \end{cases} \quad (3)$$

要估计  $R$  只需考虑模型 (3) 即可, 而模型中  $D$  为对角阵, 它使求解方便、简洁. 将模型 (3) 拉直得:

$$\begin{cases} \text{vec}(\tilde{Z}) = (I \otimes D) \text{vec}(R) + \text{vec} \\ \text{vec}(\tilde{Z}) \sim (0, W \otimes I_p) \end{cases} \quad (4)$$

↖

为使  $L(B, B, A) = \text{tr}(B^T X F X B)$  做相应的变换能化为简洁形式, 规定  $A, F$  满足以下条件:

$A = V \tilde{A} V$  记  $\tilde{A} = \text{diag}(a_1, a_2, \dots, a_p)$ ,  $a_i > 0$ ;  $F = U \tilde{F} U$ , 记  $\tilde{F} = \text{diag}(f_1, f_2, \dots, f_p, \dots, f_n)$ ,  $f_i > 0$ . 记  $F = \text{diag}(f_1, f_2, \dots, f_p)$ .

参数约束空间  $= \{B \mid \text{tr}(B^T X F X B)\} = \{R \mid \text{tr}(\tilde{R}^T \tilde{D} \tilde{F} \tilde{R})\} = \{R \mid \text{tr}(R^T D F R)\} =$

$$\{R \mid \sum_{i=1}^p \sum_{j=1}^q \tilde{r}_{ij}^2\} \quad \hat{\wedge} \quad .$$

损失函数  $L(B, B, A) = \text{tr}(\tilde{B}^T - B^T) A (\tilde{B}^T - B) = \text{tr}(\tilde{R}^T - R^T) \tilde{A} (\tilde{R}^T - R) = \sum_{j=1}^q (\tilde{r}_j^T - r_j^T) \tilde{A} (\tilde{r}_j^T - r_j^T) =$

$$\sum_{i=1}^p \sum_{j=1}^q a_i (\tilde{r}_{ij}^T - r_{ij}^T)^2 \stackrel{\hat{\wedge}}{=} L(R, R, \tilde{A}).$$

## 1 多元线性 Minimax 估计的求解

定理 1 将模型 (3) 写成元素形式为:  $z_{ij} = d_i r_{ij} + \epsilon_{ij}$ ;  $E \epsilon_{ij} = 0$ ,  $\text{cov}(\epsilon_{ij}, \epsilon_{kl}) = w_{jl} \delta_{ki}$ ;  $i = 1, 2, \dots, p$ ;  $j = 1, 2, \dots, q$

其中  $\xi_{ki} = \begin{cases} 1 & k = i \\ 0 & k \neq i \end{cases}$ ,  $\xi_{ij} = \{R \mid \sum_{i=1}^p \sum_{j=1}^q \tilde{r}_{ij}^2\}$  为约束空间,  $L(R, R, \tilde{A}) = \sum_{i=1}^p \sum_{j=1}^q a_i (\tilde{r}_{ij}^T - r_{ij}^T)^2$  为损失函数, 其中  $a_i > 0$ ,  $\tilde{f}_i > 0$  记  $c_i$  为  $C$  的第  $i$  个对角元.  $r_{ij}$  的线性 Minimax 估计为:  $\hat{r}_{ij} = c_i^* z_{ij}$ ,  $i, j = 1, 2, \dots, p$

若  $\tilde{f}_i > 0$ ,  $c_i^* = d_i^{-1} \left( 1 - h \left( \frac{\tilde{f}_i}{a_i} \right)^{\frac{1}{2}} \right)_+$ , 其中  $h$  由  $\sum_{i=1}^p \tilde{f}_i \left( \sum_{j=1}^q r_{ij}^2 \right)^* = 1$  决定,  $\left( \sum_{j=1}^q r_{ij}^2 \right)^* = \sum_{j=1}^q w_{jj} d_i^{-2} \left( \frac{1}{h} \left( \frac{a_i}{\tilde{f}_i} \right)^{\frac{1}{2}} - 1 \right)_+$ ; 若  $\tilde{f}_i = 0$ , 对第  $i$  个坐标方向无约束,  $c_i = \frac{1}{d_i}$ .

令  $\tilde{Z}$  表示所有  $p \times p$  阶矩阵组成的类,  $\tilde{Z} = (\tilde{z}_1, \tilde{z}_2, \dots, \tilde{z}_q)$ ,  $\tilde{z}_i = (z_{1i}, z_{2i}, \dots, z_{pi})$ , 则模型 (3) 的 Minimax 风险为:

$$\begin{aligned} \inf_C \sup_R \text{E} \text{tr}(\tilde{C} \tilde{Z} - R) \tilde{A} (\tilde{C} \tilde{Z} - R) &= \inf_{c_i \in R} \sup_{\tilde{Z}} E \sum_{i=1}^p \sum_{j=1}^q a_i (c_i z_{ij} - r_{ij})^2 = \\ \sup_R \sum_{i=1}^p \sum_{j=1}^q a_i (c_i^* z_{ij} - r_{ij})^2 &= \sum_{i=1}^p \sum_{j=1}^q w_{jj} a_i d_i^{-2} (1 - h \left( \frac{f_i}{a_i} \right)^{\frac{1}{2}})_+ \end{aligned}$$

证明 (1) 首先利用 Speckman 的讨论来证明使极大风险极小化的矩阵  $C$  是对角阵, 记  $C$  的  $(i, j)$  元为  $c_{ij}$

$$\begin{aligned} J(C) &= \sup_R \text{E} \text{tr}(\tilde{C} \tilde{Z} - R) \tilde{A} (\tilde{C} \tilde{Z} - R) = \\ &\sup_R \text{E} \text{tr}(\tilde{C} \tilde{Z} \tilde{A} \tilde{C} \tilde{Z} - R \tilde{A} \tilde{C} \tilde{Z} - R \tilde{C} \tilde{Z} + R^2) = \\ &\sup_R \text{E} \text{tr}(\tilde{C} \tilde{Z} \tilde{A} \tilde{C} \tilde{Z}) - \sup_R \text{E} \text{tr}(R \tilde{A} \tilde{C} \tilde{Z}) + \sup_R \text{E} \text{tr}(R^2) = \\ &\sup_{\tilde{Z}} \sum_{i,j=1}^q \{ \tilde{r}_j^T (CD - I_p) \tilde{A} (CD - I_p) \tilde{r}_j + w_{jj} \text{tr}(ACC) \} \end{aligned}$$

$$\text{记 } t_i = \frac{(c_{ii} d_i - 1)^2 a_i}{\tilde{f}_i}, \quad t_k = \max_{1 \leq i \leq p} t_i$$

$$\begin{aligned}
J(\text{diag}C) &= \sup_R \sum_{i=1}^p \sum_{j=1}^q a_i (c_{ii} d_i - 1)^2 r_{ij}^2 + \sum_{i=1}^p \sum_{j=1}^q w_{jj} a_i c_{ii}^2 = \\
&\quad \sup_R \sum_{i=1}^p \sum_{j=1}^q \tilde{f}_i t_k r_{ij}^2 + \sum_{i=1}^p \sum_{j=1}^q w_{jj} a_i c_{ii}^2 t_k + \sum_{i=1}^p \sum_{j=1}^q w_{jj} a_i c_{ii}^2 \\
\text{取 } R \text{ 满足: } i=k \text{ 时, } r_{ij} = 0 \text{ 则 } J(\text{diag}C) = \sup_R \sum_{j=1}^q (\tilde{f}_k t_k r_{kj}^2 + \sum_{i=1}^p \sum_{j=1}^q w_{jj} a_i c_{ii}^2) = t_k + \sum_{i=1}^p \sum_{j=1}^q w_{jj} a_i c_{ii}^2. \text{ 所以} \\
J_O(C) &\stackrel{\wedge}{=} \max_{1 \leq i \leq p} \left( \sum_{j=1}^q (c_{ii} d_i - 1)^2 a_i + \sum_{i=1}^p \sum_{j=1}^q w_{jj} a_i c_{ii}^2 \right) = J(\text{diag}C) \\
J(C) &= \sup_R \sum_{j=1}^q \left\{ r_j (CD - I_p) \tilde{A} (CD - I_p) r_j + w_{jj} \text{tr}(ACC) \right\} \\
&= \sup_R \sum_{i=1}^p \sum_{j=1}^q r_{ij}^2 e_i (CD - I_p) \tilde{A} (CD - I_p) e_i + \sum_{j=1}^q w_{jj} \sum_{i=1}^p a_i \sum_{l=1}^p c_{il}^2 \\
(\Leftrightarrow) \vartheta_i &= \frac{1}{\sum_{j=1}^q (a_i (c_{ii} d_i - 1)^2 + \sum_{j \neq i} a_i c_{ij}^2 d_j^2)} \vartheta_m = \max_{1 \leq i \leq p} \vartheta_i. \text{ 取 } R \text{ 满足: } i=m \text{ 时, } r_{ij} = 0 \\
&\quad \sup_R \sum_{j=1}^q \left\{ \sum_{m \neq i} \tilde{f}_m \vartheta_m r_{mj}^2 + w_{jj} \sum_{i=1}^p a_i \sum_{l=1}^p c_{il}^2 \right\} = \\
&\quad \max_{1 \leq i \leq p} \left[ \sum_{j \neq i} (a_i (c_{ii} d_i - 1)^2 + \sum_{j \neq i} a_i c_{ij}^2 d_j^2) \right] + \sum_{j=1}^q w_{jj} \sum_{i=1}^p a_i \sum_{l=1}^p c_{il}^2 = J_O(C)
\end{aligned}$$

当且仅当  $C$  为对角阵时等号成立. 因此使极大风险极小化的矩阵  $C$  是对角阵.

$$(2) E \sum_{j=1}^q (c_i z_{ij} - r_{ij})^2 = \sum_{j=1}^q \left\{ \text{var}(c_i z_{ij} - r_{ij}) + [E(c_i z_{ij} - r_{ij})]^2 \right\} = \sum_{j=1}^q c_i^2 w_{jj} + \sum_{j=1}^q r_{ij}^2 (d_i c_i - 1)^2$$

$$d_i \left( \sum_{j=1}^q r_{ij}^2 \right)$$

在  $c_i = \frac{1}{\sum_{j=1}^q (w_{jj} + d_i^2 r_{ij}^2)}$ ,  $i = 1, 2, \dots, p$  处取得最小值.

$$\text{记 } \hat{s}_i = \sum_{j=1}^q w_{jj}, s_i = \sum_{j=1}^q r_{ij}^2, \hat{d}_i = \sum_{j=1}^q (w_{jj} + d_i^2 r_{ij}^2) = + d_i^2 s_i, \sup_0 \inf_{c_i} \sum_{i=1}^p \sum_{j=1}^q a_i (c_i z_{ij} - r_{ij})^2 = \sup_R \sum_{i=1}^p \frac{a_i s_i}{i} =$$

2.

显然  $s_i$  越大,  $\sum_{i=1}^p \frac{a_i s_i}{i}$  越大, 在约束条件边界上达到. 利用 Lagrange 乘子法可求出  $s_i^*$ .

$$\text{对于 } h > 0, i = 1, 2, \dots, p, G(s_i, h) = \sum_{i=1}^p \frac{a_i s_i}{i} - h^2 \sum_{i=1}^p \tilde{f}_i s_i, \text{ 则 } \frac{\partial G(s_i, h)}{\partial s_i} = \frac{a_i}{i} - \frac{d_i^2 a_i s_i}{i^2} - h^2 \tilde{f}_i$$

$$\text{令 } \frac{\partial G(s_i, h)}{\partial s_i} = 0, \text{ 得 } (s_i)^* = d_i^{-2} \left( \frac{1}{h} \left( \frac{a_i}{\tilde{f}_i} \right)^{\frac{1}{2}} - 1 \right). \text{ 而 } \frac{\partial^2 G(s_i, h)}{\partial s_i^2} = - \frac{2 a_i d_i^2}{i^3}, \text{ 故当 } s_i = (s_i)^* \text{ 时,}$$

$\frac{\partial^2 G(s_i, h)}{\partial s_i^2} < 0$ , 所以  $s_i = (s_i)^*$  时,  $\frac{\partial G(s_i, h)}{\partial s_i} = 0$ , 可知  $G(s_i, h)$  在此范围内为减函数. 故  $s_i^* =$

$$d_i^{-2} \left( \frac{1}{h} \left( \frac{a_i}{\tilde{f}_i} \right)^{\frac{1}{2}} - 1 \right)_+ \text{ 时, 得 } s_i^* = \sum_{i=1}^p \sum_{j=1}^q w_{jj} a_i d_i^{-2} \left( 1 - h \left( \frac{\tilde{f}_i}{a_i} \right)^{\frac{1}{2}} \right)_+, \text{ 其中 } h \text{ 由 } \sum_{i=1}^p \tilde{f}_i s_i^* = \text{ 决定.}$$

将  $s_i^*$  代入 (\*) 得  $c_i^* = d_i^{-1} \left( 1 - h \left( \frac{\tilde{f}_i}{a_i} \right)^{\frac{1}{2}} \right)_+$ , 则:

$$\sup_R E \sum_{i=1}^p \sum_{j=1}^q a_i (c_i z_{ij} - r_{ij})^2 = \inf_{c_i} \sup_R E \sum_{i=1}^p \sum_{j=1}^q a_i (c_i z_{ij} - r_{ij})^2 = \sup_R \inf_{c_i} E \sum_{i=1}^p \sum_{j=1}^q a_i (c_i z_{ij} - r_{ij})^2 = s_i^*$$

当  $c_i = c_i^*$ ,  $i = 1, 2, \dots, p$  时上面不等式仍成立. 而

$$\sup_R E \sum_{i=1}^p \sum_{j=1}^q a_i (c_i^* z_{ij} - r_{ij})^2 = \sup_R \sum_{i=1}^p \sum_{j=1}^q r_{ij}^2 ((h^2 \tilde{f}_i - a_i) + \sum_{i=1}^p \sum_{j=1}^q w_{jj} a_i d_i^{-2} \left( 1 - h \left( \frac{\tilde{f}_i}{a_i} \right)^{\frac{1}{2}} \right)_+)$$

$$h^2 + \sum_{i=1}^p \sum_{j=1}^q w_{ij} a_i d_i^{-2} \left[ 1 - h \left( \frac{\tilde{f}_i}{a_i} \right)^{\frac{1}{2}} \right]_+^2 = h^2 \sum_{i=1}^p \sum_{j=1}^q w_{ij} \tilde{f}_i d_i^{-2} \left[ \frac{1}{h} \left( \frac{a_i}{\tilde{f}_i} \right)^{\frac{1}{2}} - 1 \right]_+^2 + \\ \sum_{i=1}^p \sum_{j=1}^q w_{ij} a_i d_i^{-2} \left[ 1 - h \left( \frac{\tilde{f}_i}{a_i} \right)^{\frac{1}{2}} \right]_+^2 = \sum_{i=1}^p \sum_{j=1}^q w_{ij} a_i d_i^{-2} \left[ 1 - h \left( \frac{\tilde{f}_i}{a_i} \right)^{\frac{1}{2}} \right]_+^2 =$$

由上面的不等式及证明中的(1)部分可知:

$$R \sup_O E \sum_{i=1}^p \sum_{j=1}^q a_i (c_i^* z_{ij} - r_{ij})^2 = R \sup_O E \sum_{i=1}^p \sum_{j=1}^q a_i (c_i z_{ij} - r_{ij})^2 = R \sup_O \text{Etr}(CZ - R) \tilde{A}(CZ - R)$$

由定义 1 知  $\hat{R}_M = C^* Z$  为  $R$  的 Minimax 估计. 其中  $C^* = \text{diag}(c_1^*, c_2^*, \dots, c_p^*)$ .

**定理 2** 对于多元线性回归模型 (1),  $B = \{B / \text{tr}(B X F X B)\}$ ,  $A, F$  满足条件 1, 则  $B$  的线性

Minimax 估计为  $\hat{B}_M = (I - h(X F X)^{-\frac{1}{2}} A^{-\frac{1}{2}})_+ \hat{B}_{LS}$ . 其中  $h$  满足:  $\text{tr}W \cdot \text{tr}\{(X X)^{-1} (h^{-1} A^{\frac{1}{2}} (X F X)^{\frac{1}{2}} - X F X)_+\}$

$$= \sum_{i=1}^p \sum_{j=1}^q w_{ij}^{-1} (h^{-1} (a_i \tilde{f}_{i-1})^{\frac{1}{2}} - \tilde{f}_{i-1})_+ = .$$

线性 Minimax 估计的风险为:  $\inf_S \sup_B E\{\text{tr}(S Y - B) A(S Y - B)\} = \sup_B E\{\text{tr}(\hat{B}_M - B) A(\hat{B}_M - B)\} = \text{tr}W \cdot \text{tr}\{(X X)^{-1} (A - h A^{\frac{1}{2}} (X F X)^{\frac{1}{2}})_+\}$ .

其中 表示任意的  $p \times n$  阶矩阵组成的类.

**证明** 由第一节知  $Z = U Y, \tilde{D} = U X V, R = V B, A = \tilde{V} A \tilde{V}, F = \tilde{U} F U$ . 则

$$\tilde{A}^{\frac{1}{2}} = V A^{\frac{1}{2}} V, (\tilde{D} \tilde{F} D)^{\frac{1}{2}} = V (X F X)^{\frac{1}{2}} V$$

由定理 1 知  $\hat{R}_{M,ij} = c_i^* z_{ij} = d_i^{-1} \left[ 1 - h \left( \frac{\tilde{f}_i}{a_i} \right)^{\frac{1}{2}} \right]_+ z_{ij}, i=1, 2, \dots, p, j=1, 2, \dots, q$  写成矩阵形式为:

$$\hat{R}_M = (I - h(\tilde{D} \tilde{F} D)^{\frac{1}{2}} A^{-\frac{1}{2}})_+ (\tilde{D} \tilde{D})^{-1} \tilde{D} Z = (I - h(\tilde{D} \tilde{F} D)^{\frac{1}{2}} A^{-\frac{1}{2}})_+ (\tilde{D} \tilde{D})^{-1} \tilde{D} Z = \\ V (I - h(X F X)^{\frac{1}{2}} A^{-\frac{1}{2}})_+ (X X)^{-1} X Y = V \hat{B}_M$$

所以  $\hat{B}_M = (I - h(X F X)^{\frac{1}{2}} A^{-\frac{1}{2}})_+ \hat{B}_{LS}$ ,  $h$  满足

$$= \sum_{i=1}^p \tilde{i} f_i \left( \sum_{j=1}^q r_{ij}^2 \right)^* = \sum_{i=1}^p \sum_{j=1}^q w_{ij}^{-1} (h^{-1} (a_i \tilde{f}_{i-1})^{\frac{1}{2}} - \tilde{f}_{i-1})_+ = \\ \text{tr}W \cdot \text{tr}\{(\tilde{D} \tilde{D})^{-1} (h^{-1} \tilde{A}^{\frac{1}{2}} (\tilde{D} \tilde{F} D)^{\frac{1}{2}} - \tilde{D} \tilde{F} D)_+\} = \\ \text{tr}W \cdot \text{tr}\{(X X)^{-1} (h^{-1} A^{\frac{1}{2}} (X F X)^{\frac{1}{2}} - X F X)_+\}$$

下面证明  $\hat{B}_M$  为  $B$  的线性 Minimax 估计:

$\hat{R}_M$  为  $R$  的线性 Minimax 估计, 由定义 1 知  $\sup_O \text{Etr}(\hat{R}_M - R) \tilde{A}(\hat{R}_M - R) = \sup_O \text{Etr}(\hat{R} - R) \tilde{A}(\hat{R} - R)$ .  $\hat{R}$

为  $R$  的任意估计. 而  $\text{Etr}(\hat{B} - B) A(\hat{B} - B) = \text{Etr}(\hat{R} - R) \tilde{A}(\hat{R} - R)$ ,  $\hat{B}$  为  $B$  的任意估计.  $\text{Etr}(\hat{B}_M - B) A(\hat{B}_M - B) = \text{Etr}(\hat{R}_M - R) \tilde{A}(\hat{R}_M - R)$ , 所以  $\sup_B \text{Etr}(\hat{B}_M - B) \tilde{A}(\hat{B}_M - B) = \sup_B \text{Etr}(\hat{B} - B) \tilde{A}(\hat{B} - B)$ .

由定义 1 知  $\hat{B}_M$  为  $B$  的线性 Minimax 估计. 由定理 1 知  $\hat{R}_M$  的 Minimax 风险为:

$$\inf_R \sup_O \text{Etr}(CZ - R) \tilde{A}(CZ - R) = \sum_{i=1}^p \sum_{j=1}^q w_{ij} a_i d_i^{-2} \left[ 1 - h \left( \frac{\tilde{f}_i}{a_i} \right)^{\frac{1}{2}} \right]_+ = \\ \text{tr}W \cdot \text{tr}\{(\tilde{D} \tilde{D})^{-1} (A - h A^{\frac{1}{2}} (\tilde{D} \tilde{F} D)^{\frac{1}{2}})_+\} = \\ \text{tr}W \cdot \text{tr}\{(X X)^{-1} (A - h A^{\frac{1}{2}} (X F X)^{\frac{1}{2}})_+\}$$

由  $\sup_B \text{Etr}(\hat{B}_M - B) \tilde{A}(\hat{B}_M - B) = \sup_O \text{Etr}(\hat{R}_M - R) \tilde{A}(\hat{R}_M - R)$ , 所以线性 Minimax 估计的风险为:

$$\inf_S \sup_B \text{Etr}(SY - B) A(SY - B) = \sup_B \text{Etr}(\hat{B}_M - B) \tilde{A}(\hat{B}_M - B) =$$

$$\text{tr}W + \text{tr}\{(X^T X)^{-1}(A - hA^{\frac{1}{2}}(X^T F X)^{\frac{1}{2}})_+\}.$$

当设计阵  $X = I$  (此时  $n = p$ ),  $A = I$  时, 有如下定理:

**定理 3** 对于多元标准线性模型:  $\begin{cases} Y = B + E \\ \text{vec}(E) \sim (0, W \otimes I) \end{cases}$ ,  $B = \{B \mid \text{tr}(B^T F B) \leq 0\}$ , 损失函数为  $L(B, B, A) = \text{tr}(\hat{B} - B)^2 (\hat{B} - B)$ . 对于任意的满足  $T \geq 0$  和  $(I - T) \geq 0$  的  $n$  阶方阵  $T$ , 若  $F = (I - T)^2$ ,  $\hat{B} = \text{tr}W / \text{tr}T - \text{tr}T^2$ , 则  $\hat{B}$  为  $B$  的线性 Minimax 估计.

**证明** 对  $T$  进行谱分解  $T = P^T P$ ,  $P = \text{diag}(1, 2, \dots, n)$ ,  $1 \leq i \leq 1$ ,  $i = 1, 2, \dots, p$  则:

$$F = (I - T)^2 = P(1 - \lambda_i^2)^2 P. \text{ 所以 } \hat{f}_i = (1 - \lambda_i^2)^2, \hat{B} = \sum_{i=1}^n \sum_{j=1}^q w_{ij} (\lambda_i^2 - \lambda_i^{-2}) = \sum_{i=1}^n \sum_{j=1}^q w_{ij} (\hat{f}_i^{\frac{1}{2}} - \hat{f}_i).$$

由定理 2 知  $h = 1$ ,  $SY = (1 - F^2)^{\frac{1}{2}} \hat{B}_{LS} = \hat{B}$  为  $B$  的线性 Minimax 估计, 极大化风险为:  $\text{tr}W + \text{tr}T$ .

这个定理说明: 对于特征根在  $[0, 1]$  之间的任意  $n$  阶对称阵  $T$ ,  $\hat{B} = \hat{B}$  使  $\max\{\text{Etr}(\hat{B} - B)^2 | \hat{B} \in B\}$  达到最小. 其中  $B$  为  $B$  的所有估计组成的类, 又因为  $\text{Etr}(\hat{B} - B)^2 | \hat{B} \in B = \text{tr}\{B^T (T - I)^2 B\} + \text{tr}W + \text{tr}T^2$ , 所以可以写成  $= \{B : \text{Etr}(\hat{B} - B)^2 | \hat{B} \in B\} = \text{tr}W + \text{tr}T$ .

## 2 多元线性 Minimax 估计的性质及特例

记  $\hat{B}_M = \text{vec}(\hat{B}_M)$ ,  $\hat{B}_{LS} = \text{vec}(\hat{B}_{LS})$ . 则  $\hat{B}_M = (I \otimes (I - h(X^T F X)^{\frac{1}{2}} A^{\frac{1}{2}})_+)^{\frac{1}{2}} \hat{B}_{LS}$ . 容易得到如下几条性质:

**性质 1**  $\hat{B}_M = (I \otimes (I - h(X^T F X)^{\frac{1}{2}} A^{\frac{1}{2}})_+)^{\frac{1}{2}}$ ,  $\hat{B}_{LS}$  为  $B$  的压缩有偏估计, 即  $\hat{E}_M < \hat{B}_{LS}$ .

**性质 2** 若  $W > 0$ ,  $\hat{B}_M$  是  $B$  的可容许估计.

**特例 1** 当  $A = X^T X$ ,  $F = I$  时,  $\hat{B}_M = (1 - h)\hat{B}_{LS}$ ,  $h = \frac{p \sum_{j=1}^q w_{jj}}{p \sum_{j=1}^q w_{jj} + p}$ , 此时  $\hat{B}_M$  也为多元 Stein 估计. 其 Minimax 风险为:  $\sup_{t \in B} \text{Etr}(XB_M^T - XB)^2 (XB_M^T - XB) = \frac{p \sum_{j=1}^q w_{jj}}{p \sum_{j=1}^q w_{jj} + p}$ . 进一步, 若  $p = p^*$  则  $\liminf_{p \rightarrow p^*} \sup_{t \in B} \text{Etr}(CY - B)^2 X^T X (CY - B) =$

$$\lim_{p \rightarrow p^*} \sup_{t \in B} \frac{p^{-1} \text{Etr}(XB_M^T - XB)^2 (XB_M^T - XB)}{p^{-1} + \sum_{j=1}^q w_{jj}}.$$

当  $p = p^*$  时,  $C$  变为任意的可测矩阵, 此时求得 Minimax 估计称为渐近 Minimax 估计.

**特例 2** 当  $A = X^T X$ ,  $F = U \text{diag}(-1, -2, \dots, -p+1, f_{p+1}, \dots, f_n) U$ ,  $f_i$  为任意非负数,  $i = p+1, \dots, n$  则  $X^T F X = I$ . 此种情况下  $\hat{B}_M = (I - h(X^T X)^{\frac{1}{2}})_+ \hat{B}_{LS}$ ,  $h$  满足  $\sum_{i=1}^p \sum_{j=1}^q w_{ij} (-i^{-1} (h^{-1} - i^{\frac{1}{2}})^{-1})_+ = 0$ , 此时  $\hat{B}_M$  也为多元岭估计, 其 Minimax 风险为:  $\sup_{t \in B} \text{Etr}(XB_M^T - XB)^2 (XB_M^T - XB) = \sum_{i=1}^p \sum_{j=1}^q w_{ij} (1 - h^{-1} i^{\frac{1}{2}})_+$ .

**特例 3** 当  $A = X^T X$ ,  $X^T F X = (X^T X)^{\frac{1}{2}}$  时, 此时  $\hat{B}_M = (I - h(X^T X)^{\frac{1}{2}})_+ \hat{B}_{LS}$ ,  $h$  满足  $\sum_{i=1}^p \sum_{j=1}^q w_{ij} (-i^{-1} (h^{-1} - 1)_+ = 0$ , 此时  $\hat{B}_M$  也为多元功效岭估计, 其 Minimax 风险为:  $\sup_{t \in B} \text{Etr}(XB_M^T - XB)^2 (XB_M^T - XB) = \sum_{i=1}^p \sum_{j=1}^q w_{ij} (1 - h^{-1} i^{\frac{1}{2}})_+$ .

(下转第 525 页)

# Optimal sufficient conditions of a class of multiobjective programming about $B$ -preinvex function

**ZHANG Qimao**

(College of Mathematics and Computer Science, Chongqing Normal University, Chongqing 400047, China)

**Abstract:** Under the assumption of  $B$ -preinvex function, this paper studies a class of multi-objective programming problems, and obtains Kuhn-Tucker sufficient optimality conditions

**Key words:** multiobject programming; optimal conditions;  $B$ -preinvex function; efficient solution; weakly efficient solution

责任编辑 :李翠薇

(上接第 521 页 )

**参考文献 :**

- [1] BLAKER H. Minimax estimation in linear regression under restrictions [J]. Journal of Statistical Planning and Inference, 2000, 90: 35-55
- [2] FRANK I E, FRIEDMAN J H. A Statistical view of some chemometrics regression tool (with discussion) [J]. Technometrics, 1993, 35: 109-148
- [3] 朱道元. 多元统计分析及 SASS 软件 [M]. 上海:东南大学出版社, 1998

## Minimax estimation in multivariate linear regression model under restrictions

**WANG L ifeng<sup>1</sup> ZHU Dao-yuan<sup>2</sup>**

(1. Department of Social Science Nanjing Institute of Railway Technology, Nanjing 210015;

2. Department of Mathematics, Southeast University, Nanjing 210096, China)

**Abstract:** In this paper, a multivariate Minimax estimation in all linear estimators under the loss function  $\text{tr}(\hat{B} - B)^T \hat{A} (\hat{B} - B)$  is derived. We consider its properties. In special case, the multivariate Minimax estimation includes power Ridge regression, Stein's estimator and so on.

**Key words:** multivariate linear regression model; multivariate linear Minimax estimation; multivariate Ridge regression estimation

责任编辑 :罗泽举