

多元线性模型回归系数的压缩LS估计*

陈世基 曾志斌

(福州 福建师范大学数学系) (福州 福建省统计局)
(林宗池推荐, 1993年1月4日收到)

摘 要

本文采用压缩LS估计 $\hat{B}(k)$ 来估计设计矩阵呈病态的多元线性模型的回归系数 B 。通过 k 值的选取, 可使 $\hat{B}(k) = \text{Vec}(\hat{B}(k))$ 的均方误差 MSE 小于 $\beta = \text{Vec}(B)$ 的 LS 估计 β^* 的 MSE 。证明了 $\hat{B}(k)$ 具有可容许性、抗干扰性和有效性, 并给出了实际应用中选取 k 值的方法。

关键词 多元线性模型 最小二乘估计 压缩LS估计 均方误差

一、引 言

多元线性模型

$$Y = XB + \varepsilon \quad \left. \vphantom{Y = XB + \varepsilon} \right\} \quad (1.1)$$

ε 的行向量互不相关, 均值为零, 有共同协方差阵 V

这里, $Y = (y_{ij})_{n \times q} = (y_1, y_2, \dots, y_q)$ 为 $n \times q$ 的随机观测矩阵, X 为 $n \times p$ 的设计矩阵, $R(X) = p$, $B = (\beta_{ij})_{p \times q} = (\beta_1, \beta_2, \dots, \beta_q)$ 为 $p \times q$ 的未知参数矩阵, $\varepsilon = (\varepsilon_{ij})_{n \times q} = (\varepsilon_1, \varepsilon_2, \dots, \varepsilon_q)$ 为 $n \times q$ 的随机误差矩阵, $V = (v_{ij})_{q \times q}$ 为 $q \times q$ 的未知正定矩阵。

易知模型(1.1)的典则形式为

$$Y = ZA + \varepsilon \quad \left. \vphantom{Y = ZA + \varepsilon} \right\} \quad (1.2)$$

ε 的行向量互不相关, 均值为零, 有共同协方差阵 V

这里, $Z = XQ$, $A = Q'B$, Q 为 $p \times p$ 正交矩阵, 使得 $Q'X'XQ = A = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_p)$, 称 A 为典则参数矩阵。于是模型(1.1), (1.2)可分别化成如下的一元线性模型

$$\left. \begin{aligned} \text{Vec}(Y) &= (I_q \otimes X) \text{Vec}(B) + \text{Vec}(\varepsilon) \\ \text{Cov}(\text{Vec}(\varepsilon)) &= V \otimes I_n, E(\text{Vec}(\varepsilon)) = 0 \end{aligned} \right\} \quad (1.1)'$$

$$\left. \begin{aligned} \text{Vec}(Y) &= (I_q \otimes Z) \text{Vec}(A) + \text{Vec}(\varepsilon) \\ \text{Cov}(\text{Vec}(\varepsilon)) &= V \otimes I_n, E(\text{Vec}(\varepsilon)) = 0 \end{aligned} \right\} \quad (1.2)'$$

记 $\beta = \text{Vec}(B)$, $a = \text{Vec}(A) = (I_q \otimes Q') \text{Vec}(B)$, 称 a 为典则参数。易得 B 和 A 的LS估计分别为

* 福建省自然科学基金资助项目

$$B^* = (X'X)^{-1}X'Y \quad (1.3)$$

$$A^* = A^{-1}Z'Y \quad (1.4)$$

相应地, β 和 α 的LS估计分别为

$$\beta^* = \text{Vec}(B^*) = [I_q \otimes (X'X)^{-1}X'] \text{Vec}(Y) \quad (1.3)'$$

$$\alpha^* = \text{Vec}(A^*) = (I_q \otimes A^{-1}Z') \text{Vec}(Y) \quad (1.4)'$$

且 $E(\beta^*) = \beta$, $\text{Cov}(\beta^*) = V \otimes (X'X)^{-1}$, 此时 β^* 的均方误差为

$$\text{MSE}(\beta^*) = (\text{tr}V) \sum_{i=1}^p \lambda_i^{-1} \quad (1.5)$$

这里 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p$ 为 $X'X$ 的特征根, 因为 $X'X > 0$, 所以 $\lambda_i > 0$, $i = 1, 2, \dots, p$.

从(1.5)可知, 若 $X'X$ 至少有一特征根很小, 则 $\text{MSE}(\beta^*)$ 就很大, 此时虽然LS估计 β^* 的方差在线性无偏估计类中最小, 但其值很大, 使得估计精度较差, 表现出相当的不稳定. 文[1]指出 $X'X$ 有多少个特征根接近于零, 回归自变量之间就存在多少个近似的线性关系. 文[1]称之为复共线性, 此时称设计矩阵 X 呈病态, 可见导致LS估计的性质变坏之原因是复共线性的存在. 为改进LS估计, [2]、[3]分别提出了多元广义岭估计和多元根方估计. 本文引入压缩LS估计 $\hat{B}(k)$, 给出了 $\hat{\beta}(k) = \text{Vec}(\hat{B}(k))$ 优于 β^* 的充要条件并讨论了 $\hat{\beta}(k)$ 的一些统计优良性质.

二、压缩LS估计的定义及其优于LS估计的充要条件

定义1 若存在 $1 \leq r < p$ 使 $\lambda_{r+1} < 1 \leq \lambda_r$, 记

$$K = \text{diag}\left(\frac{\lambda_1 - 1 + k}{\lambda_1}, \dots, \frac{\lambda_r - 1 + k}{\lambda_r}, k\lambda_{r+1}, \dots, k\lambda_p\right) \quad (2.1)$$

这里 $k \in [\lambda_p, 1)$ 为常数, 则称

$$\hat{B}(k) = QKQ'B^* \quad (2.2)$$

为模型(1.1)回归系数 B 的压缩LS估计.

由于 $X'X = QAQ'$, 所以从(2.2)即可得到

$$\hat{B}(k) = QKQ'(X'X)^{-1}X'Y = QKA^{-1}Q'X'Y = (QK^{-1}AQ')^{-1}X'Y$$

与LS估计 B^* 比较, 压缩LS估计是把 $X'X = QAQ'$ 换成 $QK^{-1}AQ'$ 而得到的. 直观上这样做的理由是明显的. 当 X 呈病态时, $X'X$ 的特征根至少有一个非常接近于零, 而 $QK^{-1}AQ'$ 的特征根为

$$\frac{\lambda_1^2}{\lambda_1 - 1 + k}, \frac{\lambda_2^2}{\lambda_2 - 1 + k}, \dots, \frac{\lambda_r^2}{\lambda_r - 1 + k}, k^{-1}, \dots, k^{-1}$$

它们都不小于1, 从而“打破”原来设计矩阵的复共线性, 达到降低估计量的均方误差之目的. 对于不同的 k , (2.2)给出了不同的估计, 可见压缩LS估计是一个很大的估计类. 从(2.1)可以看出, k 保证了 K 的对角元不至于在 $\lambda = 1$ 处出现跳跃, 这对于估计的稳定性是必要的, 于是通常把定义1中的 k 称为平稳参数.

记 $\hat{\beta}(k) = \text{Vec}(\hat{B}(k)) = (I_q \otimes QKQ')\beta^*$, 为了叙述上的方便, 也把 $\hat{\beta}(k)$ 称为 $\beta = \text{Vec}(B)$ 的压缩LS估计.

定理1 $\hat{\beta}(k)$ 是 β 的压缩有偏估计.

$$\text{证明 } \|\hat{\beta}(k)\|^2 = \|(I_q \otimes Q)(I_q \otimes K)(I_q \otimes Q')\beta^*\|^2 = \|(I_q \otimes K)(I_q \otimes Q')\beta^*\|^2 \\ < \|(I_q \otimes Q')\beta^*\|^2 = \|\beta^*\|^2$$

$$E(\hat{\beta}(k)) = (I_q \otimes QKQ')\beta \neq \beta, \quad (\beta \neq 0)$$

否则 $QKQ' = I_q$, 即 $K = I_q$, 这与(2.1)矛盾, 所以 $\hat{\beta}(k)$ 是 β 的压缩型有偏估计.

引理1 若 $D > 0, d > 0$, 则 $dD - xx' > 0$ 的充要条件是 $x'D^{-1}x < d$, 这里 D 为 m 阶矩阵, d 为实数, x 为 $m \times 1$ 向量.

证明 依给定的条件有

$$\begin{pmatrix} I & 0 \\ -x'D^{-1} & 1 \end{pmatrix} \begin{pmatrix} D & x \\ x' & d \end{pmatrix} \begin{pmatrix} I & -D^{-1}x \\ 0 & 1 \end{pmatrix} = \begin{pmatrix} D & 0 \\ 0 & d - x'D^{-1}x \end{pmatrix}$$

$$\begin{pmatrix} I & -d^{-1}x \\ 0 & 1 \end{pmatrix} \begin{pmatrix} D & x \\ x' & d \end{pmatrix} \begin{pmatrix} I & 0 \\ -d^{-1}x' & 1 \end{pmatrix} = \begin{pmatrix} D - d^{-1}xx' & 0 \\ 0 & d \end{pmatrix}$$

$$\text{所以 } \begin{pmatrix} D & 0 \\ 0 & d - x'D^{-1}x \end{pmatrix} \text{ 与 } \begin{pmatrix} D - d^{-1}xx' & 0 \\ 0 & d \end{pmatrix} \text{ 合同}$$

由于 D 为正定矩阵, d 为正实数, 所以

$$\begin{pmatrix} D & 0 \\ 0 & d - x'D^{-1}x \end{pmatrix}$$

正定的充要条件是 $d - x'D^{-1}x > 0$.

$$\begin{pmatrix} D - d^{-1}xx' & 0 \\ 0 & d \end{pmatrix}$$

正定的充要条件是 $D - d^{-1}xx' > 0$. 于是 $dD - xx' > 0$ 的充要条件是 $x'D^{-1}x < d$.

定理2 $\text{MSEM}(\hat{\beta}(k)) < \text{MSEM}(\beta^*)$ 的充要条件是 $\beta'R\beta < 1$. 这里 $\text{MSEM}(\hat{\beta}(k)), \text{MSEM}(\beta^*)$ 分别为 $\hat{\beta}(k)$ 和 β^* 的均方误差矩阵, $R = V^{-1} \otimes QKQ'$,

$$C = \text{diag}\left(\frac{\lambda_1 - k\lambda_1}{2\lambda_1 - 1 + k}, \dots, \frac{\lambda_r - k\lambda_r}{2\lambda_r - 1 + k}, \frac{\lambda_{r+1} - k\lambda_{r+1}^2}{1 + k\lambda_{r+1}}, \dots, \frac{\lambda_p - k\lambda_p^2}{1 + k\lambda_p}\right)$$

证明 令 $G = I_q \otimes QKQ'$, 则 $\hat{\beta}(k) = G\beta^*$, 依[4]有

$$\begin{aligned} \text{MSEM}(\hat{\beta}(k)) &= \text{Cov}(G\beta^*) + [E(G\beta^*) - \beta][E(G\beta^*) - \beta]' \\ &= G[V \otimes (X'X)^{-1}]G' + (G - I_q)\beta\beta'(G - I_q)' \\ &= V \otimes QKA^{-1}KQ' + [I_q \otimes Q(K - I_q)Q'] \\ &\quad \cdot \beta\beta'[I_q \otimes (K - I_q)Q'] \end{aligned}$$

于是

$$\begin{aligned} \text{MSEM}(\beta^*) - \text{MSEM}(\hat{\beta}(k)) &= V \otimes (X'X)^{-1} - V \otimes QKA^{-1}KQ' - [I_q \otimes Q(K - I_q)Q']\beta\beta'[I_q \otimes Q(K - I_q)Q'] \\ &= V \otimes Q(A^{-1} - KA^{-1}K)Q' - [I_q \otimes Q(K - I_q)Q']\beta\beta'[I_q \otimes Q(K - I_q)Q'] \\ &= V \otimes Q\Delta_1Q' - (I_q \otimes Q\Delta_2Q')\beta\beta'(I_q \otimes Q\Delta_2Q') \end{aligned}$$

这里

$$\Delta_1 = A^{-1} - KA^{-1}K = \text{diag}\left(\frac{2(1-k)}{\lambda_1^2} - \frac{(1-k)^2}{\lambda_1^3}, \dots, \frac{2(1-k)}{\lambda_r^2} - \frac{(1-k)^2}{\lambda_r^3}, \frac{1-k^2\lambda_{r+1}^2}{\lambda_{r+1}}, \dots, \frac{1-k^2\lambda_p^2}{\lambda_p}\right)$$

$$\Delta_2 = I_r - K = \text{diag}\left(\frac{1-k}{\lambda_1}, \dots, \frac{1-k}{\lambda_r}, 1-k\lambda_{r+1}, \dots, 1-k\lambda_p\right)$$

依引理1, $V \otimes Q \Delta_1 Q' - (I_q \otimes Q \Delta_2 Q') \beta \beta' (I_q \otimes Q \Delta_2 Q') > 0$ 的充要条件是

$$\beta' (I_q \otimes Q \Delta_2 Q') (V \otimes Q \Delta_1 Q')^{-1} (I_q \otimes Q \Delta_2 Q') \beta < 1$$

即 $\beta' (V^{-1} \otimes Q \Delta_2 \Delta_1^{-1} \Delta_2 Q') \beta < 1$

记

$$C = \Delta_2 \Delta_1^{-1} \Delta_2 = \text{diag}\left(\frac{\lambda_1 - k\lambda_1}{2\lambda_1 - 1 + k}, \dots, \frac{\lambda_r - k\lambda_r}{2\lambda_r - 1 + k}, \frac{\lambda_{r+1} - k\lambda_{r+1}^2}{1 + k\lambda_{r+1}}, \dots, \frac{\lambda_p - k\lambda_p^2}{1 + k\lambda_p}\right) \quad (2.3)$$

$$R = V^{-1} \otimes Q C Q' \quad (2.4)$$

因此, $\text{MSEM}(\beta^*) - \text{MSEM}(\hat{\beta}(k)) > 0$ 的充要条件是:

$$\beta' R \beta < 1 \quad (2.5)$$

根据[4]可得如下的推论

推论1 当且仅当 $\beta' R \beta < 1$ 时, 有

$$\text{MSE}(\hat{\beta}(k)) < \text{MSE}(\beta^*)$$

三、压缩LS估计的性质

3.1 可容许性

定理3 在线性估计类中, $\hat{\beta}(k)$ 是 β 的可容许估计.

证明 令 $G = I_q \otimes Q K Q'$, $W = (I_q \otimes X') (V \otimes I_n)^{-1} (I_q \otimes X) = V^{-1} \otimes X' X$ 则

$$\begin{aligned} & GW^{-1} - GW^{-1}G' \\ &= (I_q \otimes Q K Q') [V \otimes (X' X)^{-1}] - (I_q \otimes Q K Q') [V \otimes (X' X)^{-1}] (I_q \otimes Q K Q') \\ &= V \otimes Q K Q' (X' X)^{-1} - V \otimes Q K Q' (X' X)^{-1} Q K Q' \\ &= V \otimes Q K A^{-1} Q' - V \otimes Q K A^{-1} K Q' \\ &= (I_q \otimes Q) [V \otimes (K A^{-1} - K A^{-1} K)] (I_q \otimes Q') \end{aligned}$$

由于

$$K A^{-1} - K A^{-1} K = \text{diag}\left(\frac{(\lambda_1 - 1 + k)(1 - k)}{\lambda_1^3}, \dots, \frac{(\lambda_r - 1 + k)(1 - k)}{\lambda_r^3}, \right.$$

$$\left. k(1 - k\lambda_{r+1}), \dots, k(1 - k\lambda_p)\right) \geq 0$$

且 $V > 0$, 所以 $GW^{-1} - GW^{-1}G' \geq 0$. 依[4]则 $\hat{\beta}(k)$ 是 β 的可容许估计.

3.2 抗干扰性

定义2 对于矩阵 N , 称由 $\|N\| = \sqrt{\lambda_{\max}(N'N)}$ 定义的范数 $\|\cdot\|$ 为 N 的谱范数, 其中 $\lambda_{\max}(N'N)$ 为 $N'N$ 的最大特征根.

由定义2可得, 当 N 为非负定矩阵时, 则有 $\|N\| = \lambda_{\max}(N)$.

定义3 对于估计 $\hat{\beta} = H\beta^*$, 若 H 可逆且模型(1.1)的设计矩阵 X 列满秩, 则称

$$\text{cond}(\hat{\beta}) = \|H^{-1}(I_q \otimes X'X)\| \cdot \|H(I_q \otimes X'X)^{-1}\|$$

为估计 $\hat{\beta}$ 的条件数.

由于 $\hat{\beta}(k) = (I_q \otimes QKQ')\beta^*$, $X'X = QAQ'$, 所以

$$\text{cond}(\hat{\beta}(k)) = \|I_q \otimes QK^{-1}AQ'\| \|I_q \otimes QKA^{-1}Q'\| = \|I_q \otimes K^{-1}A\| \|I_q \otimes KA^{-1}\|$$

同理

$$\text{cond}(\beta^*) = \|I_q \otimes X'X\| \|(I_q \otimes X'X)^{-1}\| = \|I_q \otimes A\| \|I_q \otimes A^{-1}\| = \lambda_1/\lambda_r$$

模型(1.1)'的正则方程为

$$(I_q \otimes X')(V \otimes I_n)^{-1}(I_q \otimes X)\beta = (I_q \otimes X')(V \otimes I_n)^{-1}\text{Vec}(Y) \quad (3.1)$$

由于 $V > 0$, 所以方程(3.1)可化为

$$(I_q \otimes X'X)\beta = (I_q \otimes X')\text{Vec}(Y) \quad (3.2)$$

依[5], 当 $\text{cond}(I_q \otimes X'X) \|\Delta(I_q \otimes X'X)\| \|I_q \otimes X'X\|^{-1} < 1$ 时

必有

$$\frac{\|\Delta\beta\|}{\|\beta\|} \leq \frac{\text{cond}(I_q \otimes X'X)}{1 - \text{cond}(I_q \otimes X'X) \|\Delta(I_q \otimes X'X)\| \|I_q \otimes X'X\|^{-1}} \left[\frac{\|\Delta(I_q \otimes X'X)\|}{\|I_q \otimes X'X\|} + \frac{\|\Delta((I_q \otimes X')\text{Vec}(Y))\|}{\|(I_q \otimes X')\text{Vec}(Y)\|} \right]$$

这里 $\frac{\|\Delta\beta\|}{\|\beta\|}$, $\frac{\|\Delta(I_q \otimes X'X)\|}{\|I_q \otimes X'X\|}$, $\frac{\|\Delta((I_q \otimes X')\text{Vec}(Y))\|}{\|(I_q \otimes X')\text{Vec}(Y)\|}$

分别表示 β , $I_q \otimes X'X$, $(I_q \otimes X')\text{Vec}(Y)$ 的相对误差.

由于 $\text{cond}(I_q \otimes X'X) = \text{cond}(\beta^*)$, 所以 β^* 的条件数反映了 β^* 抗干扰的程度, 于是自然希望新估计 $\bar{\beta}$ 既能改进 LS 估计, 同时又不降低 $\bar{\beta}$ 的抗干扰能力, 这就得要求 $\text{cond}(\bar{\beta}) \leq \text{cond}(\beta^*)$. 通常称满足这个条件的估计 $\bar{\beta}$ 具有相对于 β^* 更强的抗干扰性.

定理4 对线性模型(1.1)', 总有 $\text{cond}(\hat{\beta}(k)) \leq \text{cond}(\beta^*)$, 即压缩LS估计改进了LS估计的抗干扰性.

证明 由于

$$\|I_q \otimes K^{-1}A\| = \max\left(\frac{\lambda_1^2}{\lambda_1^{-1} + k}, \dots, \frac{\lambda_r^2}{\lambda_r^{-1} + k}, k^{-1}\right) \leq \lambda_1 k^{-1} \leq \frac{\lambda_1}{\lambda_r}$$

$$\|I_q \otimes KA^{-1}\| = \max\left(\frac{\lambda_1^{-1} + k}{\lambda_1^2}, \dots, \frac{\lambda_r^{-1} + k}{\lambda_r^2}, k\right) \leq 1$$

所以 $\text{cond}(\hat{\beta}(k)) = \|I_q \otimes K^{-1}A\| \|I_q \otimes KA^{-1}\| \leq \lambda_1/\lambda_r = \text{cond}(\beta^*)$

即 $\hat{\beta}(k)$ 具有相对于 β^* 更强的抗干扰性.

3.3 有效性

讨论一个估计量的优劣通常是以它的均方误差来衡量的. 推论1已指出, 在MSE意义下, $\hat{\beta}(k)$ 优于 β^* , 也可以用相对效率(简称效率)来衡量一个估计量的优劣. 对于一元线性模型回归系数的无偏估计, [6]、[7]给出了两种不同形式的相对效率. 对于本文所讨论的有偏估计, 笔者引入如下的效率:

定义4 对于模型(1.1)', 若 $\bar{\beta}$ 为 β 的线性有偏估计, 则称

$$\rho(\bar{\beta}) = 1 - \frac{\text{MSE}(\bar{\beta})}{\text{MSE}(\beta^*)} \quad (3.3)$$

为 $\bar{\beta}$ 相对于 β^* 的效率。

若 $\text{MSE}(\bar{\beta}) \leq \text{MSE}(\beta^*)$, 则 $\bar{\beta}$ 的效率不小于零, 因此 $0 \leq \rho(\bar{\beta}) \leq 1$. 效率越是接近于 1, $\bar{\beta}$ 改进 β^* 的程度就越高. 下面的定理将给出压缩 LS 估计 $\hat{\beta}(k)$ 相对于 LS 估计 β^* 的效率的下界.

定理5 当 $\lambda_p [1 + (\text{tr}V)^{-1}a'a] \leq 1$ 时, 有

$$\rho(\hat{\beta}(k)) \geq \frac{1 - \lambda_p - \lambda_p (\text{tr}V)^{-1}a'a}{1 + \lambda_p(p-1)} \quad (3.4)$$

证明 依定义 1, 模型 (1.2)' 的回归系数 α 的压缩 LS 估计为 $\hat{\alpha}(k) = (I_q \otimes K)\alpha^*$, 且 $\hat{\beta}(k) = (I_q \otimes Q)\hat{\alpha}(k)$, 则

$$\begin{aligned} \text{MSE}(\hat{\beta}(k)) &= \text{MSE}(\hat{\alpha}(k)) = \text{trCov}(\hat{\alpha}(k)) + \|E(\hat{\alpha}(k)) - \alpha\|^2 \\ &= \text{tr}(V \otimes KA^{-1}K) + a'[I_q \otimes (K - I_p)]^2 a \end{aligned}$$

又 $\text{MSE}(\beta^*) = \text{MSE}(\alpha^*) = \text{tr}(V \otimes A^{-1})$, 于是

$$\begin{aligned} \rho(\hat{\beta}(k)) &= 1 - \frac{\text{MSE}(\hat{\beta}(k))}{\text{MSE}(\beta^*)} \\ &= 1 - \frac{\text{tr}V \text{tr}(KA^{-1}K) + a'[I_q \otimes (K - I_p)]^2 a}{\text{tr}V \cdot \text{tr}A^{-1}} \\ &\geq 1 - \frac{\text{tr}V \cdot \text{tr}(KA^{-1}) + a'a}{\text{tr}V \cdot \text{tr}A^{-1}} \\ &= 1 - \frac{\sum_{i=1}^p (\lambda_i - 1 + k)\lambda_i^{-2} + (p-r)k + (\text{tr}V)^{-1}a'a}{\sum_{i=1}^p \lambda_i^{-1}} \\ &\geq 1 - \frac{\sum_{i=1}^p \lambda_i^{-1} + (p-r) + (\text{tr}V)^{-1}a'a}{\sum_{i=1}^p \lambda_i^{-1} + (p-r) + \lambda_p^{-1} - 1} \end{aligned}$$

由于当 $a_1 \leq a_2$ 时, $(x+a_1)/(x+a_2)$ 是 $x(x > -a_2)$ 的增函数, 而由已知条件有 $(\text{tr}V)^{-1}a'a \leq \lambda_p^{-1} - 1$, 所以

$$\rho(\hat{\beta}(k)) \geq 1 - \frac{r + (p-r) + (\text{tr}V)^{-1}a'a}{r + (p-r) + \lambda_p^{-1} - 1} = \frac{1 - \lambda_p - \lambda_p (\text{tr}V)^{-1}a'a}{1 + \lambda_p(p-1)}$$

可见, 当设计矩阵 X 呈病态 (即 λ_p 很小) 且使 $\lambda_p (\text{tr}V)^{-1}a'a$ 相对较小时, $\rho(\hat{\beta}(k))$ 可以很接近于 1, 也就是说 $\hat{\beta}(k)$ 可以很好地改进 β^* , 且 $\rho(\hat{\beta}(k))$ 的下界与参数 k 无关. 然而 $\rho(\hat{\beta}(k))$ 的下界含有 a 和 V , 这会给应用带来不便, 对于存在较多个复共线关系的大型回归问题, 将可以避免这点, 且 $\hat{\beta}(k)$ 相对于 β^* 的效率可以达到很高.

定理6 若 $\lambda_{p-m} = \lambda_{p-m+1} = \dots = \lambda_p \approx 0$, $0 \leq m \leq p-r-1$, 则在椭球 (2.5) 内, 必有

$$\rho(\hat{\beta}(k)) \geq \frac{m(1 - k^2 \lambda_p^2)}{(p-m-1)\lambda_p + m + 1} \approx \frac{m}{m+1} \left(1 - \frac{p-m-1}{m+1} \lambda_p\right) \quad (3.5)$$

证明 首先证明在椭球 (2.5) 内有

$$\alpha' [I_q \otimes (K - I_p)^2] \alpha \leq \frac{\mu(1 - k^2 \lambda_p^2)}{\lambda_p} \quad (3.6)$$

其中 μ 为 V 的最大特征根, 即 $\mu = \lambda_{\max}(V)$. 由 $\alpha = (I_q \otimes Q')\beta$ 及 (2.3)、(2.4) 可知 (2.5) 与

$$\alpha' [V^{-1} \otimes (K - I_p)^2 (I_p - K^2)^{-1} A] \alpha < 1 \quad (3.7)$$

等价. 由于 $\lambda \geq 1$ 时,

$$\frac{\lambda^3}{2\lambda - 2k\lambda - (1-k)^2}$$

为 λ 的增函数, 所以

$$\frac{\lambda^3}{2\lambda - 2k\lambda - (1-k)^2} \geq \frac{1}{1-k^2}$$

又当 $\lambda_p \leq \lambda \leq 1$ 时, $\lambda/(1-k^2\lambda)$ 为 λ 的单调递增函数. 于是

$$\frac{\lambda_p}{1-k^2\lambda_p^2} \leq \frac{\lambda}{1-k^2\lambda} \leq \frac{1}{1-k^2}$$

由此可得

$$(I_p - K^2)^{-1} A = \text{diag} \left(\frac{\lambda_1^3}{2\lambda_1 - 2k\lambda_1 - (1-k)^2}, \dots, \frac{\lambda_r^3}{2\lambda_r - 2k\lambda_r - (1-k)^2}, \right. \\ \left. \frac{\lambda_{r+1}}{1-k^2\lambda_{r+1}^2}, \dots, \frac{\lambda_p}{1-k^2\lambda_p^2} \right) \geq \frac{\lambda_p}{1-k^2\lambda_p^2} I_p$$

又 $V \leq \mu I_q$, 即 $V^{-1} \geq \mu^{-1} I_q$, 所以

$$V^{-1} \otimes (I_p - K^2)^{-1} A \geq \frac{\lambda_p}{\mu(1-k^2\lambda_p^2)} \cdot (I_q \otimes I_p)$$

结合 (3.7) 式即可得到不等式 (3.6).

现在来证明 (3.5) 式, 利用不等式 (3.6) 及 $\mu^{-1} \text{tr} V \leq 1$, 则

$$\begin{aligned} \rho(\hat{\beta}(k)) &= 1 - \frac{\text{tr} V \cdot \text{tr}(KA^{-1}K) + \alpha' [I_q \otimes (K - I_p)^2] \alpha}{\text{tr} V \cdot \text{tr} A^{-1}} \\ &\geq 1 - \frac{\text{tr} V \cdot \text{tr}(KA^{-1}K) + \lambda_p^{-1} \mu (1 - k^2 \lambda_p^2)}{\text{tr} V \cdot \text{tr} A^{-1}} \\ &= 1 - \frac{\text{tr}(KA^{-1}K) + (\text{tr} V)^{-1} \mu \cdot \lambda_p^{-1} (1 - k^2 \lambda_p^2)}{\text{tr} A^{-1}} \\ &\geq 1 - \frac{\text{tr}(KA^{-1}K) + \lambda_p^{-1} (1 - k^2 \lambda_p^2)}{\text{tr} A^{-1}} \\ &= 1 - \frac{\sum_{i=1}^r (\lambda_i - 1 + k)^2 \lambda_i^{-3} + k^2 \lambda_{r+1} + \dots + k^2 \lambda_{p-m-1} + mk^2 \lambda_p + \lambda_p^{-1}}{\sum_{i=1}^r \lambda_i^{-1} + \lambda_{r+1}^{-1} + \dots + \lambda_{p-m-1}^{-1} + (m+1) \lambda_p^{-1}} \end{aligned}$$

$$\begin{aligned}
&\geq 1 - \frac{\sum_{i=1}^p \lambda_i^{-1} + (p-m-r-1) + mk^2\lambda_p - \lambda_p^{-1}}{\sum_{i=1}^p \lambda_i^{-1} + (p-m-r-1) + (m+1)\lambda_p^{-1}} \\
&\geq 1 - \frac{p-m-1 + mk^2\lambda_p + \lambda_p^{-1}}{p-m-1 + (m+1)\lambda_p^{-1}} \\
&= \frac{m(1-k^2\lambda_p^2)}{(p-m-1)\lambda_p + (m+1)} \\
&\approx \frac{m}{m+1} \cdot \frac{1 - [(p-m-1)/(m+1)]^2 \lambda_p^2}{1 + [(p-m-1)/(m+1)] \lambda_p} \\
&= \frac{m}{m+1} \left(1 - \frac{p-m-1}{m+1} \lambda_p \right)
\end{aligned}$$

四、平稳参数k的确定

从定理2及推论1知,当k满足(2.5)式时, $\hat{\beta}(k)$ 优于 β^* . 但(2.5)与未知参数 β , V 有关,实际应用中还必须通过实际数据来确定,此时 $\hat{\beta}(k)$ 实际上是一种非线性估计.

$$\text{令 } C_0 = \text{diag} \left(\frac{\lambda_1 - k\lambda_1}{\sqrt{2\lambda_1 - 1}}, \dots, \frac{\lambda_r - k\lambda_r}{2\lambda_r - 1}, \lambda_{r+1} - k\lambda_{r+1}^2, \dots, \lambda_p - k\lambda_p^2 \right)$$

v 为 V 的最小特征根,即 $v = \lambda_{\min}(V)$, 则 $C < C_0$, $V^{-1} \leq v^{-1}I_q$. 由于(2.5)与 $a'(V^{-1} \otimes C)a < 1$ 等价,所以 $\text{MSE}(\hat{\beta}(k)) < \text{MSE}(\beta)^*$ 成立的一个充分条件是

$$a'(I_q \otimes C_0)a \leq v \tag{4.1}$$

$$\text{由于 } V^* = \frac{1}{n-p} Y' [I - X(X'X)^{-1}X'] Y$$

为 V 的无偏估计,

$$a^* = (I_q \otimes A^{-1}Z') \text{Vec}(Y)$$

为 a 的LS估计,所以以 a^* 及 $v^* = \lambda_{\min}(V^*)$ 代替(4.1)中的 a 及 v , 即

$$a^{*'}(I_q \otimes C_0)a^* \leq v^* \tag{4.2}$$

从(4.2)可以得到 k 必须满足 $k \geq k^*$. 于是 k 的估计值可取为

$$k = \begin{cases} \lambda_p, & k^* \leq \lambda_p \\ k^*, & \lambda_p < k^* < 1 \\ 1, & k^* \geq 1 \end{cases}$$

至于选取 k 值的其它方法及各种方法之间的比较,尚有待于进一步的探讨.

参 考 文 献

- [1] 陈希孺、王松桂,《近代回归分析——原理、方法及其应用》,安徽教育出版社,合肥(1987).
- [2] 曾志斌,多元广义岭估计及 K 值选取的 $Q(C)$ 准则,福建师范大学学报(自然科学版),6(4)(1990),25—33.
- [3] 曾志斌,多元线性模型回归系数的根方估计,福建师范大学学报(自然科学版),7(3)(1991),35—40.

- [4] 王松桂, 《线性模型的理论及其应用》, 安徽教育出版社, 合肥 (1987).
- [5] 孙维广, 《矩阵扰动分析》, 科学出版社, 北京 (1987).
- [6] Bloomfield, P. and G. S. Waston, The efficiency of least squares, *Biometrika*, 62 (1975), 121—128.
- [7] 刘爱义、王松桂, 线性模型中LS估计的一种新的相对效率, 应用概率统计, 5(2) (1987), 97—104.
- [8] Arnold, S. F., *Theory of Linear Models and Multivariate Analysis*, John Wiley, New York (1981).
- [9] 杨虎, 单参数主成分回归估计, 高校应用数学学报, 4(1) (1989), 74—80.

The Compression LS Estimate of Regression Coefficient in Multivariate Linear Model

Chen Shi-ji

(*Department of Mathematics, Fujian Normal University, Fuzhou*)

Zeng Zhi-bin

(*Statistics Bureau of Fujian Province, Fuzhou*)

Abstract

In this paper, compression LS estimate $\hat{B}(k)$ of the regression coefficient B is considered when the design matrix present ill-condition in multivariate linear model. The MSE (mean square error) of the estimate $\hat{\beta}(k) = \text{Vec}(\hat{B}(k))$ is less than the MSE of LS estimate β^* of the regression coefficient $\beta = \text{Vec}(B)$ by choosing the parameter k . Admissibility, numerical stability and relative efficiency of $\hat{\beta}(k)$ are proved. The method of determining k value for practical use is also suggested.

Key words multivariate linear model, least square estimate, compression LS estimate, mean square error