

多元广义岭估计及K值选取的Q(c)准则*

陈世基 曾志斌

(福建师范大学数学系, 1991年10月18日收到)

摘 要

当自变量间存在复共线性时, 最小二乘估计就表现出不稳定并可能导致错误的结果. 本文采用广义岭估计 $\beta(K)$ 来估计多元线性模型的回归系数 $\beta = \text{vec}(B)$, 通过岭参数 K 值的选取, 可使广义岭估计的均方误差 MSE 小于最小二乘估计的 MSE. 指出了广义岭估计中根据 MSE 准则选取 K 值存在的主要缺陷, 采用了一种选取 K 值的新准则 $Q(c)$, 它包含 MSE 准则和最小二乘 LS 准则作为特例, 从理论上证明和讨论了 $Q(c)$ 准则的优良性, 阐明了 c 值的统计含义, 并给出了确定 c 值的方法.

关键词 最小二乘估计 广义岭估计 均方误差

一、引 言

我们考虑 q 个因变量的 n 个观测值 Y , 假设它满足标准的多元线性回归模型

$$Y = XB + \varepsilon \quad (1.1)$$

其中 X 为列满秩的 $n \times p$ 的已知矩阵, B 为待估的 $p \times q$ 的未知系数矩阵, 记 $\varepsilon = (\varepsilon_1, \varepsilon_2, \dots, \varepsilon_q)$, 通常的假设是

$$E(\varepsilon_j) = 0, \text{cov}(\varepsilon_j, \varepsilon_l) = v_{jl} I_n \quad (j, l = 1, 2, \dots, q)$$

这里, $V = (v_{jl}) > 0$ 表示 $q \times q$ 的正定矩阵.

当 $q=1$ 时, 模型(1.1)为一元线性回归模型

$$y = X\beta_1 + e, E(e) = 0, \text{cov}(e) = \sigma^2 I_n \quad (1.2)$$

这里 y 为 $n \times 1$ 的观测向量, β_1 为 $p \times 1$ 的未知参数向量, e 为 $n \times 1$ 的随机误差向量, $\sigma^2 > 0$ 为误差方差.

容易得到, 模型(1.1)的典则形式为

$$Y = ZA + \varepsilon \quad (1.3)$$

这里 $Z = XQ$, $A = Q'B$, Q 为 $p \times p$ 的正交矩阵, 它使得

$$Q'X'XQ = A = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_p),$$

* 福建省自然科学基金资助项目.
林宗池推荐.

$\lambda_i (i=1, 2, \dots, p)$ 为矩阵 $X'X$ 的特征根, 并称 A 为典则参数矩阵.

模型(1.1)和(1.3)可分别化成如下的一元线性回归模型

$$\left. \begin{aligned} \text{vec}(Y) &= (I_q \otimes X) \text{vec}(B) + \text{vec}(\varepsilon), \\ E(\text{vec}(\varepsilon)) &= 0 \\ \text{cov}(\text{vec}(\varepsilon)) &= V \otimes I_n \end{aligned} \right\} \quad (1.4)$$

$$\left. \begin{aligned} \text{vec}(Y) &= (I_q \otimes Z) \text{vec}(A) + \text{vec}(\varepsilon) \\ E(\text{vec}(\varepsilon)) &= 0 \\ \text{cov}(\text{vec}(\varepsilon)) &= V \otimes I_n \end{aligned} \right\} \quad (1.5)$$

令 $\beta = \text{vec}(B)$, $\alpha = \text{vec}(A)$, 则 $\alpha = (I_q \otimes Q')\beta$, 称 α 为典则参数向量.

很容易地可以得到, B 和 A 的LS估计分别为

$$B^* = (X'X)^{-1}X'Y \quad (1.6)$$

$$\text{和} \quad A^* = (Z'Z)^{-1}Z'Y = A^{-1}Z'Y \quad (1.7)$$

β 和 α 相应的LS估计分别为

$$\beta^* = [I_q \otimes (X'X)^{-1}X'] \text{vec}(Y) \quad (1.8)$$

$$\text{和} \quad \alpha^* = (I_q \otimes A^{-1}Z') \text{vec}(Y) \quad (1.9)$$

且 $\beta^* = (I_q \otimes Q')\alpha^*$, $E(\beta^*) = \beta$, $\text{cov}(\beta^*) = V \otimes (X'X)^{-1}$.

通过直接计算, β^* 的均方误差为

$$\text{MSE}(\beta^*) = (\text{tr}V) \sum_{i=1}^p \lambda_i^{-1} \quad (1.10)$$

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(1.10)式可知, 若 $X'X$ 至少有一特征根很小, 即接近于零, 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, 使得估计量表现出相当的不稳定. [1]提出, $X'X$ 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, 此时回归自变量之间存在复共线性, 并称设计矩阵 X 呈“病态”. 为克服LS估计存在的缺陷, 本文将讨论模型(1.1)回归系数的广义岭估计, 得到广义岭估计的主要性质, 并应用选取 K 值的 $Q(c)$ 准则对广义岭估计作了进一步的探讨.

二、广义岭估计及其性质

因为对一切的 β 都有 $E\|\beta^*\|^2 > \|\beta\|^2$, 所以从平均的角度来看LS估计 β^* 总是偏长, 因此有必要对 β^* 进行压缩.

模型(1.1)回归系数 B 的广义岭估计定义为

$$B^*(K) = (X'X + QKQ')^{-1}X'Y \quad (2.1)$$

其中 Q 为正交矩阵, 使得 $Q'X'XQ = A = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_p)$, $K = \text{diag}(k_1, k_2, \dots, k_p)$ ($k_i \geq 0, i=1, 2, \dots, p$), 称 $k_i (i=1, 2, \dots, p)$ 为广义岭参数. 当 $K = kI_p$ 时, 则(2.1)式化成 $B^*(k) = (X'X + kI_p)^{-1}X'Y$, 即为 B 的狭义岭估计; 当 $K = 0$ 时, (2.1)即为 B 的LS估计; 若 $q=1$, 则(2.1)即为模型(1.2)回归系数 β_i 的广义岭估计.

记 $\beta^*(K) = \text{vec}(B^*(K))$. 为了叙述上的方便, 也把 $\beta^*(K)$ 称为 $\beta = \text{vec}(B)$ 的广义岭估计. 从(2.1)式立即得到

$$\beta^*(K) = [I_q \otimes (X'X + QKQ')^{-1}] (I_q \otimes X'X) \beta^* \quad (2.1)'$$

定理2.1 当 $K > 0$ 时, $\beta^*(K)$ 是 β 的压缩型有偏估计.

$$\begin{aligned} \text{证明} \quad \text{因为 } \beta^*(K) &= [I_q \otimes (X'X + QKQ')^{-1}] (I_q \otimes X'X) \beta^* \\ &= (I_q \otimes Q) [I_q \otimes (A + K)^{-1}] (I_q \otimes A) (I_q \otimes Q') \beta^* \end{aligned}$$

$$\begin{aligned} \text{所以} \quad \|\beta^*(K)\|^2 &= \|[I_q \otimes (A + K)^{-1} A] (I_q \otimes Q') \beta^*\|^2 \\ &< \|(I_q \otimes Q) \beta^*\|^2 = \|\beta^*\|^2 \end{aligned}$$

可见, $\beta^*(K)$ 是 LS 估计 β^* 向原点压缩而得到的.

$$\text{又} \quad E(\beta^*(K)) = [I_q \otimes (X'X + QKQ')^{-1}] (I_q \otimes X'X) \beta \neq \beta,$$

否则必得到

$$I_q \otimes X'X = I_q \otimes (X'X + QKQ')$$

这说明 $K = 0$, 与 $K > 0$ 矛盾, 因此 $\beta^*(K)$ 是 β 的压缩型有偏估计.

根据 (2.1)' 式, α 的广义岭估计为

$$\alpha^*(K) = [I_q \otimes (A + K)^{-1} A] \alpha^* \quad (2.2)$$

$$\text{且} \quad \beta^*(K) = (I_q \otimes Q) \alpha^*(K) \quad (2.3)$$

定理2.2 $\beta^*(K)$ 的均方误差为

$$\text{MSE}(\beta^*(K)) = \sum_{i=1}^p \sum_{j=1}^q \frac{\lambda_i v_{jj} + k_i^2 \alpha_{ij}^2}{(\lambda_i + k_i)^2} \quad (2.4)$$

这里 α_{ij} 为 $A = Q'B$ 的元素, v_{jj} 为 V 主对角线上的元素.

证明 根据 (2.3) 式, $\beta^*(K)$ 的均方误差为

$$\text{MSE}(\beta^*(K)) = \text{MSE}(\alpha^*(K)) = \text{tr cov}(\alpha^*(K)) + \|E\alpha^*(K) - \alpha\|^2$$

$$\text{因为 } E\alpha^*(K) = [I_q \otimes (A + K)^{-1} A] \alpha$$

$$\begin{aligned} \text{cov}(\alpha^*(K)) &= [I_q \otimes (A + K)^{-1} A] (V \otimes A^{-1}) [I_q \otimes A (A + K)^{-1}] \\ &= V \otimes (A + K)^{-1} A (A + K)^{-1} \end{aligned}$$

$$\text{所以 } \text{tr cov}(\alpha^*(K)) = \text{tr}[V \otimes (A + K)^{-1} A (A + K)^{-1}]$$

$$= \left(\sum_{i=1}^q v_{jj} \right) \left[\sum_{i=1}^p \frac{\lambda_i}{(\lambda_i + k_i)^2} \right]$$

$$\|E\alpha^*(K) - \alpha\|^2 = \alpha' [I_q \otimes (A + K)^{-2} K^2] \alpha$$

$$= \sum_{i=1}^p \sum_{j=1}^q \left(\frac{k_i \alpha_{ij}}{\lambda_i + k_i} \right)^2$$

于是得到 (2.4) 式.

定理2.3 若 $0 < k_i < k_i^*$ ($i = 1, 2, \dots, p$), 则

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

$$\text{这里} \quad k_i^* = (\text{tr} V) / \sum_{j=1}^q \alpha_{ij}^2 \quad (i = 1, 2, \dots, p) \quad (2.5)$$

证明 由定理2.2有

$$\frac{\partial \text{MSE}(\beta^*(K))}{\partial k_i} = -2\lambda_i (\lambda_i + k_i)^{-3} \left(\text{tr} V - k_i \sum_{j=1}^q \alpha_{ij}^2 \right)$$

令 $k_i^* = (\text{tr}V) / \sum_{j=1}^q \alpha_{ij}^2$, ($i=1, 2, \dots, p$), 得

$$\frac{\partial \text{MSE}(\beta^*(K))}{\partial k_i} \begin{cases} > 0 & (\text{当 } k_i > k_i^*) \\ = 0 & (\text{当 } k_i = k_i^*) \\ < 0 & (\text{当 } k_i < k_i^*) \end{cases}$$

所以当 $0 < k_i < k_i^*$, 必有

$$\text{MSE}(\beta^*(K)) < \text{MSE}(\beta^*(0)) = \text{MSE}(\beta^*).$$

记 $K^* = \text{diag}(k_1^*, k_2^*, \dots, k_p^*)$, 则从定理2.3的证明过程可知, $\text{MSE}(\beta^*(K))$ 在 $K = K^*$ 达到最小值, 其最小值为

$$\min_{K \geq 0} \text{MSE}(\beta^*(K)) = \text{MSE}(\beta^*(K^*)) = (\text{tr}V) \sum_{i=1}^p \frac{\alpha_{i.}^2}{\lambda_i \alpha_{i.}^2 + \text{tr}V}.$$

其中 $\alpha_{i.}^2 = \sum_{j=1}^q \alpha_{ij}^2$ ($i=1, 2, \dots, p$).

定理2.4 $\beta^*(K)$ 是 β 的可容许估计.

证明 令 $C = I_q \otimes (X'X + QKQ')^{-1} X'X$,

$$W = (I_q \otimes X')(V^{-1} \otimes I_n)(I_q \otimes X) = V^{-1} \otimes X'X,$$

则有 $CW^{-1} - CW^{-1}C' = [I_q \otimes (X'X + QKQ')^{-1} X'X][V \otimes (X'X)^{-1}]$

$$\begin{aligned} & - [I_q \otimes (X'X + QKQ')^{-1} X'X][V \otimes (X'X)^{-1}][I_q \otimes X'X(X'X + QKQ')^{-1}] \\ & = V \otimes (X'X + QKQ')^{-1} - V \otimes (X'X + QKQ')^{-1} X'X(X'X + QKQ')^{-1} \\ & = V \otimes (X'X + QKQ')^{-1} QKQ'(X'X + QKQ')^{-1} \end{aligned}$$

因为 $V > 0$, $K \geq 0$, 且 Q 为正交矩阵, 使得

$$Q'X'XQ = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_p),$$

所以 $(X'X + QKQ')^{-1} QKQ'(X'X + QKQ')^{-1} \geq 0$

于是 $CW^{-1} - CW^{-1}C' = V \otimes (X'X + QKQ')^{-1} QKQ'(X'X + QKQ')^{-1} \geq 0$.

根据[2]的推论1.7.2, 得知 $\beta^*(K) = C\beta^*$ 为 β 的可容许估计.

定理2.3说明了 $\beta^*(K)$ 比 β^* 有较小的均方误差. 但(2.5)式与未知参数 α 和 V 有关, 所以我们必须通过观测到的数据来确定它们, 这样就导致非线性估计.

因为 $V^* = (n-p)^{-1} Y'[I - X(X'X)^{-1} X']Y$ 为 V 的无偏估计, $\alpha^* = (I_q \otimes A^{-1} Z') \text{vec}(Y)$ 为 $\alpha = \text{vec}(A)$ 的LS估计, 所以一种自然的作法是在(2.5)式中以 V^* 及 α_{ij}^* 代替 V 及 α_{ij} , 得到 k_i^* 的估计.

$$\hat{k}_i^* = \text{tr}(V^*) / \sum_{j=1}^q \alpha_{ij}^{*2} \quad (i=1, 2, \dots, p) \quad (2.6)$$

也可采用 Hemmerle-Brantle 方法来估计 k_i^* , 即

$$\hat{k}_i^* = \frac{\text{tr}(V^*)}{\sum_{j=1}^q \alpha_{ij}^{*2} - \lambda_i^{-1} \text{tr}(V^*)} \quad (i=1, 2, \dots, p) \quad (2.7)$$

当 $\sum_{j=1}^q \alpha_{ij}^{*2} - \lambda_i^{-1} \text{tr}(V^*) \leq 0$ 时, 取 $k_i^* = +\infty (i=1, 2, \dots, p)$.

事实上, $\sum_{j=1}^q \alpha_{ij}^2$ 的无偏估计为

$$\sum_{j=1}^q \hat{\alpha}_{ij}^2 = \sum_{j=1}^q \alpha_{ij}^{*2} - \lambda_i^{-1} \text{tr}(V^*)$$

这是因为

$$E(\alpha_{ij}^{*2}) = \text{Var}(\alpha_{ij}^*) + (E\alpha_{ij}^*)^2 = \lambda_i^{-1} v_{jj} + \alpha_{ij}^2,$$

$$E(v_{jj}^*) = v_{jj} \quad (i=1, 2, \dots, p, j=1, 2, \dots, q)$$

所以

$$E(\alpha_{ij}^{*2} - \lambda_i^{-1} v_{jj}^*) = \alpha_{ij}^2,$$

因此

$$E\left(\sum_{j=1}^q \alpha_{ij}^{*2} - \lambda_i^{-1} \text{tr}(V^*)\right) = \sum_{j=1}^q \alpha_{ij}^2 \quad (i=1, 2, \dots, p)$$

最后, 在(2.5)式中分别以 V 和 $\sum_{j=1}^q \alpha_{ij}^2$ 的无偏估计 V^* 和 $\sum_{j=1}^q \hat{\alpha}_{ij}^2$ 代替 V 和 $\sum_{j=1}^q \alpha_{ij}^2$ 就得到 (2.7) 式.

三、选取K值的Q(c)准则

1. 广义岭估计均方残差的性质和根据MSE 准则选取K值存在的主要缺陷

比较LS估计 β^* 和广义岭估计 $\beta^*(K) (K > 0)$, 我们可以发现它们有两个主要区别

第一, β^* 不含未知参数, 它可直接由数据估计出来, 但 $\beta^*(K)$ 的表达式(2.1)中含有参数 K , 它需要通过数据来估计.

第二, 两者的优化准则不同, β^* 是基于LS准则 (即, 最小二乘准则) 得到的最佳线性无偏估计, 而 $\beta^*(K)$ 中选取 K 值通常总是基于MSE的减少 (MSE准则是要使 $\text{MSE}(\beta^*(K))$ 达到最小). $\beta^*(K)$ 是有偏估计, 它在减少 MSE 的同时, 势必要增大对模型拟合的均方残差.

定理3.1 对 $\beta^*(K)$ 的均方残差

$$\text{MSR}(\beta^*(K)) = E \|\text{vec}(Y) - (I_q \otimes X)\beta^*(K)\|^2$$

必成立着

$$\text{MSR}(\beta^*(K)) = \text{MSR}(\beta^*) + \Delta \text{MSR}(\beta^*(K))$$

这里 $\text{MSR}(\beta^*) = E \|\text{vec}(Y) - (I_q \otimes X)\beta^*\|^2 = (n-p) \text{tr}V$ 为LS估计 β^* 的均方残差, $\Delta \text{MSR}(\beta^*(K)) = E \|(I_q \otimes X)\beta^*(K) - (I_q \otimes X)\beta^*\|^2$ 为 $\beta^*(K)$ 对 β^* 的修正所引起的MSR增量, 且

$$\Delta \text{MSR}(\beta^*(K)) = \sum_{i=1}^p \sum_{j=1}^q \frac{(v_{jj} + \lambda_i \alpha_{ij}^2) k_i^2}{(\lambda_i + k_i)^2} \quad (3.1)$$

证明 $\text{MSR}(\beta^*(K)) = E \|\text{vec}(Y) - (I_q \otimes X)\beta^*(K)\|^2$

$$\begin{aligned}
&= E \|\text{vec}(Y) - (I_q \otimes X)\beta^* + (I_q \otimes X)\beta^* - (I_q \otimes X)\beta^*(K)\|^2 \\
&= E \|\text{vec}(Y) - (I_q \otimes X)\beta^*\|^2 + E \|(I_q \otimes X)\beta^* - (I_q \otimes X)\beta^*(K)\|^2 \\
&= \text{MSR}(\beta^*) + \Delta \text{MSR}(\beta^*(K)),
\end{aligned}$$

这里 $\min_{K \geq 0} \text{MSR}(\beta^*(K)) = \text{MSR}(\beta^*(0)) = \text{MSR}(\beta^*) = (n-p) \text{tr}V$.

根据[2]的定理2.3.1, 有

$$\begin{aligned}
\Delta \text{MSR}(\beta^*(K)) &= E \|(I_q \otimes X)\beta^*(K) - (I_q \otimes X)\beta^*\|^2 \\
&= E \|(I_q \otimes Z)\alpha^*(K) - (I_q \otimes Z)\alpha^*\|^2 \\
&= E \|[(I_q \otimes Z)(I_q \otimes (A+K)^{-1}A) - (I_q \otimes Z)] \alpha^*\|^2 \\
&= E \|(I_q \otimes Z)[I_q \otimes (A+K)^{-1}K] \alpha^*\|^2 \\
&= \text{tr}\{ [I_q \otimes (A+K)^{-2}K^2A] \text{cov}(\alpha^*) \} + \alpha' [I_q \otimes (A+K)^{-2}K^2A] \alpha \\
&= \text{tr}\{ V \otimes (A+K)^{-2}K^2 \} + \alpha' [I_q \otimes (A+K)^{-2}K^2A] \alpha \\
&= \sum_{i=1}^p \sum_{j=1}^q \frac{k_i^2 v_{jj}}{(\lambda_i + k_i)^2} + \sum_{i=1}^p \sum_{j=1}^q \frac{\lambda_i k_i^2 \alpha_{ij}^2}{(\lambda_i + k_i)^2} \\
&= \sum_{i=1}^p \sum_{j=1}^q \frac{(v_{jj} - \lambda_i \alpha_{ij}^2) k_i^2}{(\lambda_i + k_i)^2}.
\end{aligned}$$

这样, 要讨论 $\beta^*(K)$ 的 MSR, 只需讨论 $\Delta \text{MSR}(\beta^*(K))$ 即可.

当 $k=0$ 时,

$$\Delta \text{MSR}(\beta^*(K)) = 0,$$

当 $k_i \rightarrow +\infty (i=1, 2, \dots, p)$ 时,

$$\Delta \text{MSR}(\beta^*(K)) \rightarrow p \text{tr}V + \sum_{i=1}^p \sum_{j=1}^q \lambda_i \alpha_{ij}^2$$

当 $K > 0$ 时,

$$\frac{\partial [\Delta \text{MSR}(\beta^*(K))]}{\partial k_i} = \frac{2\lambda_i (v_{jj} + \lambda_i \alpha_{ij}^2) k_i}{(\lambda_i + k_i)^3} > 0 \quad (i=1, 2, \dots, p)$$

这说明 $\Delta \text{MSR}(\beta^*(K))$ 关于 k_i 单调递增 ($i=1, 2, \dots, p$).

对模型(1.4)中 $\beta = \text{vec}(B)$ 的广义岭估计类

$$\mathcal{S} = \{ \beta^*(K) : K = \text{diag}(k_1, k_2, \dots, k_p) \geq 0 \}$$

关于均方误差和均方残差有如下的主要结果:

$$\max_{K \geq 0} \text{MSE}(\beta^*(K)) = \max \left\{ (\text{tr}V) \sum_{i=1}^p \lambda_i^{-1}, \sum_{i=1}^p \sum_{j=1}^q \alpha_{ij}^2 \right\}$$

$$\min_{K \geq 0} \text{MSE}(\beta^*(K)) = (\text{tr}V) \sum_{i=1}^p \frac{\alpha_{ij}^2}{\lambda_i \alpha_{ij}^2 + \text{tr}V},$$

$$\max_{K \geq 0} \Delta \text{MSR}(\beta^*(K)) = p \text{tr}V + \sum_{i=1}^p \lambda_i \alpha_{ij}^2,$$

MSR($\beta^*(K)$)和 Δ MSR($\beta^*(K)$)随 k_i 变化的情况大致如表1.

表 1

k_i	0	$0 < k_i < (\text{tr}V)/\alpha_i^2$	$(\text{tr}V)/\alpha_i^2$	$(\text{tr}V)/\alpha_i^2 < k_i < +\infty$	$+\infty$
MSE($\beta^*(K)$)	$(\text{tr}V) \sum_{i=1}^p \lambda_i^{-1}$	↓	minimum	↑	$\sum_{i=1}^p \sum_{j=1}^q \alpha_{ij}^2$
$\Delta\text{MSR}(\beta^*(K))$	0	↑	$(\text{tr}V)^2 \sum_{i=1}^p \sum_{j=1}^q \frac{v_{jj} + \lambda_i \alpha_{ij}^2}{(\lambda_i \alpha_i^2 + \text{tr}V)^2}$	↑	$p \text{tr}V + \sum_{i=1}^p \sum_{j=1}^q \lambda_i \alpha_{ij}^2$

综上所述, 广义岭估计 $\beta^*(K)$ 在改进LS估计使得MSE减小的同时却引起 ΔMSR 的增大, 导致模型的拟合变坏. MSE的最大改进可由 $(\text{tr}V) \sum_{i=1}^p \lambda_i^{-1}$ 降低到 $(\text{tr}V)$

$\sum_{i=1}^p \frac{1}{\lambda_i + (\text{tr}V)/\alpha_i^2}$, 但与此同时, ΔMSR 却由零增大到 $(\text{tr}V)^2 \sum_{i=1}^p \sum_{j=1}^q \frac{v_{jj} + \lambda_i \alpha_{ij}^2}{(\lambda_i \alpha_i^2 + \text{tr}V)^2}$.

根据MSE准则选取K值有如下的两点缺陷:

第一, 当模型(1.1)的设计矩阵呈“病态”时, 才有必要对LS估计作修正, 因此K值的选取应依赖于设计矩阵的“病态”程度. 但MSE准则对各种的“病态”情况均同等看待, 这不够恰当.

第二, 当 $K = \text{diag}(k_1, k_2, \dots, k_p)$ 时, 根据 $\text{MSR}(\beta^*(K))$ 和 $\Delta\text{MSR}(\beta^*(K))$ 的性质, $\beta^*(K)$ 在使MSE减小的同时, 必使MSR增大. MSE准则要求MSE($\beta^*(K)$)达到最小, 但此时MSR($\beta^*(K)$)较大, 使得 $\beta^*(K)$ 对模型(1.4)的拟合变坏.

2. Q(c)准则及其优良性

基于以上的分析, 我们引入如下的准则.

Q(c)准则 在广义岭估计类 \mathcal{S} 中, 选取K值使得

$$Q(c) = c\text{MSE}(\beta^*(K)) + (1-c)\Delta\text{MSR}(\beta^*(K)) \quad (3.2)$$

为最小, 其中 $c \in [0, 1]$ 为给定的常数.

对于不同的c, (3.2)给出了不同的准则, 所以Q(c)准则实际上是一族准则. LS准则和MSE准则分别为 $c=0$ 和 $c=1$ 时Q(c)准则的特例.

由(2.4)、(3.1)二式得

$$Q(c) = \sum_{i=1}^p \sum_{j=1}^q \frac{\{[c + (1-c)\lambda_i]\alpha_{ij}^2 + (1-c)v_{jj}\}k_i^2}{(\lambda_i + k_i)^2} + c \sum_{i=1}^p \sum_{j=1}^q \frac{\lambda_i v_{jj}}{(\lambda_i + k_i)^2}$$

$$\frac{\partial Q(c)}{\partial k_i} = \sum_{j=1}^q \frac{2\lambda_i \{[c + (1-c)\lambda_j]\alpha_{ij}^2 + (1-c)v_{jj}\}k_i - 2c\lambda_i v_{jj}}{(\lambda_i + k_i)^2}$$

令 $\frac{\partial Q(c)}{\partial k_i} = 0$, 则得Q(c)准则下的唯一K值为

$$k_i(Q(c)) = \frac{c \text{tr}V}{[c + (1-c)\lambda_i]\alpha_i^2 + (1-c)\text{tr}V} \quad (c \in [0, 1] i = 1, 2, \dots, p).$$

$$\text{又 } \frac{dk_i(Q(c))}{dc} = \frac{(\lambda_i a_i^2 + \text{tr}V) \text{tr}V}{\{[c + (1-c)\lambda_i] a_i^2 + (1-c)\text{tr}V\}^2} > 0, \quad (c \in [0, 1], i=1, 2, \dots, p)$$

所以 $k_i(Q(c))$ 关于 c 严格单调上升. 当 $c=0$ 时, $k_i(Q(c))=0$; 当 $c=1$ 时, $k_i(Q(c)) = (\text{tr}V)/a_i^2 = k_i^*$.

引理3.1 对线性回归模型(1.1)或(1.4), $\forall c \in [0, 1]$, 由 $Q(c)$ 准则确定的 K 满足 $0 \leq k_i \leq (\text{tr}V)/a_i^2$. ($i=1, 2, \dots, p$)

定理3.2 对 $K = \text{diag}(k_1, k_2, \dots, k_p)$, 令

$$\mathcal{G} = \{\beta^*(K) = [I_q \otimes (X'X + QKQ')^{-1}] (I_q \otimes X'X) \beta^*; K \geq 0\}$$

$$\mathcal{G}_1 = \{\beta^*(K): 0 \leq k_i \leq (\text{tr}V)/a_i^2, i=1, 2, \dots, p\}$$

$$\mathcal{G}(c) = \{\beta^*(K): K \geq 0, K \text{ 依 } Q(c) \text{ 准则选取}\}$$

则 (1) $\mathcal{G}(c) \subset \mathcal{G}_1$,

(2) $\forall \beta^*(K) \in \mathcal{G}$, 必存在 $\beta^*(K_0) \in \mathcal{G}(c)$ 使得

$$\text{MSR}(\beta^*(K_0)) \leq \text{MSE}(\beta^*(K)) \quad (3.3)$$

$$\Delta \text{MSR}(\beta^*(K_0)) \leq \Delta \text{MSR}(\beta^*(K)) \quad (3.4)$$

证明 (1) 由引理3.1即得

(2) 记 $K^* = \text{diag}(k_1^*, k_2^*, \dots, k_p^*)$, $k_i^* = (\text{tr}V)/a_i^2$. ($i=1, 2, \dots, p$),

则 $\beta^*(K^*) \in \mathcal{G}(c)$, 且 $\text{MSE}(\beta^*(K^*)) = \min_{\beta^*(K) \in \mathcal{G}} \text{MSE}(\beta^*(K))$

令 $\mathcal{G}^* = \{\beta^*(K) \in \mathcal{G}: 0 < \Delta \text{MSR}(\beta^*(K)) < \Delta \text{MSR}(\beta^*(K^*))\}$

对 $\forall \beta^*(K) \in \mathcal{G}$.

(i) 若 $\beta^*(K) \in \mathcal{G} - \mathcal{G}^*$, 当 $\Delta \text{MSR}(\beta^*(K^*)) \leq \Delta \text{MSR}(\beta^*(K))$ 时, 取 $K_0 = K^*$, 则

$$\text{MSE}(\beta^*(K_0)) = \text{MSE}(\beta^*(K^*)) \leq \text{MSE}(\beta^*(K))$$

$$\Delta \text{MSR}(\beta^*(K_0)) = \Delta \text{MSR}(\beta^*(K^*)) \leq \Delta \text{MSR}(\beta^*(K)).$$

当 $\Delta \text{MSR}(\beta^*(K)) = 0$ 时, 取 $K_0 = 0$, 由 $\Delta \text{MSR}(\beta^*(K)) = 0$ 得 $K = 0$, 于是

$$\text{MSE}(\beta^*(K_0)) = \text{MSE}(\beta^*(K))$$

$$\Delta \text{MSR}(\beta^*(K_0)) = \Delta \text{MSR}(\beta^*(K)).$$

(ii) 若 $\beta^*(K) \in \mathcal{G}^*$, 因为

$$\Delta \text{MSR}(\beta^*(K)) = \sum_{i=1}^p \sum_{j=1}^q \frac{(v_{jj} + \lambda_i a_{ij}^2) k_i^2}{(\lambda_i + k_i)^2}$$

对 k_i 连续,

$$k_i(Q(c)) = \frac{c \text{tr}V}{[c + (1-c)\lambda_i] a_i^2 + (1-c)\text{tr}V}$$

关于 c 于 $[0, 1]$ 上连续 ($i=1, 2, \dots, p$).

所以 $\Delta \text{MSR}[\beta^*(K(Q(c)))]$ 关于 c 于 $[0, 1]$ 上连续.

又 $\Delta \text{MSR}[\beta^*(K(Q(0)))] = 0$, $\Delta \text{MSR}[\beta^*(K(Q(1)))] = \Delta \text{MSR}[\beta^*(K)]$.

根据连续函数的介值定理, 必存在 $c_0 \in (0, 1)$ 使得

$$\Delta \text{MSR}[\beta^*(K(Q(c_0)))] = \Delta \text{MSR}[\beta^*(K)]$$

即 $K_0 = K(Q(c_0))$ 满足(3.4)式.

由 $\beta^*(K_0)$ 的含义, 有

$$\begin{aligned} & c_0 \text{MSE}[\beta^*(K_0)] + (1-c_0) \Delta \text{MSR}[\beta^*(K_0)] \\ & \leq c_0 \text{MSE}[\beta^*(K)] + (1-c_0) \Delta \text{MSR}[\beta^*(K)] \end{aligned}$$

考虑到 $\Delta \text{MSR}[\beta^*(K_0)] = \Delta \text{MSR}[\beta^*(K)]$

由此有 $\text{MSE}(\beta^*(K_0)) \leq \text{MSE}(\beta^*(K))$

因此(3.3)式成立.

依定理3.2, $\mathcal{S} - \mathcal{S}_{Q(c)}$ 中的岭估计是不足取的, 因为在 $\mathcal{S}_{Q(c)}$ 中有MSE和 ΔMSR 都比它小的 $\beta^*(K)$ 存在.

虽然当模型(1.1)的设计矩阵呈现“病态”时, $\beta = \text{vec}(B)$ 的LS估计将有较大的MSE, 但它毕竟是 β 的最佳线性无偏估计, 并没有完全失去它的优良性. 根据“病态”的不同程度, LS估计还有不同程度的参考价值. $Q(c)$ 准则通过 c 值在 $[0, 1]$ 中的选取在一定程度上考虑了“病态”严重程度的因素. 利用了这种参考价值, 在这种意义下, 对多元广义岭估计来说, $Q(c)$ 准则优于MSE准则.

3. 关于参数 c 及 K 的确定

(1) 因为 $Q(c)$ 准则中 c 值的大小, 反映了 $\beta^*(K)$ 的MSE和 $\beta^*(K)$ 对模型拟合好坏这两者的重视程度, 所以在实用中, 参数 c 可根据设计矩阵的“病态”严重程度来确定. 例如[1]中指出方阵的条件数 $\text{cond}(X'X) = \frac{\lambda_{\max}}{\lambda_{\min}}$, 直观上度量了 $X'X$ 的特征根散布程度, 所以可用来判断复共线性是否存在及复共线性的严重程度. 在实际应用中, 若 $0 < \text{cond}(X'X) < 100$, 则认为没有复共线性; 若 $100 \leq \text{cond}(X'X) \leq 1000$, 则认为存在中等程度或较强的复共线性; 若 $\text{cond}(X'X) > 1000$, 则认为存在严重的复共线性. 于是可取 $c = 1 - (\text{cond}(X'X))^{-1} = (\lambda_{\max} - \lambda_{\min}) / \lambda_{\max}$.

又如, 可根据最大熵原理来确定 $K(Q(c))$, 即假设 c 服从 $[0, 1]$ 上的均匀分布, 这样一来, 我们求得

$$\begin{aligned} k_i &= \int_0^1 k_i(Q(c)) dc \\ &= \frac{\text{tr}V}{\alpha_i^2 - \lambda_i \alpha_i^2 - \text{tr}V} \left[1 - \frac{\lambda_i \alpha_i^2 + \text{tr}V}{\alpha_i^2 - \lambda_i \alpha_i^2 - \text{tr}V} \ln \frac{\alpha_i^2}{\lambda_i \alpha_i^2 + \text{tr}V} \right] \\ & \quad (i=1, 2, \dots, p) \end{aligned}$$

(2) 在理论上得到 k_i 对未知参数的依赖关系的函数形式之后, 为了实际中的应用, 我们必须由模型的数据集将未知参数的函数 $k_i(\alpha_i^2, V)$ 估计出来, 简单又自然的作法是取 $\hat{k}_i = k_i(\alpha_i^{*2}, V^*)$, 其中 α_i^{*2} 和 V^* 分别为 α_i^2 和 V 的无偏估计, 即

$$\alpha_i^{*2} = \sum_{j=1}^q \alpha_{ij}^{*2} - \lambda_i^{-1} \text{tr}V^*, \quad (\alpha_{ij}^* \text{为 } \alpha_{ij} \text{ 的LS估计})$$

$$V^* = (n-p)^{-1} Y' [I_n - Z(Z'Z)^{-1}Z'] Y = (n-p)^{-1} Y' [I_n - ZA^{-1}Z'] Y.$$

我们也可对 α^* 采用迭代法来求出 k_i , 这种方法是

$$\hat{k}_i^{(m)} = k_i((\alpha_i^{*(m)})^2, V^*), \quad (\alpha_i^{*(m)})^2 = \sum_{j=1}^q (\alpha_{ij}^{*(m)})^2.$$

$$(i=1, 2, \dots, p, m=1, 2, \dots)$$

其中 $\alpha^{*(m)} = [I_q \otimes (A + \hat{k}^{(m-1)})^{-1}Z'] \text{vec}(Y)$ ($m=1, 2, \dots$),

$$\alpha^{*(0)} = (I_q \otimes A^{-1}Z')\text{vec}(Y),$$

$$V^* = (n-p)^{-1}Y'[I_n - ZA^{-1}Z']Y$$

当然这还得考虑到迭代收敛性和迭代的技巧,至于确定参数 c 、 K 的其它方法及各种方法之间的比较,尚有待于进一步探讨。

参 考 文 献

- [1] 陈希孺、王松桂,《近代回归分析——原理、方法及应用》,安徽教育出版社(1987).
- [2] 王松桂,《线性模型的理论及其应用》,安徽教育出版社(1987).
- [3] Brown, P. J. and J. V. Zidek, Adaptive multivariate ridge regression, *Ann. Statist.*, 8(1) (1980), 64—74.
- [4] Haitovsky, Yoel, On multivariate ridge regression, *Biometrika*, 74(3)(1987), 563—570.
- [5] Hemmerle, W. J. and T. F. Brantle, Explicit and constrained generalized ridge estimation, *Technometrics*, 20 (1978), 109—120.
- [6] Wichem, D. W. and G. A. Churchill, A comparison of ridge estimators, *Technometrics*, 20 (1978), 301—311.
- [7] 鲁国斌, 广义岭回归估计中关于 K 值选取的 $Q(c)$ 准则, 数理统计与应用概率, 4(2)(1989), 159—169.

Generalized Multivariate Ridge Regression Estimate and Criteria $Q(c)$ for Choosing Matrix K

Chen Shi-ji Zeng Zhi-bin

(Department of Mathematics, Fujian Normal University, Fuzhou)

Abstract

When multicollinearity is present in a set of the regression variables, the least square estimate of the regression coefficient tends to be unstable and it may lead to erroneous inference.

In this paper, generalized ridge estimate $\beta^*(K)$ of the regression coefficient $\beta = \text{vec}(B)$ is considered in multivariate linear regression model. The MSE of the above estimate is less than the MSE of the least square estimate by choosing the ridge parameter matrix K . Moreover, it is pointed out that the criterion MSE for choosing matrix K of generalized ridge estimate has several weaknesses. In order to overcome these weaknesses, a new family of criteria $Q(c)$ is adopted which includes the criterion MSE and criterion LS as its special case. The good properties of criteria $Q(c)$ are proved and discussed from theoretical point of view. The statistical meaning of the scale c is explained and the methods of determining c are also given.

Key words least square estimate, generalized ridge estimate, mean square error