

岭回归估计 $\hat{\beta}(k)$ 的一个特性及其应用

A PROPERTY OF RIDGE REGRESSION ESTIMATER $\hat{\beta}_{(k)}$
AND ITS' APPLICATION

何良材

He Liangcai

(应用数学系)

摘要 本文就岭回归估计 $\hat{\beta}_{(k)}$ 在 $0 < K \leq \sigma^2 / \max r_i^2$ 条件下, 对标准 $E \|\hat{\beta}_{(k)} - \beta\|^2$ 优于LS估计问题给出了证明, 并结合实例确定较优的岭回归K值。

主题词 岭回归估计; 最小二乘估计; 特征根; 回归离差/标准; 均方误差
中国图书资料分类号 O 212.1

ABSTRACT in this paper we prove that ridge regression estimator $\hat{\beta}_{(k)}$ under the condition of $0 < K \leq \sigma^2 / \max r_i^2$ is more superior to the LS estimator of standard $E \|\hat{\beta}_{(k)} - \beta\|^2$. We also give examples for showing the superior ridge regression K-Value.

SUBJECT WORDS ridge regression estimator; least square estimator; characteristic root; regression deviation / standard; mean square errors

一、引言

对回归系数 β 的最小二乘估计(简记为LS估计)已有相当深入的研究, 并且也发现LS估计具有若干不够理想的地方, 如线性模型

$$Y = X\beta + e$$

中的回归系数 β 用LS法来估计, 得估计量为

$$\hat{\beta} = (X'X)^{-1}X'Y \quad (1)$$

由(1)所确定的 $\hat{\beta}$, 显然地依赖于相关矩阵 $X'X$ 之道。如果 $X'X$ 退化, 则 $\hat{\beta}$ 不确定, 亦即 β

收文日期 1988年9月12日

不可估。如果矩阵 $X'X$ 的行列式值十分地小,则 $\hat{\beta}$ 也不十分可靠。鉴于LS法在某些情况下的这些弱点和不足,近十年来一些统计工作者在为提出更好的估计方法作了不少工作。A. E. Horel在六十年代提出一个新的概念——岭回归,又在1970年他同 Kennard 较为系统地介绍了这个方法,这就是所谓的岭回归分析法。

定义 设 $K \geq 0, e \sim N(0, \sigma^2 I)$ 称

$$\hat{\beta}_{(K)} = (X'X + KI)^{-1} X'Y \tag{2}$$

为模型 $Y = X\beta + e$ 中回归系数的岭回归估计,简称岭估计。

其中

$$X = \begin{pmatrix} x_{11} & x_{12} & \dots & x_{1m} \\ x_{21} & x_{22} & \dots & x_{2m} \\ \dots & \dots & \dots & \dots \\ x_{n1} & x_{n2} & \dots & x_{nm} \end{pmatrix}, Y = \begin{pmatrix} y_1 \\ y_2 \\ \dots \\ y_n \end{pmatrix}$$

I 为 m 阶单位矩阵

显然当 $K=0$ 时,则为通常所说的最小二乘估计,用如(2)式 $\hat{\beta}_{(K)}$ 来估计回归系数 β 以及一套与之有关的处理方法,称为岭回归分析。在岭回归分析中 K 值的选择是一个关键的问题,本文就岭回归估计 $\hat{\beta}_{(K)}$ 在 $0 < K \leq \sigma^2 / \max r_i^2$ 条件下,对于标准 $E \|\hat{\beta}_{(K)} - \beta\|^2$ 优于LS估计的问题作了一些研究,给出了证明;并结合实例选择较优的 K 值。

二、岭估计 $\hat{\beta}_{(K)}$ 的一个特性

定理 设 $0 < K \leq \sigma^2 / \max r_i^2$ 成立,且 $e \sim N(0, \sigma^2 I)$,则由 $\hat{\beta}_{(K)} = (S + KI)^{-1} X'Y$ 所定义的岭估计对标准 $E \|\hat{\beta}_{(K)} - \beta\|^2$ 而言优于LS估计。其中

$$(r_1 \ r_2 \ \dots \ r_m)' = r = P\beta, S = X'X = P' \Lambda P$$

P 为正交矩阵, Λ 为对角矩阵,其主对角线上元素为 S 的正值特征根,记为 $\lambda_i (i=1, 2, \dots, m)$, I 为 m 阶单位矩阵

证明:由定义

$$\hat{\beta}_{(K)} = (S + KI)^{-1} X'Y$$

$$\begin{aligned} \text{有 } \hat{\beta}_{(K)} - \beta &= (S + KI)^{-1} X'Y - \beta \\ &= (S + KI)^{-1} X'(X\beta + e) - \beta \\ &= (S + KI)^{-1} (X'X + KI - KI)\beta + (S + KI)^{-1} X'e - \beta \\ &= -(S + KI)^{-1} K\beta + (S + KI)^{-1} X'e \\ &= [(X'e - K\beta)' (S + KI)^{-1}]' \end{aligned}$$

$$\therefore E (\hat{\beta}_{(K)} - \beta) = -K I (S + KI)^{-1} \beta \tag{3}$$

$$\begin{aligned} \text{又 } \|\hat{\beta}_{(K)} - \beta\|^2 &= (\hat{\beta}_{(K)} - \beta)' (\hat{\beta}_{(K)} - \beta) \\ &= (X'e - K\beta)' (S + KI)^{-1} (S + KI)^{-1} (X'e - K\beta) \\ &= e' X (S + KI)^{-2} X'e + K^2 \beta' (S + KI)^{-2} \beta \end{aligned}$$

$$-K\beta'(\mathbf{S}+K\mathbf{I})^{-2}\mathbf{X}'\mathbf{e}-K\mathbf{e}'\mathbf{X}(\mathbf{S}+K\mathbf{I})^{-2}\beta$$

$$\begin{aligned} \text{令 } L(\hat{\beta}_{(K)}) &= E \|\hat{\beta}_{(K)} - \beta\|^2 \\ &= E[\mathbf{e}'\mathbf{X}(\mathbf{S}+K\mathbf{I})^{-2}\mathbf{X}'\mathbf{e} + K^2\beta'(\mathbf{S}+K\mathbf{I})^{-2}\beta] \\ &= K^2 E[\beta'(\mathbf{S}+K\mathbf{I})^{-2}\beta] + E[\mathbf{e}'\mathbf{X}(\mathbf{S}+K\mathbf{I})^{-2}\mathbf{X}\mathbf{e}] \end{aligned} \quad (4)$$

对 (4) 式第一项

$$\because \mathbf{S} = \mathbf{X}'\mathbf{X} = \mathbf{P}'\mathbf{\Lambda}\mathbf{P} = \mathbf{P}' \begin{pmatrix} \lambda_1 & & 0 \\ & \ddots & \\ 0 & & \lambda_m \end{pmatrix} \mathbf{P}, \mathbf{P} \text{ 正交}$$

$$\text{有 } (\mathbf{S}+K\mathbf{I})^{-1} = \mathbf{P}' \begin{pmatrix} \lambda_1+K & & 0 \\ & \ddots & \\ 0 & & \lambda_m+K \end{pmatrix}^{-1} \mathbf{P}$$

$$= \mathbf{P}' \begin{pmatrix} \frac{1}{\lambda_1+K} & & 0 \\ & \ddots & \\ 0 & & \frac{1}{\lambda_m+K} \end{pmatrix} \mathbf{P}$$

$$(\mathbf{S}+K\mathbf{I})^{-2} = \mathbf{P}' \begin{pmatrix} \left(\frac{1}{\lambda_1+K}\right)^2 & & 0 \\ & \ddots & \\ 0 & & \left(\frac{1}{\lambda_m+K}\right)^2 \end{pmatrix} \mathbf{P}$$

$$\beta'(\mathbf{S}+K\mathbf{I})^{-2}\beta = \beta' \mathbf{P}' \begin{pmatrix} \left(\frac{1}{\lambda_1+K}\right)^2 & & 0 \\ & \ddots & \\ 0 & & \left(\frac{1}{\lambda_m+K}\right)^2 \end{pmatrix} \mathbf{P}\beta$$

$$= \mathbf{r}' \begin{pmatrix} \left(\frac{1}{\lambda_1+K}\right)^2 & & 0 \\ & \ddots & \\ 0 & & \left(\frac{1}{\lambda_m+K}\right)^2 \end{pmatrix} \mathbf{r}$$

$$= \sum_{i=1}^m \frac{r_i^2}{(\lambda_i+K)^2}$$

$$\therefore K^2 E[\beta'(\mathbf{S}+K\mathbf{I})^{-2}\beta] = K^2\beta'(\mathbf{S}+K\mathbf{I})^{-2}\beta = K^2 \sum_{i=1}^m \left(\frac{r_i}{\lambda_i+K}\right)^2$$

对 (4) 式第二项

$$\begin{aligned}
& E[\mathbf{e}'\mathbf{X}(\mathbf{S}+\mathbf{K}\mathbf{I})^{-2}\mathbf{X}'\mathbf{e}] \\
&= \text{tr}[\mathbf{X}(\mathbf{S}+\mathbf{K}\mathbf{I})^{-2}\mathbf{X}']\sigma^2 \\
&= \text{tr}[(\mathbf{S}+\mathbf{K}\mathbf{I})^{-2}\mathbf{X}'\mathbf{X}]\sigma^2 \\
&= \text{tr}[(\mathbf{S}+\mathbf{K}\mathbf{I})^{-2}(\mathbf{S}+\mathbf{K}\mathbf{I}-\mathbf{K}\mathbf{I})]\sigma^2 \\
&= [\text{tr}(\mathbf{S}+\mathbf{K}\mathbf{I})^{-1}-K\text{tr}(\mathbf{S}+\mathbf{K}\mathbf{I})^{-2}]\sigma^2 \\
&= \left[\sum_{i=1}^m \frac{1}{\lambda_i+K} - K \sum_{i=1}^m \left(\frac{1}{\lambda_i+K} \right)^2 \right] \sigma^2 \\
&= \sigma^2 \sum_{i=1}^m \frac{\lambda_i}{(\lambda_i+K)^2}
\end{aligned}$$

$$\therefore E[\mathbf{e}'\mathbf{X}(\mathbf{S}+\mathbf{K}\mathbf{I})^{-2}\mathbf{X}'\mathbf{e}] = \sum_{i=1}^m \frac{\lambda_i \sigma^2}{(\lambda_i+K)^2}$$

其中 $\text{tr}[\mathbf{X}(\mathbf{S}+\mathbf{K}\mathbf{I})^{-2}\mathbf{X}']$ 表示矩阵 $\mathbf{X}(\mathbf{S}+\mathbf{K}\mathbf{I})^{-2}\mathbf{X}'$ 的迹, 即 $\mathbf{X}(\mathbf{S}+\mathbf{K}\mathbf{I})^{-2}\mathbf{X}'$ 全部特征根之和。

又当 $0 < K \leq \sigma^2 / \max r_i^2$, 有 $\max r_i^2 \leq \frac{\sigma^2}{K}$

$$\therefore r_i^2 \leq \frac{\sigma^2}{K}, \quad i=1, 2, \dots, m$$

$$\begin{aligned}
\text{故 } L(\hat{\beta}_{(K)}) &= K^2 \sum_{i=1}^m \left(\frac{r_i}{\lambda_i+K} \right)^2 + \sum_{i=1}^m \frac{\lambda_i \sigma^2}{(\lambda_i+K)^2} \quad (5) \\
&= \sum_{i=1}^m \frac{K^2 r_i^2 + \lambda_i \sigma^2}{(\lambda_i+K)^2} \leq \sum_{i=1}^m \frac{K^2 \sigma^2 / K + \lambda_i \sigma^2}{(\lambda_i+K)^2} \\
&= \sum_{i=1}^m \frac{K + \lambda_i}{(\lambda_i+K)^2} \sigma^2 = \sum_{i=1}^m \frac{1}{\lambda_i+K} \sigma^2 \\
&< \sigma^2 \sum_{i=1}^m \frac{1}{\lambda_i} = L(\hat{\beta})
\end{aligned}$$

注: 由 (5) 式, 当 $K=0$ 时, $L(\hat{\beta}_{(0)}) = \sum_{i=1}^m \frac{\lambda_i \sigma^2}{\lambda_i^2} = \sigma^2 \sum_{i=1}^m \frac{1}{\lambda_i}$

$$\text{即是 } L(\hat{\beta}) = \sigma^2 \sum_{i=1}^m \frac{1}{\lambda_i}$$

即得到 $L(\hat{\beta}_{(K)}) < L(\hat{\beta})$

〔证毕〕

三、实 例

生产某种产品, 从原料到成品需要 6 道工序, 各道工序的精度均会不同程度地影响成品的精度, 现有原始数据见表 1。分析各工序精度(质量)对成品的影响, 怎样才能有效地提高成品精度。

表 1 原始数据表

绝对偏差 序号	工 序	I	II	III	IV	V	VI	成品
1		-0.8414	-0.2070	0.0895	-0.0429	-0.0241	-0.0140	-0.6480
2		0.6238	-0.0587	-0.0955	0.0202	-0.0121	-0.0197	0.6731
3		0.5465	0.3316	0.2899	0.0293	-0.0082	-0.0039	0.6075
4		-0.5523	0.3966	-0.1210	0.0466	-0.0447	0.0024	-0.4759
5		-0.6117	-0.2779	0.0466	0.2156	0.0162	-0.0022	-0.6216
6		-0.5742	0.3839	-0.0347	-0.0107	0.1371	-0.0538	-0.5070
7		0.4050	-0.3111	-0.2196	0.0777	0.2640	0.1112	0.3585
8		-0.3105	0.3727	0.1084	-0.2166	-0.2354	-0.2702	-0.2704
9		-0.2741	0.1632	0.5751	-0.0948	-0.2574	-0.0770	0.5380
10		0.1079	-0.2454	-0.1033	0.4967	0.0911	0.3373	0.5279
11		0.3198	-0.2517	-0.2853	0.0984	0.5408	0.0937	0.5325
12		0.1250	-0.2862	-0.0691	0.4031	0.0907	0.5342	0.5819

解:

1. 用Jacobi法求相关矩阵 $X'X$ 的特征值及相应的标准正交特征向量, 见表 2

表 2 特征值及特征向量表

序 号	1	2	3	4	5	6
特征值	4.345	1.070	0.403	0.142	0.096	0.043
特	-0.435	-0.274	0.403	-0.427	-0.355	-0.485
征	0.457	-0.080	-0.430	0.202	-0.178	-0.646
向	0.371	0.453	0.732	0.292	-0.119	-0.125
量	-0.375	0.542	-0.305	0.157	-0.658	0.082
P_1	-0.415	-0.380	0.118	0.809	0.074	-0.072
	-0.390	0.525	-0.087	-0.040	0.626	-0.376

由此可把实对称阵 $X'X$ 对角化,

$$P(X'X)P' = \Lambda \quad \text{即 } X'X = P' \Lambda P$$

其中 $P = (P_1 P_2 \dots P_6)'$ 为正交矩阵,

$$\Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_6) = \begin{pmatrix} \lambda_1 & & & & & 0 \\ & \lambda_2 & & & & \\ & & \ddots & & & \\ 0 & & & & & \lambda_6 \\ & & & & & \\ & & & & & \end{pmatrix}$$

P_i 为属于特征值 λ_i 的规范特征向量

2. 求LS估计

$$\begin{aligned} \text{LS估计式 } \hat{\beta} &= (X'X)^{-1}X'Y = (P'\Lambda P)^{-1}X'Y \\ &= P'\Lambda^{-1}PX'Y \end{aligned}$$

利用已知数据求得LS估计值为

$$\begin{aligned} \hat{\beta}_1 &= 1.5545 & \hat{\beta}_2 &= 0.5705 & \hat{\beta}_3 &= 1.2024 \\ \hat{\beta}_4 &= -0.8865 & \hat{\beta}_5 &= 0.1417 & \hat{\beta}_6 &= 3.8480 \end{aligned}$$

$$\begin{aligned} \text{由此 } \hat{\sigma}_2 &= e'e / (n-m) = (Y - X\hat{\beta})' (Y - X\hat{\beta}) / (n-m) \\ &= 3.4182 / (12-6) = 0.5697 \end{aligned}$$

3. 计算 $\sigma^2 / \max_{1 \leq i \leq m} r_i^2$

由于 σ^2 和 β 在实际中不可测，故用 $\hat{\sigma}^2$ 代 σ^2 ， $\hat{\beta}$ 代 β ，则有

$$r = P\hat{\beta} = (-1.1954 \quad 1.5594 \quad 1.2121 \quad -0.3919 \quad 2.2068 \quad -2.7248)$$

$$\text{令 } K_c = \hat{\sigma}^2 / \max_{1 \leq i \leq 6} r_i^2 = 0.5697 / (-2.7248)^2 = 0.0767$$

4. 计算岭回归估计

岭估计为 $\hat{\beta}_{(K)} = (X'X + KI)^{-1}X'Y$ ，对于 K 在0到 K_c 内取值不同算得相应岭估计值及估计的均方误差和回归离差 见表3

表 3 岭估计值及相应参数值

	0	$\frac{1}{8}k_c$	$\frac{2}{8}k_c$	$\frac{3}{8}k_c$	$\frac{4}{8}k_c$	$\frac{5}{8}k_c$	$\frac{6}{8}k_c$	$\frac{7}{8}k_c$	$\frac{8}{8}k_c$	
$\hat{\beta}_{(k)} =$	$\hat{\beta}_{(k)1}$	1.5545	1.3791	1.2543	1.1601	1.0859	1.0254	0.9749	0.9318	0.8944
	$\hat{\beta}_{(k)2}$	0.5705	0.3595	0.2177	0.1172	0.0430	-0.0134	-0.0572	-0.0920	-0.1200
	$\hat{\beta}_{(k)3}$	1.2023	1.1272	1.0670	1.0164	0.9724	0.9332	0.8978	0.8654	0.8355
	$\hat{\beta}_{(k)4}$	-0.8865	-0.8208	-0.7680	-0.7238	-0.6859	-0.6525	-0.6229	-0.5962	-0.5719
	$\hat{\beta}_{(k)5}$	0.1417	0.1363	0.1358	0.1379	0.1412	0.1450	0.1490	0.1529	0.1567
	$\hat{\beta}_{(k)6}$	3.8480	3.1813	2.7148	2.3699	2.1045	1.8938	1.7221	1.5798	1.4599
$L(\hat{\beta}_{(k)})$	25.6732	19.5718	15.6277	12.8768	10.8546	9.3099	8.0951	7.1175	6.3162	
$e_{\hat{\beta}}^2$	3.4182	2.0316	1.3320	0.9564	0.7482	0.6332	0.5730	0.5454	0.5388	

其中 $L(\beta_{(K)}) = \sum_{i=1}^m \frac{K^2 r_i^2 + \lambda_i \sigma^2}{(\lambda_i + K)^2}$, $e_K^2 = (Y - X \hat{\beta}_{(K)})' (Y - X \hat{\beta}_{(K)})$ 由计算结果可知：对于

$0 < K \leq K_c = \sigma^2 / \max r_i^2$, 相应于 K 的岭回归估计对于估计均方误差 $L(\hat{\beta})$ 而言优于 LS 估计。

$$\text{设 } LE(K) = \alpha \cdot e_K^2 / e_0^2 + (1 - \alpha) L(\hat{\beta}_{(K)}) / L(\hat{\beta}_{(0)})$$

权数 α 满足 $0 \leq \alpha \leq 1$, 根据实际确定 α , 若侧重于回归离差, 则 α 取大于0.5; 反之, α 取小于0.5. 当然 $\alpha = 0$ 或1作为极端情形也是允许的。

再根据 $\min_K LE(K)$ 来确定应选取哪个值。

对此例, 由于要求刻画各道工序精度对成品精度的影响, 所以 β 的估计 $\hat{\beta}$ 的均方误差特别重要, 因此取 $\alpha = 0$ 的极端情形。

$$\text{即 } LE(K) = L(\hat{\beta}_{(K)}) / L(\hat{\beta}_{(0)}).$$

$$\text{则 } \min_{K = \frac{1}{8} K_c, t=0, 1, 2, \dots, 8} LE(K) = LE\left(\frac{8}{8} K_c\right) = 6.3162 / 25.6732 = 0.2460$$

所以, 最后接受 $K = \frac{8}{8} K_c = K_c$ 相应的岭估计值 $\hat{\beta}(K_c)$ 为 $\hat{\beta}$ 即:

$$\begin{aligned} \hat{\beta} &= (0.8944 \quad -0.1200 \quad 0.8355 \quad -0.5719 \quad 0.1587 \quad 1.4599)' \\ Y &= 0.8944x_1 - 0.1200x_2 + 0.8355x_3 - 0.5719x_4 + 0.1587x_5 + 1.4599x_6 \end{aligned}$$

当然也可不取 $\alpha = 0$ 而取 α 为0.8, 0.9...等大于0.5的数, 不过对此例特别, 由于 e_K^2 , $L(\beta_{(K)})$ 均为单调减少, 因此取为任何0, 1间的数, 都不会影响为最优选择这一结果。

鉴此, 对成品影响最大者是第6道工序, 所以我们应着重提高第6道工序的精度, 即把好最后一道工序的质量关, 其次是第1, 第3道工序, 这样便能有效地提高成品的质量。

作者感谢重庆大学应用数学系段虞荣教授与何中市同志的帮助。

参 考 文 献

- [1] 罗积玉, 邢瑛, 经济统计分析方法及预测, 北京, 清华大学出版社, 1987
- [2] 陈希孺, 王松桂, 近代回归分析——原理方法及应用, 北京, 科学出版社, 1974
- [3] 陈希孺, 陈桂景, 线性模型参数的估计理论, 北京, 科学出版社, 1983
- [4] 王启应, 回归系数岭估计的相合性, 数理统计与应用概率, 1988, (1),
- [5] A.E.Horel, R.W.Kennard, Ridge regression biased estimation for non-orthogonal problems, Technometrics, 1970, (12); 55—68