

试用最优子集与岭迹分析相结合的方法确定回归方程

俞善贤 汪 锋

(浙江省气象科学研究所) (浙江师范大学地理系)

提 要

本文针对逐步回归在气象业务应用中出现的一些问题,提出采用岭回归等方法加以改进。在太湖平原春粮产量的气象预报统计模式试验中,运用最优子集与岭迹分析相结合的方法,取得了较好的效果。

多元回归分析是气象业务中一个重要的工具,并取得了一定的成效,但也存在不少问题。比较突出的是对样本拟合好,而作外推时(实际预报应用)效果往往不理想,其原因取决于:(1)对所研究问题内在机制的认识程度和选取相应模型的正确程度;(2)数学处理技巧是否得当,如模式中变量的选入和回归系数估计方法的恰当程度等。近年来回归分析方法的研究进展较快,提出了一些新方法,企图改进古典的以最小二乘法为主体的回归分析。我们在气象业务应用中发现目前常用的回归方程有很多问题,有必要引用这些新方法,并在微型机上予以实现,从初步工作看是有意义的,本文对其中一些主要问题作初步评述和探讨。

一、逐步回归在应用中的一些问题

逐步回归方法是气象业务中最常用的方法之一,这个方法表面上看来比较“完美”,但在大量的实际应用中和理论上都发现有一定缺陷。

(1) 逐步回归最大特点是在选入或删除变量时都基于统计检验,常用的是 F 检验。但实际上正如一些统计学者所指出:除了某些特殊的、在应用上不太现实的条件外,不能认为所涉及的 F 检验是正确的^[1]。因而从理论上并不能以任何概率保证所挑选自变量的“显著性”,亦即由逐步回归建立的方程很可能不满足实际应用(做预报)的要求。

(2) 我们在实例中发现(见表1), a) 选入和删除的 F 值不是单调下降,有时会回升这个现象十分普遍; b) 有时信度虽然较高,但选进因子的回归系数与经验不符,如因子单相关系数的符号与回归系数的符号相反; c) 在实际使用中,使用者往往希望通过调节信度,使方程中含有的因子数与预定的一致(同样本数相匹配)。由于 F 值有跳动现象,信度

表 1 14 个样本作逐步回归试验分析

因子个数	自变量序	剔除 F 检验	选入 F 检验	单相关系数	回归系数
1	8		7.53		
2	2 8	-7.53	3.58		
3	2 6 8	-3.58	3.09	$r_8 = 0.46$	$\beta_8 = -103.5$
4	2 6 7 8	-3.09	9.25		
4	2 6 7 8	-0.44			
3	2 6 7	-21.19			
4	2 6 7 11		10.7	$r_{11} = -0.34$	$\beta_{11} = 0.229$
5	2 3 6 7 11	-10.7	3.59		
6	2 3 6 7 10 11	-3.59	2.65		
7	2 3 5 6 7 10 11	-2.65	8.74	$r_5 = 0.367$	$\beta_5 = 0.399$
8	2 3 5 6 7 9 10 11	-8.74	4.31	$r_9 = 0.122$	$\beta_9 = -0.313$
9	1 2 3 5 6 7 9 10 11	-4.31	21.01	$r_1 = -0.26$	$\beta_1 = 0.247$
10	1 2 3 4 5 6 7 9 10 11	-21.01	7.66		

注: 表中单相关系数 r 和回归系数 β 的下标均是自变量序。

稍低时选进因子数太多, 信度稍高时选进的因子又太少, 需要反复调节试验(有时仍难以取得理想结果)大大增加了工作量。

(3) 如果单纯从回归方程残差平方和的观点看, 逐步回归方法决定的子集残差平方和 RSS_p 可能比包含同样自变量数的子集的 RSS_p 大得多。逐步回归方法只能提供一个子集回归, 而对不同的因子数, 这些子集变量又是包含关系, 这样就很难对各个自变量的重要性及相互关系作出客观的分析。

下面给出一个虚构数组来说明。

y : 29 -48 18 -12 44 57 47 10 86 46

x_1 : 7 -19 38 45 -5 15 -38 38 59 -27

x_2 : 7 -12 39 49 -7 12 -40 39 53 -29

y 与 x_1 之间的单相关系数为 0.104, y 与 x_2 之间的单相关系数为 -0.00635, 由于逐步回归每步只考虑一个因子对 y 的作用, 在本例情况下, x_1 和 x_2 很难入选方程。选入 x_1 时的 F 值只有 0.08, 由此将得出 y 对 x_1 和 x_2 的回归没有必要的假象, 然而 y 对 x_1, x_2 的回归方程复相关系数为 0.997, 是高度相关的。

二、最优子集和岭回归方法

1. 最优子集方法

最优子集方法是随着计算机的发展, 针对上节(3)中指出的问题应运而生的。该方法是对各个因子进行组合, 从中选出最优的方程^[2]。例如对 4 个因子有 1、2、3、4、12、

13、14、23、24、34、123、124、134、234、1234 十五种组合, 从中选出最优的。

这种方法计算工作量大, 内存量也大, 十几个因子是可行的, 超过二十个因子时计算时间和内存量的矛盾就极为突出。针对气象业务需要, 可预先指定方程含有因子数的范围, 这样就不必对所有组合都运算, 用“分支定界法”可大大节省计算机的时间和空间。

2. 岭回归方法

岭回归方法是针对回归系数估计的正确性提出的。 $\hat{\beta}$ 作为 β 的估计是否良好, 应考虑 $\hat{\beta}$ 与 β 的接近程度, 可以用均方差 MSE 作为一个较好的数量指标。即:

$$\text{MSE}(\hat{\beta}) = E[\|\hat{\beta} - \beta\|^2] = E[(\hat{\beta} - \beta)^T(\hat{\beta} - \beta)] \quad (2.1)$$

可以证明在线性模型 $Y = X\beta + e$ 下有

$$\text{MSE}(\hat{\beta}) = \sigma^2 \text{tr}(S^{-1}) \quad (2.2)$$

若假定 $e \sim N(0, \sigma^2 I)$, 则

$$\text{Var}(\|\hat{\beta} - \beta\|^2) = 2\sigma^4 \text{tr}(S^{-2}) \quad (2.3)$$

由线性代数理论可知: $S = X^T X$ 是对称正定矩阵, 其特征根皆为正数, 设

$$\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_t > 0$$

则 S^{-1} 的特征根为 $\frac{1}{\lambda_i}$, $i = 1, 2, \dots, t$, 于是得:

$$\text{tr}(S^{-1}) = \sum_{i=1}^t \frac{1}{\lambda_i} \quad (2.4)$$

将 (2.4) 式代入 (2.2) 和 (2.3) 式得:

$$\text{MSE}(\hat{\beta}) = \sigma^2 \sum_{i=1}^t \frac{1}{\lambda_i} \quad (2.5)$$

$$\text{Var}(\|\hat{\beta} - \beta\|^2) = 2\sigma^4 \sum_{i=1}^t \frac{1}{\lambda_i^2} \quad (2.6)$$

由此可见, 当自变量之间存在复共线关系时, 即当 S 呈现“病态”时, λ_t 很接近 0, $\text{MSE}(\hat{\beta})$ 和 $\text{Var}(\|\hat{\beta} - \beta\|^2)$ 的值都很大, 即 $\|\hat{\beta} - \beta\|^2$ 平均来说取值很大且很不稳定, 因此就很难认为在这种情况下 $\hat{\beta}$ 仍然是 β 的良好估计。

岭回归是 1970 年以来系统发展起来的一种改进最小二乘估计的方法。

设 $0 \leq k < \infty$ 称下式为岭回归

$$\hat{\beta}(k) = [\hat{\beta}_1(k), \dots, \hat{\beta}_t(k)]^T = (S + KI)^{-1} X^T Y \quad (2.7)$$

当 $k = 0$ 时就是最小二乘估计。

据上分析, 由 S 的特征根 $\lambda_1, \dots, \lambda_t$, 可知 $S + KI$ 的特征根为

$$\lambda_1 + k, \dots, \lambda_t + k,$$

如果 S 的最小特征根 λ_t 很接近于 0, 则 $\lambda_t + k$ 接近 0 的程度就会小些。因而有理由期望 $\hat{\beta}(k)$ 比 $\hat{\beta}$ 有所改善, 可以证明存在这样的 k , 使 $\hat{\beta}(k)$ 均方误差比 $\hat{\beta}$ 的均方误差小, 即

$$E[\|\hat{\beta}(k) - \beta\|^2] < E[\|\hat{\beta} - \beta\|^2] \quad (2.8)$$

并且使左边尽可能小。当然要求出最优的 k 值, 实际计算就变得复杂起来, 但当 k 在

$(0, +\infty)$ 内变化时 $\hat{\beta}_j(k)$ 作为 k 的函数, 就描出一条曲线, 这些曲线称为岭迹。在实际应用中, 可择取适当的一些 k 值, 由此点出的岭迹来分析变量之间的关系是很有意义的。

按 $\hat{\beta}(k) = (X^T X + KI)^{-1} X^T Y$ 对每一个 k 值需计算一次逆矩阵, 计算量太大, 下面给出计算岭迹的简单公式。设线性回归模型为:

$$Y = X\beta + e, \quad E(e) = 0, \quad V_{AR}(e) = \sigma^2 I \quad (2.9)$$

且设资料已经中心化和标准化处理。记矩阵 U 为:

$$U = \begin{bmatrix} Y^T Y & Y^T X \\ X^T Y & X^T X \end{bmatrix} \quad (2.10)$$

又 A 为 $t+1$ 阶正交方阵致

$$A U A^T = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_{t+1}) = \Lambda \quad (2.11)$$

则 $\hat{\beta}_j(k)$ 表示为:

$$\hat{\beta}_{j-1}(k) = - \left[\sum_{i=1}^{t+1} \frac{a_{ji} a_{ij}}{\lambda_i + k} \right] / \left[\sum_{i=1}^{t+1} \frac{a_{ji}^2}{\lambda_i + k} \right] \quad (2.12)$$

$$(j = 2, 3, \dots, t+1)$$

此式表明一旦算出 A 和 Λ 就可方便算出岭迹, 对每个不同 k 需要重复计算矩阵。

3. 岭迹分析

在岭回归中, 岭迹分析作为了解各变量的作用及相互关系的一种工具, 有其重要作用和实用意义。表 2 是不同岭迹的特点, 参考了文献 [2] 给出的图形, 我们用来分析古典回归和岭回归的不同情况。

这里扼要介绍确定 k 的岭迹方法, 该方法为了改变古典回归中看来不合理之处 (数值、符号), 基于直观考虑在岭迹图上可找到 k_0 值, 使回归系数估计达到稳定, 即图中岭迹曲线趋于平稳 (见图 1g), 并且希望残差平方和不增加太多。具体原则是:

(1) 去掉岭回归系数稳定且绝对值较小的变量, 这里的岭回归系数是可以直接比较

表 2 古典回归与岭回归对变量的分析对比

岭迹图形	图形特点	古典回归	岭回归
图 1a	$\hat{\beta}_j(0) = \hat{\beta}_j > 0$ 且比较大, $\hat{\beta}_j(k)$ 很不稳定, k 从零开始显著下降, 且迅速趋于零	X_j 对 Y 有重要影响	由于随 k 值的增加迅速趋于零, 失去“预报能力”, X_j 不起重要影响, 甚至可以去掉这个变量
图 1b	$\hat{\beta}_j(0) > 0$ 且比较小, $\hat{\beta}_j(k)$ 比较稳定, 从零开始变成负值	X_j 对 Y 作用不大, 且影响为正	X_j 对 Y 有较显著影响, 且影响为负。
图 1c	$\hat{\beta}_j(0) = \hat{\beta}_j > 0$ 且比较大, 当 k 增加时迅速下降, 且稳定为负大值	X_j 对 Y 有正影响, 且作用较大	X_j 对 Y 有负影响
图 1d	$\hat{\beta}_1(k)$ 和 $\hat{\beta}_2(k)$ 不稳定, 但其和大体稳定	X_1 对 Y 有正影响, X_2 对 Y 有负影响, $\hat{\beta}_1(0)$ 和 $\hat{\beta}_2(0)$ 符号相反	X_1, X_2 对 Y 都是正影响, X_1, X_2 有复共线关系, 只留一个变量就行, 对古典回归的符号相反提供解释
图 1e	把所有的岭迹描在一张图上, 岭迹不稳定, 系统较乱		有理由怀疑, 古典估计的回归系数是否反映真实情况。
图 1f	迹线平稳, 系统稳定		对古典回归的估计具有信心
图 1g	当 $k < k_0$ 时, 迹线较乱, 且不稳定, 当 $k > k_0$ 时迹线稳定		选择 k_0 , 以 $\hat{\beta}_j(k_0)$ 作为回归系数, 系数较稳定




图 1 岭迹图形

大小的,因为已作中心化和标准化处理;

(2) 去掉岭回归系数不稳定又随着 k 的增加迅速趋于零的变量;

(3) 去掉一个或若干个具有不稳定岭回归系数的变量,如果不稳定的岭回归系数很多,究竟去掉几个,去掉哪几个,并无一般规律可循,只有重新进行岭回归分析,由分析效果来决定。

应当指出:岭回归分析方法与由残差平方和作为指标的古典回归方法比较,在基本概念上是完全不同的两种方法。前者作出方程的残差平方和比后者要大些,复相关系数、剩余标准差要差一些,这一点是两者考虑的目标不同所致。

三、应用实例

针对气象业务中因子较多时,一开始用岭迹法来挑选因子,或许还带有主观性;同时

照顾到残差平方和,这一点从心理上常为人们所接受,所以我们先采用最优子集的方法确定因子,然后在众多的方程中用岭迹法来分析系数的稳定性,综合两者的优点,获得的方程较为满意。

我们在太湖平原春粮产量预报模式的究制中作了一些尝试^[2]。对 29 年样本输入 12 个因子进行最优子集回归和逐步回归两种方法的对比试验,两者确定的方程都作了岭迹分析。

12 个因子是: $X_1, X_4, X_5, X_1^2, X_3^2, X_1X_2, X_1X_4, X_2X_4, X_4X_5, X_3X_5, X_7X_9$ 。

X_1 : 上年 11 月至当年 2 月,四个月总雨量;

X_2 : 上年 10 月至当年 2 月下旬,旬雨量 $> 10 \text{ mm}$ 的旬数;

X_3 : 2 月上旬至 3 月中旬雨量;

X_4 : 2 月上旬至 3 月中旬日照;

X_5 : 1 月的平均气温;

X_6 : 2 月的最低气温;

X_7 : 3 月的最低气温;

X_8 : 3 月中旬的平均气温;

X_9 : 北半球极涡中心强度,上年 12 月至当年 2 月,三个月的累积值。

用最优子集确定的因子为:

3 个因子: X_1, X_5, X_1^2 (秩为 1)

4 个因子: X_1, X_5, X_1^2, X_3X_5 (秩为 1)

5 个因子: $X_1, X_4, X_4X_5, X_1X_4, X_7X_9$ (秩为 1)

逐步回归确定方程的因子为:

3 个因子: X_1^2, X_1X_4, X_7X_9 (秩为 2)

4 个因子: $X_1, X_1^2, X_1^3, X_7X_9$ (秩 > 5)

5 个因子: $X_1, X_1^2, X_4X_5, X_3X_5, X_7X_9$ (秩 > 5) 这里的秩指残差平方和从小到大排序的位置。对最优子集和逐步回归确定的 4 个因子的方程作岭迹分别见图 2、图 3。这两个岭迹都比较稳定,图 3 中 X_7X_9 因子的数值较小,作用不大,可以去掉这个因子。5 个因子的方程中上述两种方法都选进了 X_7X_9 因子,它的作用同样也不大,故 5 个因子的方程也不宜选用。

逐步回归建立的方程为:

$$y_w = 213.1 - 0.4647X_1 - 0.001607X_1^2 - 0.001978X_1^3 + 0.4337X_7X_9 \\ R = 0.87 \quad S_y = 26$$

最优子集建立的方程为:

$$y_w = 147.8 - 0.4593X_1 + 26.86X_5 - 0.001432X_1^2 - 0.1582X_3X_5 \\ R = 0.89 \quad S_y = 24.7$$

取 $k = 0.1$, 岭回归方程为:

$$y_w = 125.5 - 0.4134X_1 + 19.05X_5 - 0.001078X_1^2 - 0.1067X_3X_5$$

三个方程对 1983、1984、1985 年进行试报,1983 年相对误差分别为: 1.62%、3.69%、2.89%; 1984 年相对误差分别为: 18.8%、9.95%、7.38%; 1985 年相对误差分别为:




图2 最优子集确定方程的岭迹




图3 逐步回归确定方程的岭迹

7.86%、5.88%、4.00%。从试报三年来看,岭回归方程预报能力较强,且比较稳定。

四、讨 论

(1) 我们认为:对回归方程预测能力问题,仅用拟合的残差平方和来衡量预测能力的好坏是不够的,应该用多个目标函数来衡量,从最优子集方法建立的众多的方程中找出各项性能较好的方程来,这样的预测能力是会提高的,对方程进行岭迹分析是其中的手段之一。在以上的实例中 X_1, X_2 这个因子,在逐步回归建立的 3 个、4 个、5 个因子的方程中一直保留下来,显得很重要,但在岭迹图上反映出它并非十分重要。

(2) 在有的方程中岭迹不稳定,所建立的方程会产生单相关系数与回归系数符号相反的问题,这自然联想到偏相关系数,偏相关系数是由回归系数确定的,当因子间存在复共线关系时,回归系数的估计偏离较大,这时算出的偏相关系数是否会失去原有的意义?是否还可信?这些问题是值得进一步讨论的。

参 考 文 献

- [1] 陈希孺、王松桂编著,1984,近代实用回归分析,广西人民出版社。
- [2] Hocking, R. R., 1981, 回归变量最好子集的选择,《数字计算机上用的数学方法》第二篇,上海科学技术出版社。
- [3] 汪铮、俞善贤,1985,太湖平原春粮产量预报统计模式试验研究,浙江师范大学学报(自然科学版)第二期。