

## 最小一乘估计快速算法\*

吕书龙 刘文丽

(福州大学数学与计算机科学学院, 福州, 350108)

### 摘要

最小二乘估计容易受奇异点的影响, 最小一乘估计是稳健估计, 可以很好地克服这个缺陷, 但计算困难. 基于非退化模型假设下的稳定极点理论, 本文找到了快速准确求解最小一乘估计的迭代算法, 并给出算法的计算过程及与线性规划求解的比较, 较好地解决了最小一乘估计计算难的问题, 使其成为有效的参数估计方法.

关键词: 最小一乘估计, 最小二乘估计, 迭代算法.

学科分类号: O212.

### §1. 引言

考虑线性回归模型:

$$y_i = \alpha + b'x_i + \varepsilon_i, \quad i = 1, \dots, n, \quad (1.1)$$

其中 $x_i$ 为已知 $p-1$ 维列向量,  $x_i = (x_{i1}, \dots, x_{i(p-1)})'$ ,  $i = 1, \dots, n$ ;  $a, b$ 为待定参数,  $a \in R$ ,  $b = (b^{(1)}, \dots, b^{(p-1)})'$ 为维回归系数向量;  $e_1, \dots, e_n$ 独立且各中位数为零. 令 $t_i = (x_i', y_i)'$ ,  $i = 1, \dots, n$ 为 $p$ 维欧氏空间 $R^p$ 中的数据点, 记 $T = \{t_1, \dots, t_n\}$ 表示模型(1.1)的数据点集合.

最小一乘准则就是寻找回归超平面

$$y = a + b'x. \quad (1.2)$$

其中变量 $y \in R$ ,  $x = (x^{(1)}, \dots, x^{(p-1)})' \in R^p$ , 使得 $\sum_{i=1}^n |y_i - a - b'x_i|$ 达到最小. 令 $c = (a, b)'$ , 则目标函数为

$$f(c) = \sum_{i=1}^n |y_i - a - b'x_i| = \sum_{i=1}^n |y_i - \langle c, (1, x_i') \rangle|, \quad (1.3)$$

其中 $\langle \rangle$ 表示内积.

对最小一乘准则而言, 由于只考虑残差的一次方而非平方, 故所受异常点的影响就小得多, 因此最小一乘准则比最小二乘准则有更好的稳健性<sup>[1][6]</sup>. Charnds等把最小一乘估计的计算同线性规划联系起来, 实现了求解, 但是在样本量 $n$ 较大的时候, 转化成线性规划

\*福州大学科技发展基金资助(2005-XQ-17).

本文2005年10月27日收到, 2007年10月27日收到修改稿.

《应用概率统计》版权所有

时变量、附加变量及约束条件的个数急剧增加,工作量和计算量都大得惊人<sup>[2][3]</sup>,在19世纪20年代Fourier提出了类似单纯形法的迭代法<sup>[4]</sup>,但最小一乘的计算难题一直存在,本文的快速算法正好解决了上述计算难的问题.

## §2. 有关定义和引理

**引理 2.1**<sup>[2]</sup> 存在 $p$ 维向量 $c_0$ ,使

1. 由(1.3)式定义的函数 $f(c)$ ,在 $c = c_0$ 处达到最小.

2. 记 $r_i(c) = y_i - c'x_i$ ,  $W_c = \{t_i : 1 \leq i \leq n, r_i(c) = 0\}$ .  $W_{c_0}$ 中的向量张成的线性子空间就是 $t_1, \dots, t_n$ 所生成的线性子空间 $M(t_1, \dots, t_n)$ .

这就是1809年Gauss得到的定理.

若 $t_i \in W_{c_0}$ ,则超平面 $y = a_0 + b'_0x = a_0 + b_0^{(1)}x^{(1)} + \dots + b_0^{(p-1)}x^{(p-1)}$ 通过样本点 $t_i$ ,一般地 $M(t_1, \dots, t_n) =$ 全空间 $R^p$ .这时,由 $W_{c_0}$ 生成 $M(t_1, \dots, t_n)$ 可知, $W_{c_0}$ 中至少包含 $p$ 个样本点,即超平面 $y = a_0 + b'_0x$ 至少通过 $p$ 个样本点.这个引理同时揭示了最小一乘与最小二乘的一个重大差别,即最小一乘回归超平面一定通过 $p$ 个样本点.曾有人据此认为最小一乘不好,因为它在全部 $n$ 个样本点中,只用了 $p$ 个.其实不然,因为究竟用哪 $p$ 个样本点,要由全体 $n$ 个样本点来决定.

设 $c \in R^p$ ,记 $r_i(c) = y_i - c'x_i$ ,  $Z_c = \{i : r_i(c) = 0\}$ ,  $|Z_c|$ 表示集合 $Z_c$ 中元素的个数.

**定义 2.1** 如果 $\dim\{t_i, i \in Z_c\} = p$ ,则称 $c \in R^p$ 为极点.显然此时 $|Z_c| \geq p$ .若 $|Z_c| > p$ ,则称 $c$ 为退化极点;否则若 $|Z_c| = p$ ,则称 $c$ 为非退化极点.

**定义 2.2** 记 $M = \{c \in R^p : f(c) \leq f(d), \forall d \in R^p\}$ ,极点 $c \in M$ 时,称 $c$ 为最优极点.显然最优极点就是模型(1.1)的最小一乘估计.

**定义 2.3** 若模型(1.1)中所有极点都是非退化极点,则称模型(1.1)是非退化的,否则称其是退化的.

本文就是要在模型(1.1)非退化的情况下讨论最优极点的求解.

对于欧式空间 $R^p$ 中的任意 $p$ 个数据点,不妨设为 $t_1, \dots, t_p$ ,若矩阵

$$((1, x'_i)', \dots, (1, x'_p)')' = \begin{bmatrix} 1 & x_{11} & \cdots & x_{1(p-1)} \\ \vdots & \vdots & \vdots & \vdots \\ 1 & x_{p1} & \cdots & x_{p(p-1)} \end{bmatrix}$$

可逆,将数据点 $t_1, \dots, t_p$ 坐标代入(1.2)式,可得通过它们的超平面为 $y = a + b'x$ ,其中

$$c = (a, b') = \varphi(t_1, \dots, t_p) = \begin{bmatrix} 1 & x_{11} & \cdots & x_{1(p-1)} \\ \vdots & \vdots & \vdots & \vdots \\ 1 & x_{p1} & \cdots & x_{p(p-1)} \end{bmatrix}^{-1} \begin{pmatrix} y_1 \\ \vdots \\ y_p \end{pmatrix}, \quad (2.1)$$

其中函数 $\varphi(t_1, \dots, t_p)$ 表示为覆盖数据点 $t_1, \dots, t_p$ 的超平面的系数向量, 显然它是极点. 此时残差绝对值之和 $f(c)$ 也是关于数据点 $t_1, \dots, t_p$ 的函数, 设为 $g(t_1, \dots, t_p)$ , 即

$$g(t_1, \dots, t_p) = \sum_{i=1}^n |y_i - \langle \varphi(t_1, \dots, t_p), x_i \rangle|. \quad (2.2)$$

易见作用在数据点集合 $T$ 上的函数 $g$ 与 $t_1, \dots, t_p$ 的排列顺序无关. 若 $((1, x'_1)', \dots, (1, x'_p)')$ 不可逆, 不妨令 $g(t_1, \dots, t_p) = \infty$ .

**引理 2.2**<sup>[5]</sup> 对于模型(1.1), 若 $p$ 个数据点 $t_{i_1}, \dots, t_{i_p} \in T$ 满足

$$g(t_{i_1}, \dots, t_{i_p}) = \min_{t_{j_1}, \dots, t_{j_p} \in T} g(t_{j_1}, \dots, t_{j_p}), \quad (2.3)$$

则 $c^* = \varphi(t_{i_1}, \dots, t_{i_p})$ 就是回归系数 $c$ 的最小一乘估计, 即最优极点.

显然遍历数据点集合 $T$ , 可得到满足式(2.3)的 $p$ 个数据点. 但是这样搜寻的计算量很大, 需要对 $n$ 个数据点中的任意 $p$ 个点计算回归系数及残差绝对值之和, 共有 $C_n^p$ 种组合方式, 可想而知当 $n$ 很大时, 计算量将异常之大.

**定义 2.4** 在线性回归模型(1.1)中若 $p$ 个数据点 $t_{i_1}, \dots, t_{i_p} \in T$ 满足

$$g(t_{i_1}, \dots, t_{i_p}) = \min_{t_k \in T} g(t_{i_1}, \dots, t_{i_{j-1}}, t_k, t_{i_{j+1}}, \dots, t_{i_p}), \quad j = 1, \dots, p, \quad (2.4)$$

则称 $c^0 = \varphi(t_{i_1}, \dots, t_{i_p})$ 为稳定极点.

**引理 2.3**<sup>[5]</sup> 对于非退化的模型(1.1),  $c^* \in R^p$ 是最优极点当且仅当 $c^*$ 是稳定极点.

由引理2.3知, 模型(1.1)的稳定极点就是最优极点, 即回归系数的最小一乘估计, 因此只要找到模型(1.1)的稳定极点, 就解决了求解最小一乘估计的问题. 下面是求解稳定极点的迭代算法.

### §3. 稳定极点的迭代算法描述

若回归模型(1.1)中只含一个自变量的情况, 即 $p = 1$ 时, 我们要寻找 $a, b$ 使目标函数(1.3)式达到最小. 下面先介绍两种特殊情况.

1. 假定 $b = 0$ , 求 $a$ .

把 $y_1, y_2, \dots, y_n$ 按由小到大的次序排列为:  $y_{(1)}, y_{(2)}, \dots, y_{(n)}$ , 可以证明: 若 $n$ 为奇数, 则 $y_{(n+1)/2}$ 是使目标函数 $\sum_{i=1}^n |y_i - a|$ 达到最小的唯一解; 若 $n$ 为偶数, 则区间 $[y_{n/2}, y_{n/2+1}]$ 内任一数都是该最小一乘问题的解.

2. 假定 $a = 0$ , 求 $b$ .

此时最小一乘准则就是使表达式 $\sum_{i=1}^n |y_i - b'x_i|$ 达到最小. 这是一个配过原点的回归直线问题. 不妨可设 $x_i \neq 0, i = 1, \dots, n$ . 计算 $y_i/x_i, \dots, y_n/x_n$ , 把它们按由小到大的次

序排列为  $y_{(1)}/x_{(1)} \leq y_{(2)}/x_{(2)} \leq \cdots \leq y_{(n)}/x_{(n)}$ . 令  $M = \sum_{i=1}^n |x_i|$ , 计算  $M_1 = |x_{(i)}|$ ,  $M_2 = |X_{(1)}| + |X_{(2)}|$ , 直到  $M_i = \sum_{j=1}^i |x_{(j)}|$ , 满足  $M_i \geq M/2$ . 可以证明  $y_{(i)}/x_{(i)}$  就是回归系数  $b$  的最小一乘估计. 详细证明过程见参考文献[1].

下面再介绍模型(1.1)稳定极点的求解方法.

1. 任意给出初始  $p$  个数据点  $t_1^{(1)}, t_2^{(1)}, \cdots, t_p^{(1)}$ ;
2. 固定  $t_2^{(1)}, \cdots, t_p^{(1)}$ , 在剩余的  $n - p + 1$  个点中寻找  $t_1^{(2)}$  使

$$g(t_1^{(2)}, t_2^{(1)}, \cdots, t_p^{(1)}) = \min_{t_i \in T} g(t_i, t_2^{(1)}, \cdots, t_p^{(1)});$$

固定  $t_1^{(2)}, t_3^{(1)}, \cdots, t_p^{(1)}$ , 在剩余的  $n - p + 1$  个点中寻找  $t_2^{(2)}$  使

$$g(t_1^{(2)}, t_2^{(2)}, t_3^{(1)}, \cdots, t_p^{(1)}) = \min_{t_i \in T} g(t_1^{(2)}, t_i, t_3^{(1)}, \cdots, t_p^{(1)});$$

同理, 依次找到  $t_3^{(2)}, \cdots, t_p^{(2)}$ , 且显然有

$$g(t_1^{(2)}, \cdots, t_{i-1}^{(2)}, t_i^{(2)}, t_{i+1}^{(1)}, \cdots, t_p^{(1)}) \leq g(t_1^{(2)}, \cdots, t_{i-1}^{(2)}, t_i^{(1)}, \cdots, t_p^{(1)}), \quad i = 1, \cdots, p,$$

$$g(t_1^{(2)}, \cdots, t_p^{(2)}) \leq g(t_1^{(1)}, \cdots, t_p^{(1)});$$

3. 若  $\forall i = 1, \cdots, p$ , 有  $t_i^{(1)} = t_i^{(2)}$ , 则迭代结束. 不然, 转到步骤2继续寻找数据点  $t_1^{(3)}, t_2^{(3)}, \cdots, t_p^{(3)}$ , 并产生数据点组合序列  $\{(t_1^{(i)}, \cdots, t_p^{(i)}) | i = 1, 2, \cdots\}$  及相应残差绝对值和序列  $\{g(t_1^{(i)}, \cdots, t_p^{(i)}) | i = 1, 2, \cdots\}$ .

#### §4. 稳定极点求解迭代算法的证明

**定理 4.1** 述迭代过程产生的数据点组合序列  $\{(t_1^{(i)}, \cdots, t_p^{(i)}) | i = 1, 2, \cdots\}$  及相应的残差绝对值之和序列  $\{g(t_1^{(i)}, \cdots, t_p^{(i)}) | i = 1, 2, \cdots\}$  均为有限序列, 分别为  $\{(t_1^{(i)}, \cdots, t_p^{(i)}) | i = 1, 2, \cdots, k\}$ ,  $\{g(t_1^{(i)}, \cdots, t_p^{(i)}) | i = 1, 2, \cdots, k\}$ , 其中  $k \leq C_n^p$ ; 且  $(t_1^{(k)}, \cdots, t_p^{(k)})$  满足式(2.4), 即  $\varphi(t_1^{(k)}, \cdots, t_p^{(k)})$  为稳定极点.

**证明:** 根据迭代过程, 数据点  $t_j^{(i)}$ ,  $j \in 1, \cdots, p$ , 满足

$$g(t_1^{(i)}, \cdots, t_{j-1}^{(i)}, t_j^{(i)}, t_{j+1}^{(i-1)}, \cdots, t_p^{(i-1)}) = \min_{t_k \in T} g(t_1^{(i)}, \cdots, t_{j-1}^{(i)}, t_k, t_{j+1}^{(i-1)}, \cdots, t_p^{(i-1)}),$$

则显然

$$g(t_1^{(i)}, \cdots, t_{j-1}^{(i)}, t_j^{(i)}, t_{j+1}^{(i-1)}, \cdots, t_p^{(i-1)}) \leq g(t_1^{(i)}, \cdots, t_{j-1}^{(i)}, t_j^{(i-1)}, \cdots, t_p^{(i-1)}),$$

从而

$$g(t_1^{(i)}, \dots, t_p^{(i)}) \leq g(t_1^{(i-1)}, \dots, t_p^{(i-1)}).$$

另外存在  $p$  个数据点满足 (2.3) 式, 则序列  $g(t_1^{(i)}, \dots, t_p^{(i)})$  单调减小且有下界, 则序列  $g(t_1^{(i)}, \dots, t_p^{(i)})$  收敛. 且数据点集合  $T$  中仅有  $C_n^p$  种不同数据点组合方式, 因此存在  $1 \leq k \leq C_n^p$ , 使

$$t_i^{(k)} = t_i^{(k+1)}, \quad i = 1, 2, \dots, p,$$

即迭代结束, 定理得证.  $\square$

事实上, 由算法描述过程及定理 4.1 易知, 算法产生的数据点组合序列

$$\{(t_1^{(i)}, \dots, t_p^{(i)}), (t_1^{(i+1)}, t_2^{(i)}, \dots, t_p^{(i)}), \dots, (t_1^{(i+1)}, \dots, t_p^{(i+1)}) | i = 1, 2, \dots\},$$

其中只要连续有  $p$  个数据点组合完全相同, 该序列就已经收敛了, 迭代便可结束.

下面说明已知  $p-1$  个数据点  $t_{i_1}, \dots, t_{i_{p-1}} \in T$ , 如何在剩余  $n-p+1$  个数据点中寻找一个样本点  $t_{i_p}$  使它们组合后回归效果最佳, 即回代残差绝对值和最小的方法, 即该点  $t_{i_p}$  满足

$$g(t_{i_1}, \dots, t_{i_{p-1}}) = \min_{t_j \in T} g(t_{i_1}, \dots, t_{i_{p-1}}). \quad (4.1)$$

显然遍历数据点集合  $T$  就可找到  $t_{i_p} \in T$ , 事实上并不需要遍历集合  $T$  就可找到满足 (4.1) 式极值条件的数据点  $t_{i_p}$ , 其计算过程见定理 4.2 证明.

**定理 4.2** 对于回归模型 (1.1), 任意不同在  $p-1$  维欧氏空间的数据点  $t_{i_1}, \dots, t_{i_{p-1}} \in T$ ,  $\{c_a \in R^p, a \in A\}$  是所有回归系数  $c$  的估计类且满足:

$$\{t_{i_1}, \dots, t_{i_{p-1}}\} \subseteq Z_{c_a}, \quad (4.2)$$

则存在估计  $c_{a^*}$ ,  $a^* \in A$  满足

$$(1) \quad f(c_{a^*}) \leq f(c_a), \quad a \in A; \quad (4.3)$$

$$(2) \quad \text{存在数据点 } t_{i_p} \in Z_{c_{a^*}}, \text{ 且 } t_{i_p} \notin \{t_{i_1}, \dots, t_{i_{p-1}}\}. \quad (4.4)$$

**证明:** 由于  $\{t_{i_1}, \dots, t_{i_{p-1}}\} \subseteq Z_{c_a}$ , 即超平面为  $y = a_a + b'_a x$  通过样本点  $t_{i_1}, \dots, t_{i_{p-1}}$ , 且因为它们不同在任意  $p-1$  维欧氏空间, 也就是  $(x_{i_1}, \dots, x_{i_{p-1}})'$  可逆, 则计算可得

$$b_a = [(x_{i_1}, \dots, x_{i_{p-1}})']^{-1} [(y_{i_1}, \dots, y_{i_{p-1}})' - a_a(1, \dots, 1)'].$$

令  $\gamma = [(x_{i_1}, \dots, x_{i_{p-1}})']^{-1} (y_{i_1}, \dots, y_{i_{p-1}})'$ ,  $\beta = [(x_{i_1}, \dots, x_{i_{p-1}})']^{-1} (1, \dots, 1)'$ , 则有

$$b_a = \gamma - a_a \beta.$$

从而回归方程为

$$y = a_a + \gamma'x - a_a\beta'x = \gamma'x + a_a(1 - \beta'x).$$

残差绝对值之和为

$$f(c_a) = \sum_{i=1}^n |y_i - \gamma'x_i - a_a(1 - \beta'x_i)|. \quad (4.5)$$

上式中 $f(c_a)$ 是仅关于参数 $a_a$ 的函数, 令

$$Y_i = y_i - \gamma'x_i, \quad X_i = 1 - \beta'x_i, \quad i = 1, \dots, n. \quad (4.6)$$

显然 $a_a$ 是最小一乘估计的解, 即是回归模型(1.1)中 $p = 1, a = 0$ 的情况. 定理得证.  $\square$

求解过程: 先计算 $Y_i$ 与 $X_i$ 的比值

$$l_i = \frac{Y_i}{X_i} = \frac{y_i - \gamma'x_i}{1 - \beta'x_i}, \quad i = 1, \dots, n;$$

将它们从小到大排列为:  $l_{(1)} \leq l_{(2)} \leq \dots \leq l_{(n)}$ ; 计算 $M = \sum_{i=1}^n |1 - \beta'x_i|$ ,  $M_i = \sum_{j=1}^i |X_{(j)}|$ ,  $i = 1, 2, \dots$ , 其中 $X_{(j)}$ 序列为 $X_i$ 序列随 $l_{(i)}$ 的重排, 直到达到某个 $i_0$ 使得 $M_{i_0} \geq M/2$ , 则 $a_a = l_{(i_0)}$ 使(4.5)式达到最小, 即找到 $t_{i_p} = t_{i_0} \in T$ , 则

$$a_{a^*} = \frac{y_{i_p} - \gamma'x_{i_p}}{1 - \beta'x_{i_p}}, \quad c_{a^*} = (a_{a^*}, \gamma' - a_{a^*}\beta'), \quad (4.7)$$

使 $f(c_{a^*}) \leq f(c_a)$ ,  $a \in A$ , 且 $t_{i_p} \in Z_{c_{a^*}}$ .

定理4.2的证明过程说明了已知 $p-1$ 个数据点 $t_{i_1}, \dots, t_{i_{p-1}} \in T$ , 如何在剩余 $n-p+1$ 个数据点中寻找一个样本点 $t_{i_p}$ 使回代残差绝对值和达到最小的方法, 使得本算法更加简单可行.

## §5. 计算过程演示及与线性规划求解的比较

### 5.1 计算过程演示

以任意 $p$ 个数据点作为本算法的初始点组进行迭代, 都能快速准确地得到最小一乘估计解, 下面通过一个随机数据演示本算法的求解过程. 以下数据中 $p = 3$ , 不妨取 $(t_1, t_2, t_3)$ 作为初始点组.

表1 随机数据

数据点	$t_1$	$t_2$	$t_3$	$t_4$	$t_5$	$t_6$
$x_1$	1	2	3	4	5	6
$x_2$	1	3	2	1	3	2
$y$	1	4	3	3	5	5

(1) 去掉点组中的第一个点 $t_1$ , 得到

$$\hat{X} = \begin{bmatrix} 2 & 3 \\ 3 & 2 \end{bmatrix}, \quad \hat{X}^{-1} = \begin{bmatrix} -0.4 & 0.6 \\ 0.6 & -0.4 \end{bmatrix}, \quad \hat{Y} = \begin{bmatrix} 4 \\ 3 \end{bmatrix},$$

然后在剩下的四个点( $t_1, t_4, t_5, t_6$ )中根据(4.6)式计算:

表2 第一步迭代

数据点	$t_1$	$t_4$	$t_5$	$t_6$
$X_i$	0.6	0	-0.6	-0.6
$Y_i$	-0.4	1	0.4	1.4
$l_i$	-2/3	$\infty$	-2/3	-7/3

依据定理4.2求解过程可找到样本点 $t_5$ 或 $t_1$ , 可将点 $t_5$ 替换掉 $t_1$ , 得到新的点组( $t_5, t_2, t_3$ ).

(2) 去掉点组中的第二个点 $t_2$ , 得到

$$\hat{X} = \begin{bmatrix} 5 & 3 \\ 3 & 2 \end{bmatrix}, \quad \hat{X}^{-1} = \begin{bmatrix} 2 & -3 \\ -3 & 5 \end{bmatrix}, \quad \hat{Y} = \begin{bmatrix} 5 \\ 3 \end{bmatrix},$$

再在剩下的四个点( $t_1, t_2, t_4, t_6$ )中根据(4.6)式计算:

表3 第二步迭代

数据点	$t_1$	$t_2$	$t_4$	$t_6$
$X_i$	0	-3	3	3
$Y_i$	0	2	-1	-1
$l_i$	$\infty$	-2/3	-1/3	-1/3

依据定理4.2求解过程可找到 $t_4$ , 将其替换掉点组中的第2点, 得到新的点组( $t_5, t_4, t_3$ ). 特别地这里的 $Y_i/X_i$ 从小到大的排序方式有两种即点(2,4,6,1)和点(2,6,4,1), 任选一种都可以.

(3) 去掉点组中的第三个点 $t_3$ , 得到

$$\hat{X} = \begin{bmatrix} 5 & 3 \\ 4 & 1 \end{bmatrix}, \quad \hat{X}^{-1} = \begin{bmatrix} -1/7 & 3/7 \\ 4/7 & -5/7 \end{bmatrix}, \quad \hat{Y} = \begin{bmatrix} 5 \\ 3 \end{bmatrix},$$

然后在剩下的四个点( $t_1, t_2, t_3, t_6$ )中根据(4.6)式计算:

表4 第三步迭代

数据点	$t_1$	$t_2$	$t_3$	$t_6$
$X_i$	6/7	6/7	3/7	-3/7
$Y_i$	-2/7	5/7	-1/7	1/7
$l_i$	-1/3	5/6	-1/3	-1/3

依据定理4.2可找到 $t_3$ , 将其替换点组中的第3点, 得到新的点组 $(t_5, t_4, t_3)$ . 此处 $Y_i/X_i$ 从小到大的排序方式有6种点序:  $(1,3,6,2)$ ,  $(1,6,3,2)$ ,  $(3,1,6,2)$ ,  $(3,6,1,2)$ ,  $(6,1,3,2)$ 和 $(6,3,1,2)$ .

这样一轮迭代完成, 但这一轮中的点组不完全相同. 所以必须进行下一轮迭代, 继续从第一个点 $t_5$ 开始. 接下来依次找到 $(t_5, t_4, t_3) \rightarrow (t_5, t_4, t_3)$ , 而该点组在点组序列中连续出现了3次, 由于 $p = 3$ , 故认为迭代结束, 取 $(t_5, t_4, t_3)$ 作为最终的解点组.

表5 算法给出的表1数据的最小一乘估计

有效的解点组	$(t_1, t_3, t_4, t_5, t_6)$ 中任取3个都可构成解点组
回归系数	$\beta^* = (-0.333333, 0.666667, 0.666667)$ 残差绝对值和 = 1.000000
超平面方程	$y = -0.333333 + 0.666667x_1 + 0.666667x_2$ (保留六位小数)

## 5.2 利用线性规划进行最小一乘的求解<sup>[2]</sup>

易知最小一乘估计的目标函数为

$$\min f(\beta) = \sum_{i=1}^n |y_i - a - b'x_i| = \sum_{i=1}^n |y_i - \beta'z_i|,$$

其中 $\beta = (a, b)'$ ,  $z_i = (1, x_i)'$ ,  $i = 1, \dots, n$ ; 向量 $\beta$ 可表示成 $d - e$ 的形式, 即 $\beta_i = d_i - e_i$ , 其中 $d, e$ 各分量都非负, 即 $d_i \geq 0, e_i \geq 0$ . 引进如下矩阵、向量:

$$A = \begin{pmatrix} z'_1 \\ \vdots \\ z'_n \end{pmatrix}, \quad B = \begin{pmatrix} I_n & A & -A \\ I_n & -A & A \end{pmatrix},$$

$$y = \begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix}, \quad r = \begin{pmatrix} r_1 \\ \vdots \\ r_n \end{pmatrix}, \quad l = \begin{pmatrix} 1 \\ \vdots \\ 1 \end{pmatrix}, \quad 0 = \begin{pmatrix} 0 \\ \vdots \\ 0 \end{pmatrix},$$

其中 $I_n$ 为 $n$ 阶单位矩阵,  $y, r, l, 0$ 为 $n$ 维向量. 可得最小一乘估计的线性规划问题:

$$\text{目标函数: } \min(l', 0', 0') \begin{pmatrix} r \\ d \\ e \end{pmatrix} = \min \sum_{i=1}^n r_i, \quad \text{约束条件 St: } \begin{cases} B \begin{pmatrix} r \\ d \\ e \end{pmatrix} \geq \begin{pmatrix} y \\ -y \end{pmatrix} \\ \begin{pmatrix} r \\ d \\ e \end{pmatrix} \geq 0 \end{cases}.$$

一旦解得 $r, d, e$ 的值, 则回归系数 $\beta = d - e$ 就可确定, 它就是使最小一乘估计目标函数 $f(\beta)$ 达到最小的解, 且该目标函数的最小值就是 $\sum_{i=1}^n r_i$ .

表6 采用线性规划软件Lindo6.01的计算程序和结果

Min R1+R2+R3+R4+R5+R6	LP OPTIMUM FOUND AT STEP 4		
st	OBJECTIVE FUNCTION VALUE 1.000000		
R1+D1+1D2+1D3-E1-1E2-1E3 >= 1	VARIABLE	VALUE	REDUCED COST
R2+D1+2D2+3D3-E1-2E2-3E3 >= 4	R1	0.000000	1.000000
R3+D1+3D2+2D3-E1-3E2-2E3 >= 3	R2	1.000000	0.000000
R4+D1+4D2+1D3-E1-4E2-1E3 >= 3	R3	0.000000	0.000000
R5+D1+5D2+3D3-E1-5E2-3E3 >= 5	R4	0.000000	1.000000
R6+D1+6D2+2D3-E1-6E2-2E3 >= 5	R5	0.000000	0.000000
R1-D1-1D2-1D3+E1+1E2+1E3 >= -1	R6	0.000000	0.000000
R2-D1-2D2-3D3+E1+2E2+3E3 >= -4	D1	0.000000	0.000000
R3-D1-3D2-2D3+E1+3E2+2E3 >= -3	D2	0.666667	0.000000
R4-D1-4D2-1D3+E1+4E2+1E3 >= -3	D3	0.666667	0.000000
R5-D1-5D2-3D3+E1+5E2+3E3 >= -5	E1	0.333333	0.000000
R6-D1-6D2-2D3+E1+6E2+2E3 >= -5	E2	0.000000	0.000000
End	E3	0.000000	0.000000
回归系数 $\beta^* = (D1-E1, D2-E2, D3-E3)$	(-0.333333, 0.666667, 0.666667)		
残差绝对值和	1.00000		

经比较, 本算法和线性规划得到的结果完全相同. 但线性规划求解最小一乘估计问题需设置 $n + 2p$ 个变量和 $3n + 2p$ 个约束条件, 当 $n(p)$ 较大时变得极其繁琐且有可能难以计算. 若用穷举搜索法, 需针对 $C_n^p$ 种点组组合求解 $\hat{\beta}$ 并计算和比较目标函数值 $f(\hat{\beta})$ , 同样当 $n(p)$ 较大时, 计算量极其巨大, 几乎无法计算; 而本文算法无变量和约束条件的限制, 在计算量上也大大减少, 且易于编程实现, 具备可行性, 准确性和快速性.

在退化模型前提下, 如何快速找出构成最小一乘超平面的所有点组, 以及这些特殊的点组的应用有待进一步的研究.

作者对审稿专家提出的修改建议表示衷心的感谢.

### 参 考 文 献

- [1] 陈希孺, 最小一乘线性回归(上), 数理统计与管理, 1989(5)(1989), 48-55.
- [2] 陈希孺, 最小一乘线性回归(下), 数理统计与管理, 1989(6)(1989), 48-55.
- [3] 谢开贵, 宋乾坤, 周家启, 最小一乘线性回归模型研究, 系统仿真学报, 14(2)(2002), 99-102.

- [4] Fisher, W.D., A note on curve fitting with minimum deviations by linear programming, *Journal of American Statistical Association*, **56**(1961), 359–361.
- [5] 刘文丽, 吕书龙, 最小一乘估计的几个性质, 福州大学学报(自然科学版), **32**(4)(2004), 442–444.
- [6] 周秀轻, 王金德, 随机删失数据非线性回归模型的最小一乘估计, 中国科学A辑(数学), **35**(4)(2005), 387–403.
- [7] Bloomfield, P., Steiger, W.L., *Least Absolute Deviation: Theory, Application and Algorithms*, Birkhäuser, Boston, 1983.

## Quick Algorithm for Least Absolute Deviation Estimator

LU SHULONG      LIU WENLI

(College of Mathematics and Computer Science, Fuzhou University, Fuzhou, 350108)

Least square estimator (LSE) is disturbed easily by singular point; least absolute deviation estimator (LADE) can overcome the influence of singular point, but it is difficult in calculation. A convergent algorithm for LADE based on the stable pole theorem of LADE under non-degenerate model is obtained in this paper. The progress of algorithm and comparison of linear programming are derived. Further this algorithm makes LADE more effective.

**Keywords:** Least absolute deviation, least square, convergent algorithm.

**AMS Subject Classification:** 62G35, 65C60.