

点到直线距离与垂线距离的平方和最小法在直线回归中的研究

1 垂线距离最小二乘法原理

最小二乘法（又称最小平方法）是一种数学优化技术，于19世纪初由勒让德和高斯分别独立提出。

现以一元线性回归为例。设有一组试验数据 $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ ，欲寻求线性函数（理论分析证明二者存在线性相关性）： $y = ax + b$ 。式中 a, b 均为待常数。现行的最小二乘法理论认为，只要 RSS(residual sum of squares) 最小，则 a, b 即为最佳拟合。简化为

$$Q = \sum [y_i - ax_i - b]^2 \quad (1)$$

最小。

对式 (1) 求偏导并另偏导为0，则

$$\begin{aligned} \frac{\partial Q}{\partial a} &= -2 \sum (y_i - ax_i - b)x_i = 0 \\ \frac{\partial Q}{\partial b} &= -2 \sum y_i - ax_i - b = 0 \end{aligned}$$

即

$$\begin{aligned} a \sum x_i^2 + b \sum x_i &= \sum x_i y_i \\ a \sum x_i + nb &= \sum y_i \end{aligned}$$

该一元二次方程解得 $a = l_{xy}/l_{xx}$, $b = \bar{y} - a\bar{x}$.

式中 $l_{xy} = \sum (x_i - \bar{x})(y_i - \bar{y}) = \sum x_i y_i - \frac{1}{n} \sum x_i \sum y_i$, $l_{xx} = \sum (x_i - \bar{x})^2 = \sum x_i^2 - \frac{1}{n} (\sum x_i)^2$.

2. 点到直线最小二乘法原理

由点到直线距离公式 $d_i = |y_i - ax_i - b|/\sqrt{1 + a^2}$, 转化为对 $Q = \sum d_i^2$ 求最小。则

$$\frac{\partial Q}{\partial a} = -2 \sum x_i (y_i - ax_i - b)/(1 + a^2) - 2a(ax_i - y_i + b)^2/(1 + a^2)^2 = 0 \quad (2)$$

$$\frac{\partial Q}{\partial b} = -2 \sum \frac{y_i - ax_i - b}{1 + a^2} = 0 \quad (3)$$

由 3 式可计算得

$$a \sum x_i + nb = \sum y_i, \quad b = \bar{y} - a\bar{x}. \quad (4)$$

平均点 (\bar{x}, \bar{y}) 落在拟合曲线上。

把 4 式代入 2 式，最后得

$$a^2 l_{xy} + a(l_{xx} - l_{yy}) - l_{xy} = 0 \quad (5)$$

上式为关于 a 的一元二次方程，可解其根形式为：

$$a_2 = \frac{(l_{yy} - l_{xx}) \pm \sqrt{(l_{yy} - l_{xx})^2 + 4l_{xy}^2}}{2l_{xy}} \quad (6)$$

分析当倾角为锐角， $a_2 > 0$ ，式 6 中取“+”有效；

当倾角为钝角， $a_2 < 0$ ，式 6 中取“+”有效；

因此

$$a_2 = \frac{(l_{yy} - l_{xx}) + \sqrt{(l_{yy} - l_{xx})^2 + 4l_{xy}^2}}{2l_{xy}} \quad (7)$$

代入式 4 可得 b_2 .

3. 实例对比

使用程序软件：R

数据集S1: 100个数据点，符合曲线 $y = 2x + 1$ 变化趋势，考虑数据的正常误差是影响因素(包括操作人员、机械等)的微小变化造成的,这类误差即随机误差，往往呈现正态分布，因此加一个正态随机偏差，符合 $N(0, 5)$ 分布。

数据集合S2: 100个数据点，符合曲线 $y = 100x + 50$ 变化趋势，采用S1类似偏差，符合 $N(0, 500)$ 分布。

数据集合S3：在S1基础上加5个噪点，噪点在可行域内均匀分布.

用两种方法对以上数据集进行拟合，拟合结果如下表1所示：

表1 拟合结果参数表

数据集	相关系数	a_1	a_2	b_1	b_2
S1	0.9968362	1.998968	2.009143	0.7784571	0.7784571
S2	0.9732198	100.5679	103.3350	69.89993	-69.83708
S3	0.9044248	1.897437	0.4766561	7.381926	-0.6093772

用r生成图像如下所示：

fitting of two methods




图1.S1图像

fitting of two methods

fitting of two methods




图2.S2图像取不同坐标




图3. S3图像

由上可知，当2个变量试验数据间线性相关系数靠近1时，差别不大，当相关系数较小，偏离度变大。