

究竟谁是回归直线的方程

花大庆

(安徽省泾县二中, 242500)

问题 某 5 名学生的数学和化学成绩如下表:

数学成绩 x	88	76	73	66	63
化学成绩 y	78	65	71	64	61

若 x, y 成线性相关, 求: (1) y 对 x 的线性回归方程; (2) x 对 y 的线性回归方程.

解 (1) 设 y 对 x 的线性回归方程为

$$\hat{y} = \hat{b}_1 x + \hat{a}_1.$$

$$\therefore \bar{x} = \frac{1}{5} \times (88 + 76 + 73 + 66 + 63) = 73.2,$$

$$\bar{y} = \frac{1}{5} \times (78 + 65 + 71 + 64 + 61) = 67.8,$$

$$\sum_{i=1}^5 x_i y_i = 88 \times 78 + 76 \times 65 + 73 \times 71 + 66 \times 64 + 63 \times 61 = 25054,$$

$$\sum_{i=1}^5 x_i^2 = 88^2 + 76^2 + 73^2 + 66^2 + 63^2 = 27174,$$

$$\therefore \hat{b}_1 = \frac{\sum_{i=1}^5 x_i y_i - 5 \bar{x} \bar{y}}{\sum_{i=1}^5 x_i^2 - 5 \bar{x}^2} = \frac{25054 - 5 \times 73.2 \times 67.8}{27174 - 5 \times 73.2^2}$$

$$\approx 0.62,$$

$$\therefore \hat{a}_1 = \bar{y} - \hat{b}_1 \bar{x} = 67.8 - 0.62 \times 73.2 = 22.42.$$

所以 y 对 x 的线性回归方程为

$$\hat{y} = 0.62x + 22.42.$$

(2) 解法一:

设 x 对 y 的线性回归方程为 $\hat{x} = \hat{b}_2 y + \hat{a}_2$.

$$\therefore \sum_{i=1}^5 y_i = 78^2 + 65^2 + 71^2 + 64^2 + 61^2 = 23167,$$

$$\therefore \hat{b}_2 = \frac{\sum_{i=1}^5 x_i y_i - 5 \bar{x} \bar{y}}{\sum_{i=1}^5 y_i^2 - 5 \bar{y}^2} = \frac{25054 - 5 \times 73.2 \times 67.8}{23167 - 5 \times 67.8^2}$$

$$\approx 1.31.$$

$$\hat{a}_2 = \bar{x} - \hat{b}_2 \bar{y} = 73.2 - 1.31 \times 67.8 = -15.62.$$

所以 x 对 y 的线性回归方程为

$$\hat{x} = 1.31y + 15.62 \quad (\text{I})$$

课堂教学时, 有学生认为问题(2)有更简单的解法.

解法二:

由问题(1)的结论, 得

$$x = \frac{\hat{y} - 22.42}{0.62} = 1.61\hat{y} - 36.16 \quad (\text{II})$$

所以 x 对 y 的线性回归方程为

$$\hat{x} = 1.61y - 36.16 \quad (\text{II})$$

方程(I)(II)明显不同, 到底哪个才是 x 对 y 的线性回归方程呢? 解法一和解法二哪个正确?

很简单! 只需比较方程(I)(II)的残差平方和的大小, 即可判断方程(I)(II)哪个方程拟合效果更好.

记由方程(I)得到各 x 的估计值为 $\hat{x}_I$, 由方程(II)得到各 x 的估计值为 $\hat{x}_{II}$, 则由方程(I)(II)得到的残差平方和分别为 $(\sum_{i=1}^5 \hat{x}_I - x)^2$ 、 $\sum_{i=1}^5 (\hat{x}_{II} - x)^2$.

列表如下:

y	78	65	71	64	61
x	88	76	73	66	63
$\hat{x}_I$	86.56	69.53	77.39	68.22	64.29
$\hat{x}_{II}$	89.42	68.49	78.15	66.88	62.05
$(x - \hat{x}_I)^2$	2.07	41.86	19.27	4.93	1.66
$(x - \hat{x}_{II})^2$	2.02	56.40	26.52	0.77	0.90

$$\therefore \sum_{i=1}^5 (\hat{x}_I - x)^2 = 69.80, \quad \sum_{i=1}^5 (\hat{x}_{II} - x)^2 = 86.61.$$

显然, 方程(I)的残差平方和较小.

结论: 通过方程(I), 由 y 的值估计 x 的值回归效果更好; 以上问题(2)的解法一正确, 而解法二是错误的.

解法二错在何处? 通

过图 1, 可以作出几何上的解释. 虽然回归直线 $l: y = bx + a$ 使得各散点 $P_i (i = 1, 2, 3, \dots, n)$ 到它的“竖直距离”和最小, 但未必能使各散点到它的“水平距离”和最小. 例如, 上




图 1

图中, 点 $P_i(x_i, y_i)$ 到直线 l 的“水平距离” $|P_i R|$ 大于它到直线 l 的“竖直距离” $|P_i Q|$. 这就使得通过方程 $y = bx + a (b \neq 0)$ 解得的方程 $x = \frac{1}{b}y - \frac{a}{b}$ 并不能作为 x 对 y 的线性回归方程, 因为各残差的绝对值 $|e_i| = |x_i - \hat{x}_i| = |P_i R|$ 之和并不一定最小, 从而残差的平方和也不一定最小.

(收稿日期: 2010-04-26)