

單元 49: 最小平方迴歸分析

(課本 §7.7)

設有一些實際收集到的資料, 描述 y 與 x 的關係, 如

$$(2, 1), (5, 2), (7, 6), (9, 12), (11, 17)$$

問. 如何根據這些資料, 估計出 y 與 x 的真實關係, 以致於可作推論之用?

答. 根據資料建構出一個最配適的模型 (most fitted model), 如

(1) 線性模型 (linear model):

$$f(x) = 1.8566x - 5.024$$

(2) 二次式模型 (quadratic model):

$$g(x) = 0.1996x^2 - 0.7281x + 1.3749$$

如圖示, 則可根據這些模型推論出 y 與 x 間的關係.

問 1. 如何建構?

問 2 何者較優?

答 2. 可採用如下定義的誤差平方和 (sum of the squared errors, SSE), 比較資料與模型間的差異, 而決定出何者較優.

定義. 設 $y = f(x)$ 為資料點

$$(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$$

的模型, 則此模型的誤差平方和 (SSE)

$$S \stackrel{\text{def}}{=} [f(x_1) - y_1]^2 + [f(x_2) - y_2]^2 \\ + \dots + [f(x_n) - y_n]^2$$

亦即, 所有真實資料的 y 值與模型的 y 值間的差異的平方和.

接著, 根據定義, 線性模型的誤差平方和

$$S = [f(2) - 1]^2 + [f(5) - 2]^2 + [f(7) - 6]^2 \\ + [f(9) - 12]^2 + [f(11) - 17]^2 \\ \approx 16.9959$$

且二次模型的誤差平方和

$$\begin{aligned} S &= [g(2) - 1]^2 + [g(5) - 2]^2 + [g(7) - 6]^2 \\ &\quad + [g(9) - 12]^2 + [g(11) - 17]^2 \\ &\approx 1.8968 \end{aligned}$$

因爲二次模型的誤差平方和較小，故二次模型較優。

答 1. 先以例說明。設資料爲

$$(-3, 0), (-1, 1), (0, 2), (2, 3)$$

則建構一個最配適的線性模型乃相當於找一個線性函數

$$f(x) = ax + b$$

使得它的 SSE 最小，其中 a 與 b 爲待定的未知常數，亦即，找 a 與 b 使得

$$\begin{aligned} S &= [f(-3) - 0]^2 + [f(-1) - 1]^2 \\ &\quad + [f(0) - 2]^2 + [f(2) - 3]^2 \end{aligned}$$

爲最小。實際地計算 f 的函數值，並化簡，亦相當於使得

$$\begin{aligned} S &= (-3a + b - 0)^2 + (-a + b - 1)^2 \\ &\quad + (b - 2)^2 + (2a + b - 3)^2 \\ &= 9a^2 + b^2 - 6ab + a^2 + b^2 + 1 \\ &\quad - 2ab - 2b + 2a + b^2 + 4 - 4b \\ &\quad + 4a^2 + b^2 + 9 + 4ab - 12a - 6b \\ &= 14a^2 - 4ab + 4b^2 - 10a - 12b + 14 \end{aligned}$$

爲最小，此乃一雙變數函數的極值問題。

故，(1) 找臨界點，亦相當於解方程組

$$S_a = 28a - 4b - 10 = 0 \quad (1)$$

$$S_b = -4a + 8b - 12 = 0 \quad (2)$$

首先，將 (1) 式乘以 2，得

$$56a - 8b - 20 = 0$$

再將上式與 (2) 式相加，得

$$52a - 32 = 0$$

由此得

$$a = \frac{32}{52} = \frac{8}{13}$$

代入 (1) 式，得

$$b = \frac{1}{4} \left(28 \cdot \frac{8}{13} - 10 \right) = \frac{112 - 65}{26} = \frac{47}{26}$$

因此，得第一類臨界點

$$\left(\frac{8}{13}, \frac{47}{26} \right)$$

無第二類臨界點，因爲一階偏導函數均有定義。

(2) 判斷. 因為只有一個第一類臨界點, 故以二階偏導函數檢定法判斷. 首先, 二階偏導函數為

$$S_{aa} = \frac{\partial}{\partial a}[28a - 4b - 10] = 28$$

且

$$S_{bb} = \frac{\partial}{\partial b}[-4a + 8b - 12] = 8$$

且

$$S_{ab} = \frac{\partial}{\partial b}[28a - 4b - 10] = -4$$

故, 判別式

$$d(a, b) = (28)(8) - (-4)^2 > 0$$

為一常數, 且恆大於 0, 表示在臨界點有極值. 又

$$S_{aa}(a, b) = 28 > 0$$

亦為一常數, 且恆大於 0, 表示圖形上凹.

因此, 在臨界點時, 亦有上述判別式大於 0, 且圖形上凹的現象, 故當

$$a = \frac{8}{13}$$

且

$$b = \frac{47}{26}$$

時, S 有最小值, 亦即, 有最小的誤差平方和 (SSE).

所以, 最配適的線性模型為

$$f(x) = \frac{8}{13}x + \frac{47}{26}$$

同理, 當有 n 個資料點

$$(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$$

時, 最配適的線性模型為

$$f(x) = ax + b$$

其中

$$a = \frac{n \sum_{i=1}^n x_i y_i - \left(\sum_{i=1}^n x_i \right) \left(\sum_{i=1}^n y_i \right)}{n \sum_{i=1}^n x_i^2 - \left(\sum_{i=1}^n x_i \right)^2}$$

且

$$b = \frac{1}{n} \left(\sum_{i=1}^n y_i - a \sum_{i=1}^n x_i \right)$$

並稱此直線為最小平方迴歸線 (Least Squares Regression Line, LSRL).

例 1. 設由 1987 年至 1995 年的每小時平均工資 y , 如下表:

年	1987	1988	1989	1990	1991
y	9.91	10.19	10.48	10.83	11.18
年	1992	1993	1994	1995	
y	11.46	11.74	12.06	12.35	

試求一最小平方迴歸線 (LSRL), 並估計 1998 年的平均工資.

<解> 令 $t = 0$ 對應到 1990 年, 則資料點為

$$\begin{aligned} &(-3, 9.91), (-2, 10.19), (-1, 10.48) \\ &(0, 10.83), (1, 11.18), (2, 11.46) \\ &(3, 11.74), (4, 12.06), (5, 12.35) \end{aligned}$$

代入上述 a 與 b 的公式, 得 LSRL

$$y = 0.31t + 10.83$$

因此, 1998 年的工資, 乃相當於 $t = 8$, 為

$$y(8) = 0.31(8) + 10.83 = 13.31$$

推廣. 最配適二次式模型

設有 n 個資料點

$$(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$$

則最配適的二次式模型爲

$$f(x) = ax^2 + bx + c$$

其中 a , b , 與 c 滿足下列方程式

$$a \sum_{i=1}^n x_i^4 + b \sum_{i=1}^n x_i^3 + c \sum_{i=1}^n x_i^2 = \sum_{i=1}^n x_i^2 y_i$$

且

$$a \sum_{i=1}^n x_i^3 + b \sum_{i=1}^n x_i^2 + c \sum_{i=1}^n x_i = \sum_{i=1}^n x_i y_i$$

以及

$$a \sum_{i=1}^n x_i^2 + b \sum_{i=1}^n x_i + cn = \sum_{i=1}^n y_i$$

並稱此拋物線爲最小平方迴歸二次式 (Least Squares Regression Quadratic, LSRQ).