


迴歸直線與相關係數

葉東進

國立科學園區實驗高中

科學活動的主要內容在通過某些基本模式的建立，以尋找變量之間的關係或規律，但是有些變量之間並不存在必然的關係或是明顯的規律，譬如人的身高與體重、學生的理化成績與數學成績、產品的廣告費與銷售量等；然而它們變化之間卻又隱約有某個趨勢存在。例如兩個變量 x 與 y 的數據：

x	$x_1, x_2, x_3, \dots, x_n$
y	$y_1, y_2, y_3, \dots, y_n$



圖一


從它們的散佈情形來看（圖一），雖然沒能找到一個基本的模式 f 來直接表出 x 與 y 的關係 $y = f(x)$ ，但是隱約之間，我們看到由這些數據所建構的點 $P_i(x_i, y_i)$ 是有向某一直線靠攏的趨勢。因此，退而求其次，我們設法找出這一直線，並對靠攏的趨勢程度加以量化。

一、迴歸直線

如（圖一）中的直線 ℓ ，其意義可以有許多不同的解釋，只要不離開這些點太離譜

，隨便哪一條直線都可以，問題是：什麼方法才能使找到的直線可以最佳地表達出數據間的變化趨勢？「最小方差法」便是其中的方法之一：

首先，考慮諸點 $P_i(x_i, y_i)$ ($i = 1, 2, 3, \dots, n$) 沿縱軸方向在 ℓ_1 上的投影 R_i (圖二)，使 $\sum \overline{P_i R_i}^2$ 為最小。



圖二

為方便處理，取 ℓ_1 的方程式為 $y = mx + k$

則有 $\sum \overline{P_i R_i}^2 = \sum (mx_i + k - y_i)^2$ (記為 $f(m, k)$)

$$\text{由 } \frac{\partial f}{\partial m} = \frac{\partial f}{\partial k} = 0$$

$$\text{得 } \begin{cases} \sum (mx_i + k - y_i) x_i = 0 \\ \sum (mx_i + k - y_i) = 0 \end{cases}$$

$$\Rightarrow \begin{cases} (\sum x_i^2) m + (\sum x_i) k = \sum x_i y_i \\ (\sum x_i) m + n \cdot k = \sum y_i \end{cases}$$

$$\text{解得 } m = \frac{\sum x_i y_i - n \bar{x} \bar{y}}{\sum x_i^2 - n \bar{x}^2}, \text{ 其中 } \bar{x} = \frac{1}{n} \sum x_i, \bar{y} = \frac{1}{n} \sum y_i$$

$$\text{由 } k = \frac{1}{n} \sum y_i - \left(\frac{1}{n} \sum x_i \right) m$$

$$\Rightarrow k = \bar{y} - m \bar{x}$$


$$\therefore \bar{y} = m \bar{x} + k$$

此式表示直線 $\ell_1: y = mx + k$ 通過點 $(\bar{x}, \bar{y})$ ，因此 ℓ_1 的方程式亦可寫成：

$$\ell_1: y - \bar{y} = \frac{\sum x_i y_i - n \bar{x} \bar{y}}{\sum x_i^2 - n \bar{x}^2} (x - \bar{x}) \dots\dots\dots(1)$$

我們把直線 ℓ_1 稱為 y 對 x 的迴歸直線。

其次，我們也必須考慮諸點 $P_i(x_i, y_i)$ ($i = 1, 2, 3, \dots, n$) 沿橫軸方向



圖三

在 ℓ_2 上的投影 Q_i (圖三), 使 $\sum \overline{P_i Q_i}^2$ 為最小。

取 ℓ_2 的方程式為

$$x = my + k$$

則有 $\sum \overline{P_i Q_i}^2 = \sum (my_i + k - x_i)^2$ (記為 $g(m, k)$)

由
$$\frac{\partial g}{\partial m} = \frac{\partial g}{\partial k} = 0$$

得

$$\begin{cases} \sum (my_i + k - x_i) y_i = 0 \\ \sum (my_i + k - x_i) = 0 \end{cases} \Rightarrow \begin{cases} (\sum y_i^2) m + (\sum y_i) k = \sum x_i y_i \\ (\sum y_i) m + n \cdot k = \sum x_i \end{cases}$$

解得
$$m = \frac{\sum x_i y_i - n \bar{x} \bar{y}}{\sum y_i^2 - n \bar{y}^2}$$

由
$$k = \frac{1}{n} \sum x_i - \left(\frac{1}{n} \sum y_i \right) m$$

$$\Rightarrow k = \bar{x} - m \bar{y}$$

$$\therefore \bar{x} = m \bar{y} + k$$

此式表示直線 $\ell_2: x = my + k$ 通過點 $(\bar{x}, \bar{y})$, 因此 ℓ_2 的方程式亦可寫成:

$$\ell_2: x - \bar{x} = \frac{\sum x_i y_i - n \bar{x} \bar{y}}{\sum y_i^2 - n \bar{y}^2} (y - \bar{y})$$

或是
$$y - \bar{y} = \frac{\sum y_i^2 - n \bar{y}^2}{\sum x_i y_i - n \bar{x} \bar{y}} (x - \bar{x}) \dots\dots\dots(2)$$

我們把直線 ℓ_2 稱為 x 對 y 的迴歸直線。

顯然, ℓ_1 與 ℓ_2 的差異如果愈小, 諸點 P_i 靠攏 ℓ_1 與 ℓ_2 的趨向便愈明顯。

二、相關係數

把前述 y 對 x 的迴歸直線(1)及 x 對 y 的迴歸直線(2)的斜率分別記為 m_1 與 m_2 :

$$m_1 = \frac{\sum x_i y_i - n \bar{x} \bar{y}}{\sum x_i^2 - n \bar{x}^2}$$

$$m_2 = \frac{\sum y_i^2 - n \bar{y}^2}{\sum x_i y_i - n \bar{x} \bar{y}}$$

$$\begin{aligned} \text{由 } \sum (x_i - \bar{x})(y_i - \bar{y}) &= \sum x_i y_i - (\sum x_i) \bar{y} - (\sum y_i) \bar{x} + n \bar{x} \bar{y} \\ &= \sum x_i y_i - n \bar{x} \bar{y} - n \bar{y} \bar{x} + n \bar{x} \bar{y} \\ &= \sum x_i y_i - n \bar{x} \bar{y} \end{aligned}$$

$$\begin{aligned} \text{及 } \sum (x_i - \bar{x})^2 &= \sum (x_i^2 - 2x_i \bar{x} + \bar{x}^2) \\ &= \sum x_i^2 - 2(\sum x_i) \bar{x} + n \bar{x}^2 \\ &= \sum x_i^2 - 2n \bar{x} \cdot \bar{x} + n \bar{x}^2 \\ &= \sum x_i^2 - n \bar{x}^2 \end{aligned}$$

$$\text{所以 } m_1 = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sum (x_i - \bar{x})^2}$$


$$m_2 = \frac{\sum (y_i - \bar{y})^2}{\sum (x_i - \bar{x})(y_i - \bar{y})}$$

$$\text{考慮 } \frac{m_1}{m_2} = \frac{[\sum (x_i - \bar{x})(y_i - \bar{y})]^2}{\sum (x_i - \bar{x})^2 \cdot \sum (y_i - \bar{y})^2} (> 0), \text{ 不失一般性, 底下的討論均}$$

假定 $m_1 > 0$, $m_2 > 0$, 而且 $m_2 \geq m_1$ 。

$$\text{取 } K = \frac{m_1}{m_2}$$

可以看出, 在 m_1 的值固定的情況下, m_2 與 K 成反比。就是說 m_2 愈小, K 值隨之




圖四

愈大； m_2 愈大， K 值隨之愈小。幾何意義看來，便是 ℓ_1 與 ℓ_2 的銳夾角 θ 愈小， K 值隨之愈大； θ 愈大， K 值隨之愈小（圖四）。因此， K 值的大小能夠適度地反映出 ℓ_2 與 ℓ_1 之間的差異。

事實上，由

$$\tan \theta = \frac{m_2 - m_1}{1 + m_2 m_1} = \frac{1 - \frac{m_1}{m_2}}{\frac{1}{m_2} + m_1} = \frac{1 - K}{\frac{K}{m_1} + m_1}$$



圖五

因為 θ 為銳角， $\tan \theta \geq 0$ ，即 $0 < K \leq 1$ 。

另外，從 $(\tan \theta + m_1)(K + m_1^2) = m_1 + m_1^3$ 可以繪出 $\tan \theta$ 與 K 之間的變化關係圖形（圖五），從圖形中我們看出 $\tan \theta$ 是隨 K 值的增大而遞減；隨 K 值的減小而遞增。也可以說 θ 與 K 值成遞減關係。

既然 K 值的大小可以反映出 ℓ_2 與 ℓ_1 間的差異，而 ℓ_2 與 ℓ_1 間的差異又反映出諸點 P_i 靠攏 ℓ_1 與 ℓ_2 的趨向，因此 K 值的大小便反映出諸點 P_i 靠攏 ℓ_1 與 ℓ_2 的趨向程度。

$$\text{由 } K = \frac{m_1}{m_2} = \frac{[\sum (x_i - \bar{x})(y_i - \bar{y})]^2}{\sum (x_i - \bar{x})^2 \cdot \sum (y_i - \bar{y})^2} > 0$$

$$\text{取 } \sigma = \sqrt{K}$$

我們把 σ 稱作是兩個變量 x 與 y 之間的相關係數。

因此，兩個變量 x 與 y 間的相關係數便是反應諸點 $P_i(x_i, y_i)$ 靠攏迴歸直線的程度的一個數量。

參考資料

1. 高中基礎數學第四冊，師大科教中心，國立編譯館。
2. 普通數學教程，楊維哲、蔡聰明，文仁。
3. 統計學初階，賴建業譯，中央。