

統計裡的關係

黃文璋

國立高雄大學應用數學系

1 前言

先看底下一則“給你笑笑”，作者是方衍濱，原文刊載於民國94年11月28日中國時報浮世繪(E6版)：

最近參加一個優良出版品頒獎典禮，在活潑熱鬧的踢踏舞後，男主持人說：「今天的舞蹈與出版品有很高的相關性？」
女主持人不解：「有什麼關係？」
男主持人說：「都是腳踏實地。」
女主持人說：「再辦吧！」
男主持人接著說：「都是一步一腳印。」
女主持人說：「還有呢？」
男主持人想了一下說：「最重要的是都跟得上時代的脚步！」
話一落下，全場掌聲響起。

民國94年12月18日，中國時報有一則關於眼科醫師梁中玲，發表“高度近視家族史對子女近視年齡與度數的影響”論文之報導。新聞中指出，高度近視的父母，所生兒女出現高度近視的機率，為一般人之7.7倍，且平均11歲開始出現近視。還說這是國內首度研究證實視力和基因遺傳的直接相關性。

一般多認為高度近視，可能與遺傳基因或環境有關，梁中玲遂蒐集887名17歲至45歲的高度近視者，進行上述研究。

我們常提到關係，或說相關、關連。例如，有沒有關係？這兩件事是相關的，統一教與基督教存在高度的關連性等。有一首陳慧琳主唱的歌，歌名就叫完美關係。比較正式的關係有：

親子關係、手足關係、師生關係、婚姻關係、婆媳關係、家庭關係、兩性關係、人際關係、勞資關係、自我關係、公共關係、國際關係等。

我國與美國間有“台灣關係法”，對大陸有“台灣地區與大陸地區人民關係條例”，在日本設有“亞東關係協會”。國民中小學九年一貫課程綱要中，有“分段能力指標與十大基本能力之關係”。不論是人、事、物、群體、概念，任兩者之間，都可有某種關係。警方及調查人員辦案時，也常需由蛛絲馬跡中，找出其中兩兩間的各種關係。大家在物理課程中也學過不少關係。例如，自由落體，時間與速度間之關係。或如愛因斯坦著名的 $E = MC^2$ 的公式。Google 的搜尋演算法，將其他網站連結到該網頁的數目列入計算，這對特定查詢來說，為一重要的相關性指標。可以這樣講，在數學及科學中(包含自然、人文及社會科學)，以及在生活裡，人們常在探討各種情況下，二者間的關係。光是數學中的關係，可說就已不勝枚舉：

等價關係、對稱關係、相等關係、全等關係、相似關係、平行關係、垂直關係、相依關係、邊與角的關係、直線和圓的位置關係、根與係數的關係，…。

任二數、形、集合、命題間，總要看其間有何影響、牽涉，或連帶作用。

有兩種關係是數學中常出現的，其一為函數關係，其二為因果關係。

在數學中函數(function)的意義大致是這樣的：給二集合 A 與 B ，由 A 至 B 的一對應(即每一 A 中的元素 x ， B 中恰有一元素 y 與 x 對應)，便稱為一由 A 至(或稱映至) B 的函數。 A 稱為此函數之定義域， B 稱為對應域。有時又可把函數想成一台機器，放進某一原料 x ，經過一些作用，出來某一產品 y 。

可看出函數的定義並未有太多限制。現代數學的發展，大約始自十七世紀，自那時起，數學家在討論數學時，常將問題設法以函數的形式來描述。在機率與統計裡，也處處藉用函數的概念。例如，對一隨機現象(即事先不能預知結果的試驗、實驗或觀測中的某些量)，常藉隨機變數來描述，而隨機變數其實就是函數：一個由樣本空間映至實數的函數。

對一函數關係，常以

$$(1) \quad y = f(x)$$

表之。其中 f 為函數的名字，對定義域中的一個 x ，經過 f 的作用後，得到對應域中的 y 。由(1)式可看出數學的特色之一：常可以簡潔的符號來替代一複雜或冗長的敘述。

函數關係可說是一種很強的關係。給定 x ，經由 f ，所對應的 y 便完全確定。因果關係則是在某假設(或說前提)下，可導致某結論成立。常以命題若 p 則 q 來描述。此命題何時為真？就是 p 成立時，的確可導致 q 成立。當此命題為真時， p 稱為因， q 稱為果。有時 q 成立，也會導致 p 成立。例如，若為全等三角形(p)，則三對應邊等長(q)。反之，若三對應邊等長(q)，則為全等三角形(p)。此時 p 與 q 互為因果關係。另外，若為全等三角形(p)，則三對應角相等(q)，但三對應角相等(q)，卻不一定為全等三角形(p)。

有些函數關係也是一種因果關係。令 $y = x^2$ ，這是指定出來的函數，並無法說明白其中有何因果關係。但圓面積為半徑 r 的函數，即 $A(r) = \pi r^2$ ，其中 $A(r)$ 表半徑 r 的圓面積， π 為圓周率。此函數關係，乃是經過證明而得到的。即有命題

若圓的半徑為 r ，則其面積 $= \pi r^2$ 。

當然我們知道對本例亦有

若圓的面積為 A ，則其半徑 $= \sqrt{\frac{A}{\pi}}$ 。

又並非每一因果關係皆為一函數關係。例如，若 $x > 0$ ，則 $x + 3 > 0$ ，便不是一函數關係。

口語裡的關係，有時沒有太嚴格的定義，如本節一開始那則給你笑笑中的“舞蹈與出版品”的關係。數學裡的各種關係，定義當然是很明確的。在科學裡，常在討論隨機現象。對二隨機變數，我們常想建立其間之關係。但二隨機變數間，往往沒有像數學中那麼明確的關係。在數學裡若覺得某種關係是對的，就要去證明。數學中自有一套邏輯推演，有被認為究竟怎樣才算得證的程序。但在科學裡，往往無法如數學中，天衣無縫的證明一關係成立。前面所引有關近視的報導，其中的證實，可不是如數學中，一步步推導證出視力與基因遺傳有某種關係。那這裡證實二字到底是什麼意思呢？科學中的證實，常是經由統計裡的假設檢定(hypothesis testing)所得之推論，可參考黃文璋(2006a)一文。

本文便是要探討隨機現象中，諸如獨立、相關、關連、無關等關係的題材。

2 獨立

統計裡常在做預測或估計的工作。收集資料後，對未來做預測，或估計某些未知的量。有些情況的預測，統計學家往往束手無策。例如，下一期樂透彩頭獎號碼，雖知道過去每一期之頭獎號碼，正規的統計學家，大約不會去做此預測，因為各期所開出之頭獎號碼為相互獨立(mutually independent, 簡稱獨立)。媒體上統計出氣較旺的號碼(常出現)，及氣較弱的號碼(久未出現)，你該簽何者呢？好像各有道理。事實上，因每組號碼出現的機率每次均相同，知道過去的資料，對預測未來，並沒有幫助。所以統計學家對這種預測絲毫不顯得高明。另外，在諸如估計銅板出現正面的機率 p ，通常的作法是持續地投擲(假設 n 次)，統計出現幾個正面(假設 k 次)，然後以 k/n 來估計 p 。這其中一個常做的假設是，各次投擲所出現的結果是“獨立且有共同分佈”(independent and identically distributed, 簡稱iid)。在很多實際的情況，樣本常可視為或設為獨立。不少統計的理論，其基本假設往往是樣本為iid。

日常生活裡常聽到“獨立”二字：主權獨立、經濟獨立，甚至金雞獨

立。統計裡的獨立，又稱隨機獨立，與前述獨立的意義不盡相同。簡單地講，對二事件 A, B ，若給定 B 發生， A 發生之機率不受影響，則稱 A 與 B 獨立。即若

$$(2) \quad P(A|B) = P(A)$$

則稱 A 與 B 獨立。通常寫成 $P(A|B)$ 時，要求 $P(B) > 0$ ，事件 B 總要有可能發生（即 $P(B) > 0$ ），給定 B 才有意義。由於依定義

$$P(A|B) = \frac{P(A \cap B)}{P(B)},$$

由(2)式引伸出，若

$$(3) \quad P(A \cap B) = P(A)P(B),$$

則稱 A 與 B 獨立。我們便以(3)式當做 A 與 B 獨立的定義，在此式裡，就不要求 $P(B) > 0$ 。當然如果 $P(B) > 0$ ，此時(2)式與(3)式便無差別。

交集表同時發生。(3)式顯示，二事件 A 與 B 獨立，若且唯若 A, B 同時發生的機率，等於 A, B 各自發生的機率之乘積。假設骰子為公正，即每面出現之機率皆為 $1/6$ 。投擲第一個骰子，會得到點數1(事件 A)之機率為 $1/6$ ，投擲第二個骰子，會得到點數2(事件 B)之機率亦為 $1/6$ 。那各投擲一次，第一個得到1，第二個得到2之機率為何？如果兩次投擲為獨立，即互不受影響，顯然答案為 $1/6 \cdot 1/6 = 1/36$ 。即有 $P(A \cap B) = P(A)P(B)$ 。

有時會有 n 個事件， n 個事件獨立的定義為何？

設有事件 $A_1, A_2, \dots, A_n, n \geq 3$ 。若對 $\forall 1 \leq k \leq n$ ，及 $1 \leq i_1 < i_2 < \dots < i_k \leq n$ ，

$$(4) \quad P(A_{i_1} \cap A_{i_2} \cap \dots \cap A_{i_k}) = P(A_{i_1})P(A_{i_2}) \cdots P(A_{i_k}),$$

則稱 A_1, A_2, \dots, A_n 為獨立事件，或說 A_1, A_2, \dots, A_n 相互獨立（獨立）。

可看出要驗證 A_1, A_2, \dots, A_n 獨立，就要驗其中任意挑出之 k 個事件之交集的機率，等於機率之乘積，而不只是驗證

$$P(A_1 \cap A_2 \cap \dots \cap A_n) = P(A_1)P(A_2) \cdots P(A_n).$$

有些事件不是那麼容易看出獨立或不獨立，見下例。

例1. 設一袋中有9張紙牌，分別寫著 (a, b, c) , (a, c, b) , (b, a, c) , (b, c, a) , (c, a, b) , (c, b, a) , (a, a, a) , (b, b, b) 及 (c, c, c) 等。隨機抽取一張，假設每一張紙牌被取中之機率均為 $1/9$ 。令事件 A_k 表袋中一紙牌上所寫 (x, y, z) 之第 k 個位置為 a , $k = 1, 2, 3$ 。如 $A_1 = \{(a, b, c), (a, c, b), (a, a, a)\}$ 。顯然

$$P(A_1) = P(A_2) = P(A_3) = \frac{1}{3},$$

$$P(A_1 \cap A_2) = P(A_1 \cap A_3) = P(A_2 \cap A_3) = \frac{1}{9}.$$

因此 A_1 與 A_2 , A_1 與 A_3 , A_2 與 A_3 皆獨立。但因

$$P(A_1 \cap A_2 \cap A_3) = \frac{1}{9} \neq P(A_1)P(A_2)P(A_3),$$

故 A_1, A_2, A_3 不為獨立事件。

事實上，若 A_1 與 A_2 均發生，則 A_3 必發生，所以 A_3 與 $A_1 \cap A_2$ 不獨立，因此 A_1, A_2, A_3 不相互獨立。

二隨機變數獨立，表知道其中之一的值，對另一變數毫無影響。正如由(2)式演變至(3)式，對二離散型之隨機變數 X, Y ，我們定義其獨立，若對所有可能取的值 a, b ,

$$(5) \quad P(X = a, Y = b) = P(X = a)P(Y = b).$$

至於對一般的隨機變數 X, Y , X 與 Y 獨立，表滿足

$$(6) \quad P(X \leq x, Y \leq y) = P(X \leq x)P(Y \leq y), \quad \forall x, y \in R.$$

這是較一般的以分佈函數來定義，如果機率密度函數(probability density function)存在，也可以機率密度函數來表示。設 $f(x, y)$ 表 X, Y 之聯合機率密度函數， $f_X(x), f_Y(y)$ 分別表 X, Y 之邊際機率密度函數，則 X 與 Y 獨立，若且唯若

$$(7) \quad f(x, y) = f_X(x)f_Y(y), \quad \forall x, y \in R.$$

對於 n 個隨機變數 X_1, \dots, X_n , 其獨立的定義為滿足

$$(8) \quad \begin{aligned} P(X_1 \leq x_1, \dots, X_n \leq x_n) \\ = P(X_1 \leq x_1) \cdots P(X_n \leq x_n), \quad \forall x_1, \dots, x_n \in R, \end{aligned}$$

或

$$(9) \quad f(x_1, \dots, x_n) = f_1(x_1) \cdots f_n(x_n), \quad \forall x_1, \dots, x_n \in R.$$

其中 f 為 X_1, \dots, X_n 之聯合機率密度函數, f_i 為 X_i 之邊際機率密度函數, $i = 1, \dots, n$ 。

本節一開始提到, 在做估計時, 常假設樣本為 iid。例如, 欲估計某銅板出現正面之機率 p , $0 < p < 1$ 。依序投擲 n 次, 得到 X_1, \dots, X_n , 其中 $X_i = 1$ 或 0 , 就依第 i 次得到正面或反面。很自然地, 以樣本平均 (sample mean)

$$\bar{X}_n = \frac{\sum_{i=1}^n X_i}{n}, \quad n \geq 1,$$

來估計 p 。弱大數法則 (weak law of large numbers) 告訴我們, $n \rightarrow \infty$ 時, \bar{X}_n 會機率收斂 (converges in probability) 至 p 。即

$$(10) \quad \lim_{n \rightarrow \infty} P(|\bar{X}_n - p| < \varepsilon) = 1, \quad \forall \varepsilon > 0.$$

簡單地講, n 很大時, \bar{X}_n 接近 p 之機率很大。這其中 X_1, \dots, X_n iid 是一關鍵。如果投擲不一樣的銅板, 每次出現正面的機率不同, 則 (10) 式通常就不成立了。如果各次投擲不獨立, (10) 式也就不見得成立。例如, 有人並未真的投擲 n 次, 而是看到第一次出現的結果 X_1 就照抄, 因而得到 $X_2 = \dots = X_n = X_1$ 。如此 $\bar{X}_n = X_1, \forall n \geq 1$ 。而 X_1 , 不是 1 就是 0, 故不論 n 多大, \bar{X}_n 當然不會接近 p 。

3 迴歸

獨立是一種很特殊的關係，就是毫無關係。即你怎麼樣，對我沒有影響。有些事件或隨機變數並不獨立，不獨立才易做預測。準備考試要先做考古題，因知道下次的考題，與過去的考題多少有些關連。送女朋友禮物，要先了解她的愛好。但如果她喜怒無常，打聽的結果可能幫助不大。第一次考試成績與第二次考試成績，兒子身高與父親身高，明天氣溫與今日氣溫，這些情況中涉及的兩個量，很可能都不獨立。既然不獨立，其間便多少有關係。如何表示其關係呢？

對隨機變數討論關係，乃指機率上的關係。獨立就是機率分佈彼此沒有任何關連，不獨立就是機率分佈有些關連。當 X, Y 二隨機變數不獨立，一個可說是最簡單的情況，就是 X 與 Y 有函數關係。如

$$(11) \quad Y = g(X),$$

即知道 X 之值後， Y 就完全決定了。

對二隨機變數 X, Y ，能夠知道其聯合分佈函數

$$F(x, y) = P(X \leq x, Y \leq y), \quad \forall x, y \in R,$$

或者聯合機率密度函數 $f(x, y)$ ，則 X 與 Y 間如何互動，或者說二者間之關係就完全知道了，這可說是非常清楚的關係。例如，由 $f(x, y)$ 我們可求出條件機率密度函數

$$(12) \quad f(y|x) = \frac{f(x, y)}{f_X(x)},$$

其中如果是連續型變數，則

$$(13) \quad f_X(x) = \int_{-\infty}^{\infty} f(x, y) dy.$$

若 X 與 Y 有如(11)式之函數關係，則給定 $X = x, Y = g(x)$ 之機率為1。即

$$P(Y = g(x)|X = x) = 1,$$

此時

$$f(y|x) = \begin{cases} 1, & \text{若 } y = g(x), \\ 0, & \text{若 } y \neq g(x). \end{cases}$$

$f(y|x)$ 表給定 $X = x$ 之下, Y 之機率密度函數。只要 X 與 Y 不獨立, $f(y|x)$ 便不等於 $f_Y(y)$ 。即 Y 之條件分佈, 隨著給定 X 不同的值而不同。由於期望值為關於隨機變數之一重要的量, 因此諸如條件期望值(仍設 X, Y 為連續型變數)

$$(14) \quad E(Y|X = x) = \frac{\int_{-\infty}^{\infty} y f(x, y) dy}{\int_{-\infty}^{\infty} f(x, y) dy},$$

便是對於二變數 X, Y 常會討論的題材。曲線 $y(x) = E(Y|X = x)$, 便稱做迴歸曲線(regression curve), 代表 Y 對 X 之迴歸。當然亦可定義 X 對 Y 之迴歸曲線 $x(y) = E(X|Y = y)$ 。當迴歸曲線為直線, 此時便稱線性迴歸(linear regression)。

隨機現象裡, 通常少有如(11)式 Y 就是 X 的函數。但若有(11)式的關係, 對預測而言, 當然是最完美的。像是知道父親身高(X), 兒子身高(Y)也就確定。退而求其次, 如果能有如下關係:

$$(15) \quad Y = g(X) + \varepsilon,$$

其中 ε 代表誤差項, 大約也會令人滿意。通常會對 ε 做一些假設。如因是誤差, ε 有時為正, 有時為負, 平均來說, 似該為 0, 所以假設 $E(\varepsilon) = 0$ 。有時為了簡便, 或是採信高斯的誤差理論, 而假設 ε 有常態分佈。 g 如果是一很簡單的函數, 如線性函數 $g(x) = ax + b$, 就會更令人滿意。依所收集到的數據 $(x_1, y_1), \dots, (x_n, y_n)$, 以估計 a, b 。這方面的討論, 就是統計裡的迴歸分析(regression analysis), 是很基本且重要的題材。

當 X, Y 之聯合分佈知道, 有時想找一適當的函數 g , 並以 $g(X)$ 來預測 Y 。也就是 X 為我們所知的資訊, 而 Y 便是要預測的值。對 Y 之預測值 $g(X)$, 我們自然希望要愈接近 Y 愈好。但怎樣是接近? 一個代表誤差的量是 $g(X)$ 與 Y 之差的絕對值 $|g(X) - Y|$, 即絕對誤差。由於此為一隨機變數, 期望值 $E(|g(X) - Y|)$ 為代表其大小的一個量。但涉及絕對值的積分或是和, 通常較難計算。只要想想積分 $\int_{-\infty}^{\infty} |x^2 + 3x - e^x| dx$ 就知道了。計算前要先去掉絕對值, 而 $x^2 + 3x - e^x$ 何時會正或負, 並不好決定。所以通常考慮誤差平方 $(g(X) - Y)^2$ 之期望

值 $E((g(X) - Y)^2)$, 或說均方差(mean squared error, 簡稱MSE)。這就像對一隨機變數 U , 以 $E((U - E(U))^2)$ 表其變異數, 並稱其正的平方根 $[E((U - E(U))^2)]^{1/2}$ 為標準差, 用來量測 U 與其期望值 $E(U)$ 偏離的大小。若有一 Y 之預測值 $g(X)$, 使得其MSE最小, 我們便稱此為 Y 之最佳MSE預測值。MSE是統計學中, 常用來表示誤差的一個量。

可以證明條件期望值 $g(X) = E(Y|X)$, 為唯一的 Y 之最佳MSE預測值。但若只想簡單地以一常數來預測 Y , 則 $g(X) = E(Y)$ 可使預測之MSE最小。這也解釋對一隨機變數, 何以期望值為其一常用的代表值。因在均方差最小的意義下, 此為隨機變數之最佳常數預測值。若想以一線性函數 $g(X) = aX + b$ 來預測 Y , 則當 $E(X), E(Y), \text{Var}(X)$ 皆存在, 可得

$$(16) \quad a = \frac{\text{Cov}(X, Y)}{\text{Var}(X)}, \quad b = E(Y) - aE(X),$$

其中

$$(17) \quad \begin{aligned} \text{Cov}(X, Y) &= E((X - E(X))(Y - E(Y))) \\ &= E(XY) - E(X)E(Y), \end{aligned}$$

表 X 與 Y 之共變異數(covariance, 又稱協方差)。上述這些最佳預測值如何求出, 可參考黃文璋(2003a)3.5節。

4 相關係數

知道 X, Y 的聯合分佈, 對 X, Y 如何互動雖然完全掌握, 但有時我們只想粗略地了解 X 與 Y 間的關係有多密切, 即想以一簡單的量來描述其關係。此正如對一場考試, 我們不見得對全部考生的成績感興趣, 平均值、標準差反而較想知道。因為此二值, 能讓人快速地了解全部考生成績之集中及散佈情況。相關係數(correlation coefficient, 或只稱correlation)的概念就因此產生。

如果二隨機變數不獨立, 則二變數間便有關係, 此關係可能強可能弱。如果是獨立, 則關係當然是最弱的。若樣本為水, 令 X 表其體積,

Y 表其重量。顯然 X 與 Y 之關係很強。如果取樣多次，如 n 次，將所得的數據 $(x_1, y_1), \dots, (x_n, y_n)$ 畫在 x - y 座標平面上，則所有的點很可能落在一直線上或直線的附近。這是因為純淨的水重量與體積有線性關係。有些數據不在直線上，可能是因量測的誤差，或水質不純所致。其次，若以 X 表某人之身高， Y 表其體重， X 與 Y 顯然亦有關係，但可能不像水的重量與體積間之關係那麼強。量測 n 個不同的人所得之 $(x_1, y_1), \dots, (x_n, y_n)$ ，大約不會形成一直線，雖然我們仍會預期在 x - y 座標平面上，圖形是向右上增長，即較大的 x 有較大的 y 之傾向。共變異數及相關係數，都可用來度量兩隨機變數關係(特別是線性關係)的強弱。

在本節中，為了簡便，令 $\mu_X = E(X)$, $\mu_Y = E(Y)$, $\sigma_X^2 = \text{Var}(X)$, $\sigma_Y^2 = \text{Var}(Y)$ ，如果這些量存在的話。又所有結果的證明，皆可參考黃文璋(2003b)3.5節。首先當 $0 < \sigma_X^2, \sigma_Y^2 < \infty$ ，定義 X, Y 之相關係數為

$$(18) \quad \rho(X, Y) = \frac{\text{Cov}(X, Y)}{\sigma_X \sigma_Y}.$$

$\text{Cov}(X, Y)$ 可以 σ_{XY} 表之， $\rho(X, Y)$ 有時以 ρ_{XY} ，或簡單地以 ρ 表之。

當 σ_X 或 $\sigma_Y = 0$ ，此時 $\text{Cov}(X, Y) = 0$ ，至於 $\rho(X, Y)$ 則不定義。由相關係數之定義知，只要我們提到相關係數，皆隱含二隨機變數之期望值及變異數皆存在，且變異數皆不為0。

顧名思義，共變異數量測兩個隨機變數同時變化的情況。正如變異數乃量測一隨機變數變化的大小。自己跟自己的共變異數就是變異數，即 $\text{Cov}(X, X) = \text{Var}(X)$ 。如果較大的 X 傾向於伴隨較大的 Y ，且較小的 X 傾向於伴隨較小的 Y ，則 $\text{Cov}(X, Y)$ 將是正的。因此若 $X > \mu_X$ 時，較可能有 $Y > \mu_Y$ ，則 $(X - \mu_X)(Y - \mu_Y)$ 較可能為正；且若 $X < \mu_X$ 時，亦較可能有 $Y < \mu_Y$ ，則 $(X - \mu_X)(Y - \mu_Y)$ 也將較可能為正。如此一來， $\text{Cov}(X, Y) = E((X - \mu_X)(Y - \mu_Y)) > 0$ 。但若較大的 X 傾向於伴隨較小的 Y ，且較小的 X 傾向於伴隨較大的 Y ，則 $(X - \mu_X)(Y - \mu_Y)$ 便較可能為負，如此一來， $\text{Cov}(X, Y) < 0$ 。故 $\text{Cov}(X, Y)$ 之正負，反映 X, Y 增長方向之相同或相反。若以 X, Y 分別表父親的身高及兒子的身高，我們會預期 $\text{Cov}(X, Y)$ 為正。若以 X, Y 分別表成人男子的體重及跳高的高度，我們

會預期 $\text{Cov}(X, Y)$ 為負。

可以證明當 X 與 Y 獨立時, $\text{Cov}(X, Y) = 0$ 。不過 $\text{Cov}(X, Y) = 0$ 時, X 與 Y 却不一定獨立。另外, $\rho(X, Y)$ 與 $\text{Cov}(X, Y)$ 之正負符號相同, 且當 σ_X 及 σ_Y 皆存在時, $\rho(X, Y) = 0$, 若且唯若 $\text{Cov}(X, Y) = 0$ 。當 $\rho(X, Y) = 0$, 則稱 X 與 Y 無相關(uncorrelated)。

做為量測二隨機變數 X 及 Y 之變化情況, 共變異數有一缺點, 就是其值與量測 X, Y 之尺度有關。例如, X 以公升為單位, Y 以公斤為單位, 跟 X 以公攝(立方公分)為單位, Y 以公克為單位, 則前者求出之共變數為後者之 10^{-6} 倍。相關係數 ρ 便可消除這種困擾, 它永遠取值在區間 $[-1, 1]$ 。 $|\rho|$ 接近 1 時, 顯示 X 與 Y 有較強的線性關係, $|\rho|$ 接近 0 時, 顯示 X 與 Y 的線性關係較弱, 而 $|\rho| = 1$ 時, 表 X 與 Y 有完美的線性關係。

可以證明, 對二隨機變數 X, Y ,

$$(19) \rho(X, Y) = \text{Cov}\left(\frac{X - \mu_X}{\sigma_X}, \frac{Y - \mu_Y}{\sigma_Y}\right) = E\left(\frac{(X - \mu_X)(Y - \mu_Y)}{\sigma_X \sigma_Y}\right)。$$

我們知道, 對一隨機變數 X , 所謂標準化就是將 X 減去期望值, 再除以標準差, 而得 $(X - \mu_X)/\sigma_X$ 。由(19)式知, 相關係數即二標準化後的隨機變數之共變異數。又對任二隨機變數 X, Y , 及常數 a, b, c, d ,

$$(20) \quad \text{Cov}(aX + b, cY + d) = ac\text{Cov}(X, Y),$$

$$(21) \quad \rho(aX + b, cY + d) = \frac{ac}{|ac|} \rho(X, Y), ac \neq 0.$$

(20)式印證我們前面所說的共變異數與所取的尺度(指 a, c 的效應)有關。不過與座標的平移(指 b, d 的效應)無關。(21)式指出, 只要尺度之改變, 並未使 X, Y 之值的方向變成相反(即 $ac > 0$), 則相關係數不變。

例2. 設 X, Y 之聯合機率密度函數為

$$f(x, y) = 1, 0 < x < 1, x < y < x + 1.$$

則 X, Y 之邊際機率密度函數分別為

$$f_X(x) = 1, 0 < x < 1,$$

$$f_Y(y) = \begin{cases} y & , 0 < y < 1, \\ 2 - y & , 1 \leq y < 2 . \end{cases}$$

則 $\mu_X = 1/2, \sigma_X^2 = 1/12, \mu_Y = 1, \sigma_Y^2 = 1/6$ 。又 $E(XY) = 7/12$ 。因此

$$\text{Cov}(X, Y) = E(XY) - \mu_X \mu_Y = \frac{7}{12} - \frac{1}{2} \cdot 1 = \frac{1}{12},$$

$$\rho(X, Y) = \frac{\text{Cov}(X, Y)}{\sigma_X \sigma_Y} = \frac{1/12}{\sqrt{1/12} \sqrt{1/6}} = \frac{\sqrt{2}}{2} \doteq 0.707 .$$

例3. 設 X 與 Z 為二獨立的隨機變數，且 X 有 $\mathcal{U}(0, 1)$ 分佈， Z 有 $\mathcal{U}(0, 1/10)$ 分佈。令 $Y = X + Z$ 。利用變數代換，可得 X, Y 之聯合機率密度函數為

$$f(x, y) = 10, 0 < x < 1, x < y < x + \frac{1}{10},$$

如此便可求出 $\text{Cov}(X, Y)$ 及 $\rho(X, Y)$ 。不過因 Y 為 X 與 Z 之和，且 X 與 Z 獨立，我們可經由 X 與 Z ，如下求出 $\text{Cov}(X, Y)$ 與 $\rho(X, Y)$ 。

$$E(X) = \frac{1}{2}, \text{Var}(X) = \frac{1}{12},$$

$$E(Y) = E(X + Z) = E(X) + E(Z) = \frac{1}{2} + \frac{1}{20} = \frac{11}{20},$$

$$\text{Var}(Y) = \text{Var}(X + Z) = \text{Var}(X) + \text{Var}(Z) = \frac{1}{12} + \frac{1}{1,200} = \frac{101}{1,200} .$$

$$\begin{aligned} \text{Cov}(X, Y) &= E(XY) - E(X)E(Y) \\ &= E(X(X + Z)) - E(X)(E(X) + E(Z)) \\ &= E(X^2) + E(XZ) - (E(X))^2 - E(X)E(Z) \\ &= E(X^2) - (E(X))^2 \\ &= \text{Var}(X) = \frac{1}{12} . \end{aligned}$$

此處用到因 X 與 Z 獨立，所以 $E(XZ) = E(X)E(Z)$ 。由此又得

$$\rho(X, Y) = \frac{\frac{1}{12}}{\sqrt{\frac{1}{12}} \sqrt{\frac{101}{1,200}}} = \frac{10}{\sqrt{101}} \doteq 0.9950 .$$

與例2比較，在例3中， X 與 Y 的相關係數很接近1。我們將兩例中使 $f(x, y)$ 為正之 (x, y) 的圖形繪出，見圖1。

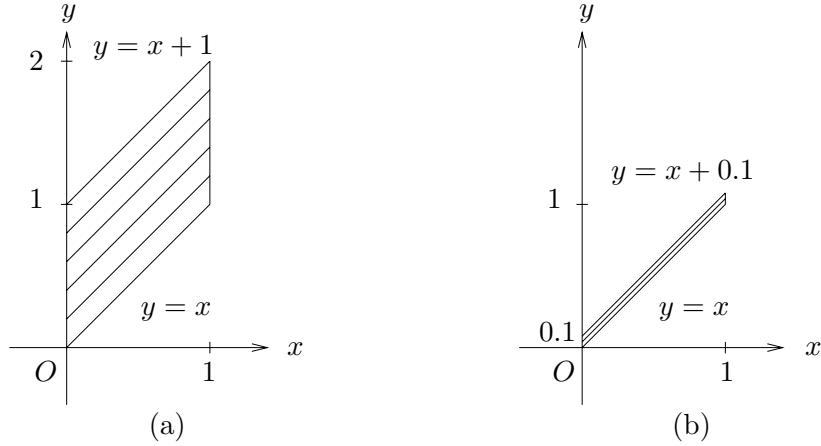


圖1 (a)例2中使 $f(x, y) > 0$ 之區域，(b)例3中使 $f(x, y) > 0$ 之區域。

圖1(a)及1(b)，顯示 X 與 Y 大致有線性的關係，但在圖1(b)中，線性關係較強(區域較窄)。也可以另一方式來看此線性關係的強弱。在例3中，因 $Y = X + Z$ ，故給定 $X = x$, Y 有 $\mathcal{U}(x, x + 1/10)$ 分佈。而在例2中，也可驗證給定 $X = x$, Y 有 $\mathcal{U}(x, x + 1)$ 分佈。故知道 $X = x$ 後，在例3中，比在例2中，提供較多關於 Y 之資訊(前者誤差不超過0.1，後者誤差不超過1)。因此在例3中， X 與 Y 的相關係數較大。

相關係數可用來量測二隨機變數之關連程度(degree of association)。但它作為一個指標，主要是反映二隨機變數之分佈的線性關係之強度及正負符號。因此相關係數為0，僅表示二隨機變數之線性關係很低，而非表示二變數機率上無關(probabilistically unrelated)，也就是二變數不一定獨立。甚至二隨機變數間，可能有強烈的關係，但該關係並非線性，所以相關係數仍可能為0。見下二例。

例4. 設 X 與 Z 為二獨立的隨機變數，且 X 有 $\mathcal{U}(-1, 1)$ 分佈， Z 有 $\mathcal{U}(0, 1/10)$ 分佈。令 $Y = X^2 + Z$ 。可看出給定 $X = x$, Y 有 $\mathcal{U}(x^2, x^2 + 1/10)$ 分佈，因此 X 與 Y 有很強的關係，只是並非線性。又可求出 X, Y 之聯合機率密度函

數為

$$f(x, y) = 5, \quad -1 < x < 1, \quad x^2 < y < x^2 + \frac{1}{10}.$$

如此便可求出 $\text{Cov}(X, Y)$ 及 $\rho(X, Y)$ 。不過如同例3，我們以下述方式求之。由於 X 有 $\mathcal{U}(-1, 1)$ 分佈，故

$$E(X) = E(X^3) = 0.$$

又因 X 與 Z 獨立，故

$$E(XZ) = E(X)E(Z) = 0.$$

因此

$$\begin{aligned} \text{Cov}(X, Y) &= E(X(X^2 + Z)) - E(X)(E(X^2 + Z)) \\ &= E(X^3) + E(XZ) = 0, \end{aligned}$$

且 $\rho(X, Y) = 0$ 。

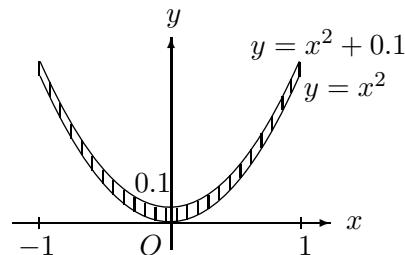


圖2 例4中使 $f(x, y) > 0$ 之區域

例5. 設 X 有 $\mathcal{U}(-1, 1)$ 分佈。令 $Y = X^2$, $Z = 2X + 3$, $W = -2X + 3$ 。則

$$E(X) = 0, \quad E(XY) = E(X^3) = 0,$$

故

$$\text{Cov}(X, Y) = E(XY) - E(X)E(Y) = 0,$$

且 $\rho(X, Y) = 0$ 。相關係數是量測線性關係的強弱，而非量測其他非線性關係之強弱。故此處雖 Y 為 X 的平方，二者有一簡單且密切的關係，仍得到 X 與 Y 無相關。換句話說，無相關並非不相關。

另外，

$$E(XZ) = E(X(2X + 3)) = 2E(X^2) + 3E(X) = \frac{2}{3},$$

$$E(X)E(Z) = 0,$$

$$\text{Var}(X) = E(X^2) = \frac{1}{3}, \quad \text{Var}(Z) = 4\text{Var}(X) = \frac{4}{3},$$

故

$$\text{Cov}(X, Z) = E(XZ) - E(X)E(Z) = \frac{2}{3},$$

且

$$\rho(X, Z) = \frac{\text{Cov}(X, Z)}{\sigma_X \sigma_Z} = \frac{2/3}{\sqrt{1/3} \cdot \sqrt{4/3}} = 1.$$

同理可得 $\rho(X, W) = -1$ 。

X 與 Z 有線性關係，且增長方向相同，故相關係數為 1。 X 與 W 亦有線性關係，只是增長方向相反，所以相關係數為 -1，一般而言這是對的。

共變異數對了解隨機變數和之變異有很大的幫助。底下先給一二變數和之變異數的公式，其中當然要假設 $\text{Var}(X)$ 及 $\text{Var}(Y)$ 皆存在。

$$(22) \quad \text{Var}(X + Y) = \text{Var}(X) + \text{Var}(Y) + 2\text{Cov}(X, Y).$$

故若 X 與 Y 為正相關，即 $\rho(X, Y) > 0$ (因此 $\text{Cov}(X, Y) > 0$)，則 $X + Y$ 之變異數，比 X, Y 變異數之和還大。反之，若 X 與 Y 為負相關，則 $X + Y$ 之變異數，比 X, Y 變異數之和還小。當負相關時， X 與 Y 一個值較大，另一值便傾向於較小，而其和就不至於那麼極端，因此 $X + Y$ 之變異減小。同理可對 $\text{Var}(X - Y)$ 做討論。

利用著名的史瓦茲不等式(Schwarz's inequality)，又稱柯西-史瓦茲不等式(Cauchy-Schwarz's inequality)，可以證明對任二隨機變數 X, Y ，只要 $0 < \sigma_X^2, \sigma_Y^2 < \infty$ ，則其相關係數介於正負 1 之間。即 $|\rho(X, Y)| \leq 1$ ，且 $|\rho(X, Y)| = 1$ ，若且唯若 $P(Y = aX + b) = 1$ ，其中 a, b 為二常數。又 $\rho(X, Y) = 1$ 時， $a > 0$ ， $\rho(X, Y) = -1$ 時， $a < 0$ 。由於相關係數的值介於正負 1 之間，且當其值等於 +1 或 -1 時，二變數有一線性關係之機率為 1，這便說明了如前所述，相關係數是用來量測二變數之線性相依情形。當 $|\rho(X, Y)| = 1$ 時，我們稱 X 與 Y 為完全相關(completely correlated)。

當 $0 < \sigma_X^2 < \infty$ ，我們注意到 $\rho(X, X) = 1$ 。自己與自己的相關係數為 1，自然是合理的。事實上，對任二常數 a, b ，且 $a \neq 0$ ， $\rho(X, aX + b) =$

1。又讀者可參考黃文璋(2003b)pp.221-223所提供的說明，以了解為何採用相關係數來量測二隨機變數的共線性。

如同對一組隨機樣本 $X_1, \dots, X_n, n \geq 2$, 以

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i, \quad S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2,$$

表樣本平均及樣本變異數(有時以 \bar{X}_n, S_n^2 表之, 此處省略足標 n)。對兩組隨機樣本 X_1, \dots, X_n , 及 Y_1, \dots, Y_n , 以

$$(23) \quad S_{XY}^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y}),$$

及

$$(24) \quad r = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{(\sum_{i=1}^n (X_i - \bar{X})^2 \sum_{i=1}^n (Y_i - \bar{Y})^2)^{1/2}},$$

分別表樣本共變異數(sample covariance)及樣本相關係數(sample correlation coefficient)。可看出

$$S_{XY}^2 = \frac{1}{n-1} (\sum_{i=1}^n X_i Y_i - \frac{1}{n} \sum_{i=1}^n X_i \sum_{i=1}^n Y_i), \quad r = S_{XY}^2 / (S_X^2 S_Y^2)^{1/2},$$

其中 S_X^2, S_Y^2 分別為 X_1, \dots, X_n 及 Y_1, \dots, Y_n 之樣本變異數。

我們藉圖3來說明。所觀測到的數據 $(x_1, y_1), \dots, (x_n, y_n)$, 若大部分都落在區域I及III, 則 r 將為正(正相關); 若大部分都落在區域II及IV, 則 r 將為負(負相關); 若散佈在I, II, III, IV等四個區域, 則 r 將接近0(無相關)。

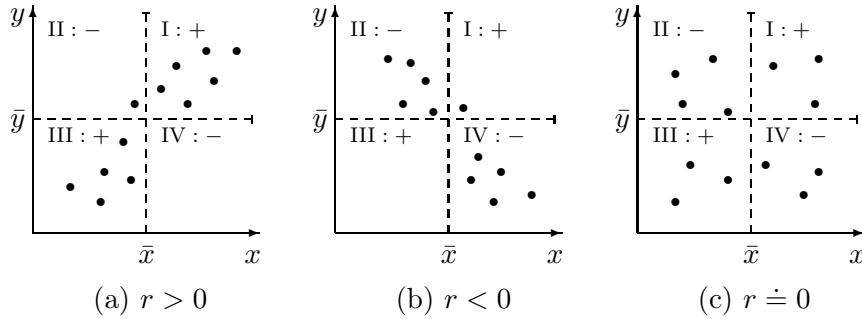


圖3 (x, y) 之散佈情況與相關係數之符號

最後，附帶一提，對二事件 A, B ，若滿足 $0 < P(A), P(B) < 1$ ，則可如下定義其相關係數 $P(A, B)$ ：

$$(25) \quad \rho(A, B) = \frac{P(A \cap B) - P(A)P(B)}{\sqrt{P(A)(1 - P(A))P(B)(1 - P(B))}}.$$

與隨機變數的相關係數有一些類似的性質。即 $|\rho(A, B)| \leq 1$ ，且 $\rho(A, B) = 1$ ，若且唯若 $A = B$ ； $\rho(A, B) = -1$ ，若且唯若 $A = B^c$ ，其中 B^c 表 B 之餘集。又 $\rho(A, B) = 0$ ，若且唯若 A, B 獨立。

5 相關與因果

如果拜訪客戶之次數(X)與客戶購買電腦的數目(Y)，其相關係數為正，且不算太小，如0.5，則顯示廠商拜訪客戶愈頻繁，客戶買的電腦數有愈多的傾向。這樣一來，廠商自然受到鼓勵，會勤於拜訪客戶。二隨機變數若不獨立，便是有關係。有時會說有關連(association)，或就說相關。雖然在上一節中已介紹，諸如無相關、正相關、負相關，及完全相關等，都有特別的定義，但人們還是常籠統的以相關一詞，表示二隨機變數之間有某種關連，也就是不獨立。相關係數主要是量測二變數間的線性關係。在上一節例4及例5看到，即使相關係數為0，二變數仍可能有密切關係。除了相關係數之大小外，諸如一個變數隨著另一變數之增大，而有較高的機率增大，或較高的機率變小，也都表二變數相關。相關性為做決策時之一有效的依據。著名的“尿布與啤酒”事件，大家可能聽過。Wal-Mart 是美國最大的一家百貨連鎖店，很擅長購物籃分析(market basket analysis)。他們檢查顧客的購物清單，發現啤酒與尿布，同時出現的比例很高。經過調查發現，很多家庭主婦會叮嚀先生下班時買尿布。需要尿布的家庭，總是在家中有嬰兒，而會買尿布的先生，大抵也較顧家。待在家中照顧嬰兒，總不能去睡覺或做太專注的事，於是通常就看看電視以打發時間，這時啤酒就需要了。弄清楚後，Wal-Mart 遂在各賣場，將表面上看起來風馬牛不相及的尿布與啤酒擺在一起，結果尿布與啤酒的銷售量雙雙大增。

網際網路的時代，使資訊的搜尋及傳遞更便捷。著名的網路書店亞

馬遜(Amazon)，從其“顧客書評”中，可了解買這本書的顧客，也買那些書。這種閱讀的相關，對讀者及出版社，都是一重要資訊。

不論醫學或商業上，甚至很多其他的領域，都常有相關性的研究。例如，

過敏性鼻炎及氣喘的相關性，

大學學測成績與大學成績的相關性，

乳房大小與乳癌發生率的相關性。

乳癌列名婦女十大死因之前幾名，各種“XX與乳癌的相關性”之研究很多，連乳房大小都可拿來探討。曾有一則新聞，標題為“美政府著手調查潛艦與海豚擋淺事件相關性”。海豚擋淺怪罪潛艦？原來美國佛羅里達州南部，有一周發生海豚大量擋淺，美國政府遂進行調查，看是否與當地海域，海軍演習中的潛艦聲納系統有關。但要注意的是，相關性很高，不表其中必有因果關係。前言裡那則“給你笑笑”，雖辦出舞蹈與出版品有很高的相關性，二者間其實並不會有太大關連。千萬不可輕率地對統計上看起來似乎相關的兩個因素，驟下結論說其間有因果關係。因果關係是否存在，並非統計理論可以證實。就算利用統計裡的假設檢定，接受買尿布者，又買啤酒的比例，高於又買其他飲料(如果汁、可樂等)之假設，也並未證出買尿布者，對啤酒的需求較高。因果關係需藉助其他科學方法來判定，無法只靠統計。見底下二實例。

例6. 1958年，著名的統計學家R. A. Fisher發表一篇有意思的文章，標題為Cigarettes, cancer and statistics(香菸、癌症與統計)。隨後(1958, 1959)又在頗負盛名的Nature雜誌上發表Lung cancer and cigarettes? 及Cancer and smoking二文。原來老菸槍Fisher，對那些抽菸會導致肺癌的研究非常不滿，他認為其中的所謂“證據”，常是有瑕疵的。例如，有些數據被刻意隱瞞，研究報告是經過篩選或刪改等。他覺得政府就是想用一切力量，讓大家接受抽菸的可怕和危險。讀者可參考葉偉文譯(2001)一書第十八章“抽菸會致癌嗎？”一文，關於此事件之來龍去脈。

時至今日，儘管反菸人士努力地宣導，仍有許多癮君子，何況是五十年

前。雖然研究顯示，肺癌與抽菸的相關性很高，但如同前面所述，相關性高並不必然導致其間有因果關係。那些嗜菸者，當然更不會輕易因一些統計分析而戒菸。就像肉食主義者，不會因“吃肉致癌的機率是抽煙的1-2萬倍”之報導(台中榮總醫師王輝明提出的)，而改為吃素。由於愈來愈多的研究指出抽菸對健康不好，而且抽二手菸也很不好，再加上反菸團體大力遊說，我國立法院早於民國86年，便通過“菸害防治法”，大幅限縮吸菸場所。

例7. 2004年5月，在美國紐奧良(New Orleans, 2005年9月遭卡崔娜颶風重創的美國南部大城)，召開的一研討會上，印度的一個醫療小組提出報告，他們從美國人過去半個世紀氣泡飲料的平均消耗，找到和食道癌罹患率提高的關連。報告中指出，美國人平均一年飲用氣泡飲料的量，過去50年增加了450%，而過去25年來，美國白人男性食道癌罹患率，也呈現明顯增加的趨勢。

有人質疑這說不定只是巧合，或如前所述可能是其他原因所造成。為什麼說可能是巧合？隨著經濟好轉，或行銷成功，不少產品銷售量大增。過去50年不只氣泡飲料的每人每年平均的飲用量，汽車購買，旅遊次數，以及很多其他的消費，可以想像都是大幅增加。但總不能說都與食道癌有關。不過該研究小組提出科學的理論基礎，即氣泡飲料會讓胃部膨脹，導致消化液逆流，而這是食道癌產生的原因之一。他們的研究還發現，氣泡飲料的消耗，和食道癌增加的關連，為一全球性的趨勢。

兩變數看起來有關連，有時可能是其中某些潛在變數所造成。著名的辛普生謬論(Simpson's paradox)，也是指因另一變數的介入，而使兩變數的關係反過來，見黃文璋(2006b)例6。下例亦為一種常見的情況。

例8. 曾有某大學女學生抱怨，該校研究所對女生較不公平，因全校研究所女生的總錄取率35%，明顯較男生的44%低。該校研究所很多，自其中挑出6個較大的研究所來比較，可得表1(見Freedman et al. (1991)p.17)。

6個研究所中，有A, B, D, F等4個研究所，女生錄取率高於男生；男生

錄取率高於女生的，僅有C,E等2研究所。但若6個研究所一起看，約有44%的男生被錄取，卻只有30%的女生被錄取，相差高達14%。此矛盾是如何產生的？

表1 6個研究所男女生錄取率

所別		申請	錄取	錄取率
A	女	108	89	82%
	男	825	511	62%
B	女	25	17	68%
	男	560	353	63%
C	女	593	201	34%
	男	325	120	37%
D	女	375	131	35%
	男	417	138	33%
E	女	393	94	24%
	男	191	53	28%
F	女	341	24	7%
	男	373	22	6%
合計	女	1835	556	30%
	男	2691	1197	44%

如果仔細檢查表1, A,B二研究所較易申請，且有一半以上的男生(共1385人)申請此二研究所，而C,D,E,F四個研究所較難申請，卻有超過90%的女生(1702人)申請。換句話說，男生較多申請較容易進的研究所，女生較多申請較難進的研究所。因此光由表面上全校研究所總錄取率之高低，來推測其錄取對女生不公，並不恰當。事實上，有可能全校每一研究所都是女生錄取率較高，但全校一起看，卻是男生錄取率較高。

這類例子不少。例如，甲乙兩袋中，皆有紅白兩種籤，每支籤可能中獎，也可能不中獎，兩袋中皆是紅籤中獎率較高。現將兩袋中的籤混為一

袋。則有沒有可能新袋中，紅籤中獎率變成較低？答案是肯定的。甚至新袋中紅籤中獎率，有可能不到白籤的百分之一（更小也都可能）。此問題不難，留給讀者自己舉例好了。

潛在變數的可能存在，使我們在依相關性做決策時要更小心，見下例。

例9. 2006年1月4日有一則“咖啡能減少罹患乳癌風險”的報導。婦女聞乳癌而色變，若喝咖啡真能減少罹患率，當然是一好消息。

加拿大多倫多大學的研究團隊，對將近1,700名體內有BRCA1特殊突變基因的婦女，探討咖啡和乳癌之間的關係。這個族群的婦女，在70歲以前，有0.8的機率會得乳癌。研究結果發現喝咖啡將可降低她們乳癌罹患率。每天若喝1到3杯含咖啡因的咖啡，罹患率可降低約10%；喝4到5杯，可降約25%；若每天平均喝6杯以上，乳癌罹患率將減少約75%。研究人員說，關鍵可能是出在植物性荷爾蒙上，咖啡中也含有多量的植物性荷爾蒙。

看起來對那些體內有BRCA1乳癌易感基因的婦女為一重大消息，似乎該拼命喝咖啡才是。但咖啡喝太多，是否會引發其他毛病？這篇報導可沒說。在準備大喝咖啡前，還是得多打聽一下（有人指出喝咖啡若加一包糖及一個奶油球，便有50大卡熱量，每天6杯就有300大卡。如果沒有適度運動，長期下來易發胖。而體內囤積過多脂肪，恰是乳癌的高危險群！）。

雖然統計分析無法證明因果關係。但統計分析後，所找出之不同變數間的相關性，可提供進一步探討的方向。探討結果可能證實其間有因果關係，或澄清純粹只是巧合，或其他因素造成。沒有進一步探討，就冒然論斷因果，甚至大作文章，有時會出笑話的。我們以下述事件做為本文之結束。

2004年3月台灣的總統大選，引發若干爭議。當年5月，於總統就職前，中央研究院有位研究人員，提出他對廢票率的分析。他指出廢票率與支持度呈現高度的關連性。廢票率愈高的投開票所，開出的選票中，陳水扁和呂秀蓮那組較佔上風，廢票率較低的投開票所，開票結果，連戰和宋楚瑜那組較居優勢。他因此斷言廢票決定了此次總統大選的結果，認為其中必

然有做票。他對自己的研究成果深具信心，不怕綠營來控告，並主動放棄抗告的權利。

造成幾天的譁然後，這件事後來不了了之，多數人都難以接受這樣的推論。總之，統計上的相關，與因果關係，有時是兩回事。很多情況下，相關性可做為決策之依據，如前述尿布與啤酒的關係之例。無論如何，將啤酒放在尿布附近，大約不會有不良後果。但對諸如氣泡飲料和食道癌的關係，或任何可能會引起很大爭議的事件，就要有更多佐證後，才適合提出研究報告，並給出建議。

參考文獻

1. 黃文璋(2003a). 機率論。華泰文化事業股份有限公司，台北。
2. 黃文璋(2003b). 數理統計。華泰文化事業股份有限公司，台北。
3. 黃文璋(2006a). 統計顯著性。數學傳播季刊, 29(4): 29-38.。
4. 黃文璋(2006b). 決策的誤差。數學傳播季刊，已接受。
5. 葉偉文譯(2001). 統計改變了世界(David Salsburg原著: *The Lady Tasting Tea*)。天下遠見出版股份有限公司，台北。
6. Freedman, D., Pisani, R., Purves, R. and Adhikari, A. (1991). *Statistics*, 2nd ed. W. W. Norton Company, New York.
7. Fisher, R. A. (1958). Cigarettes, cancer and statistics. *Centennial Review*, 2, 151-166.