

信賴區間與假設檢定

黃文璋

國立高雄大學應用數學系

1. 前言

投擲一銅板 k 次，假設銅板各次出現的結果為獨立，且每次出現正面的機率皆為 p ，則總共得到的正面數 X 有二項分佈(binomial distribution)，參數分別為 k 及 p ，我們以 $\mathcal{B}(k, p)$ 表此分佈。即 X 會是 i 的機率為

$$(1) \quad P(X = i) = \binom{k}{i} p^i (1-p)^{k-i}, i = 0, 1, \dots, k.$$

投擲一銅板 k 次，會得到幾次正面是不一定的，除非此銅板兩面皆為正(此時 $p = 1$)，或兩面皆為反(此時 $p = 0$)，否則所得的正面數 X ，其值從 0, 1 至 k 皆有可能。此種現象稱為一隨機現象(random phenomenon)， X 則稱為一隨機變數(random variable)。由排列組合中所學到的技巧，我們可輕易得到(1)式。也就是對投擲銅板會得到幾個正面此一隨機現象，由理論上的結構，我們給出了(1)式為其機率模型(probability model)。其中有一參數(parameter) p 則仍屬未知，除非知道 p 之值，否則(1)式中之機率還是求不出的。

在量測時，我們常假設誤差為常態分佈(normal distribution)，參數分別為 μ 及 σ^2 ，以 $\mathcal{N}(\mu, \sigma^2)$ 表之。若再加上誤差對稱於 0 的假設，則 μ 便取為 0。人的身高、體重及智商等，便是常以常態分佈為其機率模型的例子。這其中主要的理論依據則為著名的中央極限定理(Central limit theorem)。

其他還有許多分佈是常被拿來當作機率模型的，大家可翻閱一般機率論的書，在此不多介紹。一隨機現象(或一統計實驗(statistical experiment))之所有的結果，便構成所謂的母體(population)。如前述投擲銅板的例子，若做了 n 次實驗，且以 X_1, X_2, \dots, X_n 分別表此 n 次所得之正面數，則 X_1, X_2, \dots, X_n 為獨立且有共同分佈(independent and identically distributed, 簡稱i.i.d.)，稱為自機率密度函數(probability density function, 簡稱p.d.f.)。如(1)式之母體所產生之一組隨機樣本(random sample)，簡稱樣本。

一旦一機率模型被建立了，通常便要估計(estimate)其中未知的參數。統計學裏便發展出許多估計的方法(method of estimation)。而所謂點估計(point estimator)，便是一組樣本 X_1, X_2, \dots, X_n 之某一函數 $W(X_1, X_2, \dots, X_n)$ 。而 $W(X_1, X_2, \dots, X_n)$ 又稱為一統計

量(statistic)。因此任一統計量皆可當作一點估計。又為了判斷這些不同的估計方法孰優孰劣？便發展出評估估計量(estimator)的方法(method of evaluating estimators)。

在一機率模型中，設以0.3來估計其中某一參數 θ ，則“ $\theta = 0.3$ ”此一敘述，便稱為一假設(hypothesis, 複數為hypotheses)。所謂假設就是對母體中之參數的一些“看法”，或說一判斷。此假設是要經過檢定(test)，才知其正確與否。檢定一假設的過程，便稱假設檢定(test of hypothesis, 或hypothesis testing)。一般所謂統計推論(statistical inference)，便是包含估計及假設檢定兩部份。

對一參數 θ ，點估計給出此參數之一估計值。不過有時需要知道估計的可靠程度，這時便要給出一個區間，並且指出此區間包含 θ 之機率，這就是區間估計(interval estimation)。給定 $0 < \alpha < 1$ ，若存在二統計量 $U = U(X_1, X_2, \dots, X_n)$ ，及 $L = L(X_1, X_2, \dots, X_n)$ ， $L \leq U$ ，並滿足

$$(2) \quad P(L \leq \theta \leq U) = 1 - \alpha,$$

則隨機區間 $[L, U]$ 稱為 θ 的一 $100(1 - \alpha)\%$ 信賴區間(confidence interval)，至於 $1 - \alpha$ 則稱為信賴係數(confidence coefficient)，或稱信賴度， L 與 U 則分別成為信賴下界及信賴上界。信賴區間又稱為置信區間，信賴係數又稱置信度。

以一區間估計來取代點估計的目的，就是為使對參數的掌握能有一些保證。例如，若估計銅板出現正面的機率 $p = 0.4$ ，則因 $p \in [0, 1]$ ，為一連續的區間，故此估計會命中實際的 p 之可能性大約是零。但若給出一區間，譬如說 $[0.3, 0.5]$ ，且指出 p 會落在此區間的機率為 0.95，則對 p 之大小反而有一更清晰的概念。這是為什麼有時要討論區間估計，而不僅是點估計的主要原因。

有時候特別是對離散型的分佈，不一定可找到一區間 $[L, U]$ ，使得 $P(L \leq \theta \leq U) = 1 - \alpha$ 。此時我們便尋找 L 及 U ，使得 $P(L \leq \theta \leq U) \geq 1 - \alpha$ ，且使左側機率儘可能地接近 $1 - \alpha$ 。

信賴區間與假設檢定雖為統計學中兩個基本的題材，其原理也都不太難，但有些人在使用時，因不夠謹慎常犯了錯誤而不自知。本文便是要針對此二題材，略加闡釋。我們並不擬完整地介紹此二題材，因這是一般統計學教科書的工作，我們只是要使各位因此能在日後隨時留意，務必要正確而又有效地使用統計方法。

2. 信賴區間

設隨機變數 X_1, X_2, \dots, X_n 為i.i.d. 以 $\mathcal{N}(\mu, \sigma^2)$ 為其共同分佈，令 $\bar{X}_n = \sum_{i=1}^n x_i/n$ 表其樣本平均。則知 \bar{X}_n 有 $\mathcal{N}(\mu, \sigma^2/n)$ 分佈。令 Z 表一有 $\mathcal{N}(0, 1)$ 分佈(即標準常態分

佈 (standard normal distribution)) 之隨機變數，且令 Φ 表其分佈函數 (distribution function)，即

$$\Phi(x) = P(Z \leq x) = \int_{-\infty}^x \frac{1}{\sqrt{2\pi}} e^{-u^2/2} du, \quad x \in R,$$

又令 z_y 表 $\Phi(x)$ 之反函數，即對 $\forall 0 < y < 1$ ，

$$\Phi(z_y) = P(Z \leq z_y) = \int_{-\infty}^{z_y} \frac{1}{\sqrt{2\pi}} e^{-u^2/2} du = y.$$

現因對 $\forall 0 < \alpha < 1$ ，

$$\begin{aligned} & P(-\bar{X}_n - \sigma z_{1-\alpha/2}/\sqrt{n} \leq \mu \leq \bar{X}_n + \sigma z_{1-\alpha/2}/\sqrt{n}) \\ &= P\left(\left|\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}}\right| \leq z_{1-\alpha/2}\right) \\ &= P(|Z| \leq z_{1-\alpha/2}) = 1 - \alpha/2 - \alpha/2 = 1 - \alpha, \end{aligned}$$

即

$$(3) \quad P(\bar{X}_n - \sigma z_{1-\alpha/2}/\sqrt{n} \leq \mu \leq \bar{X}_n + \sigma z_{1-\alpha/2}/\sqrt{n}) = 1 - \alpha.$$

故若 σ 已知，則

$$(4) \quad I = [\bar{X}_n - \sigma z_{1-\alpha/2}/\sqrt{n}, \bar{X}_n + \sigma z_{1-\alpha/2}/\sqrt{n}]$$

為 μ 之一信賴係數為 $1 - \alpha$ 之信賴區間。此區間有時以 $I = \bar{X}_n \pm \sigma z_{1-\alpha/2}/\sqrt{n}$ 表之。給定一 α 值，由標準常態分佈之數值表可查出 $z_{1-\alpha/2}$ 之值，因此信賴區間便可決定了。當 $\alpha = 0.1, 0.5$ 及 0.01 時 (這是幾個常取的 α 值)， $z_{1-\alpha/2}$ 之值分別約為 $1.64, 1.96$ 及 2.576 。

例1. 某工廠生產某種花瓶，根據過去的經驗，瓶口直徑 (單位為公分) 有常態分佈，標準差為 1.1 。從某日的產品隨機抽取 10 個，量其直徑分別為 $7.2, 8, 7.3, 6.9, 7.3, 7.0, 7.1, 7.5, 7.1, 7.8$ 。試給出直徑之期望值的一 95% 信賴區間。

解. 在此 X_1, X_2, \dots, X_{10} 為 i.i.d. 之 $\mathcal{N}(\mu, 1.1^2)$ 隨機變數， μ 即為其期望值。

因 $\bar{X}_n = 7.32, \alpha = 0.05$ ，故 μ 之一 95% 信賴區間為

$$[7.32 - 1.1 \times 1.96/\sqrt{10}, 7.32 + 1.1 \times 1.96/\sqrt{10}],$$

約為 $[6.64, 8.00]$ 。

由以上的討論知，當母體有常態分佈且標準差已知時，要求出期望值 μ 之一信賴區間，可說是一極簡易的問題。當然你可能會問，在很多實例中，母體之標準差 σ 可能為未知，此時該如何？在統計學裡，樣本變異數 (sample variance)

$$S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$$

常用來做為 σ^2 之估計值。當樣本數夠大，則可以 S_n 取代(4)式中之 σ ，而得近似之信賴區間。樣本數有多少才算夠大呢？通常超過30就可以了。又若 σ 未知而樣本數又不超過30該如何呢？統計學裡也指出，利用 $(\bar{X}_n - \mu)/(S_n/\sqrt{n})$ 有自由度 (degree of freedom) $n - 1$ 的 t 分佈，以 T_{n-1} 表之，再利用假設檢定裡的一些結果仍可得到信賴區間，這也牽涉到非常態分佈的信賴區間該如何求出，細節在此不多討論（假設檢定與信賴區間二者間，有一對應關係。一般而言每一信賴區間便對應一檢定，反之亦然，在第4節裡我們會提到）。

我們既然不擬對信賴區間多做深入探討，那究竟要討論什麼呢？

首先所謂 $100(1 - \alpha)\%$ 信賴區間到底是什麼意思？當你看到有人指著一區間說，這是 μ 的 95% 信賴區間，他是在信賴什麼呢？ 95% 的意義又是什麼呢？對於(4)式，我們通常說有 $100(1 - \alpha)\%$ 的信心 μ 會屬於區間 I 。但對於例1，我們是否可說 μ 會落在區間 $[6.64, 8.00]$ 之機率約為 0.95 ？不少人以為此答案是肯定的。事實上，對於例1，敘述 $P(\mu \in [6.64, 8.00]) = 0.95$ 並不正確。(4)式為一隨機區間，在取樣前，有 $1 - \alpha$ 的機率，此區間會包含 μ 。但是一旦取得一組樣本 x_1, x_2, \dots, x_n ，且將(4)式中之 \bar{X}_n 以 $\bar{x}_n = \sum_{i=1}^n x_i/n$ 取代，則所有隨機性便消失了，而是得到一特別的區間。又因 μ 為一常數（只是不知其值為何）， μ 要嘛落在此區間，要嘛不落在此區間，說 $P(\mu \in [\bar{x}_n - \sigma z_{1-\alpha/2}/\sqrt{n}, \bar{x}_n + \sigma z_{1-\alpha/2}/\sqrt{n}]) = 1 - \alpha$ 自然不對。例如，在例1中，若該工廠一資深員工知道 μ 應很接近 8.1 ，則若你告訴他 $P(\mu \in [6.64, 8.00]) = 0.95$ ，他一定斥為無稽（此正如設一袋中有1個紅球9個白球，某人隨機地取一球，設取中紅球。這時你告訴他此球為白球之機率為 0.9 ，他必覺得你不知所云）。但在同一 α 及 n 之下，若我們持續地取樣，每次各得一信賴區間，則長期而言，這些信賴區間中，約有 $100(1 - \alpha)\%$ 個會涵蓋 μ 值。

藉圖形來說明。圖1為 $\mathcal{N}(\mu, \sigma^2)$ 分佈之樣本平均 \bar{X}_n 之p.d.f.的圖形，圖2為在 σ 已知之下，依序取樣14次（每次皆取 n 個樣本），所得之14個 95% 信賴區間。若 \bar{X}_n 介於 $\mu - 1.96\sigma/\sqrt{n}$ 及 $\mu + 1.96\sigma/\sqrt{n}$ 之間，則得到的信賴區間會包含 μ 。由於圖1中機率密度函數的圖形介於 $\mu - 1.96\sigma/\sqrt{n}$ 與 $\mu + 1.96\sigma/\sqrt{n}$ 間之面積約為 0.95 ， \bar{X}_n 會落在此範圍內之機率便也約為 0.95 。圖2中之14個信賴區間，第9個並未包含 μ 值。但由頻率對機率的解釋(frequentistic interpretation of probability)，我們知道若取樣夠多次（因此得到很多 \bar{X}_n 之實際值 \bar{x}_n ），則其中約有 95% 個（口語有時講二十次中有十九次）信賴區間會包含 μ 。至於對任一特別的區間，說其有 95% 的機率會包含 μ ，則是沒有意義的。因這一特定的區間已非隨機區間，常數（但未知） μ 會落在此區間的機率不是 1 便是 0 。

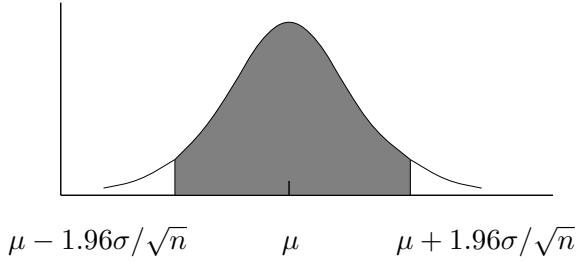


圖1 \bar{X}_n 之機率密度函數的圖形

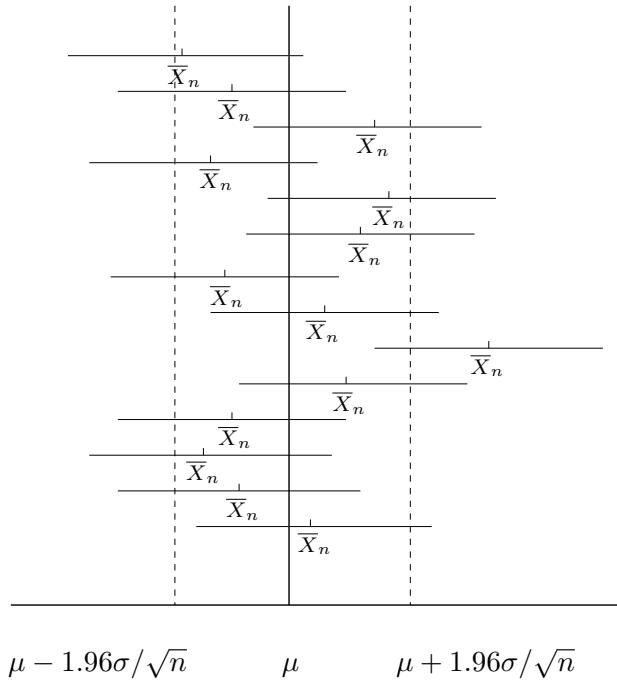


圖2 對 $\mathcal{N}(\mu, \sigma^2/n)$ 經由重複取樣所得之14個 95% 信賴區間

3. 信賴區間與品質管制

仍以常態分佈為例。在上節中，我們說(4)式給出 μ 之“一”信賴係數為 $1 - \alpha$ 之信賴區間，此即隱含對同一 α 值，信賴區間並不唯一。例如，

$$I_1 = [\bar{X}_n - \sigma z_{1-2\alpha/3}/\sqrt{n}, \bar{X}_n + \sigma z_{1-\alpha/3}/\sqrt{n}]$$

亦為 μ 之一信賴係數為 $1 - \alpha$ 之信賴區間。只是由圖1可看出(假如你有些幾何的概念)，區間 I_1 的長度大於(4)式中區間 I 之長度。一般而言，信賴區間的長度愈短愈好，愈短表愈精確。假設你給出一參數 μ 之 95% 信賴區間，若此區間極長，說不定有人會取笑你乾脆取為 $(-\infty, \infty)$ ，保證 μ 落在此區間。

有些工廠的品質管制(以下簡稱品管)人員，便以(4)式中之信賴區間，作為品管之依據。假設某產品之規格(如長度、重量等)須為 μ 。經隨機抽取 n 個樣本後，得到一如(4)式之 95% 信

賴區間(σ 假設為已知)。則若 μ 落在此區間，便認為該批產品為合格，否則認為不合格。偶而有品管人員心存疑惑，取樣愈多(n 愈大)，則信賴區間的長度愈短((4)式中之區間長度為 $2\sigma z_{1-\alpha/2}/\sqrt{n}$ ，隨著 n 增大而變小)，因此愈不容易包含 μ ，如此一來，不是產品愈容易不合規格嗎？所以他們對取樣愈多存有抗拒之心(更何況取樣多本來就已較麻煩)。你認為他們的抗拒合理嗎？檢視圖2，區間長度若較短，則會包含實際 μ 值之機會的確是較小，品管人員之排斥較大的 n 似乎是有道理的。

你若同意那些品管人員的看法，那真是印證若要將統計學好，還是得先對機率下些功夫，否則不過學些花拳繡腿，經常停留在見山不是山，見水不是水的階段。

若採用(4)式做為信賴區間，對一固定產品(因此 σ 相同)，在同一 α 值之下，信賴區間隨著 n 之增大而變短。但不要忘記， α 沒有改變，換句話說，對這些或長或短的區間，我們皆有相同的 $100(1 - \alpha)\%$ 信心，認為 μ 會落在其中。所以就理論而言，認為 n 較大時， μ 便較不易落在對應之信賴區間，其實是沒有道理的，故此實為不成問題的問題。不若為何1加1等於2？或為何複數不能比大小？都還成為一問題。但我們還是願稍加解釋，免得你嘴裡不說，心裡卻懷疑統計是否有乾坤大挪移之功。

由大數法則(Law of large numbers)知， n 愈大時， \bar{X}_n 有愈靠近 μ 之傾向(這是白話，正式的說法請查一般機率論的書)，即“在某種意義下”，隨著 n 之變大， \bar{X}_n 會趨近至 μ 。因此 n 愈大時，以 \bar{X}_n 為中心，只需要較小的半徑(長度為 $\sigma z_{1-\alpha/2}/\sqrt{n}$)，該區間仍有相同的機率 $1 - \alpha$ 會涵蓋 μ 。有點像若飛彈射得愈準，則雖爆破半徑較小，對目標物仍可有相同的摧毀效果。

其次就是涵蓋 μ 的機率若相同，我們仍較偏好區間長度較小者。原因很簡單，區間長度愈短，表示推論愈精準。你告訴別人 μ 有 0.95 的機率會落在一長度為 10 的區間，也同樣有 0.95 的機率會落在另一長度為 5 的區間，一般人當然覺得後者較準。這就是取樣較多(n 較大)所換得之代價。下例亦顯示信賴區間太大之缺失。

例2.在某項選舉中有兩位候選人，欲了解選民對其中某一候選人之支持程度。隨機抽樣 50 人，發現其中有 27 人支持該候選人。問此時該候選人是否可安心地以為穩操勝券？

解.假設選民總數夠多，因而可忽略取樣後不放回(sampling without replacement)，與取樣後放回(sampling with replacement)間之差異。則本問題可採用下述機率模型：設 X_1, X_2, \dots, X_n 為 i.i.d. 以 $\mathcal{B}(1, p)$ 為其共同分佈。我們擬給一 p 之 95% 信賴區間。利用中央極限定理(在一般的實例中，通常樣本數 30 以上，以中央極限定理來估計誤差便不大了)，得 $(\bar{X}_n - p)/(\sigma/\sqrt{n})$ 有近似的 $\mathcal{N}(0, 1)$ 分佈。其中 $\sigma = \sqrt{p(1-p)}$ 為 $\mathcal{B}(1, p)$ 分佈之標準差，此處當然是未知。利用 $n \rightarrow \infty$ 時， $\bar{X}_n(1 - \bar{X}_n)$ 機率收斂(converge in probability)至 $p(1 - p)$ ，便得 p 之一近似

的 $100(1 - \alpha)\%$ 信賴區間為

$$[\bar{X}_n - \sqrt{\bar{X}_n(1 - \bar{X}_n)/n} z_{1-\alpha/2}, \bar{X}_n + \sqrt{\bar{X}_n(1 - \bar{X}_n)/n} z_{1-\alpha/2}]。$$

因 $\bar{x}_n = 27/50 = 0.54$, 且 $\sqrt{\bar{x}_n(1 - \bar{x}_n)} = \sqrt{0.54 \times 0.46} \doteq 0.498$, 故 p 之近似的 95% 信賴區間為

$$\begin{aligned} & [0.54 - 0.498 \cdot 1.96/\sqrt{50}, 0.54 + 0.498 \cdot 1.96/\sqrt{50}] \\ & \doteq [0.402, 0.678]。 \end{aligned}$$

由於上述區間包含小於 0.5 的部分 [0.402, 0.5), 且長度並不算短, 故雖事先的抽樣顯示該候選人的支持度較高, 在選舉時若該候選人落敗並不足為奇。

但若取樣增加為 $n = 1,000$, 且得到 540 個支持者, 則 \bar{x}_n 仍為 0.54, 但此時 p 之近似的 95% 信賴區間成為 [0.510, 0.571], 區間長度不但變短, 且 0.5 落在此區間之左側。因此在相等的 \bar{x}_n , 且同樣的信賴係數之下, 後者 (n 較大, 區間較短) 顯然給我們一個較精確的推論。

4. 從信賴區間至假設檢定

我們先看下例。

例3. 假設某電池壽命(單位為小時)有常態分佈, 標準差 $\sigma = 2$, 電池壽命之期望值 μ 要等於 100 才符合要求。今對某批產品抽檢 10 個樣本, 分別測量其壽命為 101, 103, 107, 99, 102, 101, 96, 104, 99, 103。試問 μ 是否為 100 小時?

解. 依假設即知 X_1, X_2, \dots, X_n 為 i.i.d. 之 $\mathcal{N}(\mu, 2^2)$ 隨機變數, 而想回答 $\mu = 100$ 是否正確。如果 $\mu = 100$ 之假設成立, 則 X_i 有 $N(100, 2^2)$ 分佈, $i = 1, 2, \dots, n$ 。現考慮統計量

$$Z_n = \frac{\bar{X}_n - 100}{2/\sqrt{n}}。$$

則 Z_n 有 $\mathcal{N}(0, 1)$ 分佈。因此對 $\forall 0 < \alpha < 1$,

$$P\left(\left|\frac{\bar{X}_n - 100}{2/\sqrt{n}}\right| > z_{1-\alpha/2}\right) = \alpha。$$

若取 $\alpha = 0.05$, 則 $z_{1-0.05/2} = z_{0.975} \doteq 1.96$, 且取樣之 $\bar{x}_{10} = 101.5$, 而 $(\bar{x}_{10} - 100)/(2/\sqrt{10}) \doteq 2.37 > 1.96$ 。也就是小機率事件

$$\left|\frac{\bar{X}_{10} - 100}{2/\sqrt{10}}\right| > z_{0.975}$$

(此事件之機率僅約為 0.05)竟然發生了。因此我們可合理地推測原假設 $\mu = 100$ 不成立。又前述 Z_n 稱為此檢定之檢定統計量(test statistic)。

如果在另一次取樣得到 $\bar{x}_{10} = 101.1$, 因

$$\left| \frac{101.1 - 100}{2/\sqrt{10}} \right| \doteq 1.73 < z_{0.975},$$

此時我們便不否定原假設 $\mu = 100$ 。

在此我們給一些假設檢定之基本概念。我們將例3中的假設 $\mu = 100$ 記作

$$H_0 : \mu = 100,$$

並稱此為虛無假設(null hypothesis), 而把 $\mu \neq 100$ 稱作對立假設(alternative hypothesis), 記作

$$H_a : \mu \neq 100.$$

視情況之不同, 可有不同的虛無假設及對立假設。如 $H_0 : \mu \leq 100$, 且 $H_a : \mu > 100$ 等。例3中的 α 稱為顯著水準(level of significance, 或significance level)。拒絕虛無假設的區域稱為拒絕域(rejection region 或critical region), 或棄卻域。若一觀測值落在拒絕域中, 則稱該觀測值於水準 α 之下, 有統計顯著性(statistically significant at level α)。當 $\alpha = 0.05$, 例3中之拒絕域為

$$\{ |(\bar{X}_n - 100)/(2/\sqrt{n})| > z_{0.975} \},$$

即

$$(-\infty, 100 - 2z_{0.975}/\sqrt{n}) \cup (100 + 2z_{0.975}/\sqrt{n}, \infty),$$

當 \bar{X}_n 屬於此區域便拒絕 H_0 。拒絕域之餘集則稱接受域(acceptance region), 即 $\{ |(\bar{X}_n - 100)/(2/\sqrt{n})| \leq z_{0.975} \}$ 。

對於例3, 你可能會說拒絕或接受 H_0 , 似乎有些是依“運氣”。的確如此, 更明確地說, 我們可能會犯下述兩種錯誤之一：在 H_0 為真之下拒絕 H_0 , 或在 H_a 為真之下接受 H_0 。前者稱為第一型錯誤(type I error), 後者稱為第二型錯誤 (type II error)。分別以 α, β 表犯第一型及第二型錯誤的機率。我們當然希望犯此兩種錯誤的機率同時都很小。但一般而言, 在樣本數 n 固定之下, α 愈小則 β 愈大, 反之 β 愈小則 α 愈大, 並無法讓 α 及 β 同時都變小。例如, 若有一檢定, 其 α 為 0, 此表永遠接受 H_0 , 因此 $\beta = 1$ 。在實際應用時, 通常我們先控制 α 值(底下會說明為何先控制 α 值), 且在給定一 α 之下, 找一 β 值最小的檢定法, 也就是給出拒絕域。

這其間的細節我們不討論了，各位可參考一般統計學的書。我們僅提出幾個須留意的要點。

首先雖然我們採用“接受”及“拒絕”的字眼，但必須了解的是，拒絕一假設 H_0 表認為 H_0 不成立，然而接受 H_0 往往僅表沒有充分的證據顯示 H_0 不成立。通常在做檢定時，要將“想拒絕之看法”置於 H_0 ，或者說將“想接受之看法”置於 H_a 。例如，某廠牌之輪胎平均可行駛 30,000 公里，現製出一新型輪胎，想判定是否較舊型為優。令 μ 表新型輪胎行駛里程之期望值，則可取 $H_0 : \mu \leq 30,000$ ，即假設 μ 並未提高，且取 $H_a : \mu > 30,000$ 。因我們是想推翻 H_0 ，即採認新型輪胎較優。各位應也可明白為何 H_0 稱為虛無假設了。因接受 H_0 ，即認為新型輪胎並不優於舊輪胎，這種結論實在是沒什麼好公佈的(一般人是不會公佈失敗的結果)，主持這項檢定者，對接受 H_0 是毫無喜悅可言。

從以上的說明，可看出假設檢定乃採用反證法。即先假設某不想要的情況成立。然後在此假設下進行推導，如果得到矛盾，則便推翻原來的假設。如果沒有得到矛盾，則便不拒絕原來的假設。但是此處的反證法，有別於數學中的反證法。因此處所謂矛盾，並非形式邏輯中的絕對矛盾，而是基於人們在實際經驗中常採用的一原則：小機率事件，在一次實驗中不易發生。根據此一原則，如果小機率事件在一次實驗中發生了，便認為原來的假設不成立。換句話說，假設檢定中所採用者，乃是一種機率式的反證法。

底下給一例來說明為何 α 與 β 無法同時變小。

例4. 設某藥有 0.25 的機率能治癒某種疾病，現有一種新的且較貴的藥，想檢定此新藥是否優於舊藥。將新藥讓 20 個得此病的病人服用，令 X 表治癒的病人數，則 X 有 $B(20, p)$ 分佈，其中 p 表治癒率。由於目的是希望能宣稱新藥較優(新的藥且又較貴，如果不是較優又何需生產)，所以將 $p = 0.25$ 置於 H_0 , H_a 則為 $p > 0.25$ ，且若有較多的病人被治癒，則認為 H_a 為真。即我們要檢定

$$H_0 : p = 0.25, \text{ 且}$$

$$H_a : p > 0.25,$$

而拒絕域取為 $\{X \geq c\}$ 。當 $c = 9$ ，則第一型錯誤的機率為

$$\begin{aligned} \alpha &= P(X \geq 9 | p = 0.25) \\ &= 1 - \sum_{i=0}^8 \binom{20}{i} (0.25)^i (0.75)^{20-i} \\ &\doteq 1 - 0.9591 = 0.0409, \end{aligned}$$

為一個很小的值。譬如說實際觀測到 $X = 10$ ，則接受新藥較優的看法。

至於第二型錯誤的機率 β , 對此模式並無法計算出來, 除非在 H_a 中, p 為一個明確的值。現若改為 $H_a : p = 0.5$, 則

$$\beta = P(X < 9 | p = 0.5) = \sum_{i=0}^8 \binom{20}{i} (0.5)^{20} \doteq 0.2517.$$

此機率並不算小, 此結果顯示在新藥明顯優於舊藥之下(治療率為二倍), 却有超過四分之一的機率, 會拒絕新藥較佳。

在很多統計軟體裡, 於執行一假設檢定時, 會算出所謂 p 值(p-value)。

然後看你所選的 α 值為何, 若 $p < \alpha$ 則拒絕 H_0 。對一觀測值, 所謂 p 值, 乃在 H_0 為真之下, 檢定統計量會等於該觀測值, 或較該觀測值更極端的機率(也就是會使該觀測值導至拒絕 H_0 之最小的 α)。如前, 若觀測到 $X = 9$, 則 p 值為 0.0409; 若觀測到 $X = 10$, 則 p 值為 0.01385。可看出若 p 值愈小, 則觀測值所提供的拒絕 H_0 的證據就愈強, 換句話說愈顯著。

若 H_0 仍不變, H_a 改為 $p = 0.7$ 會如何? 亦即除非新藥之優勢更高, 否則寧採舊藥。此時

$$\beta = P(X < 9 | p = 0.7) = \sum_{i=0}^8 \binom{20}{i} (0.7)^i (0.3)^{20-i} \doteq 0.0051,$$

降低很多。

最後我們再看, 在 $H_0 : p = 0.25$, 且 $H_a : p = 0.5$ 之下, 若拒絕域改為 $\{X \geq 8\}$, α, β 會有什麼改變? 此時

$$\alpha = 1 - \sum_{i=0}^7 \binom{20}{i} (0.25)^i (0.75)^{20-i} \doteq 1 - 0.8982 = 0.1018,$$

而

$$\beta = \sum_{i=0}^7 \binom{20}{i} 0.5^{20} \doteq 0.1316.$$

採用此新策略, β 變小了, 但 α 却變大了。不難看出若 c 增大, 則 α 變小且 β 變大; 反之若 c 變小, 則 α 變大且 β 變小。特別地, 當 $\alpha = 0$ (即 $c > 20$)時, $\beta = 1$; 當 $\beta = 0$ 時(即 $c < 0$), $\alpha = 1$ 。印證如前所述, 在樣本數固定之下, 對同一個 H_0 及 H_a , 通常減少某一型之錯誤, 便增大另一型錯誤。

再看一個類似的例子。

例5. 一般認為生男的機率為 $p = 0.5$, 不過數據顯示 $p > 0.5$ (如對高加索人(Caucasian) p 約為 0.512)。欲證實 $p > 0.5$, 隨機地取 $n = 10$ 個初生嬰兒。則其之中男孩數 X 有 $\mathcal{B}(10, p)$ 分佈。要檢定 $H_0 : p = 0.5$, 且 $H_a : p > 0.5$ 。如上例當男孩數較多時拒絕 H_0 , 因此拒絕域為 $\{X \geq c\}$, 其中 c 要選的夠大, 使得第一型錯誤的機率 α 夠小。表一為 $p = 0.5$ 時, X 之機率密度函數, 其中 $p(i) = P(X = i | p = 0.5)$ 。

對每一 c , 由表1可求出 $\alpha = P(X \geq c | p = 0.5) = p(c) + p(c+1) + \cdots + p(10)$ 之值。當 c 分別等於5,6,7,8,9,10 時, α 分別約為0.62306、0.37697、0.17189、0.05470、0.01075、0.00098。若取 $c = 8$, 則 $\alpha \doteq 0.05470$, 即若拒絕域為 $\{X \geq 8\}$, 則 $\alpha \doteq 0.05470$, 並不算大。看到這裡, 大部分的人會覺得此檢定的過程還算合理。另一方面, 若 H_a 為真, 且 $p = 0.512$, 則 β 為

$$\begin{aligned} P(X < 8 | p = 0.512) \\ = 1 - \binom{10}{8} (0.512)^8 (0.488)^2 - \binom{10}{9} (0.512)^9 (0.488) - \binom{10}{10} (0.512)^{10} \\ \doteq 0.9364。 \end{aligned}$$

第二型錯誤的機率將近1。換句話說, 在 H_0 不真之下, 我們仍有極大的機率接受 H_0 。即不論 H_0 為真或不真, 均極易接受 H_0 為真, 因此這個檢定過程顯然並不合理。

表1 $B(10, 0.5)$ 之機率密度函數

i	0	1	2	3	4	5
$p(i)$.00098	.00977	.04395	.11719	.20508	.24609

i	6	7	8	9	10
$p(i)$.20508	.11719	.04395	.00977	.00098

事實上, 若欲使 α 約為0.05, 且 β 不超過0.1, 則要有更多的數據(即 n 要較大才行)。你要不要猜究竟 n 要多大? 可能要嚇你一跳, n 大約要15,000以上才行。主要是0.5與0.512太接近之故。

本例告訴我們千萬不要只看到 α 不大, 就貿然進行一檢定, 需也檢視 β 之值的大小。

在 $H_0 : \mu = \mu_0$, 且 $H_a : \mu \neq \mu_0$ 之下, 利用信賴區間可得一檢定法。設母體有 $\mathcal{N}(\mu, \sigma^2)$ 分佈, σ 已知, 則可取接受域為如(4)之信賴區間。換句話說, 若 $\mu \in I$ 則接受 H_0 , 若 $\mu \notin I$ 則拒絕 H_0 。舉例來說明, 設某工廠對某產品的要求為 $\mu = 7.0$ 。該工廠品管人員的作法是取樣後, 若 $7.0 \in I$, 則認為該批產品合格, 反之則認為不合格, 你認為他們的作法是否正確?

其實是不對的。用白話講放在 H_0 的敘述是要被保護的, 沒有充分的證據不輕易推翻, 接受 H_0 往往是無可奈何, 因證據不足, 並不是真相信 H_0 就一定是最好的選擇。對於諸如消費者文教基金會, 若他們懷疑前述工廠的產品有問題, 想做一個檢定, 則沒錯, 要取 $H_0 : \mu = 7.0$, 且 $H_a : \mu \neq 7.0$ 。寧可先相信該工廠, 則一旦抽樣檢定拒絕 H_0 , 該工廠就很難抗辯了。但該工廠若做品管, 也取同樣的 H_0 及 H_a , 則在接受 H_0 時如何取信大眾呢? 因為 H_0 是極容易被接受的。那麼該工廠要如何選擇 H_0 及 H_a 呢? 當然是

取 $H_0 : \mu \neq \mu_0$, 且 $H_a : \mu = \mu_0$ 。則當拒絕 H_0 , 接受 H_a 時, 自然可信心十足的宣稱該產品符合規格。雖然工廠及消費者文教基金會的目的都是想知道究竟 $\mu = 7.0$ 是否為真, 但所設的 H_0 及 H_a 却恰好相反。簡言之, 要將希望得到的結論之反面置於 H_0 。此中原委是在進行一統計檢定前不可不留意的。對消費者文教基金會而言, 如果明明 H_0 是對的(產品合格), 却被拒絕(認為產品不合格), 這當然是會引起很大爭端, 所以這種錯誤的發生要越少越好(即 α 值要控制得小些)。至於 α 要多小當然也是視情況而定。如在 $\alpha = 0.05$ 之下, 指控產品不合格, 工廠有時是不太服氣的, 此時便宜取較小的 α 值)。但若 H_a 是對的(產品不合格), 却接受 H_0 (產品合格), 工廠雖一時僥倖被放過, 但夜路走多後, 難免會遇到鬼, 總有逮到該工廠產品不合格的一天(這是為何有時 β 值雖很大, 我們仍可容忍的原因)。

附帶一提, 在法律上秉持“被告在被證明有罪之前皆為清白”之原則。很多事實上有罪之被告, 便因證據不夠充分而被開釋。政治人物被法庭宣判無罪開釋時, 往往很高興地說“司法還我清白”。如果了解法庭其實是取 H_0 : 無罪, 且 H_a : 有罪, 便不會把“無罪的宣判”與“真正無罪”劃上等號了(再回頭看一下例4及例5, β 值(在此即有罪卻誤判無罪之機率)有時會很大的)。

宋朝歐陽修在追述其父母生前言行事蹟的灑岡阡表一文(收錄於古文觀止), 提及其父治死獄的情形“求其生而不得, 則死者與我皆無恨也。”也是這種先相信對方(工廠、被告等)的精神。歐陽修又寫著“夫常求其生, 猶失之死, 而世常求其死也。”更是值得我們警惕。保持開放的態度, 不要有先入為主的偏見, 不論在法庭上、在假設檢定裡, 甚至在整個人生中, 均是適用的。

此道理一經說出, 彷如老生常談, 實際上卻並不易做到。要知自以為是, 及自以為較別人行, 為一般人的通病。上至國民大會的多次修改憲法, 下至有些單位換新主管後, 便將原有的制度(或各種辦法)修改, 甚至整個推翻。事實上, 若能虛心些, 謹守尊重現況(即置現況為 H_0 , 不輕易否定)的精神, 則於制定(或修改)一項辦法前, 大家會更慎重, 沒有充分的把握寧可不改變現況。並且因知一旦制定(或修改)後, 將來又是不易被修改, 會使大家下決定前, 能更考慮周全。古人批評“朝令夕改”, 今人說“朝令有錯, 夕改何妨?”想想古人還真有智慧。

5. 結語

本文只是就信賴區間及假設檢定, 討論一些一般人容易誤用之處。統計推論為統計學中一重要的題材, 學習統計後對那些琳瑯滿目的方法, 使用前要先了解其中的含意, 才能真正發揮統計的功能。至於完整的信賴區間及統計檢定的討論, 可參考諸如Roussas(1997)等統計學的書籍。

習題

1. 設 X 有 $\mathcal{N}(0, \sigma^2)$ 分佈, $\sigma > 0$ 。求隨機區間 $(|X|, 10|X|)$ 包含 σ 之機率, 並求此區間長度之期望值。
2. 設 X_1, X_2, \dots, X_n 為i.i.d.之隨機變數, 以 $\mathcal{U}(0, \theta)$ 為其共同分佈, 又令 $Y = \max\{X_1, X_2, \dots, X_n\}$ 。給二常數 a, b , $1 \leq a < b$, 以 $[aY, bY]$ 做為 θ 之區間估計。求此區間之信賴係數。
3. 設 X_1, X_2, \dots, X_n 為i.i.d.之隨機變數, 以 $\mathcal{N}(\mu, \sigma^2)$ 為其共同分佈, μ, σ 皆為未知。經取樣得 $n = 10, \bar{x}_{10} = 3.22, s_{10} = 1.17$ 。求 μ 之一 95% 信賴區間。
4. 設 X_1, X_2, \dots, X_n 為i.i.d.之隨機變數, 以 $\mathcal{P}(\lambda)$ 為其共同分佈。試以 \bar{X}_n 紿出一 λ 之近似的 $100(1 - \alpha)\%$ 信賴區間。
5. 對於例5, 當 $n = 15,000$ 時, 利用二項分佈趨近至常態分佈, 求 c 值使得 α 約為 0.05, 並求此時之 β 值。
6. 設 X 有 $\mathcal{B}(5, \theta)$ 分佈, $0 \leq \theta \leq 1$ 。欲檢定 $H_0 : \theta \leq 1/2$, 且 $H_a : \theta > 1/2$ 。取拒絕域為 $\{X > i\}, i = 0, 1, \dots, 5$, 且令 $\beta_i(\theta) = P_\theta(X > i)$ (對每一 i , $\beta_i(\theta)$ 稱為以 $\{X > i\}$ 為拒絕域之檢定的強力函數(power function))。
 - (i) 對 $\forall i = 0, 1, \dots, 5$, 寫出 $\beta_i(\theta)$ 。
 - (ii) 對一固定的 i , 說明 $\theta \leq 1/2$ 時, $\beta_i(\theta)$ 表第一型錯誤, 而 $\theta > 1/2$ 時, $1 - \beta_i(\theta)$ 表第二型錯誤。
 - (iii) 試藉 $\beta_4(\theta) \leq (1/2)^5$, $\forall \theta \leq 1/2$, 且只有當 $\theta > (1/2)^{1/5}$ 時, $\beta_4(\theta) > 1/2$, 說明當拒絕域為 $\{X > 4\}$ 時, 第一型錯誤皆很小; 而對大部分的 $\theta > 1/2$, 第二型錯誤皆不小。
 - (iv) 試繪 $\beta_2(\theta), \beta_3(\theta)$ 及 $\beta_4(\theta)$ 之圖形, 並分別說明對 $i=2,3,4$, 第一型及第二型錯誤之增減情況。

參考文獻

1. Roussas, G.G.(1997). *A Course in Mathematical Statistics*, 2nd.ed. Academic Press, San Diego.