

# 統計裡的估計

黃文璋

國立高雄大學應用數學系

## 1 前言

繼購物贈送 Hello Kitty 磁鐵活動後，7-ELEVEN 在民國94年的第四季，推出贈送迪士尼公仔的活動。共有42個一般型的公仔，外加10個白金色的公仔。我將原先四斗櫃上的雜物清除掉，然後將那些已擁有的公仔依序排好，重複的則排在同一行。7-ELEVEN 差不多是我每天必去的店，只要購物每滿88元，就會拿到一個公仔。要打開盒子才知到底拿到那一個，頗有樂趣。假設這些公仔是隨機發放，則要收集齊全，所需總個數之期望值是可以求出的。這是所謂古典票券收集問題(classical coupon collector's problem)，這裡面有一些有意思的機率統計問題。隔一段時間後，終於集全了，我仍繼續將它們整齊地排好，櫃子上像有一群兵馬俑一般，每行長短不一。

有一天唸數學系大四的女兒來我研究室，對那一片公仔頗好奇。她從小對收集這類小東西很感興趣，長大後不熱中了，換成他老爸。我突然問她“總共有幾個，給妳5秒”。“65個”，她脫口而出。“不太有概念喔！妳看，這42種每一種多的有10個，少的才2個，平均幾個？大約3到4個。如果假設4個，則共168個，而那些白金的都很少，一眼望去全部才12個，如此共180個。如果假設那42種，平均每種有3個，則共126個，加上12個白金的，

共138個。所以應共有138至180個。”我對女兒這樣說。我們數了一遍，結果是143個。

請幾個朋友到餐廳用餐，分別點了不同的套餐，價格不一。甜點用完後，侍者拿來帳單。總共17,270元，其中還包含小菜、開瓶費及1成服務費等。有沒有多列或算錯呢？請客嘛，總不好意思一筆一筆對。四捨五入算至百位，而有些套餐是一樣的價格，大致乘一乘，估算出來的總和，與帳單上的和相比，差異在500元左右，可以接受。

自兩千多年前起，埃及人就已在估計地球、月亮及太陽的大小。處在此一隨機世界，我們可說經常在估算、估計。拿起一個蘋果，估計它的重量。對初認識的朋友，估計他的年齡，估計其家庭狀況。要過馬路，黃燈已亮，估計是否過得去。有些情況估計準不準不太重要，可以隨便估估。有時就會稍留意些。例如，收到大學指定科目考試成績單，要做落點預測。各校系選擇方案有別，採計科目也不同，有些科目還加重計分，想估計能考上那一校系，就頗具挑戰性。其他如估計歌手周華健全年總收入，估計去美國留學的費用等。我國內政部還訂有“地價調查估計規則”。科學家及政府，也常在做種種估計。如

1. 估計宇宙年齡、地球重量、全球人口數。
2. 估計大陸石油蘊藏量。
3. 估計海棠颱風對台灣造成的農林漁牧業損失。
4. 估計一銅板出現正面的機率。
5. 估計10歲孩童身高的分佈。

這類估計顯然都不太容易。對於隨機現象，既然是估計，便可能有誤差。就如謝霆鋒主唱的那首“估計錯誤”，其中的一句歌詞：“計算自己情感，偏偏估計錯誤”。一般人以為對自己總該較了解，但似乎仍易估計錯誤。更何況對那些未知的事物，或多變的隨機現象，所做的估計，誤差當然是難免。像是有科學家估計宇宙的年齡介於100億至160億年間。這類估計，不論依據為何，究竟有多精確，是很難“估計”的，誰也不知正確答案。所以每隔一段時間，總會有人提出新的估計值。即使對地球上現存

的事物，其估計也常無定論。例如，“科學人”雜誌的“發表新鮮事”專欄，2003年8月1日，刊登鄭靜琪所撰的“鯨魚數量已經安全無虞？”一文。其中寫道，新的研究指出北大西洋座頭鯨數量的歷史高峰應有24萬，據此推算，全球座頭鯨的數量曾多達150萬，遠遠高於國際捕鯨委員會(International Whaling Commission)所估計的10萬頭。另外，有位哈佛大學(Harvard University)的教授，依據紐約市51家醫院，所提供的3萬名病人資料，發現其中約有4%的病人因醫療不當而受害。他因此推算美國一年死於醫療疏失的病人有10萬人。你可能會好奇：紐約市的資料能代表全美國嗎？事實上常有人是如此以局部放大到全體。如 BBC 中文網，2006年6月19日有一則“中國野生熊貓比估計多兩倍”之報導：

科學家根據新技術推斷，中國目前的野生大熊貓數量可能達到三千隻，比過去估計的多了兩倍。一直以來科學家都是用傳統方法估算野生大熊貓的數量，估計總共有一千多隻。但是鑑於大熊貓獨特的生活習性和生存環境，人們很難做出準確的推算。中國和英國的研究人員現在分析大熊貓糞便DNA，推算熊貓的數量。他們估計四川王朗自然保護區目前應該有66隻野生大熊貓，比1998年推斷的多了至少兩倍。…

科學家根據王朗自然保護區的研究結果推斷，目前中國全國大約有2500到3000隻野生大熊貓。…

我們不清楚如何經由分析糞便DNA以估計熊貓數量。而由一個地區的估計，是否適合放大到全國，也不太肯定。因此日後若有人提出新的估計，將不會令人太驚訝。

估計的方法很多。民國94年12月，打過大聯盟的棒球好手陳金鋒，回台灣加入 La new 熊隊。熊隊當然士氣大增，總教練洪一中說“我不能告訴你明年 La new 可以拿第幾名，但每年都預估要拿第一”。賣西瓜者用指頭敲一敲，便可估計出西瓜甜不甜。他的估計是基於什麼？聲音大小嗎？考完試，也沒對答案，有人便估計自己可考上台大醫學系，所憑藉的可能是過去在學校裡考試的表現，加上對這次考試的感覺。估計可以很

科學，也可以只基於主觀或直覺的判斷。但主觀或直覺，如果再加上一些客觀的數據，常可讓估計更精準些。洪一中的估計，可能是衡量各隊實力後客觀的判斷，也可能是為了展現信心而高估，如此則並不需要提供什麼佐證。附帶一提，有了陳金鋒的加盟，La new 隊果然在民國95年6月28日，獲得隊史上首座季冠軍。民國92年上半球季，他們的戰績是慘不忍睹的9勝37敗4和，這回則是30勝19敗1和。洪一中的估計，結果是準確的。

對不同的情況，人們常需要做估計。只是該如何估計呢？有新聞報導，日本九州佐賀縣有一神社，依據稀飯發霉的情況，及霉菌的顏色，以估計運勢，甚至估計何時會有地震發生。大陸揚州的算命師，則以“耳中長毛”，預測人可活過九十九歲（見2006年2月號“科學人”雜誌“總編輯的話”）。如何估計，對一般人，可以很有道理也可毫無道理。但統計學家做估計，總該有些依據，有些原理。做出估計後，更常要用以對未來做預測。統計學家的預測，總該比用亂猜，或諸如依稀飯、水晶球來判斷更準確才合理。量子論泰斗，丹麥的波耳（Niels Bohr, 1885-1962, 1922年獲諾貝爾物理獎）曾說“預測很難，尤其關於未來”。

世上多的是事後諸葛，放馬後砲者。“早知道就...”，是許多人的口頭禪。“既有今日何必當初”的懊惱，下次仍會發生。要對過去所開出的樂透彩號碼，找出一產生的模式是可能的，但此模式對下一期頭獎號碼的預測，很可能就不管用了。統計學裡有不少估計的方法，背後其實都有一套想法在。合理的估計法，通常也具備一些優點。但怎樣才是好的估計？選美比賽前，也得先規定評比標準，否則無從選起。本文便是要對統計裡的估計，略做討論。

## 2 一葉知秋或以偏概全

民國95年1月Yahoo奇摩知識網站上，有人提問：“預計三月去日本自助旅行，估計費用大約多少？”

內容包含：時間是五天，地點在東京，目的是去看世界棒球經典賽。有熱心人士回答：台幣22,800元。算法是：來回機票10,000元，機場來回旅館

車資2,000元，住宿費4,000元，生活開支4,000元，來回球場車資800元，購買紀念品2,000元。

回答的人可能是從他個人的經驗以做估計。他是否真很有經驗呢？我們是否就可據以說，去日本五天看球賽，只要花22,800元？要知回答者連球賽門票都未列入計算。

曾有一則新聞標題為“中國醫藥界駁斥中藥致癌論 批評美國媒體以偏概全妄下結論”。以偏概全，以管窺天，及盲人摸象等，都是我們批評人所見不夠客觀，未見到全貌，就據以下結論。但全貌常常不易見到。話又說回來，有時全貌太大，或太複雜，要想見到，可能耗時耗力耗財。像是上節中提到的全球座頭鯨的數量，及大陸野生大熊貓數量，大約皆無法將其全捉來數一遍。更何況就算真見到全貌，往往也毫無頭緒，不知該如何下結論。不是簡單地用一句諸如“橫看成嶺側成峰”便可形容。例如，對一初識者，我們常只由短暫的接觸，便對其品頭論足。但相識愈久，看到他各方面的行為表現，有時反而遲疑了，不知該如何描述他。

但我們不是也常聽到一葉知秋嗎？淮南子·說山：

以小明大，見一落葉而知歲之將暮；睹瓶中之冰而知天下之寒。

這種經驗常有：品嚐鍋中一塊肉，就可知整鍋食物的滋味；煮湯時，常憑一小湯匙來決定整鍋之鹹淡；驗血時，也是只抽一小針筒。為什麼這時又不會說是以偏概全了？

究竟何時可一葉知秋？

俗語說一樹之果有酸甜之別。但經驗告訴我們，同一株樹所結之果，酸甜的差異，大致不會太大。甚至同一果園，同一種果子的酸甜大約也差不多。淮南子一書中，所描述的地方，說不定每年總是到了秋天，每株樹就開始有落葉。如果某地有不同的樹，全年四季分別會落葉，這時見到葉落，就不一定是秋了。換句話說，就是依變異大小，變異小，便容易一葉知秋，可以嘗鼎一臠，可以因小見大；變異大，即使所見再多，仍有可能以偏概全。如果全美各地醫療不當情形大同小異，以紐約市的資料推估全美，就不會太離譜，否則就是以偏概全了。

變異小的情況，做估計當然較容易，這時見微知著並不稀奇，人人皆可一葉知秋。變異若不算小，以偏便不易概全。變異大小，深深影響估計之精準性。因此做估計時，常須掛念變異，常要考慮如何才能減小變異，而這就有賴“好的”估計方法。只要變異屬於不易忽略的情況，統計學家便有用武之地。另外，對所欲估計的量，若有一些事先的資訊，也要善用，有助於提高估計之準確性。總之，估計人人都會，但如何較準確的估計，就是學問了。只是怎樣算準確呢？有兩個錶，一個停止不動，永遠顯示上午6點32分，一個每日慢1分鐘，何者較準？有人以為是前者，因它每天有一次顯示正確時間，而後者每1,440天（1天有1,440分），才有一次顯示正確時間。故準確的定義為何，得好好斟酌。另外，有人一葉知秋，有人十葉知秋，都是知秋，顯然前者較有效率。所以除了準確性，效率也該考慮。可看出怎樣才是好的估計，是有不同的衡量標準。

下一節我們便來看，對好的估計，會有那些要求。

### 3 估計之評比

假設有一銅板，如何估計它出現正面的機率 $p$ ？重複地投擲 $n$ 次，然後以總共出現之正面數除以 $n$ ，或說以相對頻率(relative frequency)來估計 $p$ 。不論你有沒有學過統計，大約都會想到此方法。甚至這很可能是你唯一想得到的合理方法。

當然在上述估計中，我們隱含地做了一些假設。首先每次投擲，銅板出現正面的機率要相同，不可以換用出現正面機率不同的銅板，否則求出來的不知該是那一量之估計值。其次各次投擲間，出現的結果要相互獨立。如果看到第1次得什麼面，以後就都照抄，如此 $n$ 次下來，不是 $n$ 個正面，就是 $n$ 個反面。則對 $p$ 之估計，只會是1或0，這樣顯然不行。

只要是可以重複觀測的試驗，欲估計某事件發生之機率 $p$ ，都可以採用前述相對頻率的方法。雖實驗可能有很多不同的結果，但我們可將所有結果分成兩類，其一是有興趣的事件（對應銅板出現正面），其二是該事件之餘集（對應銅板出現反面）。觀測 $n$ 次後，數看看有幾次該有興趣的事件發

生。在投擲銅板的例子中，有興趣的事件，就是銅板出現正面。這種對一參數，以一個值來估計，便稱點估計(point estimation)。現以  $X_1, \dots, X_n$ , 分別表各次試驗所得之結果，其中  $X_i = 1$  或  $0$ ，就依第  $i$  次試驗，該事件發生或未發生， $i = 1, \dots, n$ 。依前述討論， $X_1, \dots, X_n$  乃假設為獨立且有共同分佈(independent and identically distributed, 簡稱iid)，且  $P(X_i = 1) = p$ ,  $P(X_i = 0) = 1 - p$ 。在統計裡若  $X_1, \dots, X_n$  為 iid，便稱此為一組隨機樣本(random sample)。

有了  $X_1, \dots, X_n$ , 如何估計  $p$ ? 用樣本平均(sample mean)! 即以

$$\bar{X}_n = \frac{1}{n}(X_1 + \dots + X_n)$$

來估計  $p$ 。而  $X_1 + \dots + X_n$  即為  $n$  次投擲中，共得之正面數。平均，生活裡我們可說經常在求平均。以  $\bar{X}_n$  估計  $p$  有那些優點呢？首先因  $P(X_i = 1) = p$ ,  $P(X_i = 0) = 1 - p$ , 且

$$E(X_i) = 0 \cdot (1 - p) + 1 \cdot p = p, \quad 1 \leq i \leq n,$$

故得

$$\begin{aligned} E(\bar{X}_n) &= E\left(\frac{1}{n}(X_1 + \dots + X_n)\right) \\ &= \frac{1}{n}(E(X_1) + \dots + E(X_n)) = \frac{np}{n} = p. \end{aligned}$$

即  $p$  之估計量  $\bar{X}_n$  的期望值為  $p$ 。

對一參數  $\theta$  做估計時，於觀測到  $X_1, \dots, X_n$  後，以它們的一個函數  $T_n(T_n$  稱為統計量(statistic)，用來做估計時，又稱估計量(estimator))來估計  $\theta$ ，若滿足  $T_n$  的期望值  $E(T_n)$ ，等於所欲估計的參數  $\theta$ ，即  $E(T_n) = \theta$ ，則  $T_n$  便稱為  $\theta$  之不偏估計量(unbiased estimator)，簡稱為不偏的。不偏性，似乎是好的估計量，所該具備的性質。期望值有平均的意思，做估計有時高估，有時低估，但估計值總該在實際值附近打轉，而不應傾向高估或傾向低估，因此平均而言，總該是準的。否則就是有偏差，即若  $E(T_n) \neq \theta$ ， $T_n$  便稱為  $\theta$  之一偏差估計量。

不難看出，前述對 $p$ 之估計，不偏估計量並不唯一。諸如 $X_1$ ,  $(X_1 + X_2)/2$ ,  $0.2X_2 + 0.3X_3 + 0.5X_6$ 等，皆為 $p$ 之不偏估計量。只要 $n \geq 2$ , 便有無限多個對 $p$ 之不偏估計量。

有些統計學家，很在乎不偏性，覺得好的估計量，都至少該為不偏的。此要求並非不合理，只是有些不偏估計量會很荒謬。例如，設 $X \sim \mathcal{P}(\lambda)$ ,  $\lambda > 0$ , 即 $X$ 有參數 $\lambda$ 之 Poisson 分佈，機率密度函數為

$$f(x) = \frac{e^{-\lambda}\lambda^x}{x!}, \quad x = 0, 1, 2, \dots$$

現欲估計 $\theta = e^{-2\lambda}$ 。取統計量 $T = T(X) = (-1)^X$ 。則

$$E(T) = \sum_{x=0}^{\infty} (-1)^x \frac{e^{-\lambda}\lambda^x}{x!} = e^{-\lambda} \sum_{x=0}^{\infty} \frac{(-\lambda)^x}{x!} = e^{-\lambda} e^{-\lambda} = e^{-2\lambda} = \theta$$

此處用到下述公式：

$$\sum_{x=0}^{\infty} \frac{a^x}{x!} = e^a, \quad a \in R$$

故 $T$ 為 $\theta$ 之一不偏估計量。這樣的估計量有何不妥呢？當觀測到的 $X$ 為偶數 $0, 2, 4, \dots$ 時，以 $1$ 估計 $\theta$ ，當 $X$ 為奇數 $1, 3, 5, \dots$ 時，以 $-1$ 估計 $\theta$ 。但 $\theta = e^{-2\lambda}$ , 其中 $\lambda > 0$ , 為一介於 $0, 1$ 間的數，既不會等於 $1$ 也不會等於 $-1$ 。估計量 $T$ 雖為不偏，明顯地卻為一極不合理的估計量。我們大致可以這麼說，儘管有一些對於估計量的評比準則，為很多統計學家所接受，但依這些準則，仍有可能產生怎麼看都不像太好的估計量。

另外，你可能也已看出，光是要求不偏性是不夠的。對前述投擲銅板的例子，若用 $X_1$ 當做估計量，即只依第一次投擲的結果來估計 $p$ ，其他資訊 $X_2, \dots, X_n$ 都不理會，這樣的估計量，顯然不會太好。直觀上，取樣愈多(即 $n$ 愈大)估計要愈準才合理。而當樣本數 $n$ 趨近至 $\infty$ , 更應準得不得了才對，也就是估計量與所欲估計的參數，差不多就該合一了。這個想法引出了一致性(consistent)的概念。

對好的估計量之第二個要求是一致性。在此對一數列之參數 $\theta$ 的估計量 $T_n$ ,  $n \geq 1$ , 若滿足 $n \rightarrow \infty$ 時,  $T_n$ 機率收斂(converges in probability)至 $\theta$ ,

以

$$(1) \quad T_n \xrightarrow[n \rightarrow \infty]{p} \theta$$

表之，便稱  $T_n$  為  $\theta$  之一致估計量 (consistent estimator)。(1)式成立的意思是

$$(2) \quad \lim_{n \rightarrow \infty} P(|T_n - \theta| > \varepsilon) = 0, \quad \forall \varepsilon > 0,$$

或者等價地說，對  $\forall \varepsilon > 0$  及  $\delta > 0$ ，存在  $-k \geq 1$ ，使得  $n \geq k$  時，

$$(3) \quad P(|T_n - \theta| > \varepsilon) < \delta.$$

看起來有點深奧，這是屬於機率論裡極限的題材。弱大數法則 (weak law of large numbers) 告訴我們，對一數列 iid 之隨機變數  $X_1, \dots, X_n, n \geq 1$ ，只要期望值  $E(X_i) = \mu$  存在，則當  $n \rightarrow \infty$  時，其樣本平均  $\bar{X}_n$  會機率收斂至  $\mu$ ，即

$$(4) \quad \bar{X}_n \xrightarrow[n \rightarrow \infty]{p} \mu.$$

所以在前述投擲銅板的例子中，由於  $\bar{X}_n \xrightarrow[n \rightarrow \infty]{p} p$ ，故  $\bar{X}_n$  為  $p$  之一致估計量。樣本平均  $\bar{X}_n$ ，不但是  $p$  之不偏估計量，且是一致估計量。至於  $X_1, (X_1 + X_2)/2, 0.2X_1 + 0.3X_3 + 0.5X_6$  等  $p$  之不偏估計量，則非  $p$  之一致估計量。通常一參數  $\theta$  之不偏估計量，往往有無限多個，但若再加上一致性的要求，就會排除很多不太好的估計量。不過要討論估計量是否有一致性，先決條件當然是樣本數  $n$  可無止盡的增大。

不偏性及一致性，是我們首先會想到“好的”估計量，似乎該有的兩個條件。估計量仍有一些其他評比之基本準則。估計量如何才算好，要依評比標準而定。

以一統計量  $T = T(X_1, \dots, X_n)$  來估計  $\theta$  (或者  $\theta$  的一函數  $g(\theta)$ )，如何衡量此估計量之表現呢？一個最自然的度量法是看誤差  $|T - \theta|$  之大小。但此度量法並非盡如人意。原因有二：其一為此度量為一隨機變數，與所觀測到的  $X_1, \dots, X_n$  有關，並非一定值；其二為此度量與未知參數  $\theta$  有關，因此估計到底多準，無法得知。第一個缺點可以解決，

取期望值即可，也就是將誤差平均掉。例如，可以考慮平均絕對誤差  $E(|T - \theta|)$ ，也可以考慮均方差 (mean squared error, 簡稱MSE)  $R(\theta, T) = E((T - \theta)^2)$ 。此處  $T$  為一隨機變數，期望值是對  $T$  取 (而非對  $\theta$ )，或者說對  $X_1, \dots, X_n$  取。以  $E(|T - \theta|)$  或  $E((T - \theta)^2)$  來度量誤差，何者較適宜？通常取後者。主要原因是，MSE 通常比  $E(|T - \theta|)$  較易計算。又 MSE 可改寫為

$$\begin{aligned} E((T - \theta)^2) &= E((T - E(T)) + (E(T) - \theta))^2 \\ (5) \quad &= E((T - E(T))^2) + (E(T) - \theta)^2 \\ &= \text{Var}(T) + b^2(\theta, T), \end{aligned}$$

其中  $b(\theta, T) = E(T) - \theta$ 。上述第二等式成立，是用到

$$\begin{aligned} E((T - E(T))(E(T) - \theta)) &= E(T - E(T))(E(T) - \theta) \\ &= (E(T) - E(T))(E(T) - \theta) = 0, \end{aligned}$$

因  $E(E(T)) = E(T)$  (記住  $E(T)$  為一常數)。

$b(\theta, T)$  稱為  $T$  之偏差 (bias)。 $\text{Var}(T)$  乃用以量測估計量  $T$  變異之大小， $b^2(\theta, T)$  則是量測偏差之大小。前者顯示精準性，後者顯示正確性。比方說射飛鏢，若射在靶上的點都很接近，我們可說射得很精準。但說不定這些點都很偏離紅心，因此正確性不夠。我們實際接觸的估計量，常都滿足  $\text{Var}(T) < \infty$ 。如果  $\text{Var}(T) = \infty$ ，則  $R(\theta, T) = \infty$ ，這種估計量當然不好，很少被考慮。

設有二  $\theta$  之估計量  $S, T$ ，所有可能的  $\theta$  之集合，以  $\Omega$  表之。例如欲估計銅板出現正面的機率  $\theta$ ，則  $\Omega$  可取成  $[0, 1]$ 。但如果確定  $\theta$  只有兩個可能的值 0.5 及 0.7，則  $\Omega$  可取成  $\{0.5, 0.7\}$ 。若  $R(\theta, T) \leq R(\theta, S)$ ， $\forall \theta \in \Omega$ ，且對某些  $\theta$ ，嚴格不等式成立，則合理的作法是不採用  $S$ 。此時我們說  $T$  較  $S$  為佳，且稱  $S$  為不可採用的 (inadmissible)。一估計量  $T$ ，若不存在較其為佳之估計量，便稱為可採用的 (admissible)。此處所謂可不可採用，是以 MSE 為評比標準。評比估計量，要留意是否為可採用的，此概念用途廣泛。例如，

在找對象時(每人標準自然不盡相同),即使未找到最佳者,至少也要選可採用的。尺有所長,寸有所短,總要有某些長處,不能樣樣皆不如人。在一團體(如企業公司)裡,要儘量避免自己是一位不可採用的人。否則不但無法扮演重要角色,當公司要裁員時,可能也是較先被想到的。

是否有一比其他估計量都為佳的估計量呢?除少數特例外,答案是否定的。假設存在一個這種估計量 $T$ ,則任取 $\theta_0 \in \Omega$ ,且考慮估計量 $S = \theta_0$ ,即恆以常數 $\theta_0$ 估計 $\theta$ 。此一估計量為高度精準( $\text{Var}(S)=0$ ),而極不正確(除非當 $\theta$ 很接近 $\theta_0$ )。由(5)式,此時 $R(\theta, S) = b^2(\theta, S)$ 。當 $\theta = \theta_0$ 時, $b(\theta_0, S) = E(\theta_0) - \theta_0 = 0$ ,故 $R(\theta_0, S) = 0$ 。因 $T$ 較 $S$ 為佳,故 $R(\theta_0, T)$ 必須等於0。但 $\theta_0$ 為 $\Omega$ 中之任一點,故得 $R(\theta, T) = 0, \forall \theta \in \Omega$ 。除了一些特殊的情況(如 $\Omega$ 中只有一個元素),此乃不可能。

事實上,由上一節中,停止的錶亦有準確時候之例,我們早就知道,對於估計量,不存在一個永遠的第一名。故除了比MSE之大小外,我們得再加上其他評比的準則。加上新的準則後,可消除一些不合理的估計量(如前述 $S(\mathbf{X}) = \theta_0$ )。在此一包含較少估計量之集合中,我們尋找最佳(指MSE最小)的估計量。要知理想狀況當然是低偏差且高精準。先控制偏差,再考慮精準性,似乎是合理的(想想射飛鏢的例子)。因此我們要求 $E(T(\mathbf{X})) = \theta, \forall \theta \in \Omega$ ,或等價地說,要求偏差等於0,即 $b(\theta, T) = 0, \forall \theta \in \Omega$ 。如前所定義,這種估計量 $T$ ,稱為 $\theta$ 之一不偏估計量,或說 $T$ 為不偏的。若 $T$ 為 $\theta$ 之一不偏估計量,則 $R(\theta, T) = \text{Var}(T(\mathbf{X}))$ 。

要求不偏除了合理外,常可在所有不偏估計量中,找到一較所有其他估計量“不差”的估計量。即有一估計量 $T^*$ ,滿足 $E(T^*) = \theta$ ,且對任一其它不偏估計量 $S$ ,皆有

$$(6) \quad R(\theta, T^*) = \text{Var}(T^*) \leq \text{Var}(S) = R(\theta, S), \forall \theta \in \Omega.$$

這種 $T^*$ 稱為一致最小變異不偏估計量(uniformly minimum variance unbiased estimator, 簡稱UMVUE)。所謂“一致”,是指對每一 $\theta \in \Omega$ , $T^*$ 之變異數皆最小。

數理統計中,會給出一些有效的步驟,以找出參數之UMVUE,此

處不多討論。不過必須一提的是，有時不偏估計量不存在，因此也就沒有UMVUE。有時UMVUE雖存在，但可能是很荒謬的估計量，或有時是不可採用的估計量，或有時計算上很複雜。前述對 $\mathcal{P}(\lambda)$ 分佈，估計 $\theta = e^{-2\lambda}$ 的例子裡， $T = (-1)^X$ 雖為一極不合理的估計量，但可以證明，它是 $\theta$ 唯一之不偏估計量，因此當然也就是 $\theta$ 之UMVUE。在只有一個估計量的集合裡，找最佳者，不論是在那一種意義下的最佳，都不會是太令人樂於接受的估計量。一般而言，並沒有那一估計量是全方位最佳的。我們在所有不偏估計量的集合中找最佳估計量，而所謂最佳乃指變異數最小。僅是依不偏及變異數最小來評比，通常還合理。但若找到的最佳估計量不盡如人意，也不用太奇怪。此正如選美不論評比標準為何，選出來的第一名，不見得人人叫好。

UMVUE是在樣本數 $n$ 固定下找的。如果樣本數 $n$ 可以無止盡的增加，估計量的近似行為，便也可拿來評比。我們期望在樣本數很大下，估計量會有一些好的性質。付出了較大的代價(取樣增大)，總該有一些所得。這方面的討論就是統計裡的大樣本理論(large sample theory)。之前已給出一致估計量，另外還有漸近不偏估計量(asymptotic unbiased estimator)。即一數列 $\theta$ 之估計量 $T_n, n \geq 1$ ，滿足

$$(7) \quad \lim_{n \rightarrow \infty} E(T_n) = \theta.$$

如果對 $\forall n \geq 1, T_n$ 皆為 $\theta$ 之不偏估計量，即 $E(T_n) = \theta, \forall n \geq 1$ ，則 $T_n$ 當然也是 $\theta$ 之漸近不偏估計量。但如果 $T_n$ 不是不偏估計量，退而求其次，當樣本數很大時，若 $T_n$ 就“差不多”是不偏的，即(7)式成立，那便也不錯。其他還有漸近相對有效性(asymptotic relative efficiency)、漸近有效估計量、漸近常態等，皆是大樣本下，“好的”估計量可能會有的性質。

設有 $T_1 = \{T_{1n}, n \geq 1\}$ 及 $T_2 = \{T_{2n}, n \geq 1\}$ 二數列之不偏估計量。又設 $\text{Var}(T_{1n}) = (n + 100)/n^2, \text{Var}(T_{2n}) = 2n/n^2, n \geq 1$ 。則當 $n = 1, 2, \dots, 99$ ，皆有 $\text{Var}(T_{1n}) > \text{Var}(T_{2n})$ ，此時 $T_{2n}$ 較佳； $n = 100$ 時， $\text{Var}(T_{1n}) = \text{Var}(T_{2n})$ ；但自 $n = 101$ 起，便皆有 $\text{Var}(T_{1n}) < \text{Var}(T_{2n})$ ，且

$$\lim_{n \rightarrow \infty} \frac{\text{Var}(T_{1n})}{\text{Var}(T_{2n})} = \lim_{n \rightarrow \infty} \frac{1/n^2}{2/n^2} = \frac{1}{2} < 1.$$

當  $\lim_{n \rightarrow \infty} \text{Var}(T_{1n})/\text{Var}(T_{2n}) < 1$ , 我們便稱  $T_1$  比  $T_2$  漸近有效。表  $n$  夠大時, 欲達到同樣的精準度, 估計量  $T_2$  所需之樣本數比  $T_1$  多。樣本的取得有時是很不容易的, 從取樣之角度而言, 在大樣本下,  $T_1$  比  $T_2$  有效率。另外, 設

$$\text{Var}(T_{1n}) = \frac{n^2}{(n+1)^2(n+2)}, \quad \text{Var}(T_{2n}) = \frac{1}{n}, \quad n \geq 1,$$

則雖  $\text{Var}(T_{1n}) \leq \text{Var}(T_{2n}), \forall n \geq 1$ , 但因  $\lim_{n \rightarrow \infty} \text{Var}(T_{1n})/\text{Var}(T_{2n}) = 1$ , 故定義  $T_1, T_2$  之漸近有效性相同。

大樣本理論是統計裡重要的題材。從微積分開始, 各種問題中, 極限下的性質常是大家感興趣的。有關估計量評比的介紹, 我們就此打住。欲進一步了解的讀者, 可參考一般數理統計的書。

## 4 估計的方法

估計要準確容易嗎? 不知大家是否有下述這類經驗: 去看電影, 或是去餐廳, 經常是人滿為患, 看來景氣極佳。但電影業, 餐飲業卻常抱怨生意不好做。學生修通識課程, 常選不上, 似乎班班爆滿。但實際上卻有很多通識課程, 修課人數並不太多。這究竟是怎麼回事。

假設有家餐廳, 有100個座位。週一至週五, 每晚只有10個人去用餐, 而週六及週日, 兩晚皆客滿, 若未預訂是沒有座位的。一週7個晚上共250個人去用餐, 則平均每晚只有  $250/7 = 35.71$  個客人, 生意並不算太好。但有80%(200/250)的顧客, 去用餐時(週末), 見到餐廳座無虛席, 他們的印象是餐廳生意真好。再看一例。假設有5班通識課程, 1班有100個人修, 另4班各只有10人修。5班修課人數共  $100 + 4 \cdot 10 = 140$ (人), 平均每班只有  $140/5 = 28$ (人)。但卻有  $100/140 = 71.43\%$  的學生, 上課得提早去搶位子。現對這5班全部140個學生發問卷, 調查其修課的班上有多少人? 又假設此140張問卷皆收回, 則其中有100張填100人, 40張填10人, 總共所得修課人數有  $100 \cdot 100 + 40 \cdot 10 = 10,400$ (人)。問卷顯示, 平均每班有  $10,400/140 = 74.28$ (人)。

這類例子很多，旅遊名勝景點，遊客常抱怨這麼賺錢，卻不提高服務品質。連餐廳都不多設幾處，財源滾滾卻不想讓它們進來，停車位也太少。真實的情況是，除了少數假日遊客摩肩接踵外，其餘的日子，大多是門可羅雀。在上述這種情況裡，若遊客(或學生)由其親身體驗，以估計該景點平均每天有多少遊客(或每門課有多少人修)，大部分人的估計，都可能極不正確。

人類是習於觀察的。觀察到天體運行的規律性，四時的變化，動物及植物的生長模式。我們做決策(或做估計)，往往也是先觀測，再依所得的資料(data, 或說數據)，而做出推論。沒有資料，統計學家是束手無策的。在 Conan Doyle 所著的福爾摩斯全集(Sherlock Holmes stories), The Adventure of the Copper Beeches 一書中，寫著：

“Data! Data! Data!” he cried impatiently.

“I can’t make bricks without clay.”

福爾摩斯說沒有data無法做判斷，正如沒有黏土(clay)無法做磚(brick)。但資料若有問題，所得的推論當然不會好。像是調查局如果情資的來源為媒體報導，或政論節目內容，可信度當然不高。資料的取得及整理，在統計裡是一大學問，本文不擬探討。假設資料沒問題，則有那些估計的方法呢？這要視估計的對象及不同的情況而定，本節我們仍僅就參數的點估計討論。

業餘球類比賽，單淘汰或雙淘汰是常採的方法。實力雖不錯，但運氣不好，包括球員臨場表現不佳，裁判誤判，或賽程排得不利，可能早早被淘汰。職業球賽如籃球、棒球等之比賽，則是依整個球季之勝率，以定出那些隊可晉級。一個球季比賽場數很多，像是職棒比賽，一個球季少說有百場，美國大聯盟每隊更要打滿162場。計算勝率，大致可稀釋掉運氣等因素，以呈現每一球隊的真正實力。在上一節中，我們以樣本平均 $\bar{X}_n$ ，估計 $X_i$ 的期望值 $E(X_i)$ 。表面上看起來，是因期望值有平均的意思，背後的理論依據為**大數法則**(law of large numbers)。大數法則有兩個版本，比較簡單的是上一節所介紹的弱大數法則，另一為**強大數法則**(strong law of large numbers)。

由於當  $X_1, \dots, X_n$ ,  $n \geq 1$ , 為 iid, 且  $E(X_i^2)$  存在時, 弱大數法則告訴我們,  $X_1^2, \dots, X_n^2$  的樣本平均  $\overline{X_n^2}$ , 機率收斂至  $E(X_i^2)$ 。即

$$(8) \quad \overline{X_n^2} = \frac{1}{n} \sum_{i=1}^n X_i^2 \xrightarrow[n \rightarrow \infty]{p} E(X_i^2).$$

所以若欲估計參數  $E(X_i^2)$ , 可以  $\overline{X_n^2}$  做為估計量。以平均估計期望值, 這樣所獲的估計量, 通常還不太壞, 至少為不偏且有一致性。

例如, 設  $X$  有常態分佈, 期望值為 0, 變異數為  $\sigma^2$ , 即  $X \sim \mathcal{N}(0, \sigma^2)$ 。因  $E(X^2) = \sigma^2$ , 所以若欲估計  $\sigma^2$ , 且觀測到隨機樣本  $X_1, \dots, X_n$ , 則可以  $\sum_{i=1}^n X_i^2/n$  做為估計量。由於對任一整數  $r$ ,  $X^r$  的期望值  $E(X^r)$  稱為  $X$  之  $r$  次動差。所以上述這種經由欲估計的參數, 是  $X$  的幾次方的期望值, 便用對應的  $X$  之次方的樣本平均來估計, 便稱動差法(method of moments), 所得之估計量, 稱為動差估計量(moment estimator)。動差估計量並不唯一。例如, 設  $X \sim \mathcal{P}(\lambda)$ 。因  $E(X) = \text{Var}(X) = \lambda$ , 而  $\text{Var}(X) = E(X^2) - (E(X))^2$ , 故

$$\overline{X}_n \text{ 及 } \frac{1}{n} \sum_{i=1}^n X_i^2 - (\overline{X}_n)^2$$

皆可用來當做  $\lambda$  之動差估計量。

這種依相對頻率來做估計, 稱為古典的作法(classical approach), 採這種主張的統計學家, 稱為頻率學派(frequentist)。在十九世紀, 這派想法可說是主導統計的應用。直至今日, 頻率的觀點, 仍是一很基本的統計思維。

底下介紹另一種估計法。

教室玻璃被打破了, 老師從平常最調皮的同學開始問。有命案發生, 從現場採到的指紋開始追查。皆是因認為這些人嫌疑最大。醫生看診, 常也是從病人的症狀, 推測那一種病最易產生此症狀。從所得之觀測值, 推測究竟參數為何, 會使得到此一觀測值之機率最大, 這也是一種常用的估計方法。在統計學裡稱為最大概似法(method of maximum likelihood)。所得之估計量稱為最大概似估計量(maximum likelihood estimator, 簡稱MLE)。這種估計法有其道理, 但會不會誤判? 當然會。只

是警方辦案，不從有前科、有地緣關係、由現場蒐到的可疑事物開始追查，難道要從毫不相干者開始查？那不是更不合理嗎？統計理論顯示，最大概似估計量，有很多好的性質。例如，常也就是UMVUE，常也有漸近常態分佈等。因此這也是廣為被採用的一種估計法。

**例1.** 設一盒子中有不少白球及黑球，假設只知數目比為3比1，但不知是白球多還是黑球多。依序隨機地抽取3球，每次取出後放回。令 $X$ 表所得之黑球數。則由假設知 $X$ 有 $B(3, p)$ 分佈，其中 $p = 1/4$ 或 $3/4$ ，即 $X$ 之p.d.f.為

$$f(x|p) = P(X = x) = \binom{3}{x} p^x (1-p)^{3-x}, \quad x = 0, 1, 2, 3,$$

且 $p = 1/4$ 或 $3/4$ 。

我們想根據觀測到之黑球數 $x$ 來估計 $p$ 。此估計並不算困難，因只有二選擇： $1/4$ 或 $3/4$ 。抽取後，有四種可能的結果，其機率值為

$x$	0	1	2	3
$f(x 1/4)$	$\frac{27}{64}$	$\frac{27}{64}$	$\frac{9}{64}$	$\frac{1}{64}$
$f(x 3/4)$	$\frac{1}{64}$	$\frac{9}{64}$	$\frac{27}{64}$	$\frac{27}{64}$

如果 $x = 0$ ，就宜選 $p = 1/4$ ，因為 $27/64$ 的機率值較 $1/64$ 為大。也就是 $p = 1/4$ 比 $p = 3/4$ ，更會使 $x = 0$ 發生。所以 $x = 0$ 出現時，認為 $p = 1/4$ 才較合理。 $x = 1$ 時，也宜選 $p = 1/4$ 。至於若出現 $x = 2$ 或 $3$ ，則 $p = 3/4$ 當然是較合理的選擇。故 $p$ 之最大概似估計值 $\hat{p}$ 為

$$\hat{p} = \begin{cases} 1/4, & \text{若 } x = 0, 1, \\ 3/4, & \text{若 } x = 2, 3. \end{cases}$$

對同一參數所做之估計，最大概似法與動差法，有時會得到相同的估計量。這並不足為奇，因二者皆是很好的估計法，難免英雄所見略同。不過因畢竟是兩種不同的方法，當然也有所得之估計量不同的時候。

除了以上所介紹的兩種估計法外，另有一種常用的估計法，就是貝氏作法(Bayesian approach)，持此主張者，也稱貝氏學派(Bayesian)。在

前兩種估計法中，欲估計的參數 $\theta$ ，被視為一未知但固定的值。但在有些情況，我們對 $\theta$ 有一些事先的了解。例如，設 $\theta$ 為銅板出現正面的機率。有人以為，由於這是政府發行的銅板，不至於太離譜， $\theta$ 應在0.5附近，甚至認為 $\theta$ 就在0.45至0.55間，且在這區間中的所有值，可能性皆相同。因此假設 $\theta$ 在區間[0.45, 0.55]均勻分佈。即 $\theta$ 有 $\mathcal{U}[0.45, 0.55]$ 分佈。

對 $\theta$ 假設有一事前分佈(prior distribution)。此分佈可視為主觀的分佈(subjective distribution)，因此乃做估計者主觀的看法。當然主觀的看法，也可以是依據過去的資料，而做出客觀的推斷。要知或出於天生，或因擁有的資訊很豐富，有些人主觀的看法可能很客觀。而合理的思維是，於取樣後，根據所得之觀測結果，修正對 $\theta$ 之分佈的看法，如此便得到事後分佈(posterior distribution)。貝氏此一名稱的由來，是因這一經修正所得的分佈，是利用貝氏定理(Bayes' rule)而得。貝氏(Thomas Bayes, 1702-1761)為英國牧師，但其姓氏早已成為一重要的統計名詞。

事後分佈是一條件分佈，給定的條件是觀測到的樣本。利用事後分佈，以對 $\theta$ 做推估。本來我們對 $\theta$ 有一看法(事前分佈)，看到樣本後，看法改變(事後分佈)，基於此新看法以估計 $\theta$ 。事後分佈與事前分佈往往有很大差異。可以一簡單的例子來說明。有人敲門，若沒有其他資訊，則可合理地假設是男或是女的機率，各為 $1/2$ 。這是事前機率。但若由虛掩的門，看到來者穿裙子，這資訊就要好好利用。男生穿裙子的很少見吧，大約只有蘇格蘭人，假設任一男生穿裙子的機率為 $1/10,000$ 。女生也不見得都穿裙子，假設任一女生穿裙子的機率為 $3/10$ 。所以任一敲門者，穿裙子的機率為

$$\frac{1}{10,000} \cdot \frac{1}{2} + \frac{3}{10} \cdot \frac{1}{2} = \frac{3,001}{20,000}.$$

因此給定敲門者穿裙子的條件下，來者是女生的機率為

$$\begin{aligned} P(\text{女生} | \text{敲門者穿裙子}) &= \frac{P(\text{敲門者為女生且穿裙子})}{P(\text{敲門者穿裙子})} \\ &= \frac{\frac{3}{10} \cdot \frac{1}{2}}{\frac{3,001}{20,000}} = \frac{3,000}{3,001} \doteq 0.9996667777. \end{aligned}$$

即在我們的假設下，當觀測到敲門者“穿裙子”，則敲門者是女生的機率，由事先的 $1/2$ ，增高至一很接近 $1$ 的值。至於是男生的機率，則從 $1/2$ 降至很接近 $0$ 的 $1/3,001$ 。事後分佈與事前分佈，可能會有極大不同，貝氏學派認為不容忽視此點。他們主張事先掌握的資訊(事先分佈)，就是該充分利用，而也必須依觀測值做修正(以到事後分佈)，再依據事後分佈，進行推估。

註1.  $3,000/3,001$ 並非就是一直 $0.9996667777$ 循環下去，接著的幾位為 $40753$ 等。事實上，若將此數展開為小數，其循環節長達 $1,500$ 位。

一個常見的 $\theta$ 之貝氏估計量，為給定觀測值 $X$ 下，事後分佈的期望值，即 $E(\theta|X)$ 。我們稱此為貝氏估計量(Bayesian estimator)，不過也還有很多其他不同的貝氏估計量。近年來，貝氏的作法愈來愈被廣為採用，特別是在醫學及商業上。

上述這三種估計法，反映三種不同的統計估計思維。在做估計時，有時是三種方式混合著用。視不同的情況或所擁有不同的資訊而定。要善用這三種方法，以得到較好的估計品質。

對於一參數 $\theta$ ，除了點估計外，還有區間估計(interval estimation)。即給出一隨機區間，並指明此為 $\theta$ 之若干百分比(通常取 $90\%$ 、 $95\%$ 或 $99\%$ 等)的信賴區間(confidence interval)。信賴區間的討論，可參考黃文璋(2006)一文。

不只是估計一參數 $\theta$ ，有時可估計 $\theta$ 的某一函數 $g(\theta)$ ，或二參數 $\theta_1, \theta_2$ 的某一函數 $h(\theta_1, \theta_2)$ 等。例如，對 $\mathcal{N}(\mu, \sigma^2)$ 分佈，估計 $\mu/\sigma$ 。這些都是有關參數估計的問題，其他尚有分佈的估計等。估計論是統計裡一重要的題材，這方面的探討很多。本文為一初步的介紹，無法多加討論。對估計論有興趣的讀者，可參考一般數理統計的書。

## 5 回歸效應

本節我們介紹一種並非參數估計的估計法。

回歸一詞，為十九世紀英國統計學家高頓(Francis Galton, 1822-

1911)所首先引進，以描述諸如父親身高與兒子身高等二變數間的關係。設以  $x_i$  表第  $i$  個父親的身高， $Y_i$  表其兒子之身高， $i = 1, \dots, n$ 。高頓想建立一如下式之  $x$  與  $Y$  的關係：

$$(9) \quad Y = Q(x) + \varepsilon,$$

即以父親的身高  $x$ ，來預測兒子的身高  $Y$ 。為何父親身高以小寫，兒子身高以大寫？對那些父親身高為 172 公分者，高頓並不將 172 視為隨機變數。但同是 172 公分高的父親，兒子則不一定有多高，所以將兒子身高  $Y$  視為一隨機變數。在(9)式中，隨機變數  $Y$ ，可表示為一  $x$  的函數  $Q(x)$ (不為隨機的量)，加上一項隨機的誤差  $\varepsilon$ 。由所收集到的數據  $(x_1, y_1), \dots, (x_n, y_n)$ ，來估計函數  $Q(x)$ 。身高為  $x$  的父親，其小孩的身高便為  $Q(x) + \varepsilon$ 。此雖是一隨機變數，但若誤差項  $\varepsilon$  不太大，則以  $Q(x)$  來估計  $Y$ ，就不會太離譜。比較一般的模式是，對不同的  $x$ ，誤差可能不同。所以可考慮下述模式：

$$(10) \quad Y_i = Q(x_i) + \varepsilon_i, \quad i = 1, \dots, n.$$

**迴歸分析**(regression analysis)，特別是**線性迴歸**(linear regression)，幾乎可說是最常用的統計方法。有各種形式的迴歸，如線性、非線性、多元、參數(parametric)及非參數(non-parametric)等。這其中最簡單的，應屬**簡單線性迴歸**(simple linear regression)，即  $Q(x) = \alpha + \beta x$ ，而  $\alpha, \beta$  為二常數。稱“簡單”是為了與多元線性迴歸(multiple linear regression)區隔。

如前所述，迴歸分析是為了探討一變數與另一變數相依的情形。設有一簡單線性迴歸模式，即設

$$(11) \quad Y_i = \alpha + \beta x_i + \varepsilon_i, \quad i = 1, \dots, n,$$

其中  $\alpha, \beta$  為二未知常數。又  $\varepsilon_1, \dots, \varepsilon_n$  常設為獨立，但分佈不一定要相同。有時僅假設  $\varepsilon_1, \dots, \varepsilon_n$  為無相關，即  $\text{Cov}(\varepsilon_i, \varepsilon_j) = 0$ ， $1 \leq i < j \leq n$ 。統計模型總是可以有各種假設，只要看合不合理，及是否符合實際情況。對  $\varepsilon_1, \dots, \varepsilon_n$ ，通常又假設期望值皆為 0，變異數亦皆相同，即設  $E(\varepsilon_i) = 0$ ， $\text{Var}(\varepsilon_i) = \sigma^2$ ， $i = 1, \dots, n$ 。此時由(11)式得

$$(12) \quad E(Y_i) = \alpha + \beta x_i.$$

在迴歸分析裡，當知道  $x_i$  之值，我們常以(12)式右側，做為  $Y_i$  之估計值。(12)式給出  $E(Y_i)$  為  $x_i$  的函數，稱為**母體迴歸函數**(population regression function)。至於  $\alpha, \beta$  如何估計呢？一個常用的方法是**最小平方法**(least squares method)，此法可追溯到法國數學家拉格朗治(Joseph Louis Lagrange, 1736-1813)，及德國的高斯(Carl Friedrich Gauss, 1777-1855)。對於如(11)式之模式，於觀測到  $(x_1, y_1), \dots, (x_n, y_n)$  後，最小平方法乃基於使誤差平方和

$$(13) \quad U(\alpha, \beta) = \sum_{i=1}^n (y_i - \alpha - \beta x_i)^2$$

達到最小值的原理，以求出  $\alpha, \beta$ 。將函數  $U(\alpha, \beta)$ ，分別對  $\alpha, \beta$  微分，且皆令其為0，得

$$\begin{aligned} \sum_{i=1}^n (y_i - \alpha - \beta x_i) &= 0, \\ \sum_{i=1}^n x_i(y_i - \alpha - \beta x_i) &= 0. \end{aligned}$$

由上二式解出  $\alpha, \beta$  之估計值

$$(14) \quad \hat{\beta} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2},$$

$$(15) \quad \hat{\alpha} = \bar{y} - \hat{\beta} \bar{x},$$

其中

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i, \quad \bar{y} = \frac{1}{n} \sum_{i=1}^n y_i.$$

由上述方法所得之  $\alpha, \beta$  之估計量，便稱為**最小平方估計量**(least squares estimators)。我們便以  $\hat{\alpha} + \hat{\beta} x_i$  做為  $Y_i$  之估計。

線性函數當然是一極簡單的函數。簡單線性模型，就是以一線性函數  $\alpha + \beta x$ ，由知道  $x$ ，來預測  $Y$ 。這種作法，不用知道  $X, Y$  二變數之聯合分佈，樣本數  $n$  也不用很大。如果將所觀測到之  $(x_1, y_1), \dots, (x_n, y_n)$ ，描繪於  $x - y$  座標平面上，所得的直線  $y = \hat{\alpha} + \hat{\beta} x$ ，便是在最小平方法的意義下，

最能描述這些數據的一條直線。底下給一例子。

例2. McDonald and Studden(1990)曾研究汽車排出碳氫化合物(hydro-carbon)的量。他們得到下述成對總哩程數 $x$ (單位為千英哩), 與碳氫化合物 $y$ (單位為公克/英哩)的值如下:

$$\begin{aligned} &(5.133, 0.265), (10.124, 0.278), (15.060, 0.282), (19.946, 0.286), \\ &(24.899, 0.310), (29.792, 0.333), (29.877, 0.343), (35.011, 0.335), \\ &(39.878, 0.311), (44.862, 0.345), (49.795, 0.319) . \end{aligned}$$

在此 $n = 11$ , 且 $\sum_{i=1}^{11} x_i = 304.377$ ,  $\sum_{i=1}^{11} x_i^2 \doteq 10461.814$ ,  $\sum_{i=1}^{11} y_i = 3.407$ ,  $\sum_{i=1}^{11} y_i^2 \doteq 1.063$ ,  $\sum_{i=1}^{11} x_i y_i \doteq 97.506$ 。故得 $\bar{x} \doteq 27.671$ ,  $\bar{y} \doteq 0.310$ , 且

$$\begin{aligned} \hat{\beta} &\doteq \frac{97.506 - 304.377 \cdot 3.407/11}{10461.814 - (304.377)^2/11} \doteq 0.00158, \\ \hat{\alpha} &\doteq 0.310 - 0.00158 \cdot 27.671 \doteq 0.266 . \end{aligned}$$

即可以簡單線性迴歸函數 $y = 0.266 + 0.00158x$ 來預測 $y$ 。例如, 若汽車行駛30,000英哩, 則預測 $y = 0.266 + 0.00158 \cdot 30 = 0.3134$ (公克)。

我們繪出 $(x_i, y_i)$ ,  $i = 1, \dots, 11$ , 及估計的簡單線性迴歸函數於圖1。

高頓在研究父親與兒子身高的關係時, 發現較高的父親, 兒子有較高的傾向, 而較矮的父親, 兒子亦有較矮的傾向。這當然是眾所周知, 並非一了不起的發現, 不過就是遺傳而已。但他也發現那些較高的父親, 兒子往往卻稍矮些; 而很矮的父親, 兒子卻常稍高些。此現象即為著名的迴歸效應(regression effect), 高頓稱此現象為向平均迴歸(regression toward the mean)。regression 有回歸, 後退, 或退化的意思。在此即表靠向平均。大致可以這麼說, 回歸的意思就是回歸。就如我們常說的回歸正傳, 回歸祖國, 回歸專業倫理等。而迴歸效應是向平均回歸。這是迴歸這一名詞的由來。由於迴歸與回歸意思近似, 因此也有人使用回歸及回歸分析。

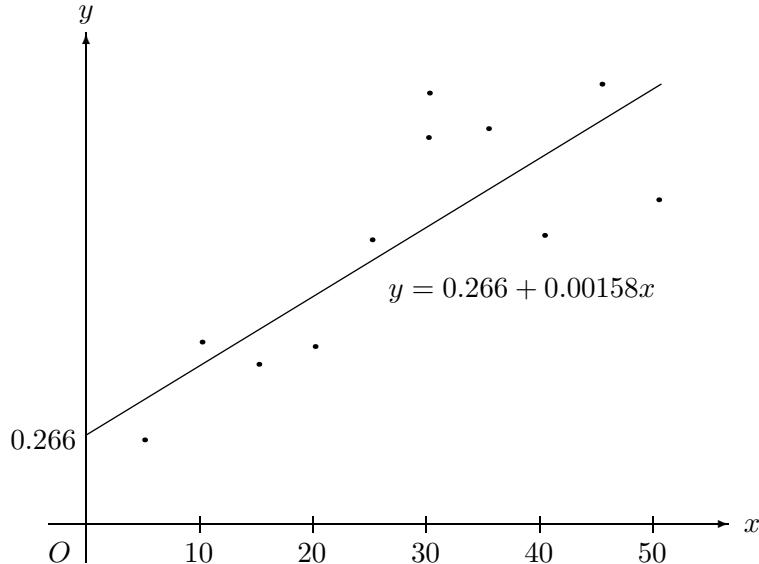


圖1 簡單線性迴歸函數,  $x$ 軸單位為千英哩,  $y$ 軸單位為公克/英哩

在高頓所獲得之1,078對父子的身高,父親的平均身高約為68英吋,兒子的平均身高約為69英吋,高了一英吋。樣本標準差則皆約為2.5英吋。對一72英吋高之父親,我們會猜想其兒子應有73英吋高,而對一64英吋高之父親,會猜想其兒子應有65英吋。真實的情況是,72英吋高的父親,兒子之平均身高約為71英吋,而64英吋高之父親,兒子之平均身高約為67英吋,皆向平均69英吋靠近。

其實不獨父子的身高,考試成績亦有此現象。計算兩次考試成績,假設兩次全班的平均成績差不多。但第一次成績較高的那群學生,第二次的成績常略降低,而第一次成績較低的那群學生,第二次的成績常略提高。迴歸效應再度發威。

是老天爺有心做一些平衡嗎?倒也非如此。以身高為例,來解釋實際上的確會這樣。假設某地區30歲男子的身高,最高者為240公分。不需再高些,就假設這群人兒子的平均身高亦為240公分。因不致於全部兒子都等高,故其中必會有比240公分還矮者,也會有比240公分還高者。如此一代超越一代,人類身高之極大值將不斷提高,但情況顯然並非如此。故身

高240公分的那群父親，其兒子的平均身高應小於240公分。對身高最矮的那群父親，其兒子的平均身高，也有類似的解釋。

再以考試為例。考試成績為真實的成績加上誤差。第一次考高分者，運氣總不會是壞的。第二次就不容易在好運之上再加上好運。例如，第一次考98分的人，往上只有兩分的成長空間，要提高相當不容易。而第一次只考3分的人，第二次又能再怎麼往下掉呢？往上升還較可能。這樣看來，迴歸效應的存在，就不是太怪異了。早期有些中小學老師以嚴厲著稱。對考試成績不佳的學生，常予以處罰，而對考得好的學生，也少有讚美。他們是不相信鼓勵這一套的。因長期的經驗告訴他們，經過處罰後，原先考差的學生，有不少下次的確進步了。至於原先考好的學生，下次卻常略有退步，若當初還讚美他們，不是讓他們更鬆懈，退步更多？因此那些老師堅信其作法是對的。你現在知道了，這些成績的進步或退步，很可能只是迴歸效應，而非老師的作法生效。

## 6 結語

我們經常在做估計，生活上、商業上、科學上、政治上，各種估計不斷地在進行。讀者是否注意到“做”這一個字的中間及左邊即為“估”。各種估計法，背後都有些原理，也反映人們做決策的某種思維。沒有一種估計法，能行走天下萬無一失。本文只是對統計裡的估計，略做介紹。讓讀者得到一些基本的概念。有興趣的讀者，可從汗牛充棟的統計書中，找到各種統計估計的方法。

## 參考文獻

1. 黃文璋(2006). 統計裡的信賴。數學傳播季刊，已接受。
2. McDonald, G.C. and Studden, W.J.(1990). Design aspects of regression-based ratio estimation. *Technometrics*, 32, 417-424.