

庶民中央極限定理

黃文璋

國立高雄大學應用數學系

1 前言

德國馬克是以前西德的法定貨幣，東西德統一後，繼續使用至2002年歐元流通為止。有段時間10馬克紙幣上，放的是高斯(Carl F. Gauss, 1777-1855)之肖像。大數學家高斯，在許多領域，如統計、代數，及分析等，皆有極開創性的突破。甚至還有人認為，不少高斯的研究成果，至今仍能深深影響人類生活，其貢獻較其他舉世知名的科學家，都廣泛許多，可參考黃文璋(2008)一文。但被挑出來放在紙幣上與他長相左右，不是別的，而是常態分佈的機率密度函數及其圖形。由此一方面可看出常態分佈的重要，一方面大約可理解，德國這個國家，其國民的數學素養怎會不好？他們鈔票上有數學家，還有一個大有來頭的函數。這函數絕非簡單，其中有兩個數學中極重要的常數 π 及 e ，連同幾個數學中常用的符號 $\sqrt{}$ 及希臘字母 μ 與 σ 。

近年來可能是鑑於各行各業常在做民調，民調已融入生活，負責制訂高中數學課程綱要的委員，因此覺得有必要讓一般人民了解其中常出現的信賴區間。於是在民國95年版的高中數學課程綱要裡，開始引進信賴區間。民國99年版的課程綱要中，仍保有此題材。雖僅討論二項分佈 $B(n, p)$ 裡參數 p 之估計，但為了近似，也引進中央極限定理，及隨之而來

的常態分佈。德國在鈔票上有常態分佈，我們在高中裡介紹中央極限定理，算是與他們互別苗頭。只是鈔票能用就好，其上的圖案，有何深遠的含意，懂不懂都沒關係。但既然將這些題材擺進高中數學，顯然是想提高國民的統計素養，且還不得不擠掉一些原本有的題材，因此總要能傳遞正確的概念。否則不但無法達到統計深耕的目的，並將有礙日後學習進階的統計。

大家可能也聽過有些人是怎麼看統計的：

有三種謊言：謊言，可惡的謊言，統計。

時至今日，統計早已成為做決策不可缺少的工具。但若未運用得當，將比不採任何統計方法還要糟。統計工作者，當然得避免提出的分析報告，被與謊言歸於同一類，棄之如敝屣。只是統計裡的一些基本想法，所謂統計思維，與數學是大異其趣的，可參考黃文璋(2009)一文。統計裡強調隨機性，與一向著重必然性的數學，本質上並不易相容。因此要在中學裡教統計，比較好的作法，是讓統計成為單獨的一科，而非像目前放進數學課程中。要知信賴區間與中央極限定理，這些連在大學機率統計課程裡，都不算簡單的題材，即使循序漸進地跨入，學生都難免一知半解，如今卻堂而皇之地進入高中數學。在低估此題材之深度下，缺乏足夠鋪陳，便快速進入一雖非邈然不可攀，但也有些難度的境界，不論在教學或學習，引起很多困擾，乃可預期。

有如憲法是國家的根本大法，教科書乃依課程綱要而編寫。為何我們說制訂時，低估信賴區間等題材之深度，甚至因此還訂出這套缺乏一言而為天下法的課程綱要呢？在課程綱要“常態分布、信賴區間與信心水準的解讀”那項下寫著：

高中程度的統計推論只做隨機變數期望值的估計，它的背後理論是中央極限定理。要介紹中央極限定理，就需要引入常態分布。此部分僅做通識性的介紹，以活動方式建立學生對於中央極限定理的直觀。

對一固定的信心水準，給出信賴區間公式，再讓學生以亂數

表模擬或實驗投擲正面出現機率為 p 的銅板 n 次，代入信賴區間公式，以說明信心水準的意涵；並以此解讀，何以大多數的學生所得的信賴區間都會涵蓋 p ？

首先，“隨機變數期望值的估計，它的背後理論是中央極限定理”，此講法不知從何而生。要知參數估計，通常分點估計及區間估計。中央極限定理，對於點估計(不管是否估計期望值)，根本用不到；而對區間估計，不少情況下也不需要，遑論成為背後理論？以此做為引進中央極限定理的理由，高斯若地下有知，恐亦會感到莫名其妙。其次“此部分僅做通識性的介紹”，雖說得輕鬆，只是中央極限定理的概念，豈有那麼容易？而且究竟“通識性”是指什麼？難道高中課程裡，有非通識性的嗎？由於課程綱要中特別強調通識性，有些教科書可能因企圖落實通識性，將氣勢磅礴的中央極限定理，寫得花拳繡腿。這還不打緊，有時還因此忽略嚴謹性，甚至將此定理詮釋錯誤。

主要由於隨機性的本質，再加上不同分佈間的差異，對參數估計，往往有不一而足的方法，由於各有優點(可參考黃文璋(2007)一文)，因此能長期並存。沒有放之四海而皆準的估計，乃統計的特色之一。參數區間估計的方法不會唯一，便也很顯然。因此有關統計的教材裡，通常不會出現有如昔日的建構式數學，“給出”信賴區間公式，這種定於一尊的說法。

至於對銅板正面出現的機率 p ，課程綱要中提議以實驗來顯示“大多數”學生得到的信賴區間皆會涵蓋 p 。此講法完全缺乏隨機的概念，其不恰當，雖早在黃文璋(2006)一文中便已指出，只是顯然未被理會。

另外，有幾本教科書裡，皆曾出現類似“本書僅討論離散型的隨機變數”之句子，頗令人納悶。不是有重頭戲常態分佈嗎？這難道不是連續型？原來課程綱要裡有一句“高中課程只處理離散型的隨機變數”。編撰者只顧擷取課程綱要中的句子，也不管究竟正不正確。

絕學無憂，重重問題固然令人憂心忡忡。只是這些題材都已經放進高中數學了，一時也無可奈何。務實地看，到底有沒有什麼方式，可以略微提高學習成效？雖云道可道非常道，本文仍嘗試對現行高中數學裡，環繞中央極限定理的幾個概念，做些闡釋。

2 隨機現象

宇宙的運轉，有必然性和隨機性。銅板落地所需時間可求出，這是必然性，但那一面將朝上卻不知，這是隨機性。對事先不能預知結果的觀測或試驗，便稱為隨機現象(random phenomenon)。意思本已很明白，但曾有教科書又畫蛇添足，加以如下說明：

一般而言，如果一個試驗具有隨機現象，可在相同條件之下重複進行；雖然無法預知其結果，但是我們可以知道所有可能出現的結果。

這段文字不太通順就不去管它，但必須一提的是，以這樣的方式解釋隨機現象，是不夠“一般”的。

諸如A先生是否今年底前結婚，B籃球隊是否得年度冠軍，都屬隨機現象。但“今年”只有一次；至於球隊是可能在未來某年獲冠軍，只是每年每隊的成員都不盡相同，連參賽隊伍也不見得一樣，因此每年的球賽，並不能算是在相同條件下重複進行。

另外，“可以知道所有可能出現的結果”，此句也有些爭議。首先，我們得釐清什麼是可能，不可能。有時人們遇到較困難的事，會說“這是不可能的任務”，但再如何不可能，有些最後仍完成。考完大學學測，某人問你的總級分可能多少？你正為考得不太好而傷心，實在沒興趣回答此問題，便敷衍地說0至75分都有可能。問的人覺得你不可能考到75分，也不可能考0分。所以可能，不可能，不見得有那麼嚴格的界限。因此將“知道所有可能出現的結果”，特別放進對隨機現象的解釋，彷彿此為隨機現象須具備的條件，並不恰當。

你想知道今天出門，所遇到最高的人，身高可能是多少？你其實連世界身高最高紀錄為何，都不太清楚。但你認為將“所有可能出現的結果”，取成介於150公分至300公分間，便萬無一失。換句話說，不像投擲一公正的骰子一次，並觀測所得點數的情況，在討論隨機現象時，那些才屬於可能出現的結果，有時不太確定。這時將所有可能出現的結果之集合，取得較大些，乃無關緊要。亦即雖列在可能出現的結果中，有些其實根本“不可

能”出現。因此，在不少情況下，所有可能出現的結果之集合，不見得有一致的看法。此集合有時是為了不至於掛一漏萬而取的，倒不見得是我們一開始便知道那些結果真會出現。讀者也不難想通，不能以發生的機率不為0，來界定那些屬於可能出現的結果。例如，由0至1的區間中，隨機地取1點，則整個區間中的點，當然都屬所有可能出現的結果。但顯然該區間中任何一點，被取中的機率皆為0。

對一隨機現象，所有可能出現的結果之集合(可以是觀測所得，或指定)，稱為樣本空間。我們已指出，前述集合常非固定。因此如Feller(1968) pp.13-14所說，樣本空間的概念，有如幾何學裡的點、線、面，並無嚴格定義，指定樣本空間是較明確的作法。投擲一銅板兩次，如果不指定，卻問樣本空間為何？這是不清不楚的問題。若觀測兩次會出現正、反面的情況，則樣本空間可取為 $\{(正, 正), (正, 反), (反, 正), (反, 反)\}$ ，其中(正, 反)表第一次得正面且第二次得反面，餘類推。若觀測兩次共出現的正面數，則樣本空間可取為 $\{0, 1, 2\}$ 。若觀測兩次共出現的正面數減去共出現的反面數，則樣本空間可取為 $\{-2, 0, 2\}$ 。因觀測的不同，尚可有其他樣本空間。整個機率的架構是很有彈性的，萬不可以為對投擲一銅板兩次，樣本空間一定是 $\{(正, 正), (正, 反), (反, 正), (反, 反)\}$ 。會這樣誤解，原因大約是根深蒂固古典機率的想法所造成。以為銅板必公正，各次投擲必相互獨立等。趁早跳出此桎梏，對往後靈活且正確的學習機率，其實是較好的。通常若確定觀測什麼現象，便可寫出一樣本空間。甚至可更一般，連觀測都不必，直接說“取”，或“令”樣本空間為何，然後繼續之後的討論。

為何我們強調上述那幾點呢？對於數學，人們通常較能嚴肅以對，因從小在數學課中，我們一再被要求須精準。但對涉及隨機現象的問題，以為反正也不一定會出現什麼結果，因此不管提出什麼結論，都不見得立即能被判定對或錯，何必如數學中的嚴謹？在一知半解下，隨機遂轉化為隨便，對事物的描述，便常不覺得須很明確。

今日大家對機率一詞，皆能朗朗上口，但究竟其意義為何，一般人卻可能不甚了了。在機率教科書上，通常可見到下述三種對機率的解釋：

以相同的可能性來定義機率，此為古典的定義。

在多次相同條件下重複試驗後，以一事件出現的相對頻率，來定義機率，此為統計的定義，或說客觀的解釋，或說頻率對機率的解釋。

以觀察者對一事件之相信程度，來定義機率，此即主觀的觀點，或說對機率的主觀解釋。

由前述三種解釋，得到啓示，二十世紀的三十年代，產生了以公理化的方式，來定義機率。定義中包含三基本要件：

樣本空間，事件的集合，及機率函數。

各基本要件，皆有一些條件。如樣本空間不可為空集合，這是很顯然的；又事件為樣本空間之子集合，其機率須介於0與1之間等，這符合長久以來人們對機率的認知。前述三基本要件，便構成機率空間，想進一步了解的讀者，可參考黃文璋(2011a)一文。

你可能會好奇，我們不是早就經常在求機率，為什麼還需要機率空間？此有如原本只是一群人分兩隊在操場踢球，發展夠久後，總會想訂個足球的比賽規則。此規則當然會吸收長期以來，在球場上形成的默契，但會考慮的更周詳，以因應各可能發生的情況。

在機率空間裡，樣本空間可以是虛擬的，不必真的在執行什麼試驗，或做什麼觀測。就算真有試驗，如前已指出，樣本空間可以是指定的，而試驗也不必是可以重複的。對實際情況，不能重複的試驗，所涉及的機率，往往是主觀的。但主觀機率，常也是根據過去一些客觀的資料而產生，並非都毫無憑據。只是由於觀測僅有一次，在一翻兩瞪眼下，難免被質疑所給的機率之正確性。比如說，我們想知道最近形成的那一個颱風，是否會登陸台灣。這怎能重複觀測？氣象局預測登陸機率低，颱風卻帶來強風豪雨；預測登陸機率高，颱風卻不見蹤影，屢有發生。

在機率空間裡，集合不論有限或無限，離散或連續，都可以用來當做樣本空間。不像在古典機率裡，樣本空間只能是有限集合，而且由於發生機率相同之故，須知樣本空間中有幾個元素，才能給定機率，因此對那些能放進樣本空間，便很在意。事件的集合，更是可大可小。可小到只包含空

集合及樣本空間兩個元素；也可大到包含樣本空間之所有子集合。在古典的機率裡，以及一般較初等的討論裡，就是取這最大的樣本空間。至於機率，只對事件才給，而機率函數也僅需滿足幾個特定的條件即可。在看似有約束的機率空間中討論機率，但一切可說彈性極大。

你不妨這樣想，訂出一很有彈性的足球比賽規則，其中每隊人數、場地大小，及比賽時間等皆不固定，但都得滿足某些條件。訂規則者可不管地球上是否存在能供幾十億，甚至更多的人比賽的場地。換句話說，所有對機率的討論，可以僅是紙上談兵。但這看起來抽象的機率空間，卻非常一般，無所不包。那些原本常見的投擲骰子，及撲克牌遊戲等，所產生的機率情境，不過都是機率空間之簡單實例而已。

自引進機率空間的架構後，機率理論便開始長足發展，一切概念遂逐漸清晰起來。大部分的情況下還無妨，即使機率空間究竟為何，並沒有很清楚，也能討論機率。只是若遇到有爭議，或處理較細膩的問題時，可能便得先釐清，到底當下的機率空間為何？有如必要時，就得將平常束之高閣的憲法搬出。

你是否信心十足，覺得自己並非一般人，了解機率的意義有何困難？在奇摩的網頁上，曾有人提出下述問題：

我先生的爺爺本身是雙胞胎，我外婆也生過雙胞胎，但公婆及我父母都沒有生下雙胞胎，請問我們會不會生下雙胞胎？如果會，那機率會是多少？

有一個可能是醫學院的學生，給出如下的答覆：

你的問題讓我一看就很想回答，因為很像教授考試的題目，大部分教授考的題目，在臨牀上都沒什麼用途。

一般而言，孕婦生雙胞胎機率是 $1/89$ 。如果家族中有雙胞胎，這機率比 $1/89$ 一定還要大。你問我；你會不會生下雙胞胎？答案是會，但是不保證，只是機率比較大，就好像你問我；走在路上會不會被廣告看板砸下來，打到頭？我的答案也是會，但是機率比較小。結論是：有問好像沒問。

機率是統計學上騙人的東西，許多事情要重複做100次才有機率可言，懷孕不可能100次，每次懷孕生雙胞胎機率是 $1/89$ ，但單次懷孕生雙胞胎機率若不是0%，就是100%，就好像問我，50元銅幣丟到地上一次，是蘭花機率有多少？事實上，50元銅幣丟到地上，不是總統府，就是蘭花，如果丟到地上100次，那麼機率就會接近50%。如果丟到地上一次，蘭花的機率若不是0%，就是100%。

前述回答者對機率的解釋，雖然不正確，但可能是不少人的看法。要知只要尚未確定前，皆可問生出雙胞胎之機率。只是一旦“你”確定後，對你而言，此機率便不是0就是1了。投擲銅板的情況也類似，並非要投擲很多次，僅投擲1次就能談機率。而投擲100次，也非(正面出現的)機率就會接近50%。而是正面出現次數的相對頻率，在“某種意義”下，會接近0.5。至於究竟如何接近，以及對於隨機現象，到底我們能否保證什麼？這些問題較難些，我們留待第5節再討論。

最後必須一提的是，依機率空間的定義，樣本空間中允許僅有一個元素。例如，假設投擲一兩面皆為正之銅板，則會出現那一面？毫無疑問，當然只可能是正面，即樣本空間內只有正面一個元素。這原本並非隨機現象，但我們仍將此視為隨機現象。或更明確地說，視此為一退化的(degenerate)隨機現象。此兩正面銅板一擲之下，出現正面之機率為1，出現反面之機率為0。將退化的情況亦納入(其實是不得不納入)，河海不擇細流故能就其深，所有觀測及試驗，便都是隨機現象了。兩千多年前，畢氏(畢達哥拉斯，Pythagoras，約西元前580-500年)學派有“萬物皆數”(All is number)。我們則說“萬物皆隨機”(All is random)。處在這隨機世界裡，我們怎能不將隨機以及機率的概念，都弄得更清楚些？

3 隨機變數

不時會聽到有些具統計學位的學者坦誠，他們是進了研究所後，才真弄清楚隨機變數的意義。看來隨機變數的概念並不簡單。但不必訝

異，這是我們高中數學裡便有的題材。

我們知道，樣本空間裡的元素，不一定是數字。例如，做一民意調查，想了解民眾對某議題的看法，選項可能有極力贊成、贊成、不贊成、極不贊成，及沒意見等。由於我們一向較慣於處理數字的問題，因此可將極力贊成視為5，贊成視為4，不贊成視為3，餘此類推。也就是將觀測的結果數值化。又如袋中有5紅球、2白球及3藍球，每次隨機取一球，取出後放回，連取10次，想看能取中幾個紅球。則可將紅球視為1，白球及藍球皆視為0。即使原先樣本空間中的元素就已是數字，因種種目的，我們仍可能會考慮它的某一數值函數。眾所周知，在數學中我們一向常考慮各式各樣的函數。假設隨機選取一蘋果，且秤其重量，則可取樣本空間為區間 $(0, \infty)$ 。若蘋果每單位重量的價格為 a 元，則將蘋果的重量 u ，對應至 $X = au$ ，而得其價格。

由於以上這些原因，隨機變數(random variable)的概念便自然地產生了。如前所述，在初等的機率論裡，由於所有事件的集合，通常取成最大，即包含樣本空間的所有子集合，因此所謂隨機變數，不過就是一個定義在樣本空間上的實數值函數。若以 X 表一隨機變數，則此函數的定義域為樣本空間，對應域為實數集合 R 。在較高等的機率論裡，事件的集合不見得是取最大者，則隨機變數便需額外的條件，詳情可參考黃文璋(2011b)一文。底下除非特別聲明，否則我們都僅考慮初等的情況。在同一樣本空間，可定義出無限多個隨機變數。引進隨機變數，可能是基於數值化，也可能只是純粹數學的目的。

簡單講，隨機變數就是一個函數。既然如此卑之無甚高論，那為何會讓不少人得經過多年後，才終於豁然貫通，了解其意義？

首先，以往我們對函數，常以 f, g, h ，或大寫的 F, G, H 等命名；函數的變數，則以 x, y, z 等表示。例如，我們常說給定一函數 $f(x)$ 。即使有時因討論的函數較多， f, g, h 等符號不夠用了，取名為 $a(x), b(x)$ 等，或藉助希臘字母，以 $\xi(x), \eta(x)$ 等來表示亦可。但對隨機變數，我們往往名之為 X, Y, Z 等。又以往的函數，變數常是附在一起的，如 $f(x), g(y)$ 等。但隨機變數，雖明明是函數，其變數卻不常與函數一起出現。例如，我們會

寫 $f(x) = 3$, 或 $g(y) > 5$ 等。而對隨機變數，卻寫成 $X = 3$, 或 $Y > 5$ 等。尤有進者，除了在一開始定義時，說隨機變數為一實數值函數，之後我們幾乎不稱它為函數，連名稱都含有“變數”。因此較不易讓人與以往所學的函數，連結在一起。

再看一個原因。樣本空間常以希臘字母 Ω 表示。隨機變數定義於 Ω ，至於 Ω 中的元素如何出現，則是隨機的，依一機率函數來描述。與數學裡的情況相比，我們說解 $f(x) = 3$ ，其中 x 為實數，就是找出所有滿足 $f(x) = 3$ 的實數 x ，沒有那一實數會較易或較不易出現。但對隨機變數 X ，我們較少說解 $X = 3$ 。 X 如果是由 Ω 映至 R ，是可以有一滿足 $X(\omega) = 3$ 之解集合 $\{\omega | X(\omega) = 3, \text{ 其中 } \omega \in \Omega\}$ （此集合常簡寫為 $\{X = 3\}$ ）。但我們通常不會就此打住，而會去求諸如此集合之機率等。甚至後來經過一番改造，我們常略去解 $X = 3$ 的過程，而直接給出事件 $\{X = 3\}$ 的機率。換句話說，雖然隨機變數本身是一函數，但常另有跟機率有關的函數伴隨它，指揮該隨機變數的行為。那些伴隨函數的性質，就比較接近我們以往所遇到的函數。因此那些伴隨的函數，便採用一般我們熟悉的函數之符號，如 f, g, h , 及 F, G, H 等。這也可以解釋為什麼在隨機變數這一階段，我們不採慣用的函數符號。

第三個原因是，如前所述，有時事件的集合取得較小，使得並非每一由 Ω 映至 R 的函數，皆可當做隨機變數。這點便造成隨機變數的意義不是那麼容易理解了。

此外，隨機變數的概念，有時可能未精準地講授。我們來看現行高中數學課程綱要中，是如何介紹隨機變數。在機率統計 II 中寫著：

生活中所接觸的變量(variables)常常具有隨機現象，比如甲乙兩人猜拳 n 次，甲贏乙的次數；投擲銅板 n 次，出現正面的次數；…等等。這些具有隨機性(不確定性)的變量就稱作隨機變量(也叫隨機變數)。…但隨機變數不需用機率空間上的函數來嚴格定義。

首先，強調不需用機率空間上的函數，來嚴格定義隨機變數，此講法便有問題。在上一節我們已指出，機率空間中有三基本要件，但隨機變數僅定

義於其中的樣本空間，因此不宜視為機率空間上的函數。且只說不需嚴格定義，卻未說該如何定義。而所舉的例子，皆為隨機現象觀測的結果原本便已是數值，未能突顯數值化是隨機變數概念產生的主因。另外，有教科書曾出現下述講法：

我們常將試驗的結果賦予數值，稱為隨機變量。…試驗的結果可以用一個變量來表示時，我們稱這個變量為隨機變量。

前面一句還好，後面一句就沒那麼妥當，恐讓學生以為隨機變數僅針對試驗的結果為數值，此句實有蛇足之嫌。底下為另一教科書裡的講法：

隨機表示結果的不可預知，而變數表示每次結果會有不同的變化。

“結果的不可預知”，與“每次結果會有不同的變化”，不知其間有何差異？為何一名之為隨機，一名之為變數？學生心中原有過去熟知的變數概念，如今加上這樣的說明，恐讓學生對“變數”一詞的意義更感迷惑。

其實在很多隨機試驗裡，我們早就隱含地使用隨機變數的概念了。例如，投擲一公正骰子兩次，令 X 表點數和；投擲一公正銅板20次，令 Y 表所得正面數等。對於前述 X ，可以想成原先觀測到 (u, v) ，其中 u, v 各為 $1, \dots, 6$ 中的某數，再轉換至 $X = u + v$ 。但也可想成一開始所觀測到的結果就是 X 。又雖隨機變數常以大寫的英文字母表示，但其觀測值則以對應的小寫字母表示。有時會說“隨機變數 X 取值 x ”，或說“求 $X = x$ 之機率”。

仍以 Ω 表樣本空間。如果 Ω 本來就是實數的一個子集合，則對每一 Ω 中的元素 ω ，令 $X(\omega) = \omega$ ，為一很自然的隨機變數。例如，一袋中有10張紙牌，分別寫數字1至10。隨機地取一張，並觀測所得點數。取 $\Omega = \{1, 2, \dots, 10\}$ ，令 $X(\omega) = \omega$ ，便得一隨機變數。另一種講法是，自袋中隨機地取一張紙牌，並令 X 表所得點數。這種講法就是直接引進隨機變數。其他如令 Y 表某袋中的紅球數，令 Z 表某校戴眼鏡的學生人數等，都是直接引進隨機變數之例。紅球、戴眼鏡者，本來皆非數字，但因我們將觀測的結果數值化，或者說考慮數值上的特性，便產生了隨機變數。

在同一樣本空間 Ω 中，可定義無限多個隨機變數。即使 $\Omega = \{0, 1\}$ 只有兩個元素，對任二實數 a, b ，令 $X(0) = a, X(1) = b$ ，便得一隨機變數。常數也是一隨機變數。即對一實數 c ，若對每一 Ω 中的 ω ，令 $X(\omega) = c$ ，則 X 為一隨機變數。這種只取一個值之隨機變數，由於並不會有變化，有時稱之為退化的隨機變數。

隨機變數已經是一函數，對一隨機變數 X ，我們又引出另一重要的函數，即**分佈函數**(distribution function)，又稱分布函數，或分配函數：

$$F(x) = P(X \leq x), \quad x \in R.$$

統計裡有時稱為**累積分佈函數**(cumulative distribution function)，但“累積”一詞，其實多餘。對隨機變數 X ，給定一實數 x ， $F(x)$ 乃表一機率值。由於我們常對形如 $\{X \leq x\}$ 的事件之機率感興趣，所以特別以函數 $F(x)$ 表此機率值，而且簡單地寫為 $P(X \leq x)$ ，而非 $P(\{X \leq x\})$ 。一些常會用到的與 X 有關的機率值，都可藉由 F 表示出來。分佈函數與隨機變數之關係，可說極為密切。

分佈函數是一定義域為實數集合，對應域為區間 $[0, 1]$ 的函數。由機率空間，隨機變數，至分佈函數，當只給分佈函數時，源頭之機率空間為何，可能毫不清楚。自完全不同的機率空間，有可能會得到相同的分佈函數。這就像紙雖然是由樹木製造出來，但當我們振筆疾書時，往往不會知道這張紙當初是在那一棵樹上。而不同的樹木，也可能造出品質無分軒輊的紙來。不過有時討論較細膩的問題，就仍須把機率空間找出來。

如果我們只討論機率，有時只須知隨機變數之分佈，這時機率空間並無關緊要。隨機變數的“名字”亦不重要，稱為 X ，或 Y 等皆可。

對一隨機變數 X ，除了伴隨分佈函數 F ，亦有一與其關係密切的函數，即**機率密度函數**(probability density function)，或是**機率質量函數**(probability mass function)，前者是針對連續型，後者是針對離散型。不過為了簡便，常不分連續或離散，皆以機率密度函數稱之。底下我們給其定義。

設 X 為一隨機變數，以 F 為分佈函數。若 X 為離散型，則下述函數 f ，便稱為 X 之機率密度函數：

$$f(x) = P(X = x),$$

其中 x 屬於某一離散的集合。此集合若以 B 表之，則 f 滿足 $\sum_{x \in B} f(x) = 1$ 。若 X 為連續型，則其機率密度函數，乃定義為滿足下式之非負函數 f ：

$$F(x) = \int_{-\infty}^x f(t)dt, \quad x \in R.$$

對一隨機變數 X ，我們常想粗略地知道其值究竟多大，**期望值**(expectation, 或稱expected value, mean) $E(X)$ ，就是常被拿來扮演這種以一單一的值，來代表一隨機變數大小的角色。設 X 之機率密度函數為 f ，則

$$E(X) = \begin{cases} \int_{-\infty}^{\infty} xf(x)dx, & \text{連續型}, \\ \sum_x xf(x), & \text{離散型}. \end{cases}$$

期望值這個名詞，也許會令人感到有些困擾。投擲一公正的骰子一次，令 X 表所得之點數。則 X 之機率密度函數為

$$f(x) = \frac{1}{6}, \quad x = 1, 2, \dots, 6.$$

因此投擲骰子之期望值為 3.5。點數為整數，無論怎麼投擲都得不到 3.5，怎會期望得到 3.5 呢？所以暫時不要去想期望值字面上的含意，那是不易想通的。不過期望值是一隨機變數之“最佳”常數的代表值。所謂最佳，指的誤差平方的期望值最小。

果園裡生產的蘋果，大小頗有差異。有人問你，蘋果每個重量大約是多少，如何回答呢？人們往往想以一常數 a ，來代表一隨機變數 X 。很難說那一個 a 最好，誤差 $X - a$ 仍是隨機的。但在誤差平方 $(X - a)^2$ 之期望值 $E((X - a)^2)$ 最小下，期望值 $E(X)$ 便是最好的選擇。

在機率論裡，我們引進了隨機變數的概念。例如，學生不再如小學的練習裡，每位體重 30 公斤，求 25 位學生的總體重，而是讓每位學生的體重有一機率分佈。雖然這樣的模式較合理，但因無法掌握隨機變數之大小，我們才想要有一代表值。由於具備很多好性質，期望值遂常被拿來當做隨機變數之代表值。期望值像是隨機變數分佈之一個核心，隨機變數可能取

的值，散佈在期望值的左右。其他亦常被拿來當做隨機變數之代表值者，尚有中位數(median)及眾數(mode)等。

我們常要藉助統計做各種決策。投資某項事業，可能成功而獲利若干，可能失敗而損失若干。那到底要不要投資呢？不能只看到成功機率很大(說不定獲利很小)，也不能只看到獲利很大(說不定成功機率很低)，算一算淨所得之期望值，是一簡單的決策依據。判斷出門要不要帶雨傘，也是先盤算一下期望損失(先估計下雨的機率，及下雨不帶傘的損失等)。期望值在做決策時，便常扮演重要的角色。

不論期望值是多好的一個隨機變數之代表值，難免會偏離該隨機變數，如何量測偏差究竟有多大？這就是變異數(variance)與標準差(standard deviation)的功能。

設有一隨機變數 X ，且設期望值 $E(X)$ 存在(期望值並不一定會存在)。則 X 與 $E(X)$ 之離差為 $X - E(X)$ 。此值有正有負，但期望值 $E(X - E(X)) = E(X) - E(X) = 0$ 。離差之期望值為0，亦為期望值之一性質。但我們往往是對離差之絕對值較感興趣。此正如射飛鏢時，有時偏右有時偏左，總不能得意地說平均命中紅心。

離差之絕對值 $|X - E(X)|$ 仍為一隨機變數，如何衡量其大小呢？取期望值為一辦法。也就是求離差絕對值的“平均”。但有關絕對值函數之求和或積分，往往有些麻煩。對於 $E(|X - E(X)|)$ ，須討論何時 $X \geq E(X)$ ，何時 $X < E(X)$ ，這些不等式不見得好解。因此通常的作法，乃考慮離差平方之期望值。我們便將變異數定義為

$$\text{Var}(X) = E((X - E(X))^2)。$$

由於是平方的期望值，像是距離的平方。因此若將變異數開平方，就像使其回到距離，標準差便產生了。

如同期望值，標準差一詞可能亦會令人感到迷惑。取名“標準”，並不表示隨機變數有較大的機率(如大於 $1/2$)，與期望值之差距不超過1個標準差。曾有教科書上出現這樣的誤解。我們給一反例如下：

設有一隨機變數 X ，滿足

$$P(X = 0) = 0.1, \quad P(X = 2) = P(X = -2) = 0.45.$$

即只取-2, 0, 2等3個值。則

$$E(X) = 0,$$

$$\text{Var}(X) = E(X^2) = 0.1 \cdot 0^2 + 0.45 \cdot 2^2 + 0.45 \cdot (-2)^2 = 3.6.$$

因此 X 之標準差 $= \sqrt{3.6} \doteq 1.8972 < 2$ 。但有 $0.9 (= P(X = 2) + P(X = -2) = 0.45 + 0.45)$ 之機率， X 取值與期望值0之差距超過標準差。

與數學不同，在統計裡允許誤差的存在，我們並不要求百分之百的精準。以估計一銅板出現正面之機率 p 為例。除非此銅板兩面皆為正面或皆為反面(即 $p = 0$ 或 1)，否則不論投擲再多次，皆難以估計出正確的 p 值。因此對於估計，我們只能要求誤差在可接受的範圍。而這誤差其實也是隨機的，故我們才考慮“平均式”(即取期望值)的誤差。大家常說，雖不中亦不遠矣。但不遠到底是多遠？標準差的功能，就是對誤差之大小，提供一參考值。如果說期望值是描述一隨機變數分佈的“集中處”，標準差便是描述分佈對該集中處之偏離程度。標準差愈小(或等價地說變異數愈小)，表隨機變數之分佈較集中在期望值附近；標準差愈大，表隨機變數之分佈，分散的較開。人們常說命運，命就有點像是期望值，運則像是標準差。命也許不太好(期望值不大)，但由於有變異的關係，使得有時好運會發生。

假設兩組學生參加測驗，每組各有3人。平均成績皆為60分，但第一組之成績為61, 60, 59；第二組之成績為90, 60, 30。第一組學生的程度很接近，而第二組學生的程度則有很大差異。可看出光由平均成績，並無法了解兩組學生程度差異之情況。對於數據，光知道平均(或期望值)，常是不夠的。例如，射箭時，不能只說平均命中紅心；要泡溫泉，不能只看到平均水溫攝氏42度，符合標準，因說不定有時80度太燙，有時10度太冷，讓人根本不敢下去。因此對於隨機變數，除了期望值，我們尚須給出標準差。有了期望值及標準差，對一隨機變數的中心，及散佈範圍，才有一較清晰的概念。

如同函數可以有多個變數，我們也可以有多維(或說多變數，多變量)隨機變數。聯合分佈函數，及聯合機率密度函數，也就對應產生。例如，二

隨機變數 X, Y 之聯合分佈函數的定義為

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

統計分析要先收集資料，而很多資料有不只一個變數，多變數的討論，為統計學中重要的題材。此處只是對隨機變數給一初步的介紹，因此不多著墨。我們只給幾個概念。

設二隨機變數 X, Y ，以 $f(x, y)$ 為聯合機率密度函數， X, Y 之機率密度函數則分別為 $f_X(x)$ 及 $f_Y(y)$ 表之。若

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

則稱 X 與 Y 相互獨立(mutually independent)，或只簡單地說獨立。

二隨機變數獨立，表知道其中之一的值，對另一變數的分佈，沒有影響。在某些情況，有可能一隨機變數為另一隨機變數之函數，兩者可說關係極度密切，但卻相互獨立。隨機變數的獨立，有其特殊的意義，與平常所說的獨立自主，含意不同。

同理我們也可以定義 n 個隨機變數之獨立。另外，二隨機變數若不獨立，如何來表示兩者之關係，或說互相變化之情況，也是統計裡常討論的題材。

設以 F, G 分別表二隨機變數 X 及 Y 之分佈函數。 X 與 Y 分佈相同，表對每一實數 x ， $F(x) = G(x)$ 。也可說 X 與 Y 有共同的分佈。但分佈相同，與隨機變數相同是完全不一樣的，即使二截然不同的隨機變數，都可有相同的分佈函數。舉例如下。投擲一公正的骰子，並觀測所得點數，則樣本空間 $\Omega_1 = \{1, 2, 3, 4, 5, 6\}$ 。對 $\omega \in \Omega_1$ ，令 $X(\omega) = 1$ ，若 ω 為偶數； $X(\omega) = 0$ ，若 ω 為奇數。其次投擲一公正的銅板，並觀測會得那一面，則樣本空間 $\Omega_2 = \{\text{正面}, \text{反面}\}$ 。令 $Y(\text{正面}) = 1, Y(\text{反面}) = 0$ 。 X, Y 為二相異的隨機變數(定義域便不同)，但 X, Y 分佈相同。

n 個隨機變數 X_1, \dots, X_n ，若相互獨立，且有共同的分佈(independent and identically distributed, 簡稱iid)，便稱此為一組隨機樣本(random sample)。在統計分析裡常會接觸隨機樣本，很多統計的理論都基於隨機樣本。

4 伯努力試驗

在日常生活裡，有很多我們接觸的隨機現象，往往恰有兩種可能的結果。譬如說生男或生女，考試及格或不及格，投擲一骰子是否得到點數3，選民是否會投給某特定候選人等。上述這一切，都可簡化為成功及失敗兩種結果。即在二結果中，指定一為成功，另一結果則稱為失敗。只有兩種可能的結果，可說是會令人感興趣之最簡單的隨機現象了。比此更簡單的，便是退化的情況，只有一種結果。

一試驗若只有兩種可能的結果，便稱為伯努力試驗(Bernoulli trial)。重複且獨立地觀測此試驗，即得一數列之伯努力試驗。

對一伯努力試驗，令樣本空間 $\Omega = \{\text{成功}, \text{失敗}\}$ ，又設 $P(\{\text{成功}\}) = p$, $P(\{\text{失敗}\}) = 1 - p$ ，其中 $0 \leq p \leq 1$ 。在 Ω 上定義隨機變數 X ，令 $X(\text{成功}) = 1$, $X(\text{失敗}) = 0$ 。此為一僅取0, 1二值之離散型的隨機變數， $P(X = 1) = p$, $P(X = 0) = 1 - p$ 。我們稱 X 有參數 p 之伯努力分佈(Bernoulli distribution)，以 $Ber(p)$ 表之。

對一數列 n 個獨立的伯努力試驗，我們常對總成功數有興趣，而不關心究竟那幾次成功。假設每次成功機率皆為 p ，又以 S_n 表總成功數。則

$$S_n = X_1 + X_2 + \cdots + X_n,$$

其中如前，若第 i 次成功，則 $X_i = 1$ ，否則 $X_i = 0$, $i = 1, \dots, n$ 。 X_1, \dots, X_n 即為iid的隨機變數，以 $Ber(p)$ 為共同分佈。

利用排列組合的技巧，可得

$$(1) \quad P(S_n = i) = \binom{n}{i} p^i (1-p)^{n-i}, \quad i = 0, 1, \dots, n,$$

其中

$$(2) \quad \binom{n}{i} = \frac{n!}{i!(n-i)!},$$

而 $i! = i(i-1)\cdots 3 \cdot 2 \cdot 1$, $i \geq 1$ ，且令 $0! = 1$ 。 $\binom{n}{i}$ 便是所謂二項式係數(binomial coefficient)。 S_n 稱為有參數 n 及 p 之二項分佈(binomial distribution)，以 $B(n, p)$ 表之，其中 n 為一正整數， $0 \leq p \leq 1$ 。當然 $Ber(p)$ 即

為 $\mathcal{B}(1, p)$ 。 $\mathcal{B}(n, p)$ 亦為離散型的分佈。由二項式定理(binomial theorem)可驗證

$$\sum_{i=0}^n P(S_n = i) = \sum_{i=0}^n \binom{n}{i} p^i (1-p)^{n-i} = (p+1-p)^n = 1.$$

故(1)式的確定義出一離散型的分佈。又可求出期望值 $E(S_n) = np$, 及變異數 $\text{Var}(S_n) = np(1-p)$ 。

要注意的是, n, p 須固定, 且 n 次伯努力試驗須為iid, 否則其總成功數, 便不見得是二項分佈了。底下給一例。

例1.假設一袋中有100個球, 其中有40個白球, 60個其他顏色的球。依序隨機地取(即每次取球時, 袋中每一球皆有相同的機率被取中)二球, 每次取出後不放回, 令 X 表共取中的白球數。底下來看 X 並無二項分佈。

令 $Y_i = 1$, 若第*i*次取中白球, 否則 $Y_i = 0$, $i = 1, 2$ 。顯然 Y_1 有 $\text{Ber}(0.4)$ 分佈。其次若 $Y_1 = 0$, 即第1次未取中白球, 則第2次有 $40/99$ 之機率取中白球; 若 $Y_1 = 1$, 即第1次取中白球, 則第2次有 $39/99$ 之機率取中白球。因 $Y_2 = 1$ 之機率與 Y_1 之值有關, 故 Y_1 與 Y_2 不獨立。由上討論並得

$$P(Y_2 = 1) = \frac{60}{100} \cdot \frac{40}{99} + \frac{40}{100} \cdot \frac{39}{99} = 0.4.$$

即 Y_2 亦有 $\text{Ber}(0.4)$ 分佈。因

$$P(X = 0) = \frac{60}{100} \cdot \frac{59}{99} \neq 0.36 = \binom{2}{0} 0.4^0 \cdot 0.6^2,$$

故(1)式不成立, 因此 X 並無二項分佈。

附帶一提, 若重複前述試驗, 即每次隨機地取一球, 取出後皆不放回, 且類似地定義出隨機變數, Y_1, \dots, Y_{100} 。則可證明雖 Y_1, \dots, Y_{100} 並不獨立, 但分佈皆為 $\text{Ber}(0.4)$ 。此可說明在摸彩活動中, 先後抽獎順序, 並不影響中獎機率。當然若情況改為每次取出後放回, 則對每一 $n \geq 1$, Y_1, \dots, Y_n (此時 n 可大於100)便為iid, 以 $\text{Ber}(0.4)$ 為共同分佈。

上例為一伯努力試驗中, 各次試驗不獨立之例。生活裡屢見這種取出後不放回的情境。底下來看, 總成功數若不具二項分佈, 會有什麼分佈?

考慮一般的情況。假設袋中有 N 個球，其中有 D 個白球， $N - D$ 個非白球，自袋中依序隨機地取出 n 個球，每次取出後不放回，令 X 表總共取得之白球數。則

$$(3) \quad P(X = k) = \frac{\binom{D}{k} \binom{N-D}{n-k}}{\binom{N}{n}}, \quad \max\{0, n - N + D\} \leq k \leq \min\{n, D\},$$

其中 \min, \max 分別表較小及較大者。我們說明 k 之範圍的由來。因只取 n 個球，且白球數共只有 D 個，所以 k 不能超過 n 及 D ，即 $k \leq \min\{n, D\}$ 。又取中之非白球的個數 $n - k$ ，當然不可超過全部之非白球數 $N - D$ ，而 $k \geq 0$ 又要成立，因此 $k \geq \max\{0, n - N + D\}$ 。

(3)式便定義出一常見的超幾何分佈(hypergeometric distribution)，以 $\mathcal{H}(N, D, n)$ 表之。此分佈在有關品質管制(quality control)的探討裡常出現。對 X 有 $\mathcal{H}(N, D, n)$ 分佈，可證明(見黃文璋(2003b)pp.251-252)

$$E(X) = \frac{nD}{N}, \quad \text{Var}(X) = \frac{nD(N - D)(N - n)}{N^2(N - 1)}.$$

我們給一超幾何分佈之例如下。

例2.設有 $N = 200$ 個零件，其中有 $D = 4$ 個不良品(不良率為2%)。隨機地取3個樣本，每次取出後不放回，則樣本中之不良品數 X 有 $\mathcal{H}(200, 4, 3)$ 分佈。因此

$$\begin{aligned} P(X = 0) &= \frac{\binom{4}{0} \binom{200-4}{3-0}}{\binom{200}{3}} = \frac{1,235,780}{1,313,400} \doteq 0.9409, \\ P(X = 1) &= \frac{\binom{4}{1} \binom{200-4}{3-1}}{\binom{200}{3}} = \frac{4 \cdot 19,110}{1,313,400} \doteq 0.0582. \end{aligned}$$

同理可求出

$$P(X = 2) \doteq 0.000895,$$

$$P(X = 3) \doteq 3.046 \cdot 10^{-6},$$

此二機率值可說非常地小。

例2給出一種小樣本事件。通常我們做決策要仰賴大樣本，小樣本怎會值得重視？大家都聽過“曾參殺人”的典故吧。在戰國策的秦策二：昔者曾子處費，費人有與曾子同名族者，而殺人，人告曾子母曰“曾參殺人”。曾子之母曰“吾子不殺人”，織自若。有頃焉，人又曰“曾參殺人”，其母尚織自若也。頃之，一人又告之曰“曾參殺人”。其母懼，投杼踰牆而走。夫以曾參之賢，與母之信也，而三人疑之，則慈母不能信也。

曾子是孔子的弟子，戰國策記載，以他的賢能及其母對他的信任，但接連三個人告訴其母他殺人，其母對他的信心便動搖了。

如果某公司宣稱其生產之某零件不良率僅2%。有一回你買了一盒有200個，並取出三個使用。若其中壞了一個尚可忍受，因機率約為0.0582。若壞了兩個，可能便要找公司退貨了，因機率才約為0.000895。若三個皆壞，大概便不相信不良率才2%而已，因機率僅約百萬分之3。有些事件我們原先的認知是不太會發生，偶而碰到一次只是覺得運氣不好。碰到第二次時，心裡便可能覺得怪怪的。若再多碰到一、二次，便很可能覺得要嘛有人搞鬼，要嘛這件事發生的可能性其實不是那麼低。小樣本就是在這類發生機率很低之情況中，顯現其影響力，要知有時是可以偏概全的。

超幾何分佈在做民調時亦常會出現。例如，想知道某特定候選人A所獲得之支持率。設有 N 個選民，其中有 D 個支持A， $N - D$ 個不支持，隨機地取 n 個選民回答問卷。令 X 表總共支持A之人數。若每次取出後放回，則 X 有二項分佈。只是總不能重複問同一個人，因此通常是取出後不放回的情況，則 X 便有超幾何分佈。

直觀上，若取出的樣本數 n ，與總人數 N 相比很小，則雖取出後不放回， X 之分佈應近似於二項分佈。在丁村成(2010)一文，遂“證明”當 $N \rightarrow \infty$ 時，

$$(4) \quad \frac{\binom{D}{k} \binom{N-D}{n-k}}{\binom{N}{n}} \rightarrow \binom{n}{k} \left(\frac{D}{N}\right)^k \left(1 - \frac{D}{N}\right)^{n-k},$$

並說此為“超幾何分配之極限是二項分配的事實”。(4)式右側為 $\mathcal{B}(n, D/N)$ 分佈之機率密度函數，此二項分佈即為該文作者想表達的超幾何分佈之極

限。可惜只要具正確極限概念的讀者，應已看出(4)式有誤。

既然讓 N 趨近 ∞ ，極限怎能還有 N ？此犯了極限理論裡，可說是最基本的錯誤。在丁村成(2010)一文，一開始便舉了幾個取樣的例子，以說明超幾何分佈如何產生。既然源自於取樣， N 自然是有限，不會趨近 ∞ 。就算不理會取樣，只純就數學討論， $N \rightarrow \infty$ 時， D 若維持有限，則 $D/N \rightarrow 0$ ，且 $1 - D/N \rightarrow 1$ 。如此除非 $k = 0$ ，否則(4)式右側將趨近0。這是對的， D 若固定，當 $N \rightarrow \infty$ 時，所取的 n 個樣本裡，會至少有1個出自那 D 個的機率，將趨近0。也就是會有0個出自那 D 個的機率趨近1。

如何修正(4)式？仍純就數學而言，設 $N \rightarrow \infty$ 時， D 也隨之增加，且 $D/N \rightarrow p$ 。則可證明

$$(5) \quad \frac{\binom{D}{k} \binom{N-D}{n-k}}{\binom{N}{n}} \rightarrow \binom{n}{k} p^k (1-p)^{n-k}, \quad k = 0, 1, \dots, n.$$

就實務上來說，不會有 $N \rightarrow \infty$ 之情況。但如果 n/N 很小，即取的樣本數，與母體數相比很小(做民調或檢驗時，此條件常會滿足)，則(4)式左、右兩側二機率值之差異便不大。這是以二項分佈做為超幾何分佈之近似的含意，而非如丁村成(2010)所述之極限結果。機率的概念本已不易掌握，若又涉及極限，更不可輕率以對。

超幾何分佈源自於抽樣，且是一種簡單隨機抽樣(simple random sampling)。曾有教科書說：

當母群體中每一元素被抽中的機會均等時，從母群體中隨機抽取所需樣本的方法，稱為簡單隨機抽樣法。

底下為另一說法：

設母體個數為 N ，從中抽取 n 個樣本，則每一個體被抽到的機率都是 n/N ，此種抽樣法稱為簡單隨機抽樣法。

此二講法乃類似，只是皆不正確。

正確的定義是，假設欲自有 N 個元素的母體中，抽取 n 個樣本，若母體那 $\binom{N}{n}$ 個有 n 個元素的子集合，皆有相同的機率被取中，則此法稱為簡單隨

機抽樣法，得到的樣本即為簡單隨機樣本。此定義導致母體中之每一元素，被取中的機率皆相同，即 n/N 。反之，即使滿足前述二課本中的條件，也不一定滿足簡單隨機抽樣法的定義。我們給一反例如下。

假設母體中有 a, b, c, d 四個元素，要抽取兩個樣本。即 $N = 4, n = 2$ 。現各以 $1/2$ 的機率取 $\{a, b\}$, 及 $\{c, d\}$ 。顯然母體中的四個元素，每一被取中的機率皆為 $2/4 = 1/2$ ，所以這種取法，符合前述二課本上的要求。但 $\{a, c\}, \{a, d\}, \{b, c\}, \{b, d\}$ 等，皆不會被取中，故此非簡單隨機抽樣。可看出此抽樣法是偏頗的，有四個組合必不會產生。執行抽樣時，當然不可有這種偏差，否則將無法達到一葉知秋的目的。

讀者易見，我們所給的定義是較強的，必須母體全部有 n 個元素之子集合，每一皆有相同的機率 $1/(N)_n$ 被取中。當此條件成立時，極易推導出，母體中的任一元素，甚至任意有 k 個元素的子集合， $k = 1, 2, \dots, n$ ，也皆有相同的機率被取中。又若慢慢取，每次只隨機取一樣本，取出後不放回，持續取 n 個樣本，則所得即為一組簡單隨機樣本。

通常簡單隨機抽樣法是指取出後不放回。若是取出後放回，反而得特別強調。

二項分佈當 n 較大時，計算上便有些困難。例如，若獨立地投擲一銅板 100 次，每次成功的機率設為 $1/2$ ，則總共之正面數 X ，便有 $B(100, 1/2)$ 分佈。由此得 $X = 30$ 之機率為

$$P(X = 30) = \binom{100}{30} \left(\frac{1}{2}\right)^{100},$$

$\binom{100}{30}$ 自然是不太好計算的。為解決此困難，遂發展出中央極限定理，我們留至第6節再談。

另外，由伯努力試驗，在不同的情境下，可得好幾個機率裡重要的分佈，可參考黃文璋(2003a)一書“銅板乾坤”，此處不多討論。

5 大數法則

只要懂點機率統計的人，都聽過大數法則(law of large numbers)。大

數法則究竟是什麼？討論大數法則，無可避免的，會涉及極限。弄懂極限，乃進入較高深數學的第一步，這得看一般微積分的書。底下我們只略做介紹。

任給一實數列 $\{a_n, n \geq 1\}$ ，當 $n \rightarrow \infty$ 時， a_n 不見得會趨近至某一定值。例如，若 $b_n = (-1)^n, n \geq 1$ ，則此數列為-1, 1, -1, 1, …，不論 n 多大，數列都是-1, 1交錯著進行，不會接近任一定值；若 $c_n = n, n \geq 1$ ，則當 n 愈來愈大， c_n 將無止盡地增大。此二數列皆稱為發散。但若取 $a_n = (1/2)^n, n \geq 1$ ，則隨著 n 之增大， a_n 將任意接近0。我們以

$$n \rightarrow \infty \text{時}, a_n \rightarrow 0$$

表之，也可寫成

$$\lim_{n \rightarrow \infty} a_n = 0.$$

對於 $n \rightarrow \infty$ 時， $a_n \rightarrow a$ ，其中 a 為一實數，是說當 n 不斷地增大， a_n 可任意接近 a 。此表 a_n 與 a 之差距 $|a_n - a|$ 可任意小。而怎樣是任意小？0.01算小嗎？還是0.0001才算小？就任給一差距，以 ε 表之，即要求 $|a_n - a|$ 須小於被指定的 ε 。但何時 $|a_n - a| < \varepsilon$ ？可沒要求對每一 $n \geq 1, |a_n - a| < \varepsilon$ 都要成立，而是說 n 很大時， $|a_n - a| < \varepsilon$ 才須成立。但 n 怎樣才算很大？如果從某一項 n_0 開始， $|a_n - a| < \varepsilon$ 皆成立，大約便只好服氣了。於是產生了下述極限的定義：假設有實數列 $\{a_n, n \geq 1\}$ ，及實數 a ，

若每一 $\varepsilon > 0$ ，存在一 $n_0 \geq 1$ ，使得 $|a_n - a| < \varepsilon$ ，當 $n \geq n_0$ ，
則稱 $n \rightarrow \infty$ 時， $a_n \rightarrow a$ ，以 $\lim_{n \rightarrow \infty} a_n = a$ 表之。

上述定義並非微積分一開始發展便有的，而是經過一百多年，數學家才以此方式來定義極限。要知數學上一個概念，常是經過長期的演變，才能以簡潔、嚴密、一般，且抽象的方式呈現。後來的學習者，自然得花一點功夫，才能領悟此概念之內涵。

講大數法則前，可能得先正名。巨數法則，雖然英文名為law of truly large numbers，但其實與大數法則並不太相干。在一般正規的機率論書

中，並不會提到此法則。它主要是出現在通俗性的文章中，有時也被稱為law of large numbers。我們實在不願稱它為**真大數法則**，只好含混地稱它為**巨數法則**。在Diaconis and Mosteller(1989)一文中，對此法則給出如下定義：

With a large enough sample, any outrageous thing is likely to happen(當樣本數夠大，任何聳人聽聞的事，都可能發生)。

雖明明與大數法則大異其趣，但由於都涉及大樣本，有些人遂將二者混在一起。如Shermer(2004, 姚若潔譯(2004)為其翻譯)一文中有底下一段：

A principle of probability called the Law of Large Numbers shows that an event with a low probability of occurrence in a small number of trials has a high probability of occurrence in a large number of trials. Events with million-to-one odds happen 295 times a day in America.

不但提到“Law of Large Numbers”，且說發生機率百萬分之一的怪異事件，在美國每天可發生295次。這是基於美國有2.95億(295百萬)的人。又順便一提，根據美國人口普查局(U.S.Census Bureau)網頁，至2011年8月底，美國人口超過3.12億。

Shermer為著名通俗科學雜誌Scientific American的專欄作家。上述他那篇文章雖然有趣，但對機率的描述，卻不夠準確，恐易引起誤解。首先，他所引用的不是大數法則，而是巨數法則。其次，他說“在數量樣本較少時，機率很小的事件，在數量樣本較大時，其發生的機率會變高”(見姚若潔譯(2004))，也該修正為“發生機率很小的事件，若樣本數較少時，會有這種事件發生的機率不高；若樣本數較大時，會有這種事件發生的機率會變高”。至於單一事件發生的機率，並不會隨試驗數之多寡而改變。另外，最後一句話，宜改為“在一個人身上每天發生機率為百萬分之一的怪異事件，在美國平均一天可發生295次”才較恰當。

一事件發生的機率 p 雖然很小，若重複觀測 n 次，且假設各事件相互獨立，則 n 次皆未發生之機率 $(1 - p)^n$ ，隨著 n 之增大，將愈來愈接近0；而至少

發生一次之機率 $1 - (1 - p)^n$ 則逐漸接近1。這也可以解釋，只要觀測數夠多，任一聳人聽聞的事件，其發生便都不必驚訝。

巨數法則可用來解釋何以生活上處處有巧合。關於巧合事件之無所不在，可參考黃文璋(2003a)“純屬巧合”一章。

大數法則又稱大數率，或平均法則(law of averages)。由於有大數法則，使得在不確定性(uncertainty)中，我們仍能掌握一些確定性(certainty)。大數法則是說，若一試驗(或觀測)，能重複且獨立地進行，則觀測值之平均，將任意接近期望的結果。比較正式一點地說，就是隨機產生樣本之平均，當樣本數很大，將有很大的機率，接近母體之期望值。

機率論早期的發展，常對某事件是否發生有興趣。如上節所說，這種發生或不發生，兩個結果的觀測，便產生伯努力試驗。這是因瑞士數學家伯努力(Jacob Bernoulli, 1654-1705)，最先探討而得名。在他死後8年，1713年，他姪兒尼古拉斯伯努力(Nicholas Bernoulli, 1687-1759)，替他出版那本可說是機率論最早的書籍Ars Conjectandi(原文為拉丁文，英文書名為The Art of Conjecturing)。在這本書中，伯努力證明了一以他的姓名命名的定理，即伯努力法則(Bernoulli law)：

獨立且重複地觀測一發生機率為 p 之事件A，當觀測次數趨近 ∞ ，事件發生之相對頻率接近 p 之機率，將趨近1。

伯努力所指的“機率趨近1”是什麼意思？

令 $n(A)$ 表獨立且重複地觀測 n 次，事件A所發生之次數。則 $n(A)$ 有 $B(n, p)$ 分佈。即

$$(6) \quad P(n(A) = k) = \binom{n}{k} p^k (1-p)^{n-k}, \quad k = 0, 1, \dots, n.$$

伯努力指出，當 n 很大時，事件A發生之相對頻率 $n(A)/n$ 與 p 之差距，應極可能很小。但 $n(A)$ 可能每回觀測都不盡相同，畢竟這是一隨機現象。有時 $n(A) = n$ ，有時 $n(A) = 0$ 。投擲一公正銅板100次，100次全出現正面的機率當然很低，僅 $1/2^{100}$ ，微乎其微。但若一直重複執行此試驗(每回投擲100個銅板)，譬如說做了 2^{100} 回，則如果其中出現一回100個全正

面，就不用太奇怪。如果回數再多些，譬如做 2^{110} 回，就更容易出現好幾回100個全是正面了。因平均可出現 $2^{110}/2^{100} = 2^{10} = 1,024$ (回)。此即巨數法則。

註1.要完成 2^{100} 回投擲銅板100次，其實並非易事。假設以電腦模擬，且1秒鐘可模擬1萬兆($=2^{16}$)回。1天有86,400秒，1年365天約有 $3.1536 \cdot 10^7$ 秒。因此一年約可模擬 $3.1536 \cdot 10^{23}$ 回。又 $2^{100} \doteq 1.2676506 \cdot 10^{30}$ ，二者相除，得到約要模擬 $4.01969 \cdot 10^6$ 年。即要四百多萬年才能模擬完。野史裡偶有投擲出100個正面的記載，見黃文璋(2003a)p.71，那些銅板當然都是特製的。如果銅板為公正，你現在知道了，在不作假之下，投擲100個，是很難出現100個全是正面。若想靠多投擲幾回而得，那回數之多，乃遠超乎我們想像。

對於隨機現象的種種解釋，自然須以機率為依歸。伯努力所說 n 很大時， $n(A)/n$ 與 p 之差應極可能很小，表只要 n 夠大， $|n(A)/n - p| \leq \varepsilon$ 之機率應很大，其中 ε 為任一正數。而前述機率即

$$(7) \quad \sum_{|k/n-p| \leq \varepsilon} P(n(A) = k) = \sum_{|k/n-p| \leq \varepsilon} \binom{n}{k} p^k (1-p)^{n-k}.$$

伯努力辛苦地證明 $n \rightarrow \infty$ 時，上式右側和趨近1。事實上，後人利用柴比雪夫不等式(Chebyshev inequality, Pafnuty L. Chebyshev, 1821-1894，為俄國著名數學家)，可輕易地證出比伯努力更一般的結果，可參考黃文璋(2010a)p.124。但伯努力的原創性，至今仍被推崇。

伯努力所指的事件發生之相對頻率，可表示為

$$(8) \quad \frac{n(A)}{n} = \frac{X_1 + \cdots + X_n}{n} = \frac{S_n}{n} = \bar{X}_n, \quad n \geq 1,$$

其中 X_1, \dots, X_n 為iid之隨機變數，以 $Ber(p)$ 為共同分佈，而 $S_n = X_1 + \cdots + X_n$ ， $n \geq 1$ ，有 $B(n, p)$ 分佈。伯努力即指出，iid以 $Ber(p)$ 為共同分佈的隨機變數 X_i ， $1 \leq i \leq n$ ，當 $n \rightarrow \infty$ 時，樣本平均(sample mean) \bar{X}_n ，會很接近 p 的機率趨近1，即會稍偏離 p 的機率趨近0。

讀者應可看出大數法則與巨數法則，乃不同的兩個法則。曾在網路上一篇文章中，看到底下一段話：

記得保險業流行一條“大數法則”，意思是只要大量接觸客人，十位或一百位或一千位，總有一位客人投保。換句話說，你失敗，只是個人不夠勤力，接觸的客人不夠多之故。

其實這是巨數法則，而非大數法則。對一事件 A ，當觀測數 n 很大，巨數法則關心 A 是否發生，大數法則卻是說事件 A 發生的總次數 $n(A)$ ，“約”是 np ，其中 p 為 A 發生的機率。也可以這麼說，大數法則是比巨數法則更精確的法則。它指出當觀測數 n 很大，一特定事件將“大約”發生多少次。因 n 很大時，事件 A 發生“約” np 次，故即使 p 很小，只要 $np > 1$ ，則看到事件 A 發生，就不足為奇。這就是巨數法則所指出的現象。

大數法則可以支持頻率對機率的解釋。設有一銅板，出現正面的機率為 p (或一事件發生之機率為 p)，只投擲一次，不是正面就是反面，無法感受 p 的意義。但只要投擲數夠大，銅板出現正面的相對頻率，就很可能會接近 p 了。伯努力之後的機率學家們，繼續探討大數法則。1928年，俄國機率學家辛欽(Aleksandr, Y. Khinchin, 1894-1959)，證明對iid的隨機變數，只要期望值存在，不論分佈為何，大數法則便成立。即對 $\forall n \geq 1$ ，設 X_1, \dots, X_n 為iid之隨機變數，且設 $E(X_1)$ 存在(即 $-\infty < E(X_1) < \infty$)，則當 $n \rightarrow \infty$ 時， \bar{X}_n 會機率收斂(converges in probability)至 $E(X_1)$ ，以 $\bar{X}_n \xrightarrow[n \rightarrow \infty]{P} E(X_1)$ 表之。在此機率收斂的定義如下：

設有一數列之隨機變數 $\{Y_n, n \geq 1\}$ ，及一隨機變數 Y ，若

$$(9) \quad \lim_{n \rightarrow \infty} P(|Y_n - Y| > \varepsilon) = 0, \forall \varepsilon > 0,$$

則稱 $n \rightarrow \infty$ 時， $Y_n, n \geq 1$ ，機率收斂至 Y ，且以 $\bar{Y}_n \xrightarrow[n \rightarrow \infty]{P} Y$ 表之。

(9)式是說，對 $\forall \varepsilon > 0$ ，當 $n \rightarrow \infty$ 時， $|Y_n - Y| > \varepsilon$ 之機率趨近0。亦即 $|Y_n - Y| \leq \varepsilon$ 之機率趨近1。

辛欽所證出的結果，後來被稱為弱大數法則。你可預期亦有強大數法則，此處略過不表，可參考黃文璋(2010a)5.7節。當iid的隨機數

列 $\{X_n, n \geq 1\}$, 只取0, 1兩個值, 且 $P(X_1 = 1) = p$, 則 $E(X_1) = p$, 這時弱大數法則就回到伯努力的版本。弱大數法則並無法保證 n 很大時, 樣本平均與隨機變數之期望值 $E(X_1)$ “必會”很接近, 這點與常數數列的收斂大不相同。對於隨機現象, 所有的保證, 都是機率式的。即弱大數法則保證 n 很大時, \bar{X}_n 與期望值 $E(X_1)$ 很接近的機率很大。即 \bar{X}_n 不論與 $E(X_1)$ 差距多小之機率要多大, 皆能辦到, 只要樣本數 n 夠大。

弱大數法則並沒有說, n 很大時, \bar{X}_n 會等於 $E(X_1)$ 。有些初學者誤以為如此。教科書中也有下述離譜的講法:

機率裡的期望值就是統計試驗中大量數據的平均值。

即使說 n 很大時, $|\bar{X}_n - E(X_1)|$ 必很小, 此講法也是錯的。這些皆屬於缺乏隨機的概念。正確的說法是, n 很大時, $|\bar{X}_n - E(X_1)|$ 很小的機率很大。

對於隨機現象, 我們通常只能做機率式的保證。初學者或許會以為, 我們的保證好似都有些保留, 不像數學中一向斬釘截鐵式的說法有權威。但看似不太確定, 實際上是更可靠的保證。只要想甲醫生肯定地說這病人活不過3個月, 乙醫生說病人活不過3個月的機率為0.99, 你覺得那一種講法較精準?

弱大數法則不只針對iid的隨機變數才成立, 歷來機率學家, 紛出不同條件下的弱大數法則, 使其適用性更廣。

對iid的隨機變數, 期望值若不存在, 則弱大數法則就不適用了。設 $X_n, n \geq 1$, 為iid的隨機變數。若以 $Ber(1/2)$ 為共同分佈, 此時圖1給出 \bar{X}_n 之一模擬圖形, $1 \leq n \leq 1,000$ 。可看出除了 n 不太大時, \bar{X}_n 與0.5有較大差距, 之後就與0.5很接近了。其次若共同分佈為參數2.5及1之柯西分佈(Cauchy distribution), 以 $\mathcal{C}(2.5, 1)$ 表之, 即機率密度函數為

$$f(x) = \frac{1}{\pi(1 + (x - 2.5)^2)}, x \in R,$$

圖2給出此時 \bar{X}_n 之模擬圖形, $1 \leq n \leq 1,000$ 。 $\mathcal{C}(2.5, 1)$ 分佈之期望值不存在, 圖形顯示 \bar{X}_n 之振盪頗大。

我們常會接觸到機率為0之事件。自區間 $[0, 1]$ 隨機地取一個點, 會取

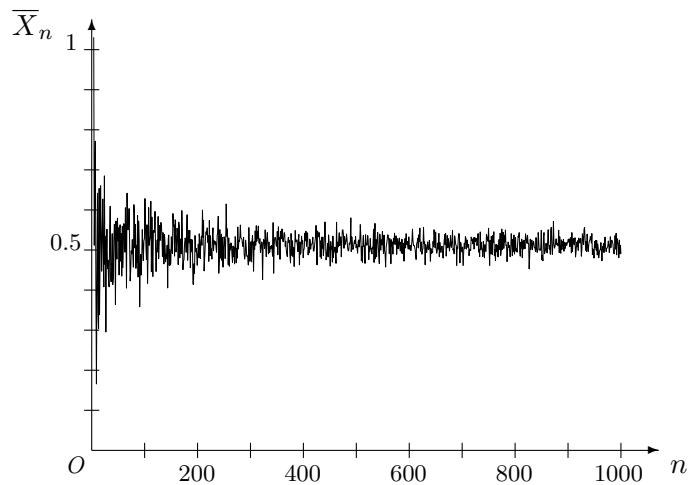


圖1. $\text{Ber}(1/2)$ 分佈 \bar{X}_n , $1 \leq n \leq 1,000$, 之模擬圖

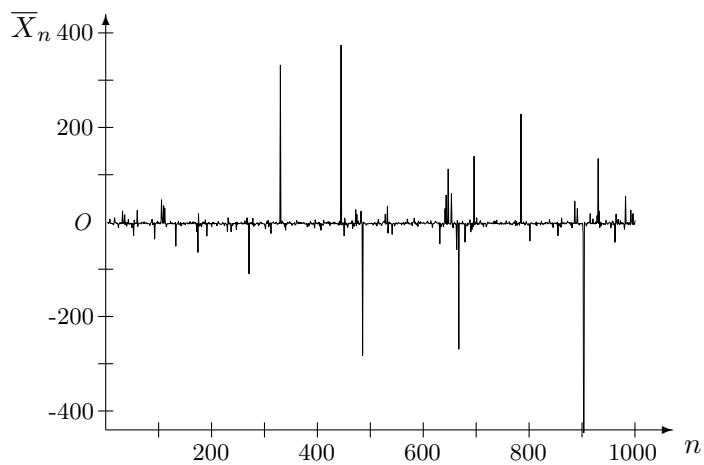


圖2. $\mathcal{C}(2.5, 1)$ 分佈 \bar{X}_n , $1 \leq n \leq 1,000$, 之模擬圖

中0.3的機率為何？0，你可能會不假思索地回答。你還知道任何一點被取中之機率皆為0。如果令 X 表取中之點，則 X 為一連續型的隨機變數。因此 X 會等於 $[0, 1]$ 間任一數之機率皆為0。修過機率及統計的課程，使你具備基本的機率知識。但有人一取之下，取中0.729，他問你機率不是為0嗎？怎麼卻發生了？

要知機率為0的事件，不代表不會發生，此現象常讓初學者感到迷

惑。事實上，事件之“不會發生”、“會發生”，及“一定發生”等，皆非專業的說法。正確的說法分別是：機率為0，機率為正，及機率為1。有人取中0.729，他懷疑0.729被取中的機率其實大於0。如何跟他解釋？此時大數法則便可派上用場。你請他繼續取，依序取了 n 次，如此得到隨機數列 X_1, \dots, X_n ，其中 $X_i = 1$ ，表第*i*次取中0.729； $X_i = 0$ ，表第*i*次未取中0.729， $i \geq 1$ 。然後算出0.729出現次數的相對頻率 \bar{X}_n 。雖然 $X_1 = 1$ ，但自 X_2 起，應沒有人覺得會是1了。隨著 n 之增大，你愈來愈相信 \bar{X}_n 將很接近0。何以我們那麼“確定”？因弱大數法則告訴我們， $n \rightarrow \infty$ 時，

$$\bar{X}_n \xrightarrow[n \rightarrow \infty]{P} E(X_1) = 0.$$

由於有上述這類困擾，有時機率學家，傾向以幾乎不可能(almost impossible)，及幾乎確定(almost certain)，來取代“不可能”(不會)，及“確定”(必會)。

在統計裡，很多不錯的統計估計方法，都基於弱大數法則。著名的動差估計法(method of moment estimator)即為一例。大數法則除支持頻率對機率的解釋，在統計學裡用途亦不小。

6 中央極限定理

如前所述，生活裡伯努力試驗可說處處可見。而若有 n 個獨立的伯努力試驗，每次成功機率皆為 p ，則總成功數 S_n 便有 $B(n, p)$ 分佈。二項分佈也就是如此容易產生。在機率論發展的早期，由於沒有快捷的計算工具，因此尋找易於處裡的方法，來計算二項分佈的機率值，便很迫切。

伯努力的大數法則指出， n 很大時， S_n/n 差不多就是 p 。即只要 n 夠大， S_n/n 應有很大的機率，只在 p 附近變動。有些人因此以為，當 n 很大時， S_n 便應很接近期望值 np 。此想法導致獨立地投擲一公正銅板($p = 1/2$)多次後，會以為正、反兩面數將差不多。甚至加以引申，以為樂透彩若公正，則開獎多期後，各號碼累積出現的次數，應大致相同。這並不正確。事實上，開獎期數愈多，各號碼累積出現次數之差異，反該預期會愈大。可參考黃文璋(2005)圖2。不妨以一常數數列來說明。取 $a_n = n + \sqrt{n}$ ，

$n \geq 1$ 。雖 n 很大時, $a_n/n = 1 + 1/\sqrt{n}$ 很接近 1, 但 a_n/n 與 1 各放大 n 倍後, a_n 與 n 之差 \sqrt{n} , 却隨著 n 之增大而無止盡地增大。由此可理解, n 很大時, 雖 S_n/n 大致在 p 附近, 但 S_n 却很可能會愈偏離 np 。

直觀上, 對一固定的 p , 不論 p 多小, 有如聚沙成塔, 只要 n 夠大, 則 n 次試驗後的總成功數 S_n 很可能會很大。但 S_n 究竟大到什麼地步? 也就是說, 能否了解 S_n 隨 n 成長的方式? 如在天文學裡, 以光年來量度很遠的距離。有沒有什麼辦法, 將 S_n 轉換成不是那麼大, 使求其機率值, 變得較有意義?

對 S_n 有 $\mathcal{B}(n, p)$ 分佈, 則

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

由於 $\binom{n}{k}$ 中有階乘的關係, 使得當 n 較大時, $P(S_n = k)$ 有多大, 除非 k 很靠近 0 或 n , 否則便不易掌握。我們來看比較簡單 $p = 1/2$, 且 n 為偶數的情況。利用可近似階乘的史德林公式(Stirling formula, 可參考黃文璋(2010a)p.128), 得 $n \rightarrow \infty$ 時, S_n 等於期望值 $n/2$ 之機率

$$(10) \quad P(S_n = \frac{n}{2}) = \binom{n}{n/2} \left(\frac{1}{2}\right)^n \sim \frac{\sqrt{2}}{\sqrt{\pi n}},$$

其中符號 “~” 表 $n \rightarrow \infty$ 時, 兩側比值趨近 1。因 n 很大時, $\sqrt{2}/\sqrt{\pi n}$ 很小, 因此(10)式左側也必很小。印證我們之前所說的, 投擲一公正銅板 n 次(n 為偶數), 若 n 很大時, 乃極不容易出現 $n/2$ (半數)次正面。另一方面, 對 $\mathcal{B}(n, 1/2)$ 分佈, 其中 n 為偶數, 可證明其機率密度函數之極大值, 發生在 $S_n = n/2$ 處。圖 3 給出 $\mathcal{B}(20, 1/2)$ 之(機率)直方圖(histogram)。所謂直方圖乃描述離散型隨機變數取各可能值之機率, 其中每一長方條之底部中點, 為所取的值, 面積則為會取該值之機率。所以長方條之面積和為 1。圖 3 顯示, 此直方圖在 $n = 10$ 時最高, 並往兩側下降。

對二固定的整數 r, s , 其中 $0 \leq r \leq s$, 可證明當 n 很大時,

$$P(r \leq S_n \leq s) = \sum_{k=r}^s \binom{n}{k} \left(\frac{1}{2}\right)^n,$$

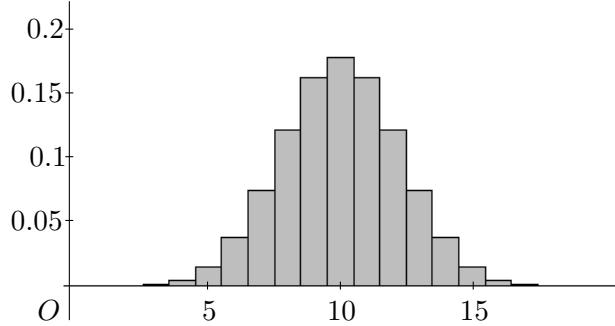


圖3. $\mathcal{B}(20, 0.5)$ 分佈直方圖

也將很小。事實上，仍考慮 n 為偶數，利用史德林公式，對每一固定整數 k ，可得 n 很大時，

$$(11) \quad P(S_n = \frac{n}{2} + k) \sim \frac{\sqrt{2}}{\sqrt{\pi n}}.$$

由上討論知，除非在 $n/2$ 附近有“夠多”的項，否則 S_n 落在 $n/2$ 附近一區間 $[n/2 + a, n/2 + b]$ 之機率將很小，其中整數 a, b 滿足 $-n/2 \leq a \leq b \leq n/2$ 。即 n 很大時，

$$(12) \quad P(\frac{n}{2} + a \leq S_n \leq \frac{n}{2} + b) = \sum_{k=a}^b P(S_n = \frac{n}{2} + k) \doteq 0.$$

而且所謂夠多的項，由(11)式看出，隨著 n 之增大，所需項數，應須能與 \sqrt{n} 相匹比。

明乎此，隸美弗 (Abraham de Moivre, 1667-1754) 以適當的 a_n, b_n 取代(12)式中的 a, b 。仍利用史德林公式，經過一番取極限的過程，他得到那些機率值的和，可表示為一個積分，並在 1733 年發表此結果。這個劃時代的發現，也就是後來中央極限定理的雛型，遠超過當時代的人對機率論的理解，因此並未引起重視。就在幾乎已被遺忘時，拉普拉斯 (Pierre-Simon, Marquis de Laplace, 1749-1827)，把此結果從塵封中救了出來。在拉普拉斯 1812 年出版的那篇機率史上不朽的論文裡，推廣棣美弗 $p = 1/2$ 的結果至一般的 p 。但如同棣美弗，拉普拉斯的曠世巨著，仍未引起同時代的人太多注意。直到 19 世紀結束後，中央極限定理的重要性，才被完

全認識。1901年，里阿普那夫(Aleksandr M. Lyapunov, 1857-1918)，給出此定理較一般的敘述，及嚴密的證明。由於有前述這一段歷史，中央極限定理又稱棣美弗-拉普拉斯定理。有關中央極限定理的歷史，可參考Tijms(2004)p.169。

對 S_n 有 $\mathcal{B}(n, p)$ 分佈，拉普拉斯即證出對實數 $\alpha \leq \beta$, $n \rightarrow \infty$ 時，

$$(13) \quad P(np + \alpha\sqrt{np(1-p)} \leq S_n \leq np + \beta\sqrt{np(1-p)}) \\ \rightarrow \Phi(\beta) - \Phi(\alpha) = \int_{\alpha}^{\beta} \phi(u)du,$$

其中

$$(14) \quad \Phi(x) = \int_{-\infty}^x \phi(u)du, \quad x \in R,$$

$\Phi(\infty) = \int_{-\infty}^{\infty} \phi(x)dx = 1$, 而

$$(15) \quad \phi(x) = \frac{1}{\sqrt{2\pi}} e^{-x^2/2}, \quad x \in R.$$

(15)式定義出一標準常態(以 $\mathcal{N}(0, 1)$ 表之)分佈之機率密度函數。對 $x \in R$, $y = \phi(x)$ 之圖形對稱於 y 軸，是所謂鐘形曲線(bell-shaped curve)，圖形下與 x 軸間之面積為 1。圖 4 約出其圖形，注意橫軸及縱軸之單位長不同。圖形最高點發生在 $x = 0$, 其值為 $\phi(0) = 1/\sqrt{2\pi}$, 約為 0.39894。故若兩軸單位長取的相同，則圖形將更呈現平坦，便不易看似鐘形了。

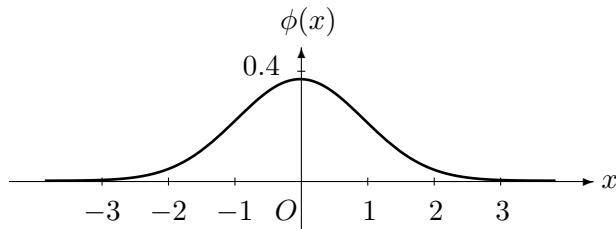


圖 4. $\mathcal{N}(0, 1)$ 分佈之機率密度函數圖形

(13)式之另一表示法為，對 $\alpha \leq \beta$, $n \rightarrow \infty$ 時，

$$(16) \quad P\left(\alpha \leq \frac{S_n - np}{\sqrt{np(1-p)}} \leq \beta\right) \rightarrow \Phi(\beta) - \Phi(\alpha).$$

上式給出了所謂二項分佈趨近至常態分佈。底下我們略為說明。

首先，對 S_n 有 $\mathcal{B}(n, p)$ 分佈， np ，及 $\sqrt{np(1-p)}$ 分別為 S_n 之期望值及標準差。我們說過， n 很大時， S_n 也幾乎是很大。 S_n 的“核心”是 np ，隨著 n 之增大，此核心已移至很遠處。將 S_n 減去期望值 np ，則 $S_n - np$ 的“核心”便成為0了。此步驟有如經過座標平移，將很遠的點拉回來。再經改變尺度，單位長由1成為 $\sqrt{np(1-p)}$ ，則 S_n 便不再是遙不可及的龐然大物。而令人感到驚訝的是，(13)式指出， S_n 的直方圖，從 np 量起， α 個標準差至 β 個標準差間，那些長方條面積和，當 $n \rightarrow \infty$ 時，可表為 $y = \phi(x)$ 之圖形下與 x 軸間，介於 $x = \alpha$ 至 $x = \beta$ 間的面積。

如(16)式左側，對一隨機變數減去期望值，再除以標準差，此過程便稱為將其標準化。

隨機變數若有二項分佈，則可表為iid伯努力隨機變數之和。將其標準化後，會趨近至 $\mathcal{N}(0, 1)$ 分佈。只限伯努力隨機變數之和嗎？其他分佈呢？

中央極限定理，差不多可以說是機率論裡，最重要的一個定理。此定理是說，若有夠多的獨立且同分佈隨機變數之和，則經標準化後，當 n 很大時，將可以 $\mathcal{N}(0, 1)$ 分佈做為近似。設對每一 $n \geq 1$ ， X_1, \dots, X_n 為iid的隨機變數，且設 $\mu = E(X_1)$ ，及 $\sigma^2 = \text{Var}(X_1)$ 皆存在。中央極限定理指出，對任二實數 $\alpha < \beta$ ，

$$(17) \quad \lim_{n \rightarrow \infty} P\left(\alpha \leq \frac{X_1 + \dots + X_n - n\mu}{\sigma\sqrt{n}} \leq \beta\right) = \Phi(\beta) - \Phi(\alpha).$$

令 $\bar{X}_n = (X_1 + \dots + X_n)/n$, $n \geq 1$ 。則(17)式導致

$$(18) \quad \lim_{n \rightarrow \infty} P\left(\alpha \leq \frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} \leq \beta\right) = \Phi(\beta) - \Phi(\alpha), \quad \alpha < \beta.$$

這是以樣本平均來表示的中央極限定理。又 $\Phi(x)$ 滿足

$$(19) \quad \Phi(-x) = 1 - \Phi(x), \quad x \in R.$$

利用(17)及(19)式，得(取 $\beta = c$, $\alpha = -c$) n 很大時，

$$(20) \quad P\left(\left|\frac{X_1 + \dots + X_n - n\mu}{\sigma\sqrt{n}}\right| \leq c\right) \doteq 2\Phi(c) - 1, \quad c \geq 0,$$

由(20)式即得

$$(21) \quad P\left(|\bar{X}_n - \mu| \leq \frac{c\sigma}{\sqrt{n}}\right) \doteq 2\Phi(c) - 1, \quad c \geq 0.$$

上式又導致

$$(22) \quad P\left(|\bar{X}_n - \mu| > \frac{c\sigma}{\sqrt{n}}\right) \doteq 2(1 - \Phi(c)), \quad c \geq 0.$$

令 $c\sigma/\sqrt{n} = \varepsilon$, 由上式得

$$(23) \quad P(|\bar{X}_n - \mu| > \varepsilon) \doteq 2(1 - \Phi(\varepsilon\sqrt{n}/\sigma)), \quad \varepsilon \geq 0.$$

弱大數法則指出，對每一 $\varepsilon > 0$, n 很大時， $P(|\bar{X}_n - \mu| > \varepsilon)$ 將很小。但究竟多小，便沒說了。中央極限定理便給出 n 很大時， $P(|\bar{X}_n - \mu| > \varepsilon)$ 約為 $2(1 - \Phi(\varepsilon\sqrt{n}/\sigma))$ 。且不論 $\{X_n, n \geq 1\}$ 之共同分佈為何，都有此結果，這是中央極限定理的威力所在。因此雖然無法保證 n 很大時， $|\bar{X}_n - \mu|$ 不會超過 ε ，但只要變異數 σ^2 存在，則此機率 $P(|\bar{X}_n - \mu| > \varepsilon)$ 的大小，便可掌握，即約 $2(1 - \Phi(\varepsilon\sqrt{n}/\sigma))$ 。此值隨著 n 之趨近 ∞ 而趨近 0 (因 $n \rightarrow \infty$ 時， $\Phi(\varepsilon\sqrt{n}/\sigma) \rightarrow 1$)。另外，若(23)式成立，即得 $n \rightarrow \infty$ 時， $P(|\bar{X}_n - \mu| > \varepsilon) \rightarrow 0$ ，弱大數法則便成立了。因此乍看之下，中央極限定理是一比弱大數法則還強的定理。不過前者要假設變異數存在，後者不用。在較強的假設下，是可能得到較強的結果。

在中央極限定理裡，不論隨機變數之共同分佈為何，只需期望值及變異數皆存在便適用。甚至它有更一般的型式。獨立性及分佈相同的假設皆可放寬，可參考黃文璋(2010a)第五章定理5.3。由於有此推廣的版本，更可以解釋何以不少隨機現象，皆可以常態分佈來描述。諸如人的智商、身高，及膽固醇含量等，這些隨機的量，常可視為很多微小的隨機效應累積所造成，因此往往能用常態分佈來描述。19世紀時，奎特雷(Adolphe Quetelet, 1796-1874)及高頓(Francis Galton, 1822-1911)，發現很多生物裡的特徵，其分佈皆符合常態分佈。這是此分佈被稱為常態的一個主因，也隱含其他分佈不算常態。常態分佈就是如此被推崇。

常態分佈又稱高斯分佈(Gaussian distribution)。誤差理論是高斯對機率論的主要貢獻，而中央極限定理，能對此理論有很好的解釋。常態分佈機率密度函數的圖形，原先稱為高斯曲線(Gaussian curve)，或高斯誤差曲線(Gaussian error curve)。不過自皮爾生(Karl Pearson, 1857-1936)之後，人們開始稱此為常態曲線(normal curve)。另外，“中央極限定理”的名稱，則是1920年，由波里亞(George Pólya, 1887-1985)所取的。時至今日，中央極限定理在機率論裡的地位，仍是屹立不搖。

由於當 $x \rightarrow \infty$, $\Phi(x)$ 趨近1的速度很快，因此 $1 - \Phi(x)$ 及 $2(1 - \Phi(x))$ 趨近0的速度亦很快。例如， $1 - \Phi(4)$ 就已約是 $3.17 \cdot 10^{-5}$ 了。表1給出一些與 $\Phi(x)$ 有關之近似值。

表1. 一些關於 $\Phi(x)$ 之值

x	$\Phi(x)$	$1 - \Phi(x)$	$2\Phi(x) - 1$	$2(1 - \Phi(x))$
1	0.8413447	0.1586553	0.6826895	0.3173105
2	0.9772499	0.0227501	0.9544997	0.0455003
3	0.9986501	0.0013499	0.9973002	0.0026998
4	0.9999683	0.0000317	0.9999367	0.0000633
5	0.9999997	0.0000003	0.9999994	0.0000006

圖5給出本文一開始所說德國10馬克上，所放的一般常態分佈 $\mathcal{N}(\mu, \sigma^2)$ 之機率密度函數及其圖形，其中參數 μ 為實數， $\sigma > 0$ 。

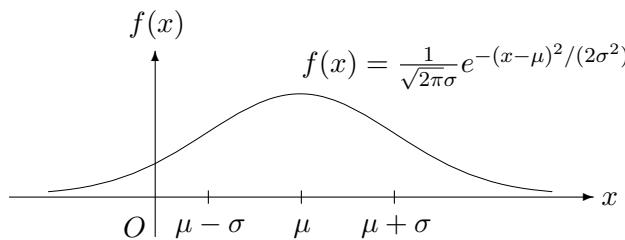


圖5. $\mathcal{N}(\mu, \sigma^2)$ 分佈之機率密度函數及其圖形

設 X 有 $\mathcal{N}(\mu, \sigma^2)$ 分佈，則 μ, σ 分別為 X 之期望值及標準差。常態分佈有個特性，即 $(X - \mu)/\sigma$ 有 $\mathcal{N}(0, 1)$ 分佈。也就是經標準化後， $\mathcal{N}(\mu, \sigma^2)$ 成為標

準常態分佈。再度利用(19)式，得

$$\begin{aligned} P(|X - \mu| \leq \sigma) &= P\left(\left|\frac{X - \mu}{\sigma}\right| \leq 1\right) = 2\Phi(1) - 1 \doteq 0.6827, \\ P(|X - \mu| \leq 2\sigma) &= P\left(\left|\frac{X - \mu}{\sigma}\right| \leq 2\right) = 2\Phi(2) - 1 \doteq 0.9545, \\ P(|X - \mu| \leq 3\sigma) &= P\left(\left|\frac{X - \mu}{\sigma}\right| \leq 3\right) = 2\Phi(3) - 1 \doteq 0.9973. \end{aligned}$$

即 X 若有 $\mathcal{N}(\mu, \sigma^2)$ 分佈，則標準化後的 X ，落在距期望值1,2,3個標準差內之機率，分別約為0.68, 0.95及0.997，與 μ, σ^2 之值皆無關。這就是中學教科書裡，所謂68-95-99.7法則(規則)。有些還稱此為“68-95-99.7經驗法則”，或就只稱“經驗法則”。尚有作者則稱此為“常態分配的經驗法則”(如丁村成(2010))。事實上，是有人說68-95-99.7 rule，或three-sigma rule，或empirical rule，但並無68-95-99.7 empirical rule。並且前述三種稱呼，均未見於一般機率統計的書中。各種中西文統計學名詞，及統計大詞典中，也少有選錄者。對隨機變數 X 具 $\mathcal{N}(\mu, \sigma^2)$ 分佈，會有所謂68-95-99.7的性質，是先“證明”出 $(X - \mu)/\sigma$ 有 $\mathcal{N}(0, 1)$ 分佈；然後“計算”出表1，絕不是憑什麼“經驗”而得到的。

例3. 如果有人告訴你，他獨立地投擲1個公正的銅板10,000次，得到5,250個正面，你相信嗎？

解. 由大數法則，你知道大約會得到5,000個正面。但由(10)式($n = 10,000$)，會恰好得到5,000個正面的機率，僅約0.008。因此不能要求一定要出現恰好5,000個正面，才相信此銅板為公正。但一個合理的要求是，出現的正面數該在5,000“附近”。即如果離5,000過遠，會令人懷疑銅板不是公正。更進一步，如果得到的正面數過多，可能會傾向相信銅板出現正面的機率大於 $1/2$ ；如果得到的正面數過少，可能會傾向相信銅板出現正面的機率小於 $1/2$ 。

若銅板為公正，則要得到至少5,250個正面之機率為

$$\sum_{k=5,250}^{10,000} \binom{10,000}{k} \left(\frac{1}{2}\right)^k,$$

前面說過了，因有 $\binom{10,000}{k}$ 這項，除非 k 很接近 10,000，否則上述和中的任一項，都不太好求出，更不要說求其和了。這時中央極限定理便可派上用場了。

對本例中投擲公正銅板的情況。令 $X_i = 1$ ，表第 i 次得正面， $X_i = 0$ ，表第 i 次得反面， $i = 1, 2, \dots, 10,000$ 。則 $P(X_i = 1) = P(X_i = 0) = 1/2$ 。因此 $\mu = E(X_i) = 1/2$, $\sigma^2 = \text{Var}(X_i) = 1/4$, $\sigma = 1/2$ 。由此得

$$\frac{X_1 + \dots + X_n - n\mu}{\sigma\sqrt{n}} = \frac{5,250 - 5,000}{1/2 \cdot 100} = 5.$$

利用中央極限定理，並由表 1，得 $P(X_1 + \dots + X_n - n\mu > 5\sigma\sqrt{n})$ 之機率約為 $3 \cdot 10^{-7}$ （我們要的其實是 $P(X_1 + \dots + X_n - n\mu \geq 5\sigma\sqrt{n})$ ，不過二者差異極有限）。此機率小至夠讓我們強烈懷疑此銅板之公正性，我們推測銅板正面出現的機率很可能大於 $1/2$ 。

將 μ 及 σ 皆以 $1/2$ 代入(20)式，得

$$(24) \quad P(X_1 + \dots + X_n \in [\frac{n}{2} - \frac{c\sqrt{n}}{2}, \frac{n}{2} + \frac{c\sqrt{n}}{2}]) \doteq 2\Phi(c) - 1, \quad c \geq 0.$$

另一方面，取 $c = 3$ ，得對投擲一公正的銅板 10,000 次，出現的正面數落在 $[4,850, 5,150]$ 間（離期望值 5,000 不超過 3 個標準差）之機率，約為 0.9973。此機率通常便已被認為夠大了。即認為所得正面數，不太會落於此區間外。此概念我們下一節會再討論。

(24) 式顯示，當 n 夠大時，獨立地投擲一公正銅板 n 次，所得正面數落在一以 $n/2$ 為中心之對稱區間的機率若固定，譬如說皆為 $2\Phi(c) - 1$ ，則該區間之半徑 $c\sqrt{n}/2$ ，將隨著 n 之增大而增大。但此半徑若除以投擲數 n ，得相對半徑 $c/(2\sqrt{n})$ ，將隨 n 之增大而漸減。對同一機率，隨著投擲數 n 之增大，所得正面數落在的範圍會愈來愈大。但相對投擲數而言，乃落在一愈來愈窄的區間。

考慮相對區間是有道理的。對投擲 100 次，區間半徑 5 次，佔投擲數之 5%；投擲 1,000,000 次，區間半徑成為 500 次，區間雖然變長，但半徑卻只佔投擲數之 0.05%。相對於投擲數，後者乃是一較無關痛癢的小區間。

再看一個例子。

例4. 某次考試題目全為選擇題共50題，每題有4個選項。某生宣稱他都沒唸書，因此全部都用猜的。成績發下後，他答對21題。你有何評論？

解. 如果隨機地猜，答對的題目數，應在期望值 $50 \cdot 1/4 = 12.5$ 附近。若偏離此數過遠，我們會懷疑是否真隨機地猜。若答對的題目過多，顯示該生可能並非完全不會。如今該生答對21題，21題夠不夠多呢？我們來分析看看。

假設隨機地答。令 $X_i = 1$, 表第 i 題答對, $X_i = 0$, 表第 i 題答錯, $i = 1, \dots, 50$ 。則 $P(X_i = 1) = 1/4$, $P(X_i = 0) = 3/4$ 。因此 $\mu = E(X_i) = 1/4$, $\sigma^2 = \text{Var}(X_i) = 3/16$, $\sigma = \sqrt{3}/4$ 。由此得

$$\frac{X_1 + \dots + X_n - n\mu}{\sigma\sqrt{n}} = \frac{21 - 50 \cdot 1/4}{\sqrt{3}/4 \cdot \sqrt{50}} \doteq 2.776.$$

經查表得 $1 - \Phi(2.776) \doteq 0.0027$ 。也就是若隨機地猜，則會猜中至少21題之機率約為0.0027。此機率夠小，足以讓我們得到該生很可能並非完全用猜的之推論。

例3及例4這類問題，皆屬統計裡假設檢定(hypothesis testing)的範疇。在數學裡我們常在證明。但在科學上或生活中，一件事是否為真，常只有天曉得。我們只能依發生機率之大小，來做推論。不論是例3中的投擲銅板，或例4中的考試答題，即使銅板為公正，是可能投擲出5,250個正面；答題全用猜的，也有可能答對21題，甚至50題全猜對也非不可能。因為此二事件發生之機率皆為正。由於真相為何，常就是無法判定，所以採用“假設”一詞。而得到的推論乃是接受某一假設，或拒絕某一假設。假設檢定裡，設計出一套做推論的程序。發生機率之大小，為做推論之主要依據。當機率計算不易，若樣本數夠大，往往中央極限定理便可派上用場，以簡化計算。

很多機率統計書上說當樣本數 $n \geq 30$ ，中央極限定理便適用。即若有 iid 的隨機變數 X_1, \dots, X_n ，且 $\mu = E(X_1)$, $\sigma^2 = \text{Var}(X_1)$ 皆存在，則當 $n \geq 30$, $(X_1 + \dots + X_n - n\mu)/(\sigma\sqrt{n})$, 或 $(\bar{X}_n - \mu)/(\sigma/\sqrt{n})$, 便皆可以 $\mathcal{N}(0, 1)$ 分佈來近似。這點比較微妙，留待本節最後再說明。若 X_i 有

$Ber(p)$ 分佈,書上更說,根據經驗法則(a rule of thumb, 這才真是經驗法則),通常只要 np 及 $n(1 - p)$ 皆大於5,中央極限定理便適用。亦即當 $p = 0.2$ 時, $n \geq 26$ 即可;而當 $p = 0.5$ 時, n 更只要少少的11以上便可。真有這麼神奇嗎?極限下的結果,卻不用太大的樣本數,便可適用?

事實上,若 X_i 's共同分佈之機率密度函數,對稱於其期望值, n 往往不用太大,中央極限定理便已適用。否則 n 就得較大些。以 p_i 表骰子出現*i*點之機率, $i = 1, \dots, 6$ 。於三組不同的 p_i 's下,圖6給出 $n = 5$,及 $n = 10$, $X_1 + \dots + X_n$ 直方圖。在(a)圖中, p_i 's皆為 $1/6$,則即使 $n = 5$,直方圖便已讓人產生常態分佈的“感覺”,但仍呈鋸齒狀。在(b)圖中, p_i 's為對稱($p_1 = p_6, p_2 = p_5, p_3 = p_4$), $n = 10$ 時,直方圖已有些平滑了。而可看出在(c)圖中,即使 p_i 's較偏斜, $n = 5$ 時,直方圖雖不會讓人聯想到常態分佈,但 $n = 10$ 時,直方圖即使仍有些鋸齒狀,但已大致已會讓人想到常態分佈了。底下我們對這種以圖形來說明中央極限定理,略做說明。

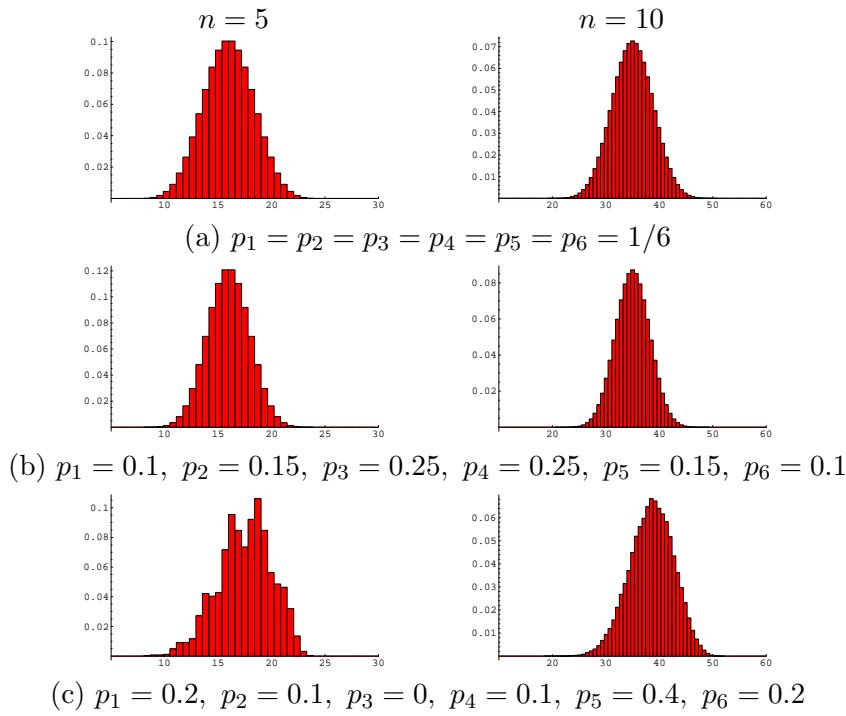


圖6. 各面出現機率不同的3個骰子,分別投擲5次及10次,所得點數和之直方圖

我們先來看一下中學教科書怎麼說。在中學裡介紹中央極限定理，大抵僅針對二項分佈，只是有些詮釋並不太正確。底下為一些教科書中的講法：

在參數是 (n, p) 的二項分布中，當試驗的次數 n 足夠大時，成功次數 X 的機率分布會近似於平均數 μ 為 np ，標準差 σ 為 $\sqrt{np(1-p)}$ 的常態分布。

當 n 足夠大時，二項分配的圖形近似一平滑的鐘形曲線，此時二項分配近似於常態分配。

可看出當 $n = 32$ 而 $p = 0.5$ 時，二項分配機率圖是對稱且呈鐘形，接近常態分配。…事實上，對任意 $0 < p < 1$ ，由中央極限定理可知： n 夠大時， X 會接近常態分配。

\bar{X}_n 的相對次數直方圖長相非常接近鐘形。

n 夠大，隨機變數 $\hat{p} = X/n$ 近似常態分布，其平均數 $\mu = p$ ，標準差 $\sigma = \sqrt{p(1-p)/n}$ ，…。

當樣本數 n 夠大時， \hat{p} 的分佈會趨近於平均數為 p ，標準差為 $\sqrt{p(1-p)/n}$ 的常態分佈。

我們仍是一字不改，而如前所述，分佈、分布、分配乃通用。

所謂 n 足夠大，當然包含 n 無止盡地增大。對 S_n 有 $B(n, p)$ 分佈，我們已說過，不論 p 為何， n 愈大時， S_n 將很可能也是很大。以機率的語言來說，就是 $n \rightarrow \infty$ 時， S_n 機率收斂至 ∞ 。同理，在上一節討論大數法則時已說了， $n \rightarrow \infty$ 時， S_n/n 機率收斂至 p 。因此說， n 夠大時， S_n 及 S_n/n 會分別近似那一常態分佈，都非正確。其次來說明圖形。隨著 n 之增大， $B(n, p)$ 分佈之直方圖，將愈趨貼近水平座標軸（想想最大高度趨近0），怎會近似鐘形曲線（見圖7）？至於 n 很大時， S_n/n 的直方圖，將如底部中點為 p 之一座尖塔，高聳入雲（見圖8），也絕不會讓人聯想到鐘形曲線或常態分佈。又“趨近”為極限下的行為。前面所引最後一則中，樣本數 n 僅為“夠大”，便接到“會趨近”，此並非極限裡的說法。

當 n 持續增大，想圖示中央極限定理，都要很謹慎，絕不可想當然

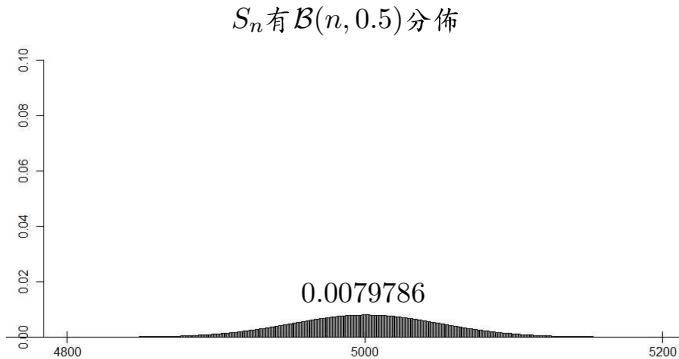


圖7. S_n 之直方圖, $n = 10,000$

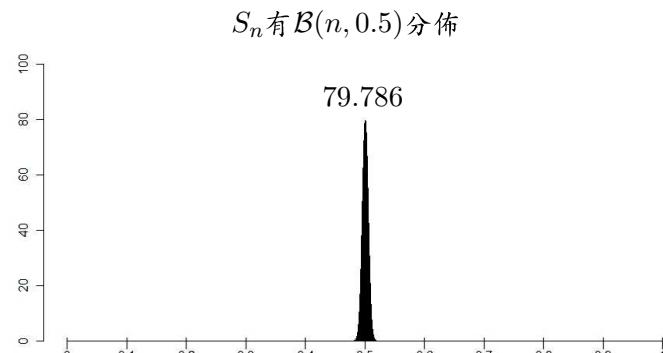


圖8. S_n/n 之直方圖, $n = 10,000$

耳。記住，對iid的隨機變數，中央極限定理是說，樣本和 $X_1 + \dots + X_n$ ，及樣本平均 \bar{X}_n ，都要經標準化後，才會近似 $\mathcal{N}(0, 1)$ 分佈。並不是說 $X_1 + \dots + X_n$ ，及 \bar{X}_n 有近似的 $\mathcal{N}(0, 1)$ 分佈，這點須特別強調。關於圖示中央極限定理的進一步說明，可參考黃文璋(2011c)一文。

事實上，在Feller(1968)p.185建議，對 S_n 有 $\mathcal{B}(n, p)$ 分佈，及 $0 \leq a \leq b$ ，若以下式來近似 S_n 介於 a, b 二整數間之機率

$$P(a \leq S_n \leq b) \doteq \Phi\left(\frac{b - np}{\sqrt{np(1-p)}}\right) - \Phi\left(\frac{a - np}{\sqrt{np(1-p)}}\right),$$

則 n 宜“適當地大”(注意並非要求“ n 夠大”)。原因乃若不是採(13)或(16)式，則給定 a, b , $0 \leq a \leq b$ ，當 n 很大時， $P(a \leq S_n \leq b)$ 根本就很小，這時上式並無功能(此時右側當然也很小)。

又必須一提的是，由於獨尊的名稱“中央”，與涉及的分佈名之為“常態”，有些人遂誤以為機率統計裡只有常態分佈。要知常態分佈雖無所不在，所謂萬物有常，但在實務上，仍要謹慎判斷是否適合用來當模型。尤其有時明明一看就非具常態分佈，更不可輕率採用。如2011年7月號科學月刊“Hello Kitty的數學”一文中，對蒐集到一套時所要買的次數，寫著“根據常態分佈的50-68-95法則…”，實不知彼處常態分佈從何而生？似亦為想當然耳。切記，並非任意獨立隨機變數和，當樣本數夠多，只要經標準化後，便可以常態分佈來近似，而是有須滿足的條件。另外，有教科書說：

這類資料的次數分布圖呈現中間較高，且左右對稱的鐘形時，我們就稱這組資料呈現常態分佈。

亦有作者說(見丁村成(2010))：

分佈曲線都是呈現單一高峰的左右對稱曲線，這種曲線稱為常態曲線。

此類講法都是誤導。到底何謂鐘形？即使常見分佈裡，除常態分佈外，便有好幾個也具“單一高峰左右對稱”的機率密度函數圖形。如柯西分佈， t 分佈，拉普拉斯分佈(Laplace distribution)，及羅吉斯分佈(Logistic distribution)等。圖9給出 $\mathcal{C}(0, 1)$ 分佈之機率密度函數圖形，僅就形狀而言，你能分辨圖9不像鐘形嗎？

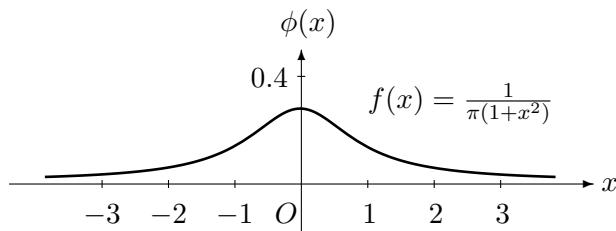


圖9. $\mathcal{C}(0, 1)$ 分佈之機率密度函數圖形

另有教科書說：

對一組數據畫其直方圖後，若將每個長條頂端中點以折線連接會有很多種不同的式樣，但最後看到的是中間高而往左右兩邊下降，近似鐘形。

這樣講對常態分佈的鐘形乃過度推崇。即使左右對稱都不見得是常態分佈，何況很多數據連左右對稱都不是，當然更不會有什麼近似鐘形。

最後，前面提到很多書上說，當樣本數 $n \geq 30$ ，中央極限定理便適用。但中央極限定理畢竟是極限下的結果，而實際應用時，樣本數當然是有限。就算樣本數超過30，利用中央極限定理，以常態分佈來近似標準化後的 $X_1 + \dots + X_n$ ，或 \bar{X}_n ，須在意此近似究竟好不好？換句話說，誤差是否夠小？要知你可以任意近似，但誤差大小可不能置之不理。而誤差大小，乃與 X_1, \dots, X_n 之共同分佈為何有關。舉例來看，假設 X_i 's 之共同分佈為 $Ber(0.02)$ ，且 $n = 100$ 。則 $X_1 + \dots + X_{100}$ 有 $\mathcal{B}(100, 0.02)$ 分佈。而 $\mathcal{B}(100, 0.02)$ 之分佈可以 $\mathcal{P}(2)$ 分佈做很好的近似。此處 $\mathcal{P}(\lambda)$ 表參數 λ 之波松分佈 (Poisson distribution)，其機率密度函數為

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

乃一離散型的分佈。圖10給出 $\mathcal{P}(2)$ 分佈之直方圖，這當然絕不像常態分佈，再怎麼標準化都沒用。對 $Ber(p)$ 分佈，只要降低 p ，則對更大的 n ，仍有這種波松近似的結果。這是所謂二項分佈趨近波松分佈，可參考黃文璋 (2010a) 5.1 節。這類例子不少。如 1,000 個 iid 以 $\mathcal{P}(0.001)$ 為共同分佈之隨機變數，其和有 $\mathcal{P}(1)$ 分佈 (可參考黃文璋 (2010a) 第二章定理 6.8)。雖樣本數高達 1,000，常態近似對此卻不適用。

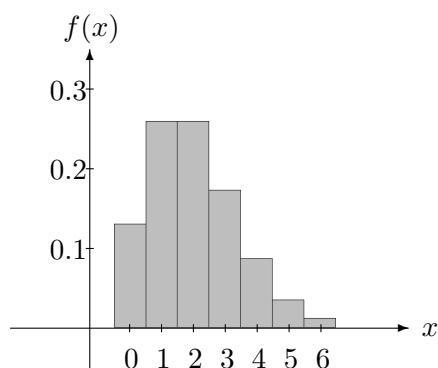


圖10. $\mathcal{P}(2)$ 分佈之機率密度函數圖形

7 信賴區間

人們常在做估計。如氣象局估計即將登陸颱風的降雨量，政府估計明年經濟成長率，學生拿到入學考成績單後，估計能進那一校系等。有些情況很複雜，沒那麼容易估計，來看兩個較簡單的例子。

欲估計一銅板出現正面的機率 p 。一個簡單的方法是投擲若干次，譬如說 n 次，且得到 X 個正面，則以正面數出現的平均，或說相對頻率 X/n ，來估計 p 。

想知道某地區最高的人之身高，有何方法？若能取得該地區所有人身高的資料，立刻便知道了。只是可能沒有這種資料，也很難將所有人都找來量測。仍有一個簡單的方法，但這回不再是求平均了，而是以所見過該地區最高者之身高來估計。只要你見過的人夠多，且大致是隨機出現，則此估計法將夠準確。

是否一定要這樣估計呢？當然不見得。對於銅板，你可以認為由於是政府發行的，一定公正，即 $p = 0.5$ 。對於身高，你也可根據過去經驗，不做量測，就估計最高者，其身高必至少是188公分。所以若見到的最高者未達此值，便估計188公分，否則以所見到的最高者來估計。

上述二例皆屬點估計，以一量來估計某未知參數。點估計要剛好命中的機率，通常微乎其微，於是便發展出區間估計(interval estimation)，以一區間來估計某參數。而這種區間，便稱為信賴區間(confidence interval)。

中央極限定理在建立信賴區間時，常也能發揮功能。底下給一情況來說明。

假設 X_1, \dots, X_n 為iid之隨機變數，且設 $\mu = E(X_1)$, $\sigma^2 = \text{Var}(X_1)$ 皆存在。對於 μ ，我們知道常以樣本平均 \bar{X}_n 來估計。底下我們來看，如何以一區間來估計 μ 。即使不知 X_i 's之共同分佈為何，當 n 夠大，且 σ 已知，利用(22)式，且取 $c = z_{1-\alpha/2}$ (因此 $2\Phi(c) - 1 = 2(1 - \alpha/2) - 1 = 1 - \alpha$)，其中 $0 < \alpha < 1$ ，得

$$(25) \quad P(-z_{1-\alpha/2} \cdot \sigma / \sqrt{n} \leq \bar{X}_n - \mu \leq z_{1-\alpha/2} \cdot \sigma / \sqrt{n}) \doteq 1 - \alpha.$$

在此設 Z 有 $\mathcal{N}(0, 1)$ 分佈，則對 $\forall 0 < \alpha < 1$, z_α 滿足 $P(Z \leq z_\alpha) = \alpha$ 。即

圖4中，在 $x = z_\alpha$ 左側面積為 α ，因此 $\Phi(z_\alpha) = \alpha$ 。(25)式等價於

$$(26) \quad P(\bar{X}_n - z_{1-\alpha/2} \cdot \sigma / \sqrt{n} \leq \mu \leq \bar{X}_n + z_{1-\alpha/2} \cdot \sigma / \sqrt{n}) \doteq 1 - \alpha.$$

故當 σ 已知，區間

$$(27) \quad [\bar{X}_n - z_{1-\alpha/2} \cdot \sigma / \sqrt{n}, \bar{X}_n + z_{1-\alpha/2} \cdot \sigma / \sqrt{n}],$$

便稱為參數 μ 之一近似的(“近似的”三字常被省略) $1 - \alpha$ ，或者說 $100(1 - \alpha)\%$ ，信賴區間。通常 α 取為一較小的正數，如 $0.01, 0.05, 0.10$ 等。 μ 的 $1 - \alpha$ 信賴區間自然不唯一，只要 μ 落在該區間之機率為 $1 - \alpha$ 便可。譬如說

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

亦是。可看出有無限多個 μ 之 $1 - \alpha$ 信賴區間。一般在同樣的 α 下，會取信賴區間的長度愈短愈好。

表2給出一些常用的 z_α 之近似值。至於一般的 α ，就要藉助查表或使用計算機而得。

表2. 常用之 z_α 值

α	0.90	0.95	0.975	0.99	0.995	0.999
z_α	1.282	1.645	1.960	2.326	2.576	3.090

如果 σ 未知，因以一區間來估計 μ ，該區間當然不能有另一未知的參數 σ ，在此情況下，常以樣本變異數(sample variance) S_n^2 之正的平方根 S_n ，來取代 σ ，其中

$$(28) \quad S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2, \quad n \geq 2.$$

$1 - \alpha$ ，或 $100(1 - \alpha)\%$ ，稱為上述信賴區間之信心水準(confidence level)，或信賴係數(confidence coefficient)。我們來看信賴區間的概念，如何應用至做民調的情況。

例5. 欲估計某地選民對某候選人之支持度 p 。經由簡單隨機抽樣，得到 n 個樣本 X_1, \dots, X_n ，其中 $X_i = 1$ ，表第*i*個人支持該候選人， $X_i = 0$ ，表不支持。以 \bar{X}_n 來估計 p 似乎是合理的。這樣估計的誤差為何？

解。假設選民中有 p 的比例支持該候選人。但 X_1, \dots, X_n 並不獨立，因這是屬於取出後不放回，總不能同一個人問他兩次同樣的問題。不過通常選民數相對於樣本數 n 很大，所以取出後不放回，由於樣本不獨立所造成的誤差，就忽略好了。即考慮簡化後的情況，假設 X_1, \dots, X_n 獨立，且 $P(X_i = 1) = p, P(X_i = 0) = 1 - p$ 。因 $\mu = E(X_i) = p, \sigma^2 = \text{Var}(X_i) = p(1 - p)$ ，由(23)式得

$$(29) \quad P(|\bar{X}_n - p| > \varepsilon) \doteq 2(1 - \Phi(\varepsilon\sqrt{n}/(p(1 - p)))) , \quad \varepsilon \geq 0 .$$

只要 n 夠大，上式給出 \bar{X}_n 與 p 之差異大於 ε 之機率的近似值。

如果事先給定一 α 值， $0 < \alpha < 1$ ， α 通常是一較小的值，而要求

$$(30) \quad P(|\bar{X}_n - p| > \varepsilon) < \alpha,$$

或等價地，

$$(31) \quad P(|\bar{X}_n - p| \leq \varepsilon) \geq 1 - \alpha,$$

則 n 要多大呢？由(29)式，

$$(32) \quad P(|\bar{X}_n - p| \leq \varepsilon) \doteq 2\Phi(\varepsilon\sqrt{n}/(p(1 - p))) - 1 \geq 1 - \alpha .$$

上式導致

$$\frac{\varepsilon\sqrt{n}}{p(1 - p)} \geq z_{1-\alpha/2} .$$

即

$$n \geq \frac{p(1 - p)z_{1-\alpha/2}^2}{\varepsilon^2} .$$

由於 $p(1 - p) \leq 1/4, 0 \leq p \leq 1$ ，故樣本數

$$(33) \quad n \geq \frac{z_{1-\alpha/2}^2}{4\varepsilon^2}$$

即可。當然因(29)式為一近似的式子，所以此 n 亦為一近似值。

例如，若 $\varepsilon = 0.03$, $\alpha = 0.05$ (這是一般做民調時所設定的 ε 及 α)，則由表2, $z_{1-\alpha/2} = z_{0.975} \doteq 1.960$, 而 $1.960^2 / (4 \cdot 0.03^2) \doteq 1,067.1$ 。故取樣本數 $n \geq 1,068$ 。實際抽樣後，成功的樣本數往往不會恰好是1,068，代入(33)式(令等式成立)，而解出誤差 ε 之值。 $n > 1,068$ 時， ε 便小於0.03；反之 ε 則大於0.03。

附帶一提，有些民調結果宣稱“在有效樣本數1,068下，百分之95的信賴區間為…，且誤差不超過3%”，這種數據一看便有些可疑。因民調通常是多位訪員同時進行，因此停止時，成功的樣本數，可說很難恰好是當初所設定的目標1,068。因此教科書上舉的例子，如果盡是“成功訪問1,068位選民”，也都非恰當。

另外，你可能覺得以 $1/4$ 取代 $p(1 - p)$ 太粗糙。此點倒還好，因這樣會造成須取較大的 n ，並不會減小精確性。又(29)式也只是一近似公式而已。由於受訪者不見得能誠實回答問題，民意也隨時會變，因此民調的結果只能供參考。在一些細節過度在意精確度，可能會見樹不見林。例如，誤差 $\varepsilon = 0.03$ 看似蠻大的，可否降低，如取 $\varepsilon = 0.01$? 由(33)式，在 $\alpha = 0.05$ 下，當 ε 由0.03降至0.01，樣本數要成為9倍，達到9,604。對民調而言，因常得在短時間內完成取樣，困難度將增加很大，說不定因此造成更大的誤差。以更好的調查設計，包含更好的問卷題目，更好的訪員訓練等，使樣本更隨機，並設法減小拒訪率，以得到更接近真實的意見，才是較重要的。

要特別提醒的是，如第4節中所述，簡單隨機抽樣所得樣本並不獨立，須樣本數相較於母體數很小，此時誤差才較小。有些教科書未留意此點，如有書上說：

簡單隨機抽樣調查一千個合格選民，就相當於丟擲一枚正面機率為 p 的銅板一千次的試驗，而推論甲候選人支持率的問題，就相當於推論銅板正面之機率的問題。

此說法當然為錯誤。有些作者如江前佑(2006)及丁村成(2010)，忽視 X_1 ,

\dots, X_n 不獨立，而去證明樣本獨立下， \bar{X}_n 變異數的公式，所得當然也是錯的。

統計實務裡，為了簡化常採近似。使用這些方法時要清楚知道能近似的原因。否則若遇不適用近似的情況，而貿然採用，所得結果便不可靠了。例如，假設選民數有1,000人，其中有300人支持某候選人，即 $p = 0.3$ 。今採簡單隨機抽樣，且 $n = 1,000$ ，即採普查。則樣本數等於母體數，二者比值為1，當然不是很小。這時若仍宣稱樣本 $X_1, \dots, X_{1,000}$ 為近似獨立，便很荒謬了。事實上，此時 $\bar{X}_{1,000} = p = 0.3$ ，為一常數，並不隨機。中央極限定理在此完全不適用。

在例5關於民調的例子裡，當 $\varepsilon = 0.03$, $\alpha = 0.05$, $n = 1,068$ ，給出支持度 p 之估計值 $\bar{X}_n = \bar{x}_n$ 後，民調裡的說法是“在95%之信心水準下，抽樣誤差不超過3%”。這其實就等同於說 p 之95%信賴區間為 $[\bar{x}_n - 0.03, \bar{x}_n + 0.03]$ 。

例6. 對於一發生機率為 p 之事件，經重複觀測，則可以該事件出現之相對頻率來估計 p 。我們亦可給出 p 之信賴區間，作法類似例5。即設有隨機變數 X_1, \dots, X_n ，其中 $X_i = 1$ ，表第*i*次觀測事件發生， $X_i = 0$ ，表未發生。則 X_1, \dots, X_n 為iid，且 $P(X_i = 1) = p$, $P(X_i = 0) = 1 - p$ 。因此 $\mu = E(X_i) = p$, $\sigma^2 = \text{Var}(X_i) = p(1 - p)$ 。則由(27)式，且將其中的 σ 以 $\sqrt{\bar{X}_n(1 - \bar{X}_n)}$ 取代，得 p 之近似的 $100(1 - \alpha)\%$ 信賴區間為

$$(34) \left[\bar{X}_n - z_{1-\alpha/2} \sqrt{\bar{X}_n(1 - \bar{X}_n)/n}, \bar{X}_n + z_{1-\alpha/2} \sqrt{\bar{X}_n(1 - \bar{X}_n)/n} \right].$$

此處以 $\sqrt{\bar{X}_n(1 - \bar{X}_n)}$ 取代 σ ，較以 S_n 取代 σ ，形式簡單些。

對42取6的樂透彩，若開獎公正，則開出的頭獎號碼，連號（含各種可能之連號，如6連號，一個3連號一個2連號，及三個2連號等）發生之機率不小，大於 $1/2$ ，高達 $0.5568 (= 2,921,002/5,245,786)$ 。此利用排列組合便可求出，並不困難。現假設有某人並未去計算此機率，他統計了400期，發現其中有219期開出的頭獎號碼有連號。因 $219/400 = 0.5475$ ，且 $z_{0.975} \doteq 1.960$,

故由所得數據，得到連號出現機率之95%信賴區間為

$$\begin{aligned} & \left[0.5475 - 1.960 \sqrt{0.5475 \cdot \frac{0.4525}{400}}, 0.5475 + 1.960 \sqrt{0.5475 \cdot \frac{0.4525}{400}} \right] \\ & = [0.4987, 0.5963] . \end{aligned}$$

實際的連號機率0.5568的確落在此區間。

我們提過，在高中引入信賴區間，可說是問題重重。底下略做說明。在高中數學裡，為了近似，先介紹中央極限定理，且以最簡單的情況，即伯努力分佈為例。講完中央極限定理後，便以民調當應用，因引入信賴區間，才是大費周章介紹中央極限定理的主要目的。只是民調的取樣，為簡單隨機抽樣，也就是取出後不放回。既然是取出後不放回，則取出的樣本便不獨立。在第4節我們已說了，此時涉及的是超幾何分佈，而非二項分佈。只是要講清楚為什麼在此情況下，中央極限定理仍適用，可不是那麼容易。高中數學課本，寫到這裡，彆扭不產生也難。於是或不講原因，讓細心的學生充滿疑慮；或講得一團混亂，製造出更多困擾。

另外，信賴區間的含意，也讓很多人產生困惑。我們必須略做闡釋，也可參考黃文璋(2006)一文。

在取樣前，(27)式為一隨機區間。取樣後，得到 $\bar{X}_n = \bar{x}_n$ ，代入(27)式，則得一常數區間，即

$$[\bar{x}_n - z_{1-\alpha/2} \cdot \sigma / \sqrt{n}, \bar{x}_n + z_{1-\alpha/2} \cdot \sigma / \sqrt{n}] .$$

此固定區間或包含 μ ，或不包含，說有 $1 - \alpha$ 的機率會包含 μ ，難免令人難以置信。以投擲來估計銅板出現正面的機率 p 。假設經投擲100次後，得到 p 之一95%信賴區間(0.33,0.45)。如何解釋95%呢？考慮下述三選項：

1. 有95%的信心，區間(0.33,0.45)包含 p 。
2. p 落在區間(0.33,0.45)之機率為0.95。
3. 若持續重複前述投擲的實驗，每次得一信賴區間，則那些區間中，約有95%會包含 p 。

有些人可能知道了，一般認為選項3乃正確解釋，此即對機率的頻率觀點。不過要注意，是“約有”95%會包含 p 。有些作者如江前佑(2006)及丁村成(2010)，分別解釋為“有95%包含真正的 p ”，及“有足夠的信心使其中的95%…”，少掉了“約”，一字之差，便未能顯現隨機的概念。選項1說了等於沒說，並且也非十分恰當的講法。因所謂“信心”(或“信賴”)，是對整個建立該信賴區間過程的信心，而非只是對所得到的那一固定區間的信心。至於選項2，雖 p 並非隨機變數，但倒也不要覺得有此看法很荒謬，這其實是對機率主觀的解釋。原因是由于一本為隨機的區間，經取樣而得一固定，即不再隨機的區間，若根本不知實際 p 值為何，只好由當初此區間產生的方式，主觀地認為此區間包含 p 的機率為0.95。此正如在汽車與山羊問題(Car-Goat Problem)中(可參考黃文璋(2010b)，及(2011d))，有三扇門，其中一扇後面有汽車，另兩扇後各只有一頭山羊。你選定一扇門後，主持人打開另兩扇門中的一扇，門後是山羊，問你是否要更改選擇。汽車究竟在那扇門之後，在節目開始前早已確定，並非隨機。但由於你不知，所以仍可依“自認合理”的假設下，大算機率。並根據選擇更改或不更改，何者得到汽車之機率較大，而做決定。當然，如果你知道 p 之值，就不一樣了。譬如說取一介於0,1之間的 p ，然後經由模擬，產生一信賴區間，這時你完全知道此區間是否包含 p ，就不能說有0.95之機率 p 落在此區間。

底下為一類似的情況，但也困擾不少人。假設有一公正銅板，投擲後遮蓋住，不讓人看見。則可否說會是正面的機率為 $1/2$? 答案是可以，仍可視為主觀機率。雖是否正面朝上已經確定了(有人因此說正面的機率不是1便是0)，但因你並不曉得，所以仍可談機率。

試驗若僅做1次，則不是發生就是不發生，這時看不出機率的作用。例如，假設有一正面出現機率為0.9之銅板，要人猜投擲之後出現正面或反面？答案當然很明顯該猜正面。但若有人不信邪，選擇反面，他可能會猜對，因發生機率0.1為正。這時他是否可很得意地說，打敗機率了嗎？可以預期，若持續投擲，則堅持選反面者，將大部分是猜錯的。機率的功能，便是在這種情況下顯現。同理，試驗若能一再重複，則即使主觀的機率，也能因此驗證其主觀是否夠客觀，以及該主觀機率是否須做調整。以前述認

為經取樣後，所得特定信賴區間包含 p 的機率乃0.95為例，弱大數法則告訴我們，只要重複多次，則將有約95%的區間會包含 p ，不就印證其主觀機率有道理！要知主觀機率也並非能假主觀之名，而太隨意。只要能重複的試驗，其主觀機率是否夠客觀，便不難檢驗了。

$1 - \alpha$ 就是機率。如果做很多次實驗，得到很多信賴區間，長度皆為 $2z_{1-\alpha/2} \cdot \sigma / \sqrt{n}$ (或 $2z_{1-\alpha/2} \cdot S_n / \sqrt{n}$)，但各區間之起始點跟終點可能不同。由機率的意義，這些區間中，大約有 $1 - \alpha$ 的比率，會涵蓋 p 。例如，若 $\alpha = 0.05$ ，且得到100個信賴區間，則其中將約有95個左右會涵蓋 p 。實際上有幾個涵蓋 p 當然不一定。但在取樣前，我們知道(不妨忽略這些95%信賴區間只是“近似的”)，會涵蓋 p 之區間數，此為一隨機變數，有 $B(100, 0.95)$ 分佈，可能有95個，也可能有85個(此機率很小，利用中央極限定理，得此機率小於 $\Phi(-4.588) < \Phi(-4) \doteq 3.164 \cdot 10^{-5}$ ，精確值為 $\Phi(-4.588) \doteq 2.238 \cdot 10^{-6}$)，或其他值，但大致是95個左右。

本文在前言中指出，課程綱要裡，要學生以模擬或實驗，來解讀“何以大多數的學生所得的信賴區間都會涵蓋 p ”之講法不妥。各位現在應知道了，只要班級數夠多，或實驗次數夠多，則若有某一班，全班學生所得的信賴區間，有好幾個未涵蓋 p ，乃不足為奇。詳細討論可參考黃文璋(2006)一文。

另外，求信賴區間並不一定要用到中央極限定理。在估計期望值時，如果共同分佈就已是常態分佈了，那(27)式給出 μ 一恰好是(而非近似) $1 - \alpha$ 之信賴區間。估計量若非樣本平均(如本節一開始估計身高之例)，很可能也用不到中央極限定理。在黃文璋(2003b)9.2節，更有不少不需中央極限定理，便能給出信賴區間之例。所以課程綱要中說，估計背後的理論是中央極限定理，此講法實有待商榷。

我們再以保險為例。保險對保戶而言，當然不是一公正賽局(fair game)。對於意外險，通常只有死亡或全身殘障才理賠。一年幾千元的保費，賠償高達數百萬元，保戶似乎頗划得來。保費的計算，乃根據過去死亡的資料訂出。以期望淨所得而言，保險公司是不會吃虧的。對保戶來說，保險的目的，並非為了賺錢。這一年若平安無事，則幾千元的保費便

有如蒸發掉了。此時應感慶幸，他可不想被理賠。

只要保戶愈多，保險公司的風險就愈小。為了簡化，一切營運成本都不計好了，且假設保險公司無任何準備金。則若保險公司只有一個保戶，且保意外險，一旦該保戶死亡，保險公司便破產了。例如，設任何人，一年會意外死亡的機率為0.0007。保500萬，一年保費設為5,000元。對保戶，期望淨所得為 $5 \cdot 10^6 \cdot 0.0007 - 5,000 = -1,500$ (元)，是划不來。但有0.0007的機率，保險公司會破產。不過實際上不會只有1人投保，只要保戶愈多，保險公司破產的機率便愈小。保險每人保的金額、項目不盡相同；因工作性質，及年齡等原因，每人保險費率也可能不同。底下我們以一簡單的賭博之例，來顯示“保戶愈多，保險公司破產的機率便愈小”之現象。

例7. 假設每次投注1元，贏則得2元(淨得1元)，輸則1元為賭場收走。設每次賭客贏的機率為 p , $0 < p < 1$, 且賭了 n 次, $n \geq 1$ 。即設有iid的隨機變數 X_1, \dots, X_n , $P(X_i = 1) = p$, $P(X_i = -1) = 1 - p$ 。賭客之淨所得為 $X_1 + \dots + X_n$ 。我們想求 $P(\sum_{i=1}^n X_i \geq 1)$, 此為賭 n 次後賭客之淨所得為正之機率。由於 $\mu = E(X_i) = 2p - 1$, $\sigma^2 = \text{Var}(X_i) = 4p(1 - p)$, 利用中央極限定理得，當 n 夠大時，

$$(35) \quad P\left(\sum_{i=1}^n X_i \geq 1\right) = P\left(\frac{\sum_{i=1}^n X_i - n(2p - 1)}{2\sqrt{p(1-p)}\sqrt{n}} \geq \frac{1 - n(2p - 1)}{2\sqrt{p(1-p)}\sqrt{n}}\right) \\ \doteq 1 - \Phi\left(\frac{(n+1)/2 - np}{\sqrt{np(1-p)}}\right).$$

舉個例來看上式。輪盤的歷史悠久，可說是最古老的賭戲之一。這是源自於17世紀，法國數學家巴斯卡(Blaise Pascal, 1623-1662)所發明的一種遊戲。現假設賭的是歐式輪盤(European roulette)，即有1至36的數字，奇數為紅色，偶數為黑色，加上一綠色的0(美式輪盤(American roulette)則尚有一00)，0出現算莊家贏。押紅黑中的某一顏色，賠率為1賠1，則 $p = 18/37$, 約為0.4865，僅略小於 $1/2$ 。每賭1次，莊家平均只淨贏 $1/37 \doteq 0.027$ (元)，賭客並未太吃虧(美式輪盤則對賭客更不利)，賭

客總不能期望賭場裡提供“公正賽局”。對一些不同的 n , 表3給出賭客淨所得為正，亦即賭場虧錢之機率的近似值。若賭的次數不多，如只賭1次，賭場有約0.4865的機率會虧，賭100次，賭場虧的機率都還有約0.3555。但隨著賭的次數持續增加，賭場幾乎可說穩賺不賠。

表3. 歐式輪盤賭場虧之機率

賭的次數 n	10^2	10^3	10^4	10^5
賭場虧之機率	0.3555	0.1876	$3.327 \cdot 10^{-3}$	$5.997 \cdot 10^{-18}$

由上例，讀者應可接受只要保戶愈多，保險公司可說就不用擔心有破產的問題。當然這裡面有一點要留意，就是保險公司要有相當夠的資金才行。因並非所有保戶同時加入保險，且保費為一次收齊，若才收了幾份保費，就有人要理賠，則便付不出理賠金了。

例8. 承上例。賭場想知道有0.99的機率，它至少可淨賺多少元？

解。賭場淨賺至少 a 元，即表賭客淨所得少於 $-a$ 元。現要求 $P(\sum_{i=1}^n X_i \leq -a)$ 。令

$$\begin{aligned} P\left(\sum_{i=1}^n X_i \leq -a\right) &= P\left(\frac{\sum_{i=1}^n X_i - n(2p-1)}{2\sqrt{p(1-p)\sqrt{n}}} \leq \frac{-a - n(2p-1)}{2\sqrt{p(1-p)\sqrt{n}}}\right) \\ &\doteq \Phi\left(\frac{-a - n(2p-1)}{2\sqrt{np(1-p)}}\right) = 0.99. \end{aligned}$$

因 $z_{0.99} \doteq 2.326$, 由上式得

$$-a - n(2p-1) \doteq 2.326\sqrt{np(1-p)}.$$

故

$$(36) \quad a \doteq n(1-2p) - 2.326\sqrt{np(1-p)}.$$

即有0.99的機率，賭場約至少可淨贏 $(n(1-2p) - 2.326\sqrt{np(1-p)})$ 元。

對 $p = 18/37$, 及一些不同的 n , 表4給出 a 之近似值。通常 $p < 1/2$, 由(40)式看出, 只要 n 夠大, a 皆為正。對於 $p = 18/37$, $n \rightarrow \infty$ 時, $a \sim n/37$ 。

表4. 歐式輪盤賭場有0.99的機率約至少可淨贏的金額

賭的次數 n	10^2	10^3	10^4	10^5	10^6
賭場	-8.9	-9.7	154.0	2,335.1	25,864.5

若對機率與信心二詞之區隔仍有疑惑者, 可參考黃文璋(2011e)一文。

8 結語

一般認為, 機率統計乃比微積分不易教。後者有物理意義, 前者卻缺乏, 因此較難用直觀的方式來教機率統計。近年來, 統計的題材陸續被引入高中。只是要在中學數學課本少少的篇幅裡, 將一些有點深奧的機率統計概念講清楚, 乃屬高難度。對教科書的編輯, 為一大挑戰。導致現行教科書中於此部分, 往往語焉不詳, 讓教師與學生, 皆常產生困惑。而熱心教師所發表的心得, 也無可避免充斥不少錯誤。對基本概念的詮釋未能很精準, 這點國外較初等的大學機率統計教科書, 也不例外。看來機率統計要普及化, 的確是困難, 不分中外。

本文既名之為“庶民中央極限定理”, 顯然初衷是設定普羅大眾(proletariat, 平民百姓)皆能讀得懂。這當然不容易, 退而求其次, 若能讓至少具備高中數學程度者, 便可以吸收, 也就不枉寫此文了。因希望對在高中任教的數學老師, 及一般系所的大學生及研究生, 於理解機率統計的內涵, 能有些幫助, 所以下筆時雖力求淺白, 但仍儘量嚴謹, 務求正確。為導正概念, 也將個人所知, 教科書及文章上出現的一些問題, 拿出來討論, 用意是避免類似錯誤一再發生。而若本文有任何錯誤, 也歡迎讀者指出。對機率統計概念之解釋, 是很容易犯錯, 有時還有不同的觀點。須反覆切磋琢磨, 以求精進。由於是以目前中學裡, 與中央極限定理相關的題材為骨幹,

所以雖基礎的機率統計中，尚有些也常讓人迷惑的概念，如獨立性，及條件機率等，本文皆未多著墨。可參考黃文璋(2010b)，及(2011d)二文。

機率統計既然要深耕，就得嚴肅以對，釐清其中隨機的本質，而不是僅視其為較簡單的數學。如此才能生根，提高國民統計素養，達到在高中引進機率統計題材之目的。

參考文獻

1. 丁村成(2010). 談高中新教材中機率統計的缺失與改進。數學傳播季刊, 34(4): 9-23。
2. 江前佑(2006). 關於高中統計課程的一些說明。高中數學電子報第10期(2006年5月31日)。
3. 姚若潔譯(2004). 奇蹟？機率!？。科學人, 31期(2004年9月號): 18。
4. 黃文璋(2003a). 隨機思考論。華泰文化事業股份有限公司，台北。
5. 黃文璋(2003b). 數理統計。華泰文化事業股份有限公司，台北。
6. 黃文璋(2005). 應隨機以恆周。科學發展月刊, 394期(2005年10月號): 68-73。
7. 黃文璋(2006). 統計裡的信賴。數學傳播季刊, 30(4): 48-61。
8. 黃文璋(2007). 統計裡的估計。數學傳播季刊, 31(1): 3-20。
9. 黃文璋(2008). 誰與達爾文爭鋒。心在南方(<http://www.stat.nuk.edu.tw/South.asp>)，2008年4月7日。
10. 黃文璋(2009). 統計思維。數學傳播季刊, 33(4): 30-46。
11. 黃文璋(2010a). 機率論，第二版。華泰文化事業股份有限公司，台北。
12. 黃文璋(2010b). 機率應用不易。數學傳播季刊, 34(1): 14-28。
13. 黃文璋(2011a). 機率空間。黃家小館(<http://huang.nuk.edu.tw/cindex.htm>)。

14. 黃文璋(2011b). 隨機變數。黃家小館(<http://huang.nuk.edu.tw/cindex.htm>)。
15. 黃文璋(2011c). 關於中央極限定理之圖示。黃家小館(<http://huang.nuk.edu.tw/cindex.htm>)。
16. 黃文璋(2011d). 認識機率。數學傳播季刊, 35(2): 32-44。
17. 黃文璋(2011e). 對機率要有信心。黃家小館(<http://huang.nuk.edu.tw/cindex.htm>)。
18. Diaconis, P. and Mosteller, F.(1989). Methods for studying coincidences. *Journal of the American Statistical Association*, 84, 853-861.
19. Feller, W.(1968). *An Introduction to Probability Theory and Its Applications*, Vol. 1, 3rd ed. John Wiley & Sons, New York.
20. Shermer, M.(2004). Miracle on probability street. *Scientific American*, August, 291(2), 32.
21. Tijms, H.(2004). *Understanding Probability: Chance Rules in Everyday Life*. Cambridge University Press, Cambridge.

附錄一 對機率要有信心

黃文璋

國立高雄大學應用數學系

1 前言

在高中數學學科中心網站的討論區看到一篇“機率或信心Q&A”的文章(以下稱為Q&A),由題目即知該文試圖解釋機率與信心二名詞。

處在一個生活中已缺不了統計的時代,具備足夠的統計知識,似乎是必須的。這可能是近年來,高中數學增加不少統計題材的主因。但我一直不贊成高中數學裡教太多統計。因要在一向講究精準及不變性的高中數學裡,讓學生理解涉及隨機概念的題材,先天便有其困難。尤其信賴區間,在一般大學統計教科書中,是放在較後面的章節。學生接觸信賴區間時,已具備夠多的機率統計基礎。如今卻跳過一切預備知識,堂而皇之地進入高中數學裡,引發的困惑,多過吸收到的統計知識,也就不足為奇。有些認真的高中教師,想釐清一些概念,但由於高中數學裡,能用的工具極有限,因此很多釐清的文章,往往淪為郢書燕說。既未澄清任何概念,反讓原本清晰的部分,也模糊起來。本文便擬對Q&A,略做修正及補充。

2 機率的意義

在Q&A中，以下述問題開場：

在某一次教師研習的綜合座談中，有老師提到以下的問題：

投擲1只骰子（傳統6面骰字，點數1,2,3,4,5,6，點數1,4為紅色，其他點數為黑色），擲出1點的機率為何？若已知擲出的顏色為紅色，請問擲出1點的機率為何？

這個問題在學生沒有學過“信賴區間與信心水準”之前是沒有意義的，還沒有擲出骰子前，擲出1點的機率是 $1/6$ ；在擲出的顏色為紅色的條件下，擲出1點的機率為 $1/2$ 。但學生學過信賴區間之後會說，不，老師，既然骰子已擲出，則骰子是1點的機率不是1就是0，不會是 $1/2$ 或其他任何數字。

結果，學得越好的學生心中的疑惑卻越深。我們該如何回應這個學生？在條件機率的情境下，應該使用「機率」或「信心」？

Q&A作者如下回答：

擲一個公正骰子一次，出現一點的機率= $1/6$ 。這是由大數法則得到的，故以機率稱之。擲一個公正骰子一次，在已知出現紅色點數的條件下，出現一點的機率= $1/2$ 。這是由大數法則得到的，故仍以機率稱之。

其中我們除了加上幾個標點外，其餘一字未改。

我們說投擲一個公正骰子，此處“公正”一詞乃口語，其含意為骰子各面出現的機率相同，即皆為 $1/6$ 。這是骰子公正下的結果，與“大數法則”並無關係。就如若假設生男、生女的機會相同，那便表生男、生女的機率各為 $1/2$ 。僅是一件事不同的講法而已。說是由大數法則得到，不但不是事實，而且易讓人對機率生畏，後果是令師生連對中文字的運用，都將失去

信心。Q&A作者說“學得越好的學生心中的疑惑卻越深”，豈不就是因常看到這些夾纏不清的講法所造成？

前述Q&A所提出的問題，最後有句“在條件機率的情境下，應該使用機率或信心？”依題意，在擲出骰子的顏色為紅色之條件下，擲出1點的機率就是 $1/2$ ，毫無疑義。提到什麼在條件機率的“情境”下，提到什麼“信心”，只有令人更為困惑而已。本來無一物，就不要惹塵埃。

現在來看“骰子已擲出，則骰子是1點的機率不是1就是0，不會是 $1/2$ 或其他任何數字”，此Q&A中所提學生的困擾。欲解此疑惑，歸根究柢，仍是要回到機率的意義。

事實上，只要是隨機現象，便能談機率。有人敲門，是男是女？你可說男女機率各 $1/2$ 。門外那人的性別當然是確定的，並不會忽男忽女。但由於你不知，對你而言，可能男可能女，這樣的“未知”，造成“你”可視門外者之性別為一隨機現象。而基於社會上男女約各半的認知，在無其他資訊下， $1/2$ 的機率便是這樣產生。此與Q&A中，已知擲出的顏色為紅色（點數有1,4二可能），則擲出1點的機率為 $1/2$ ，乃一樣的原理。但若你聽到門外傳來高跟鞋的走路聲，說不定會說8成是女的。這裡使用到條件機率，給定的條件是“敲門者穿高跟鞋”。當然，若你以往的經驗，是男生也有不少穿高跟鞋者，因此認為敲門者乃女生的機率為0.6，亦無不可。對同一隨機現象，每個人認定的機率，可以很主觀的。但要注意一點，一旦門打開，則門外那人，不是男就是女。即這時敲門者為女生的機率，將不是1就是0，不能再說0.8或0.6了。機率裡自有一套邏輯，而既然是邏輯，就要合理。若明明已看到是女生（或男生），還說女生的機率為0.8；或若已假設骰子為公正，卻認為投擲一次後，會得到偶數的機率為0.7，那就絕非在談機率了。

上述那類例子處處可見。投擲一銅板，待落地後蓋起來，要人猜正面或反面？拿個蘋果放背後，要人猜蘋果或橘子？這些都是對有些人並非隨機現象，但對某些人卻為隨機現象之例。又如考試前一天仍可猜題，題目不是早已出好了嗎？怎還有人在說“這題很可能會考”？也是類似的道理。再給一例。大家聽過“汽車與山羊”的問題嗎？此問題亦曾出現在電影“決勝21點”中。有三扇門，其中一扇門後有汽車，另兩扇門後為

山羊。你選定一扇門後，主持人打開另兩扇門之一，問你是否要更改選擇。選擇要不要更改，當然是依更改後得到汽車的機率是否會變大？你看，汽車在那一扇門之後，也是早已確定，但仍可談機率。汽車與山羊問題之詳細討論，可參考黃文璋(2010)一文。

至於為什麼可以說骰子為公正，即何以知道骰子各點數出現的機率皆為 $1/6$ ？這有幾種可能的想法，牽涉到“機率”一詞幾種不同的意義，可參考黃文璋(2011)一文。我們列出幾種常見的想法如下。第一種是因骰子有6個面，基於相同的可能性(古典機率)，導致每個面出現的機率皆為 $1/6$ 。第二種想法可稱為主觀的，說不定就是覺得沒有道理那一面較易出現。第三種可能，乃由過去多次投擲的經驗，觀察到骰子各面出現的“相對頻率”(即某面出現的次數除以總投擲數)難分軒輊。還有一種可能(這是不少數學家採用的)，就是此為一假設。若骰子不是虛擬，而是真有一骰子，則不論基於上述那一種想法，究竟是否可採信骰子各面出現的機率皆為 $1/6$ ，可以做一統計檢定。因此，在上述第三種對機率的想法裡，骰子各面出現的相對頻率，是否夠接近到足以視為相等，便可藉助統計檢定來判定。而也是在第三種想法裡，某面出現的機率為 $1/6$ ，導致多次投擲後，該面出現的相對頻率將接近 $1/6$ ，才用到大數法則。但要有隨機的概念，即使是公正的骰子，不論投擲再多次，各面出現的相對頻率，都很難相等。有些人以為投擲數夠多後，會使各面出現的相對頻率“相等”，這完全是錯的。

另外，必須一提的是，在隨機世界中，一切都是假設，只看你接受那一個。骰子是否公正，不論投擲再多次，仍是天曉得。統計檢定裡，依無罪推定的原則，及在給定所能容忍之犯錯機率下，有一套程序，以判定該接受，或拒絕(更保守的講法是“不能接受”)那一假設。除非不是隨機現象(如銅板兩面皆為正)，否則不論證據再顯著(如投擲銅板100次都得正面)，其推論均可能犯錯。我們僅能以較好的統計方法，減小犯錯機率。

3 信心水準

Q&A的第二部分如下：

中央極限定理

- 從平均數為 μ , 標準差為 σ 的母群體中, 以簡單隨機抽樣法抽取 n 個樣本, 以 \bar{X} 表示樣本平均值, 當樣本數 n 足夠大時, 則 \bar{X} 的期望值為 μ , 變異數為 σ^2/n 。
- CLT: \bar{X} 分配近似常態分配 $\mathcal{N}(\mu, \sigma^2/n)$ 。
- 平均數標準化後, 分佈近似 $\mathcal{N}(0, 1)$ 的分佈, 即

$$\frac{\bar{X} - E(\bar{X})}{\sqrt{Var(\bar{X})}} = \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \rightarrow \mathcal{N}(0, 1),$$
$$P\left(-1.96 < \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} < 1.96\right) \approx 0.95. \quad (*)$$

由(*)式子得到

$$P\left(\mu - 1.96\sigma/\sqrt{n} < \bar{X} < \mu + 1.96\sigma/\sqrt{n}\right) \quad (**)$$
$$= P\left(\bar{X} - 1.96\sigma/\sqrt{n} < \mu < \bar{X} + 1.96\sigma/\sqrt{n}\right) \approx 0.95.$$

但是, 我們僅作一次抽樣, 得到樣本平均數 \bar{x} , 標準差 S , 95%信賴區間 $[\bar{x} - 1.96S, \bar{x} + 1.96S]$, 此區間有包含到真正的 μ 值, 要不就是沒有包含到真正的 μ 值。(**)式中, \bar{X} 為隨機變數, 所以是重複做相同的抽樣很多次以後所得到機率, 故(**)的結果, 仍以機率表示。

但是受限於人力、物力、財力, 我們僅作一次抽樣, 故稱 $[\bar{x} - 1.96S, \bar{x} + 1.96S]$ 為 μ 的95%信賴區間, 我們有95%信心說 μ 會落在此區間內。

此處, 我特別以 μ 、 \bar{X} 表示, 希望不要被 p 、 \hat{p} 搞混, 但其意思是相同的。

Q&A中缺乏足夠文字的鋪陳，文字也屢有跳躍或不明確處。例如，根本沒有 p 、 \hat{p} ，何以說不要搞混？因此有時不太知道作者的意思。但再度，第一個黑點後那段敘述，與中央極限定理沒有關係。此句並不嚴謹，本擬設法修正此句，但如前所述，因Q&A的作者並未加以說明，無法了解此句與全文之關聯。為避免誤導，此句宜刪除，所以就不費神去修改。

簡單隨機抽樣，分取出後放回及取出後不放回兩種。若是前者，則對所有的樣本數 n ， \bar{X} 的期望值必為 μ ，變異數必為 σ^2/n ，不需 n 很大。若是後者，如做民調時，從母體中（設有 N 人）隨機抽取 n 個樣本（名字，或電話）後不放回，欲估計母體中對某一議題支持之比率，則知道 N 、 n 及 μ ，支持的人數 X 有超幾何分佈(hypergeometric distribution)，期望值為 $n\mu$ 。因此支持的比率 $\bar{X}(= X/n)$ 之期望值，對每一樣本數 n 皆為 μ 。至於 \bar{X} 的變異數給在下式：

$$Var(\bar{X}) = \frac{N-n}{N-1} \frac{\sigma^2}{n},$$

稍複雜些。可看出只有當 n 與 N 相比很小時， $(N-n)/(N-1)$ 才會接近1。所以無論那一種簡單隨機抽樣， \bar{X} 的期望值皆為 μ 。至於 \bar{X} 的變異數，對取出後放回，等於 σ^2/n ；對取出後不放回，只要 n/N 很小（而非 n 足夠大），便接近 σ^2/n 。也就是都不需要用到中央極限定理。

必須一提的是，中央極限定理通常是針對取出後放回的簡單隨機抽樣，或更一般地，針對獨立且有共同分佈之樣本。另外，對於取出後不放回的簡單隨機抽樣，在 n 與 N 相比很小下，說 n 足夠大時（當然仍要比 N 小）， \bar{X} 的變異數“為” σ^2/n 固然不對，但“接近”或“近似”也都不是貼切的講法。因 n 夠大時， \bar{X} 之變異數及 σ^2/n ，二者皆近似於0。而二近似於0的數，自然彼此近似。

第二個黑點後那句也宜刪除。中央極限定理，並非在講 \bar{X} 的分佈，乃是針對標準化後 \bar{X} 之分佈。對獨立且有共同分配之樣本，當 n 很大時， \bar{X} 之變異數 σ^2/n 近似於0。而一隨機變數之變異數很小，表示它有很大的機率近似於常數。即此時 \bar{X} 近似於 μ 之機率很大。也就是對 \bar{X} ，與它較相關的是大數法則，並非中央極限定理。因此這句就不理它了，直接刪掉。

在第三個黑點裡，幾個式子大抵可接受。文字敘述中以樣本標準差 S 取代(**)中的 σ 也無妨，仍為一近似的式子。只是第一個式子中有趨近的符號“ \rightarrow ”，因此宜在“即”之後，加上“ n 趨近 ∞ 時”，或“ $n \rightarrow \infty$ 時”。不過“所以是重複做相同的抽樣很多次以後所得到機率”這句一定得刪除，完全畫蛇添足，徒增困擾。 \bar{X} 為隨機變數，是使 μ 落在區間有“機率”可言之原因，與做多少次抽樣無關。再來“受限於人力、物力、財力，我們僅作一次抽樣”也宜刪除。每次依同樣步驟抽樣，不論得到再多的區間，每一個皆是 μ 的95%信賴區間，且95%永遠稱為“信心水準”，不會變成“機率”0.95。在估計時，即使“人力、物力，及財力”皆不設限，每次也只會(或說只想)得到一個信賴區間，否則究竟要“信賴”那一個？但在不受限制下，取樣愈多(即 n 愈大)，所得的信賴區間長度將愈短。亦即對 μ 的估計將更準確，這是花更多精力後的代價。

從估計的觀點，區間較一個點更可“信賴”。想想醫生宣佈病人可再活1年，跟說大約可再活6個月至3年間，何者讓人覺得此醫生較科學，更值得信賴？對於估計，譬如估計一銅板出現正面的機率 μ ，在實際取樣前， μ 有一機率值會落在信賴區間。如前述(**)式，其中有一“機率”0.95。但我們一開始就不稱0.95“機率區間”。因就是為了估計才得到該區間，接續便要取樣。而一旦得到一固定的信賴區間，說此一特定的區間，有0.95的機率包含 μ ，難免讓人覺得不太妥當，而又不易解釋清楚，所以當初引進信賴區間概念之統計學家，才自始便不稱0.95為機率。但 μ 的真實值畢竟乃屬未知，而數據會說話，你還是覺得你的投擲結果，總有值得“信賴”處。即除非已經知道 μ 值了，否則有一定的“信心”， μ 會落在此區間。95%，便用來描述該信心之大小，稱為信心水準。至於Q&A的第一部分，即原先大家所熟知的機率及條件機率的概念，與信賴區間根本無關，不會因引進信賴區間的概念後而改變。

只要是為隨機現象(即使對有些人並非隨機)，就能談機率。引進信賴區間及附隨的信心水準後，原先的機率不會變成“信心”。對機率要有信心。

參考文獻

1. 黃文璋(2010). 機率應用不易。數學傳播季刊, 34(1): 14-28。
2. 黃文璋(2011). 認識機率。數學傳播季刊, 35(2): 32-44。