

統計學簡介

統計學的意義

- 統計學(statistics)是一種科學方法與原理，其包括資料的蒐集，資料的整理，陳示，分析與解釋，並獲得結論，以幫助做更有效的決策。
 - 統計學包含敘述統計學(descriptive statistics)與推論統計學(inferential statistics)。
-

統計學的意義

完成統計任務的三個步驟為：

1. 統計資料的搜集與整理
 2. 統計資料的分析
 3. 統計資料的推論
-

統計專有名詞

□ 母體(**population**)

人們在研究某一現象或問題時，必須針對發生此一現象或問題的對象進行調查研究，調查研究的全體對象所成之全部集合即為所謂的母體。

□ 樣本(**sample**)

樣本是研究者從母體中所抽取的部分元素所組成的集合，亦即為有興趣研究之全體對象的部分集合。

統計專有名詞

□ 普查(**census**)

一旦我們確定要研究的對象母體，且母體是有限的，則了解母體最好的方法，就是對母體內每一個個體加以調查並記錄其特徵，這種調查方式就稱為普查(**census**)。

□ 抽樣調查(**sampling survey**)

相對於普查，若隨機自母體中抽選出一部份具有代表性的個體當作樣本來加以調查，依據此組樣本進行統計分析，再將所得的結果來推論未知母體，則此種方法即稱為抽樣調查。

統計專有名詞

□ 參數(**parameter**)

爲了推論母體，研究者必須知道描述母體特徵的某些特徵值，這些特徵值即稱爲參數或母數。

□ 統計量(**statistic**)

統計量是由樣本中所計算出的量，其爲隨機樣本觀察值的函數，用來推論未知母體參數。

統計專有名詞

□ 估計誤差(**error of estimation**)

當我們利用估計量來估計母體參數時，不論用什麼抽樣方式或多精密的測量，估計量與母體參數間總會有差距。這樣的差距即稱為估計誤差。

□ 可能誤差(**possible error**)

為統計數值最末一位數的半個單位。

統計學的發展

劃分階段		代表人物	主要貢獻
古典時期	十六世紀中至十九世紀初	國勢學派 發展於歐洲大陸，以研究國情為主 政治算術學派 發展於英國，舉凡與數字資料有關的社會現象均包含在內	
近代時期	十九世紀初至二十世紀初	<u>卡爾・皮爾生</u> (Karl Pearson, 1857 - 1936)	簡單的統計量，如標準差、相關係數等 迴歸分析的觀念和卡方檢定
		費雪(R.A. Fisher, 1890 - 1962)	實驗設計和隨機過程
現代時期	二十世紀初至今	<u>聶曼</u> (J. Neyman, 1894-1981) 及 <u>伊根・皮爾生</u> (Egon Pearson)	估計和檢定方面提出理論的基礎
		<u>華德</u> (A. Wald, 1902-1950)	逐次分析(sequential analysis)

統計技術

以下列出一些有名的統計檢定方法以及可供驗證實驗數據的程序

- ❑ 變異數分析(ANOVA)
 - ❑ 費雪最小顯著差異法 (Fisher's Least Significant Difference test)
 - ❑ 學生t檢驗(Student's t-test)
 - ❑ 曼-惠特尼 U 檢定 (Mann-Whitney U)
 - ❑ 回歸分析 (regression analysis)
 - ❑ 相關性 (correlation)
 - ❑ 皮爾森積矩相關係數(Pearson product-moment correlation coefficient)
 - ❑ 史匹曼等級相關係數 (Spearman's rank correlation coefficient)
 - ❑ 卡方分配 (chi-square)
-

統計的應用

- 政府統計方面：如失業率、人口普查
 - 企業統計方面：如產品滿意度、商品佔有率
 - 財務金融統計方面：如股價指數預測、物價變動
 - 教育統計方面：如學校經費預估、師生人數比例
 - 農業統計方面：如季節變動與農產品收成數量的關係
 - 生物統計方面：如藥物對疾病的有效度
 - 其它統計方面：如氣象預測
-

統計方法的限制

1. 樣本必須具有代表性
 2. 必須使用大樣本
 3. 必須使用正確資料
 4. 態度必須公正客觀
 5. 統計數字必須經過比較才有意義
 6. 統計結果必須作出合理的解釋
-

圖解式統計學方法目標

- 圖解式統計學方法具有四個方面的目標
 - (1) 探究數據集的內容；
 - (2) 用於發現數據之中的結構；
 - (3) 檢查統計學模型之中的假設；
 - (4) 溝通傳達分析結果。
 - 如果不採用統計圖形，也就會喪失深入認識數據基礎結構之一個或多個方面的機會。
-

圖解分析方法的統計學工具

- ❑ 這些工具包括散點圖、直方圖、機率圖、殘差圖（residual plot）、箱形圖、塊圖以及雙標圖。探索性數據分析（Exploratory data analysis, EDA）就密切地依賴於這些手段以及與此類似的其他技術方法。
 - ❑ 圖解分析操作程序不僅僅是在EDA背景下才使用的工具；在檢驗假設、模型選擇、統計模型驗證、估計量（estimator）選擇、關係確定、因素效應判定以及離群值檢出方面，此類圖解分析工具還可以作為最佳捷徑，用來深入認識數據集。
 - ❑ 此外，優質的統計圖形還可以作為一種令人信服的溝通手段，用來向他人傳達存在於數據之中的基本訊息
-

樣本大小之選擇

- 樣本不要過大，過大浪費成本；但也不要過小，過小則會有太大的抽樣誤差。如何決定適當的樣本大小？在機率抽樣的情況下，有關樣本大小的決定及樣本統計顯著性的判斷，可藉由機率法則的運用。（也就是說，有公式可供計算）
 - 但在非機率抽樣的情況下，除了依靠抽樣人員的主觀判斷或假設外，實無客觀之科學方法可資應用。
-

集中趨勢

□ 均數函數應用

- AVERAGE 傳回引數的平均值
- AVERAGEA 傳回引數的平均值，包含數字、文字和邏輯值
- AVEDEV 傳回一組資料與其平均值絕對偏差的平均值
- HARMEAN 傳回調和平均值
- COVAR 傳回共變數，即成對偏差乘積的平均數
- GEOMEAN 傳回幾何平均數

□ 中位數應用

- MEDIAN(number1,[number2], ...)

□ 眾數應用

- MODE(number1,[number2], ...)

□ 以線圖表示注重程度差異

中位數

- ❑ 中位數（Median）是指將所有數字依大小順序排列後，排列在最中間之數字，其上與其下的數字個數各佔總數的二分之一。也就是說，將所有次數當100%，累積之次數達50%的位置，其觀測值就是中位數（用Me來表示）。
 - ❑ 於Excel是以MEDIAN()函數來求算中位數，
 - ❑ 語法：MEDIAN(number1,[number2], ...)
用以求一陣列或範圍資料的中位數，若這數字為偶數個數，將計算中間兩個數字的平均值。其算法很簡單，當n為奇數，按大小排列後，第 $(n+1)/2$ 個觀測值，就是中位數。當n為偶數，則取第 $n/2$ 與 $(n+2)/2$ 個觀測值之平均數為中位數。
 - ❑ 數值1,[數值2],...為要求中位數之儲存格或範圍引數，最多可達255個。式中，方括號所包圍之內容，表該部份可省略。
-

□ 如：

10, 3, 4, 5, 8, 7, 12

等7個數字資料， n 為7是個奇數，依大小排列後為：

3, 4, 5, 7, 8, 10, 12

第 $(7+1)/2=4$ 個觀測值7，就是中位數。而

3, 4, 5, 8, 12, 7

等6個數字資料， n 為6是個偶數，依大小排列後為：

3, 4, 5, 7, 8, 12

則取第 $6/2=3$ 與 $(6+2)/2=4$ 個觀測值之平均數 $(5+7)/2=6$ 為中位數。

B2		fx		=MEDIAN(A1:G1)			
	A	B	C	D	E	F	G
1	10	3	4	5	8	12	7
2	中位數	7	<-- =MEDIAN(A1:G1)				
3							
4	3	4	5	8	12	7	
5	中位數	6	<-- =MEDIAN(A4:F4) 取(5+7)/2				

- 中位數與平均數，均是用來衡量母體的集中趨勢。但中位數不會受極端值影響。如：3, 4, 5, 7, 8, 10, 90

之平均數為18.43比六個數字中之五個數字都大，以它來代表這組數字；反不如使用中位數7，來得恰當一點！

- 中位數不會受極端值影響，且無論極端值如何變化，中位數均不變。如：

3, 4, 5, 7, 8, 10, 500

或

-200, 4, 5, 7, 8, 10, 90

之中位數均還是7

B3		fx =MEDIAN(A1:G1)					
	A	B	C	D	E	F	G
1	3	4	5	8	7	12	90
2							
3	中位數	7	<-- =MEDIAN(A1:G1)				
4	平均數	18.43	<-- =AVERAGE(A1:G1)				
5							
6	3	4	5	8	7	12	500
7	中位數	7	<-- =MEDIAN(A6:G6)				
8	平均數	77	<-- =AVERAGE(A6:G6)				
9							
10	-200	4	5	8	7	12	500
11	中位數	7	<-- =MEDIAN(A9:G9)				
12	平均數	48	<-- =AVERAGE(A10:G10)				

中位數之優點

□ 以中位數代表一群數字之集中趨勢的優點爲：

- 不受極端值的影響
- 恆爲所有資料的中間分界，它是存在的且易瞭解
- 對於分配不對稱之資料，中位數比平均數更適合當集中趨勢的代表值。這就是爲何政府機關所公佈之國民所得，常以中位數爲代表值的理由。但對於分配並不是非常不對稱之資料，平均數還是比中位數更適合當集中趨勢的代表值。

□ 但其缺點爲：

- 僅注重中央之數字，忽略了兩端之所有數字
 - 不靈敏，當資料發生變動，中位數並不一定會變動
-

眾數

- 眾數（Mode，以Mo表示）係指在一群體中出現次數最多的那個數值，於Excel係利用MODE()函數來求得。其語法為：

MODE(數值1,[數值2], ...)

MODE(number1,[number2], ...)

- 數值1,[數值2], ...為要求眾數之儲存格或範圍引數，最多可達255個。式中，方括號所包圍之內容，表該部份可省略。如：

3, 2, 1, 3, 1, 3, 3, 2, 3

之眾數為3：

B3		fx		=MODE(A1:H1)				
	A	B	C	D	E	F	G	H
1	3	2	1	3	1	3	2	3
2								
3	眾數	3	<-- =MODE(A1:H1)					

□ 眾數、中位數與平均數，均是用來衡量母體的集中趨勢。眾數與中位數是較不會受極端值。不過，眾數並非衡量集中趨勢的好方法，因為當分配不規則或無顯著之集中趨勢，眾數就無意義。

□ 如，可能會同時有好幾個眾數的情況發生：

3, 2, 1, 3, 1, 3, 2, 2

之眾數為3與2，但僅傳回3而已：

B6		fx =MODE(A5:H5)						
	A	B	C	D	E	F	G	H
5	3	2	1	3	1	3	2	2
6	眾數	3						

□ 同時，也可能會沒有眾數！如果資料組中不包含重複的資料點，本函數將傳回#N/A的錯誤值：

B9		fx =MODE(A8:H8)						
	A	B	C	D	E	F	G	H
8	1	2	3	4	5	6	7	8
9	眾數	#N/A						

眾數之優/缺點

□ 眾數之優點為：

- 簡單易瞭解
- 不受兩端極端值影響

□ 但其缺點為：

- 可能會同時有好幾個眾數的情況發生
 - 也可能會沒有眾數
 - 不靈敏，當資料發生變動眾數並不一定會變動
-

離散程度

- 均數雖然是一組樣本重要之統計量；但各樣本間之離散程度也是觀察一分配的重要特徵。如果，一分配之離散程度較小，其均數對全體的代性就較高；反之則否。因此，欲瞭解一分配的基本性質，除需計算均數等集中趨勢數量外；還得衡量其標準差、全距、.....等離散程度。
- 最大值減最小值就是全距（range）：
$$\text{全距} = \text{最大值} - \text{最小值}$$

全距表示一群體全部數值的變動範圍，是一種離中量數，可用來表示群體中各數字之分散情形，數字大表母體中之數值高的很高，但低的卻很低。

離散程度函數應用

- 四分位差
 - QUARTILE(陣列,類型)
 - QUARTILE(array,quart)
 - 百分位數
 - PERCENTILE(陣列,百分比)
 - PERCENTILE(array,percent)
 - 變異數
 - 是用來衡量觀測值與平均值間的離散程度，其值越小表母體的離散程度越小，齊質性越高。
 - VARP(number1,[number2],...)
 - VARPA(number1,[number2],...)
 - 母體標準差
 - STDEV(number1,[number2],...)
 - STDEVA(number1,[number2],...)
 - STDEVP(number1,[number2],...)
 - STDEVPA(number1,[number2],...)
-

四分位差

QUARTILE(陣列,類型)

QUARTILE(array,quart)

- 求一個數值陣列或儲存格範圍的第幾個四分位數：將所有數字依大小順序排列後，排列在0%、25%、50%、75%與100%之數字。如果該位置介於兩數之間，將計算該點左右兩個數字的平均值。
 - 陣列是要求得四分位數的數值陣列或儲存格範圍。
 - 類型用以指出要傳回的數值：
 - 0 表最小值(0%處)
 - 1 表第一個四分位數(25%處)，下四分位數，Q1
 - 2 表第二個四分位數(50%處)，即中位數，Q2
 - 3 表第三個四分位數(75%處)，上四分位數，Q3
 - 4 表最大值(100%處)
-

百分位數

PERCENTILE(陣列,百分比)

PERCENTILE(array,percent)

- 可用來求一個數值陣列或儲存格範圍的第幾個百分位數：將所有數字依大小順序排列後，排列在百分比所指定位置之數字。如果該位置介於兩數之間，將計算該點左右兩個數字的平均值。
 - 陣列是要求得百分位數的數值陣列或儲存格範圍。
 - 百分比是介於0~1之百分比數字，如：0.25將求得第一個四分位數(Q_1 ，25%處，也可以 P_{25} 表示)，0.5將求得第二個四分位數(Q_2 ，50%處，也可以 P_{50} 表示)，即中位數。當其百分比為10的倍數，則求得者即為十分位數。如：0.3將求得第三個十分位數 D_3 （也可以 P_{30} 表示），0.9將求得第九個十分位數 D_9 （也可以 P_{90} 表示）。
-

母體變異數VARP()與VARPA()

□ 母體變異數的計算公式爲：

$$S^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}$$

即取每一觀測值與其均數間之差異的平方和的算術平均。取其平方就是因爲無論正差或負差，經平方後均爲正值，就不會產生正負相抵銷之情況，以代替取絕對值之麻煩。

□ 變異數是用來衡量觀測值與平均值間的離散程度，其值越小表母體的離散程度越小，齊質性越高。於Excel是以VARP()與VARPA()函數來求算母體變異數，其語法爲：

■ VARP(number1,[number2],...)

■ VARPA(number1,[number2],...)

□ 式中，方括號包圍之部份表其可省略。數值1,[數值2],...爲要計算變異數之儲存格或範圍引數，它是對應於母群體的1到255個數字引數。

母體標準差STDEVP()與STDEVPA()

□ 將母體變異數開根號，即可求得母體標準差。其公式為：
$$s = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}}$$

變異數取其平方是因為要避免正差或負差，產生正負相抵銷之情況。而標準差將其開根號，即是將平方還原，以代替原須取絕對值之麻煩。

□ 母體標準差，於Excel也可以STDEVP()與STDEVPA()函數來直接求算。其語法為：

- STDEVP(number1,[number2],...)

- STDEVPA(number1,[number2],...)

□ 式中，方括號包圍之部份表其可省略。數值1,[數值2],...為要計算標準差之儲存格或範圍引數，它是對應於母群體的1到255個數字引數。

變異數與標準差之優缺點

- 變異數與標準差是最常被用來衡量離散程度的方法
 - 其優點為：
 - 感應靈敏
 - 嚴密精確
 - 適於代數處理
 - 受抽樣變動之影響甚小
 - 但其缺點為：
 - 不是簡明易解
 - 計算困難
 - 受極端值影響較大
-

敘述統計

- 若曾安裝『分析工具箱』，則可以『資料分析』之「敘述統計」增益集，來計算一組資料內之各相關統計值。如：均數、變異數、標準差、全距（範圍）、.....等。
- 擬使用『資料分析』之「敘述統計」，來計算運動時間之各敘述統計值。其處理步驟為：

	A	B
1	編號	每次運動時間/分
2	1	120
3	2	10
4	3	0
5	4	120
6	5	120
7	6	15

參考資源

□ 維基百科

□ <http://zh.wikipedia.org/wiki/%E7%B9F%E8%AE%A1%E5%AD%A6>
