從頭開始

認識世代研究資料的分佈及資料庫整理

醫學研究部 基礎醫學科 生物統計小組

徐倩儀

2023/10/18

內容大綱

- 認識世代研究Medical Data的分佈
- 並學習如何整理成可用統計軟體分析的資料庫類型
- 如何探討資料的分佈

資料分類

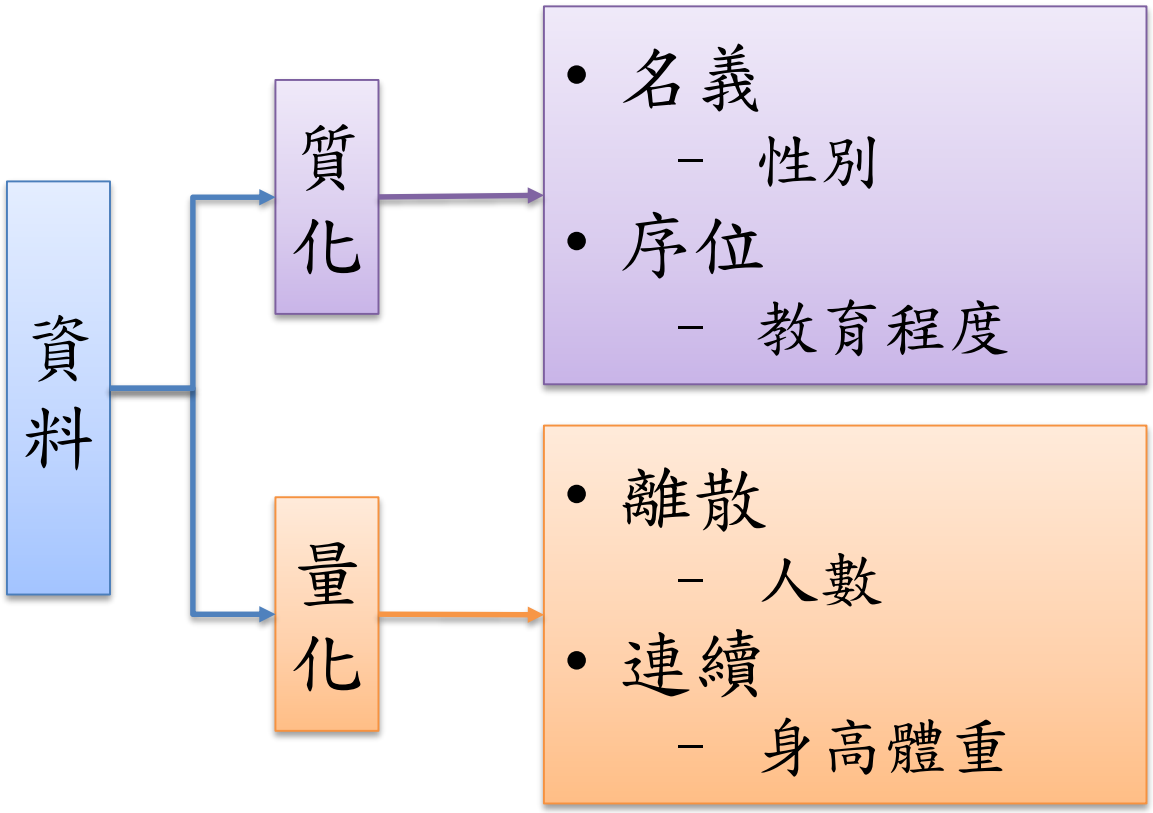

測量尺度

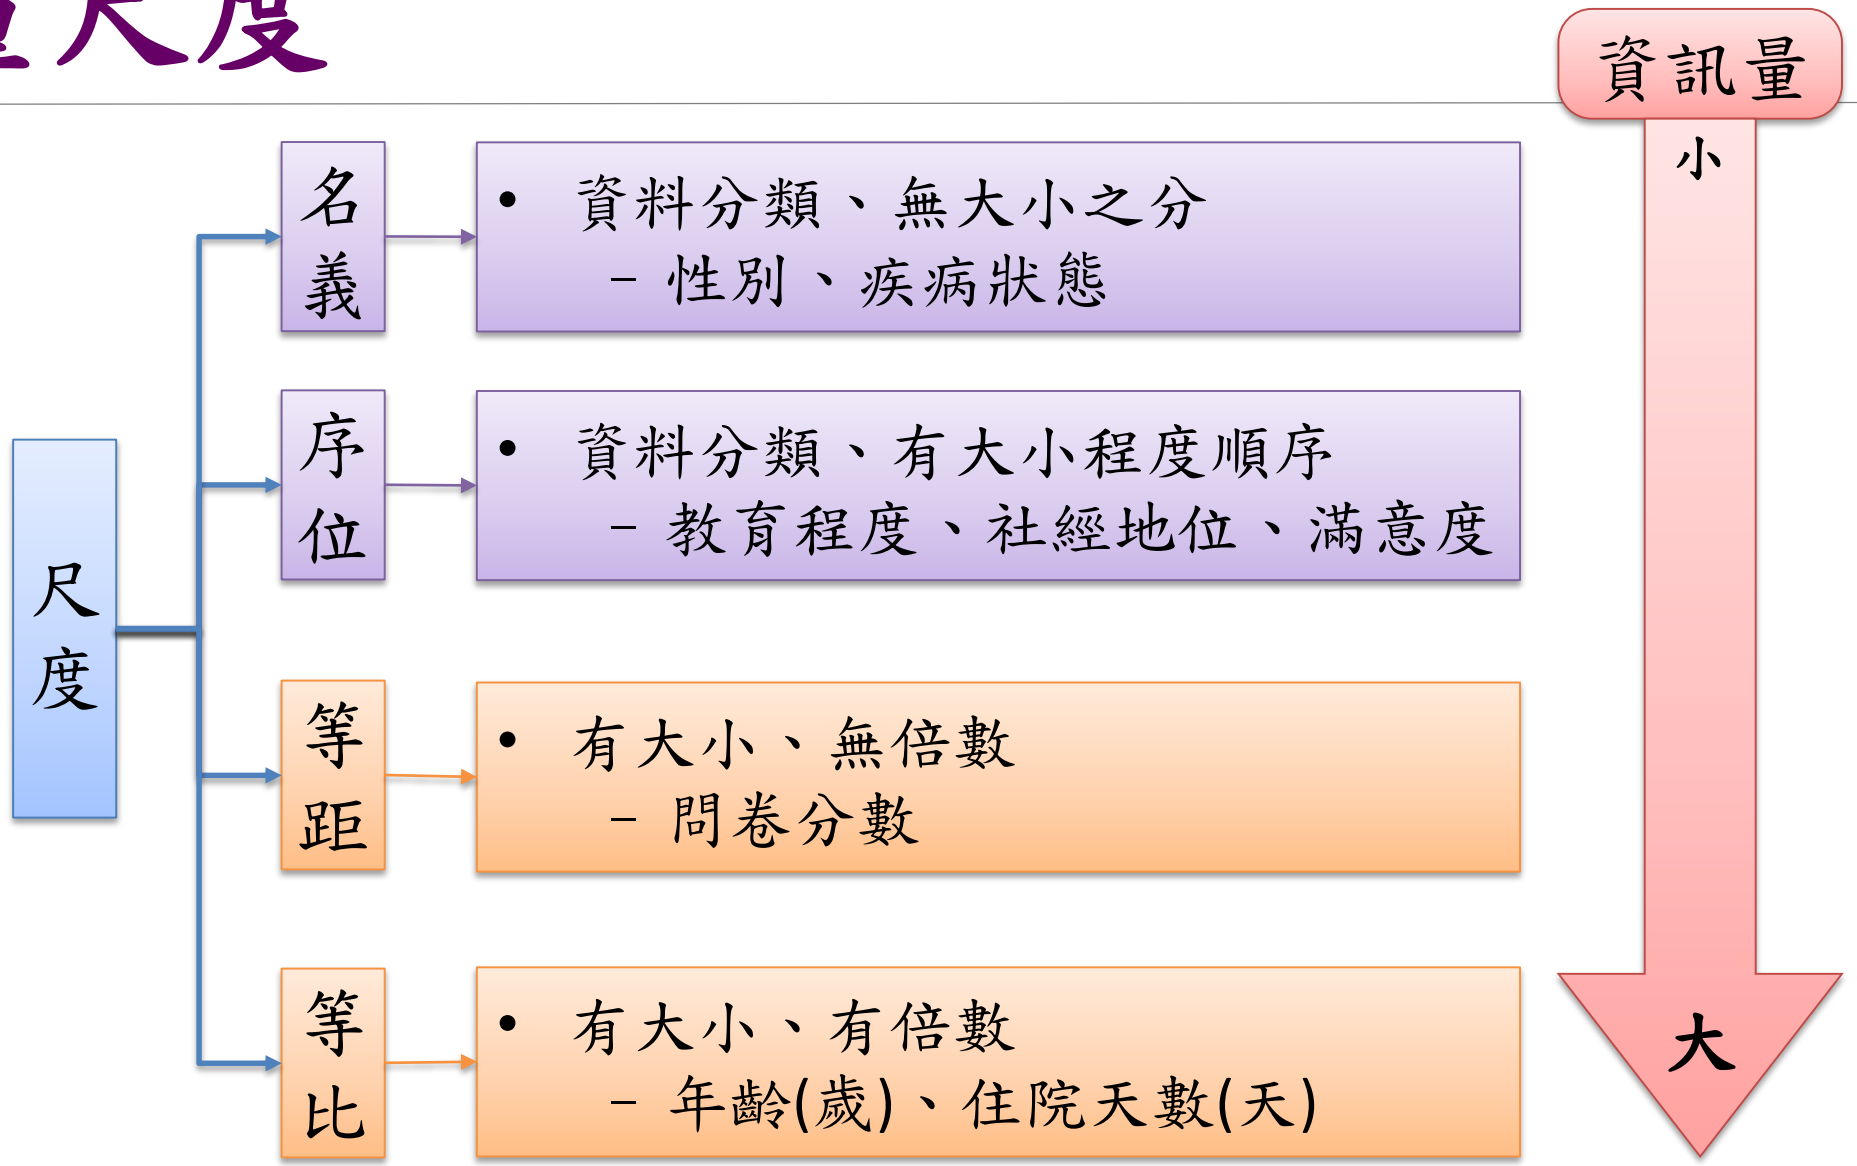
資訊量
小
大
尺度
名義
• 資料分類、無大小之分
– 性別、疾病狀態
序位
• 資料分類、有大小程度順序
– 教育程度、社經地位、滿意度
等距
• 有大小、無倍數
– 問卷分數
等比
• 有大小、有倍數
– 年齡(歲)、住院天數(天)

測量尺度

- 研究者問卷設計(收集資料)
  - 請問您今年幾歲？_____歲
  - 請問您今年幾歲？

    ①20歲以下②21-30歲③31-40歲④41-50歲

    ⑤51-60歲⑥61-70歲⑦71歲以上

年齡的測量尺度?

1)等比尺度

2)序位尺度

測量尺度 (SPSS設定)

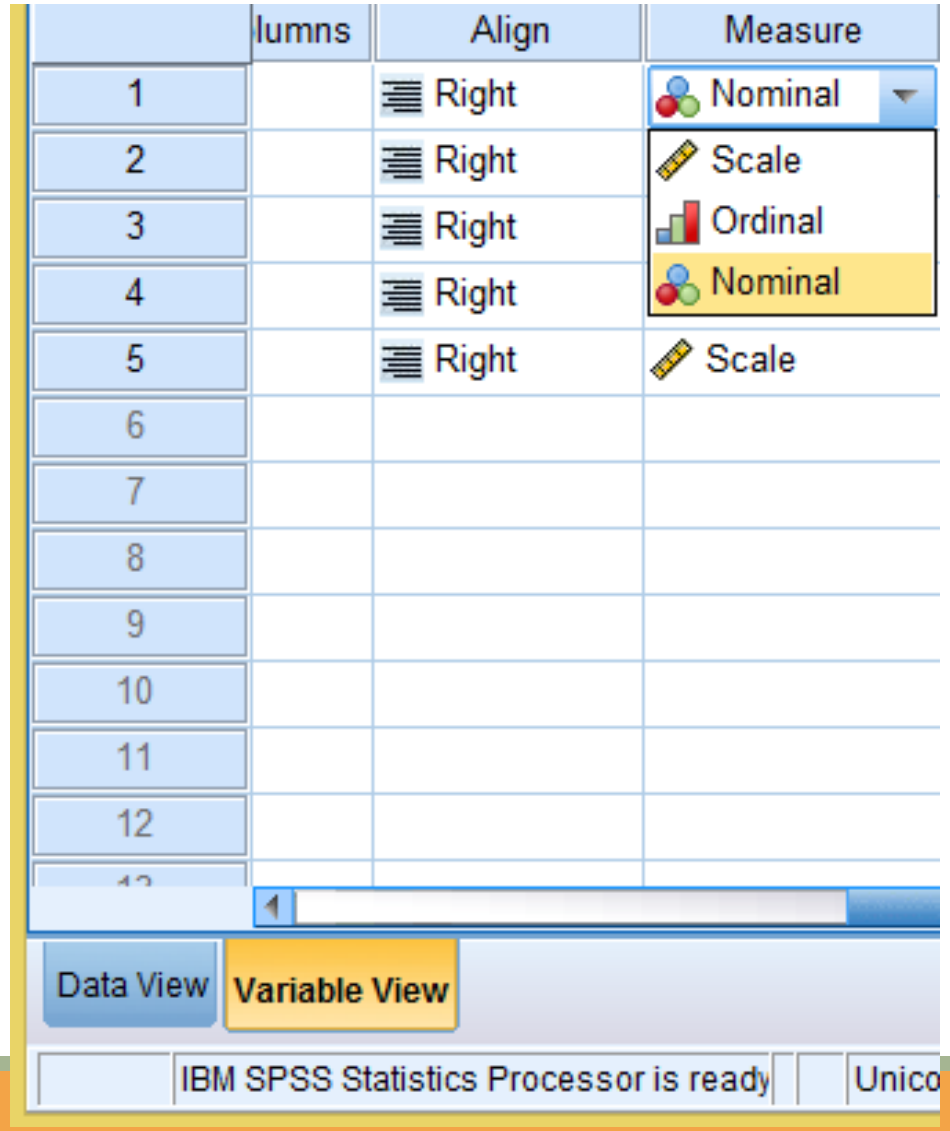
lumns
Align
Measure
1
Right
Nominal
2
Right
Scale
3
Right
Ordinal
4
Right
Nominal
5
Right
Scale
6
7
8
9
10
11
12
Data View
Variable View
IBM SPSS Statistics Processor is ready
Unico

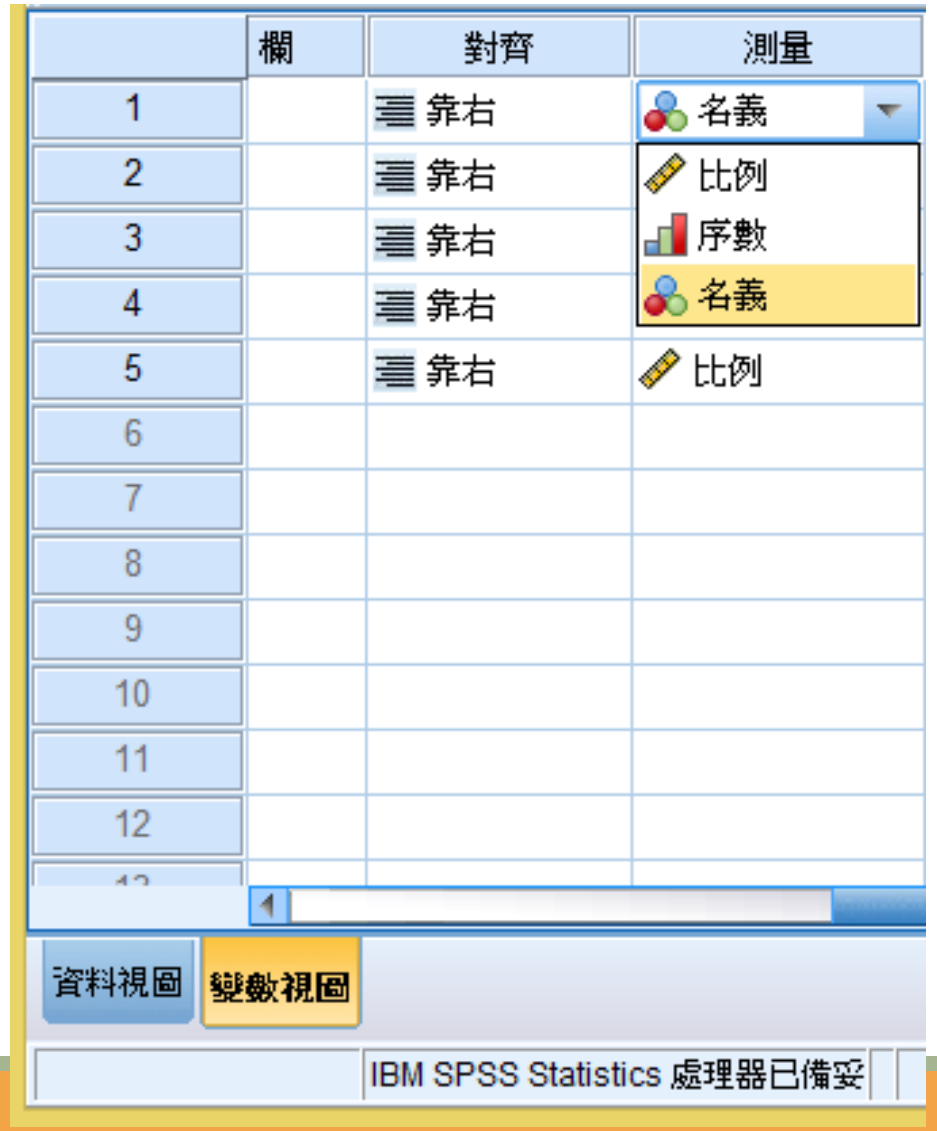
欄
對齊
測量
1
靠右
名義
2
靠右
比例
3
靠右
序數
4
靠右
名義
5
靠右
比例
6
7
8
9
10
11
12
資料視圖
變數視圖
IBM SPSS Statistics 處理器已備妥

描述性統計

- 類別型(名義/序位尺度)
  - n (%)
- 連續型(等距/等比尺度)
  - Mean ± SD
  - Median, IQR

Mean ± SD

- 平均值(mean)
  - 中心點位置
- 標準差(SD)
  - 鐘型曲線形狀

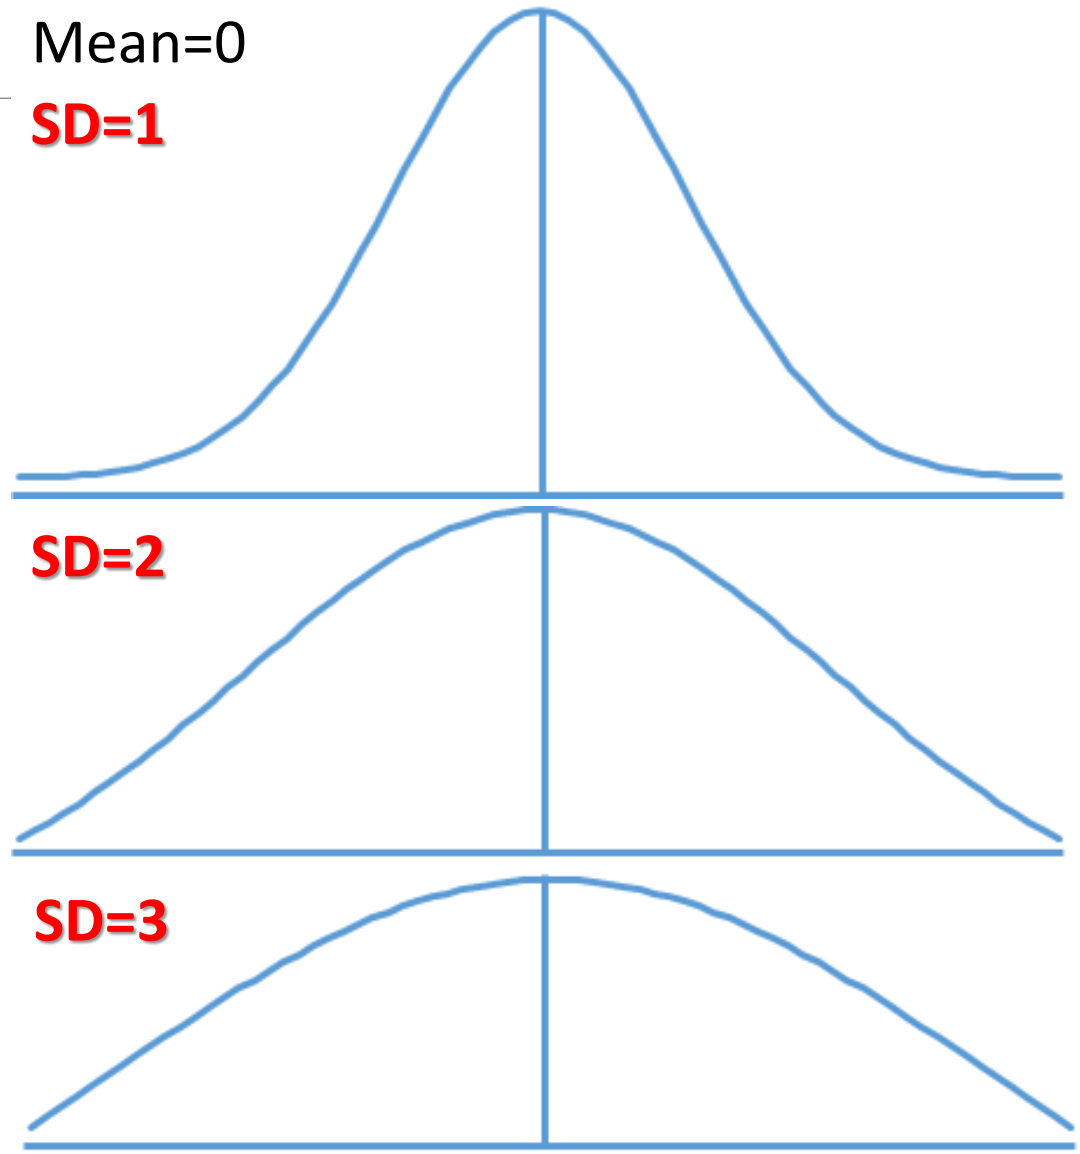

資料分佈

常態分佈

- Gaussian distribution
- 以<u>平均值</u>為中心的對稱曲線
  - **Mean = Median = Mode**

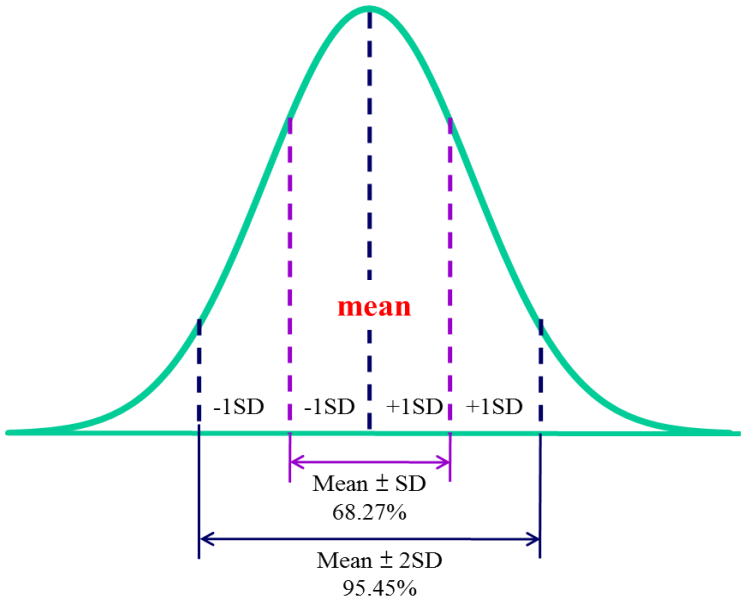

非常態分佈

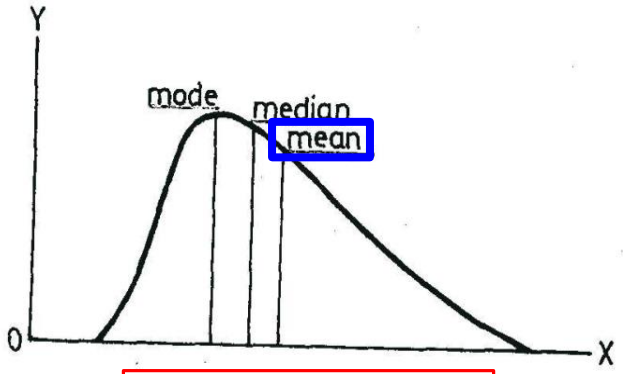

右偏分布

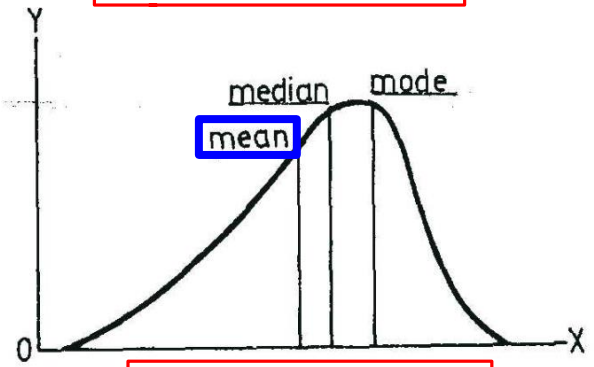

左偏分布

Box plot

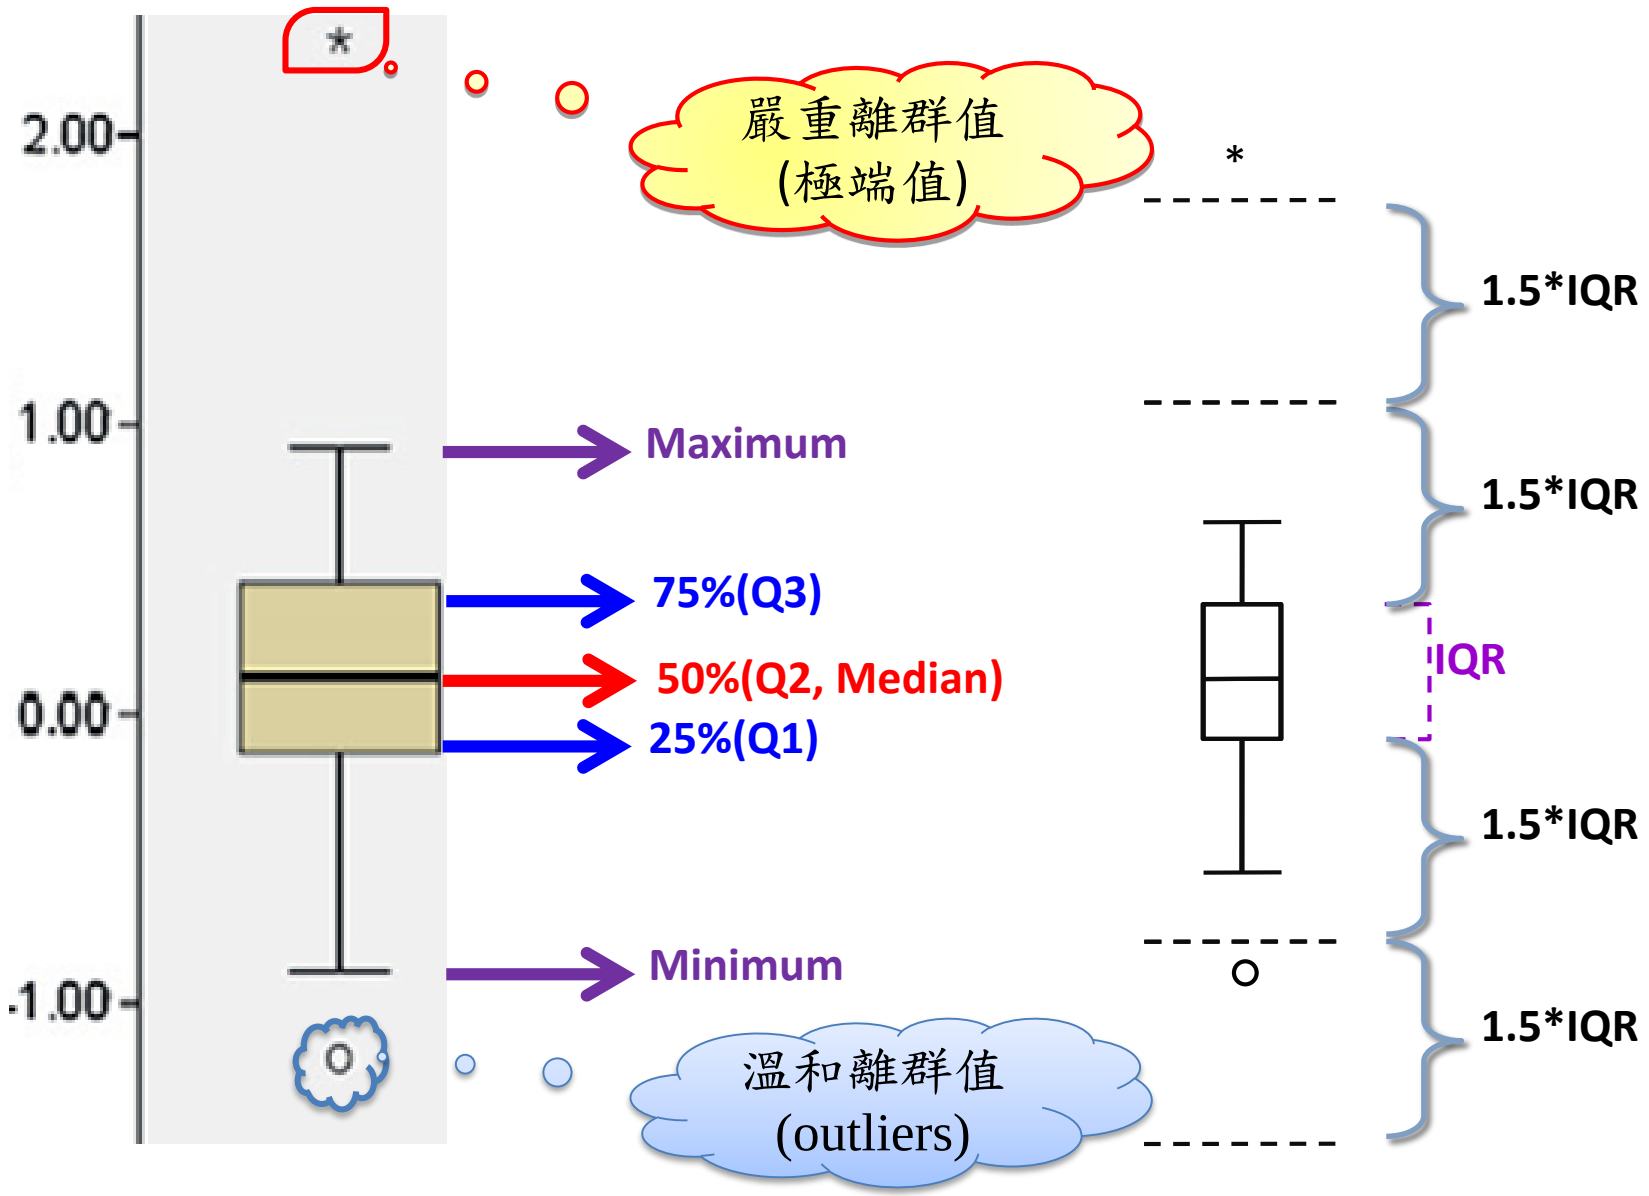
2.00
1.00
0.00
-1.00
嚴重離群值
(極端值)
Maximum
75%(Q3)
50%(Q2, Median)
25%(Q1)
Minimum
溫和離群值
(outliers)
1.5*IQR
1.5*IQR
IQR
1.5*IQR
1.5*IQR

統計圖

- 資料分佈

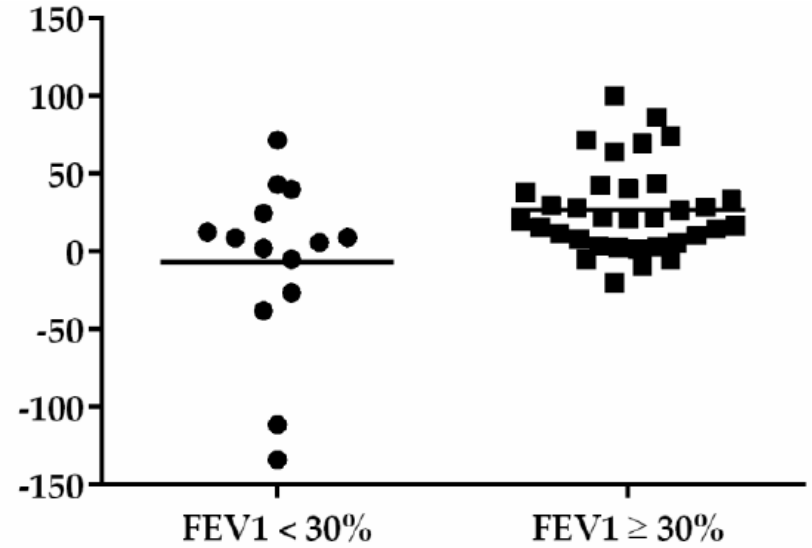

Cheng, Y.Y., Lin, S.Y., Hsu, C.Y., & Fu, P.K. (2022). Respiratory Muscle Training Can Improve Cognition, Lung Function, and Diaphragmatic Thickness Fraction in Male and Non-Obese Patients with Chronic Obstructive Pulmonary Disease: A Prospective Study. J Pers Med. 2022 Mar 16;12(3):475. doi: 10.3390/jpm12030475.

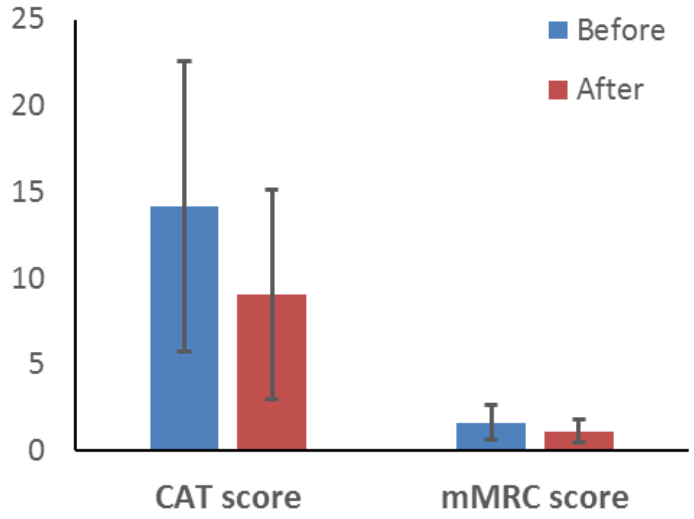

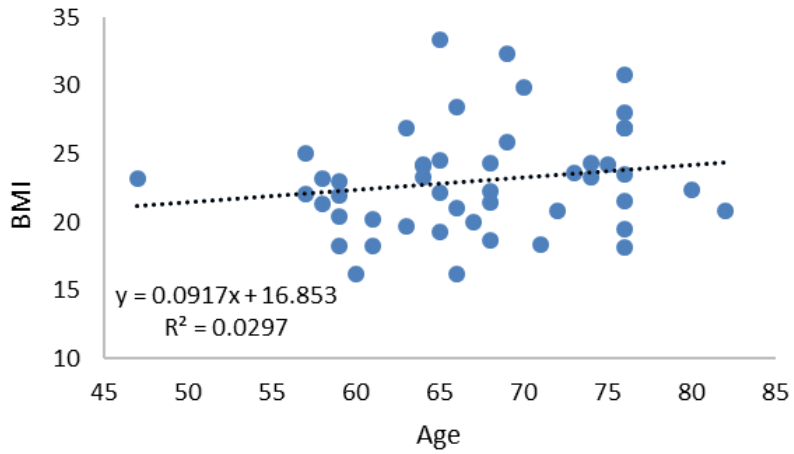

Hypothesis

- Null hypothesis(H0)：虛無假設
- Alternative hypothesis (H1)：對立假設

		真實情形	
		The Null hypothesis(H_0) is true	The Alternative hypothesis (H_1) is true
研究結果	The Null hypothesis(H_0) is true	**Accurate (1-α)**	**Type II error (β)**
	The Alternative hypothesis (H_1) is true	**Type I error (α)**	**Accurate (1-β) (Power)**

α level (推翻虛無假設)

- 可容忍的最大誤差
- 通常設為0.05、0.1及0.01

α level = 0.05
Power = 0.8

Hypothesis

α level = 0.05

雙尾檢定

$H_0 : \mu = \mu_0$

$H_1 : \mu \neq \mu_0$

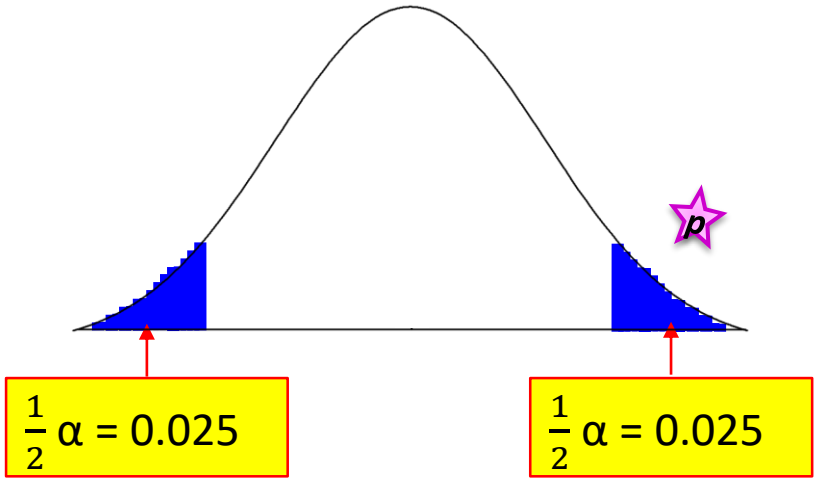

Q1.男女體重是否相同?

Q2.新藥是否比傳統用藥的血壓值較低?

單尾檢定

$H_0 : \mu \leq \mu_0$

$H_1 : \mu > \mu_0$

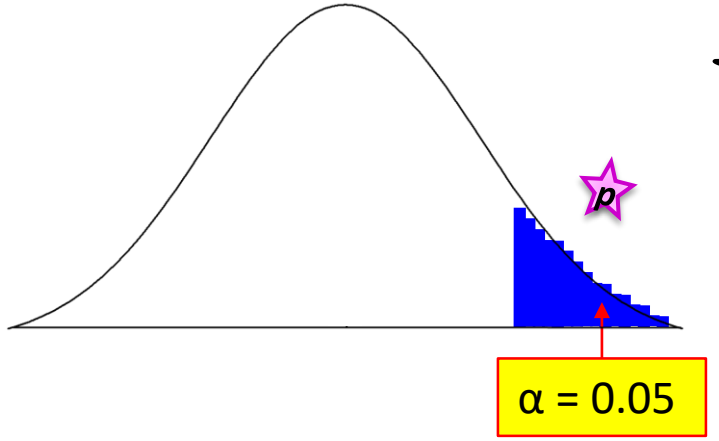

單尾檢定

$H_0 : \mu \geq \mu_0$

$H_1 : \mu < \mu_0$

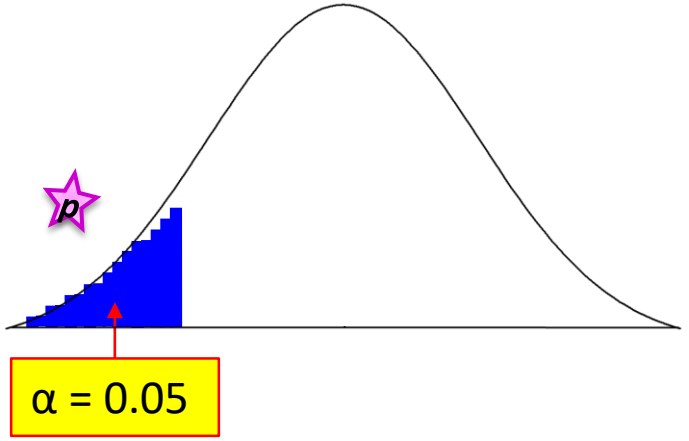

p value

- significance level
  - 機率
    - 錯誤地接受對立假設的統計機率
    - 介於0-1之間
  - 統計顯著差異
    - 與alpha值(α level)比較
      - 接受Alternative hypothesis (H_1)
        - *p* value ≤ α level
      - 接受Null hypothesis (H_0)
        - *p* value > α level

資料建檔-1

ID	性別	年齡	婚姻	教育	體重	身高	抽菸	喝酒	日期
001	M	57	已婚	高中	89	186	無	無	2013/4/1
002	F	46	已婚	大專以上	57	160	有	無	2012/6/28
003	F	55	已婚	國中	90	170	無	無	2013/1/21
004	M	65	已婚	大專以上	60	160	有	有	2014/6/20
005	M	60	已婚	國中	58	162	有	有	2013/9/18

- 欄
  - 變項**數值**
- 列
  - 變數**名稱**
- 譯碼簿(編碼簿 coding book)

資料建檔-2 (譯碼簿)

ID	性別	年齡	婚姻	教育	體重	身高	抽菸	喝酒	日期
001	M	57	已婚	高中	89	186	無	無	2013/4/1
002	F	46	已婚	大專以上	57	160	有	無	2012/6/28
003	F	55	已婚	國中	90	170	無	無	2013/1/21
004	M	65	已婚	大專以上	60	160	有	有	2014/6/20
005	M	60	已婚	國中	58	162	有	有	2013/9/18

轉碼

ID	性別	年齡	婚姻	教育	體重	身高	抽菸	喝酒	日期
001	1	57	1	3	89	186	0	0	2013/4/1
002	0	46	1	4	57	160	1	0	2012/6/28
003	0	55	1	2	90	170	0	0	2013/1/21
004	1	65	1	4	60	160	1	1	2014/6/20
005	1	60	1	2	58	162	1	1	2013/9/18

性別		
	0	F
	1	M

婚姻	
1	已婚
2	單身
3	離婚

教育	
1	小學
2	國中
3	高中
4	大專以上

抽菸	
0	無
1	有

喝酒	
0	無
1	有

文字型態
改為
數值型態

資料建檔-3 (複選題)

請問有無以下疾病？

☐1.高血壓 ☐2.高血脂 ☐3.心臟病 ☐4.糖尿病
☐5.腎炎、腎徵候群及腎性病變 ☐6.慢性阻塞性肺病 ☐7.慢性肝病及肝硬化 ☐8.其他_____

一個變項數值
一個概念

ID	疾病
001	
002	1,4
003	2,4
004	1,2,4
005	3
006	1

高血壓	高血脂	心臟病	糖尿病
0	0	0	0
1	0	0	1
0	1	0	1
1	1	0	1
0	0	1	0
1	0	0	0

資料建檔-4(日期格式)

ID	日期1	日期2	日期3	日期4	日期5
001	2013/4/1	2015/12/10	20130401	1020401	102/4/1
002	2012/6/28	2015/11/27	20120628	1010628	101/6/28
003	2013/1/21	2015/12/12	20130121	1020121	102/1/21
004	2014/6/20	2015/12/8	20140620	1030620	103/6/20
005	2013/9/18	2015/12/3	20130918	1020918	102/9/18

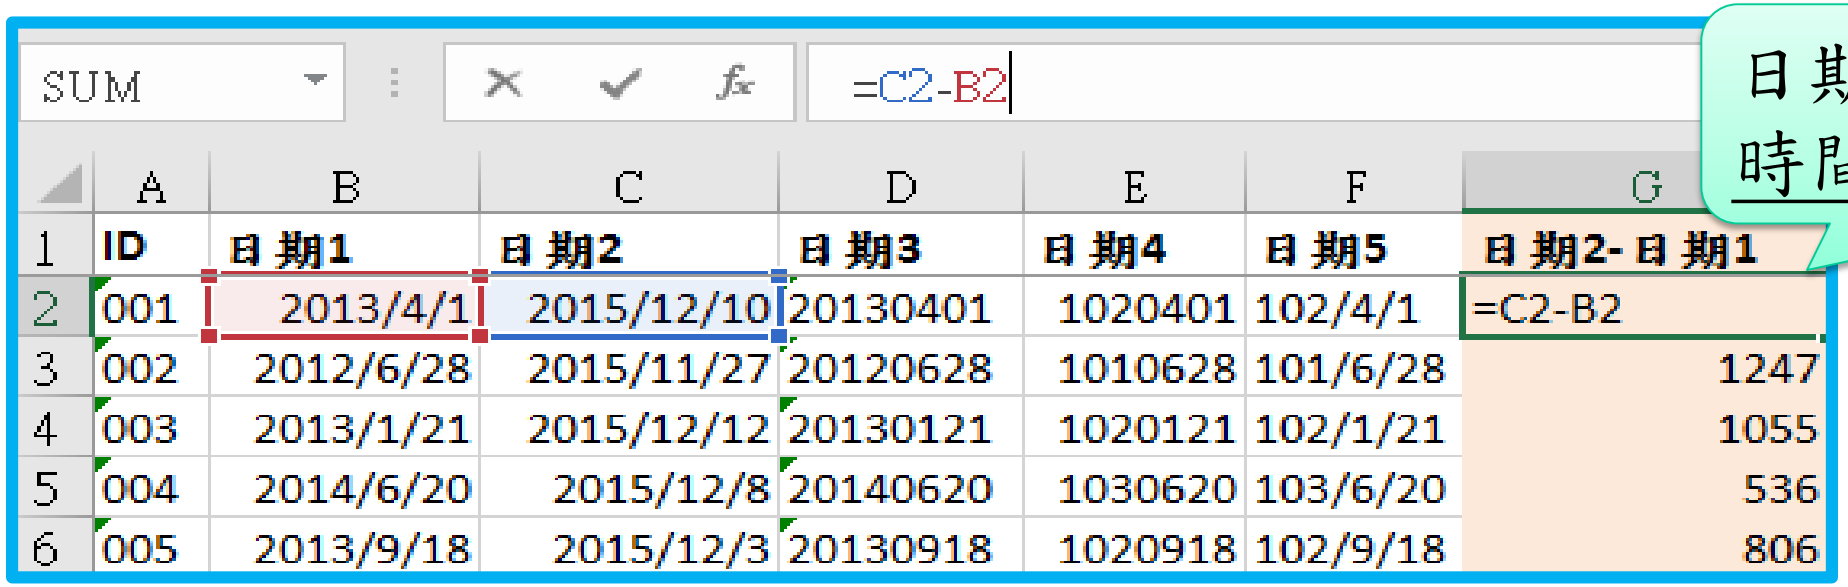

日期格式可直接計算時間差(**天數**)

資料建檔-5

- 簡單且明確建檔
  - 不同檔案各別建立
    - 基本資料
    - 追蹤資料
  - 關鍵字(如病歷號)合併資料

ID	Training mode	Age	BMI	CAT score (Before)	mMRC score (Before)
N01	0	57	25	23	3
N02	0	67	20	27	2
N03	0	63	20	16	3
N04	0	76	24	19	3
N05	0	57	22	19	3
N06	1	66	16	28	3
N07	1	65	25	18	1
N08	1	64	23	12	1

ID	CAT score (After)	mMRC score (After)
N01	10	1
N02	10	1
N03	13	1
N04	4	1
N05	16	3
N06	13	1
N07	16	2
N08	20	2

資料檔範例-1

- 不建議建檔方式

ID	Training mode	Age	BMI	Time	CAT score	mMRC score
N01	0	57	25	Before	23	3
				After	10	1
N02	0	67	20	Before	27	2
				After	10	1
N03	0	63	20	Before	16	3
				After	13	1
N04	0	76	24	Before	19	3
				After	4	1
N05	0	57	22	Before	19	3
				After	16	3
N06	1	66	16	Before	28	3
				After	13	1
N07	1	65	25	Before	18	1
				After	16	2
N08	1	64	23	Before	12	1
				After	20	2

資料檔範例-2

- 無法直接檢定的類型
  - 彙整資料

年度	評分項目	Dis1						Dis2						Dis3						總平均
		優	佳	普通	待改進	差	分數	優	佳	普通	待改進	差	分數	優	佳	普通	待改進	差	分數	
2019	A	4	2	0	0	0	91.7	2	3	0	0	0	89.0	1	3	2	0	0	83.3	88.0
	B	3	3	0	0	0	90.0	5	0	0	0	0	95.0	0	4	1	1	0	80.0	88.3
	C	2	4	0	0	0	88.3	4	1	0	0	0	93.0	2	1	3	0	0	83.3	88.2
	D	4	2	0	0	0	91.7	4	1	0	0	0	93.0	3	3	0	0	0	90.0	91.6
	E	6	0	0	0	0	95.0	4	1	0	0	0	93.0	3	3	0	0	0	90.0	92.7
	F	3	3	0	0	0	90.0	5	0	0	0	0	95.0	2	4	0	0	0	88.3	91.1
2020	A	4	0	0	0	0	95.0	2	2	0	0	0	90.0	4	2	0	0	0	91.7	92.2
	B	0	2	2	0	0	80.0	2	2	0	0	0	90.0	3	2	1	0	0	88.3	86.1
	C	0	2	2	0	0	80.0	3	0	1	0	0	90.0	3	3	0	0	0	90.0	86.7
	D	4	0	0	0	0	95.0	4	0	0	0	0	95.0	5	1	0	0	0	93.3	94.4
	E	4	0	0	0	0	95.0	3	1	0	0	0	92.5	5	1	0	0	0	93.3	93.6
	F	1	2	1	0	0	85.0	2	2	0	0	0	90.0	4	2	0	0	0	91.7	88.9
2021	A	3	4	0	0	0	89.3	3	2	0	0	0	91.0	5	0	0	0	0	95.0	91.8
	B	4	3	0	0	0	90.7	3	1	1	0	0	89.0	1	3	1	0	0	85.0	88.2
	C	4	3	0	0	0	90.7	3	2	0	0	0	91.0	3	2	0	0	0	91.0	90.9
	D	5	2	0	0	0	92.1	2	3	0	0	0	89.0	5	0	0	0	0	95.0	92.0
	E	5	2	0	0	0	92.1	3	2	0	0	0	91.0	5	0	0	0	0	95.0	92.7
	F	5	2	0	0	0	92.1	4	1	0	0	0	93.0	5	0	0	0	0	95.0	93.4

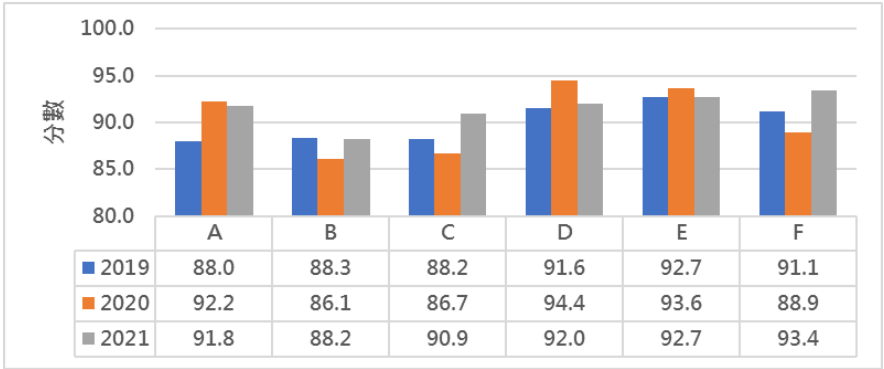

資料檔範例-3

- 統計軟體無法直接計算的類型
  - 變項『數值』及『名稱』位置相反

ID	N01	N02	N03	N04	N05	N06	N07	N08
Training mode	0	0	0	0	0	1	1	1
Age	57	67	63	76	57	66	65	64
BMI	25	20	20	24	22	16	25	23
CAT score (Before)	23	27	16	19	19	28	18	12
CAT score (After)	10	10	13	4	16	13	16	20
mMRC score (Before)	3	2	3	3	3	3	1	1
mMRC score (After)	1	1	1	1	3	1	2	2

資料檔範例-4

- 需要進行清理/擷取的資料

病歷號	檢查日期	檢查項目	檢查數值
[redacted]	20090115	HGB	10.4
[redacted]	20090115	PLT	398
[redacted]	20090115	WBC	9400
[redacted]	20090115	ALB	3
[redacted]	20090115	Creatinnine	1.3
[redacted]	20090115	GPT	11
[redacted]	20090115	Glucose	110
[redacted]	20090120	HGB	10
[redacted]	20090121	Glucose	NEG
[redacted]	20090123	Creatinnine	0.8
[redacted]	20090123	HGB	10.6
[redacted]	20090123	LYM	9.5
[redacted]	20090123	NEUT	83.3
[redacted]	20090123	PLT	301
[redacted]	20090123	WBC	12900
[redacted]	20090204	Creatinnine	0.9
[redacted]	20090204	HGB	11.2
[redacted]	20090204	WBC	10400
[redacted]	20090205	Glucose	NEG
[redacted]	20090209	HGB	10.4
[redacted]	20090209	WBC	8800
[redacted]	20090209	Creatinnine	1

資料檔範例-5

Age	Age	BMI	BMI
Male	Female	Male	Female
57	57	25	22
58	58	23	21
59	59	23	20
59	59	22	18
60	61	16	20

一個變項數值
一個概念
但這樣是對的嗎？

Sex	Age	BMI
1	57	25
1	58	23
1	59	23
1	59	22
1	60	16
2	57	22
2	58	21
2	59	20
2	59	18
2	61	20

動手做做看-資料建檔

- 從以下資料試著自行輸入資料

序號0597

1. 生日：23.10.01
2. Sex：■ Male □ Female
3. BMI：24
4. Smoking：□ No ■ Yes
5. Albumin (g/dL) ：3.6
6. Hba1c (%)：____
7. Proteinuria (mg/g)：0.08
8. Diuretics：□ No ■ Yes
9. MRA：□ No ■ Yes

序號1713

1. 生日：1945.09.05
2. Sex：□ Male ■ Female
3. BMI：___
4. Smoking ：■ No □ Yes
5. Albumin (g/dL) ：___
6. Hba1c (%)：7.9
7. Proteinuria (mg/g)：___
8. Diuretics： ■ No □ Yes
9. MRA： ■ No □ Yes

序號0796

1. 生日：33/11/01
2. Sex：□ Male ■ Female
3. BMI：26
4. Smoking ：■ No □ Yes
5. Albumin (g/dL) ：3.9
6. Hba1c (%)：5.7
7. Proteinuria (mg/g)：0.13
8. Diuretics：■ No □ Yes
9. MRA：■ No □ Yes

動手做做看-統計值/統計圖

- EXECL
  - Bar chart (mean ± SD)
  - Scatter plot

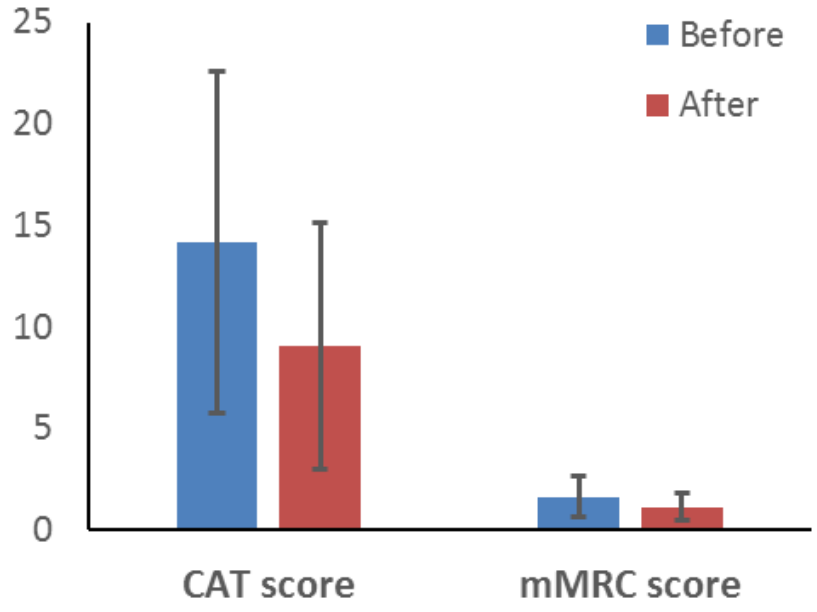

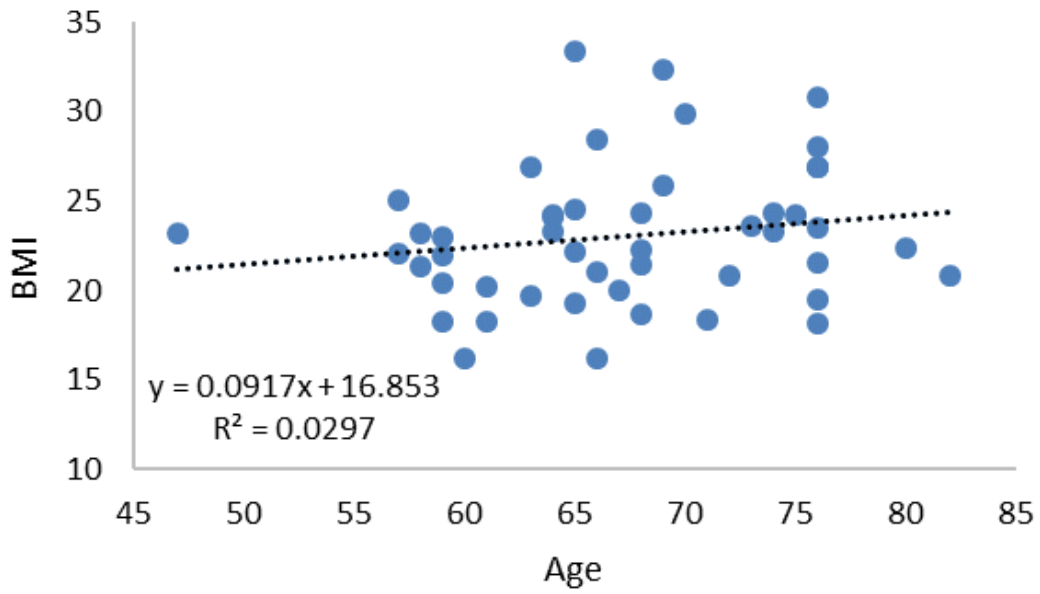

動手做做看(練習資料檔.xlsx)

ID	Age	BMI	CAT0	CAT1	mMRC0	mMRC1
N01	57	25	23	10	3	1
N02	67	20	27	10	2	1
N03	63	20	16	13	3	1
N04	76	24	19	4	3	1
N05	57	22	19	16	3	3
N06	66	16	28	13	3	1
N07	65	25	18	16	1	2
N08	64	23	12	20	1	2
N09	76	22	2	3	1	0
N10	76	27	33	21	2	1
N11	69	32	20	7	3	1
N12	59	20	19	15	1	1
N13	58	21	17	9	3	2
N14	61	20	18	18	2	2
N15	71	18	34	19	4	2
N16	76	20	5	8	1	1
N17	64	24	6	2	1	1
N18	59	23	15	5	1	1
N19	72	21	9	4	1	1
N20	74	23	10	6	2	1
N21	58	23	5	3	0	1
N22	80	22	7	7	1	1
N23	68	19	15	4	2	1
N24	68	22	14	6	2	1
N25	75	24	15	7	2	1
N26	76	18	11	8	2	2
N27	47	23	21	10	0	0
N28	65	22	5	3	1	1
N29	76	31	23	10	2	2
N30	73	24	26	9	3	2
N31	65	19	24	7	3	1
N32	64	24	9	6	1	1
N33	82	21	8	27	2	2
N34	63	27	16	4	1	1
N35	76	28	11	5	1	1
N36	66	21	22	12	2	1
N37	68	22	15	11	1	1
N38	59	22	7	5	1	0
N39	74	24	2	2	1	0
N40	76	27	3	2	1	1
N41	60	16	9	10	1	1
N42	65	33	6	6	1	1
N43	70	30	18	13	1	2
N44	68	24	3	2	1	0
N45	66	28	3	1	0	0
N46	61	18	0	2	0	0
N47	59	18	14	15	1	1
N48	69	26	18	19	3	2

CAT0	CAT score (Before)
CAT1	CAT score (After)
mMRC0	mMRC score (Before)
mMRC1	mMRC score (After)

Thank you

問卷調查

10/18問卷

For your attention!!