

統計實務

Spring 2024

授課教師：統計系余清祥

日期：2024年2月21日

第一週：課程介紹



本課程的目標



<https://leverageedu.com/blog/application-of-statistics/>

- 介紹以統計思維解決實務問題。
 - 例如：變數間的關聯經常是研究議題，藉此提高利潤與管理績效。
- 統計不僅是一門資料分析的科學，也是一門決策科學，能協助訂定正確決策。
 - 未來情況視為隨機事件，統計決策提供在不確定性時的處理原理和方法，在各領域經營決策中有廣泛應用。（*MBA 智庫百科*）

為什麼學統計？



<https://www.eapfoundation.com/writing/essays/problemsolution/>

- 當我們遭遇問題時，如何做出選擇及判斷？
 - 政大附近的餐廳、購物及購書的選擇、畢業後的生涯規劃？（資訊來源及可信度）
 - 學校篩選申請者、工作過濾求職履歷、銀行核准貸款及信用卡（推薦及評分系統）
 - 選擇錄取的學校或公司、總統大選民調的誤差範圍是3%或6%？（解讀結果及決策）

統計思維

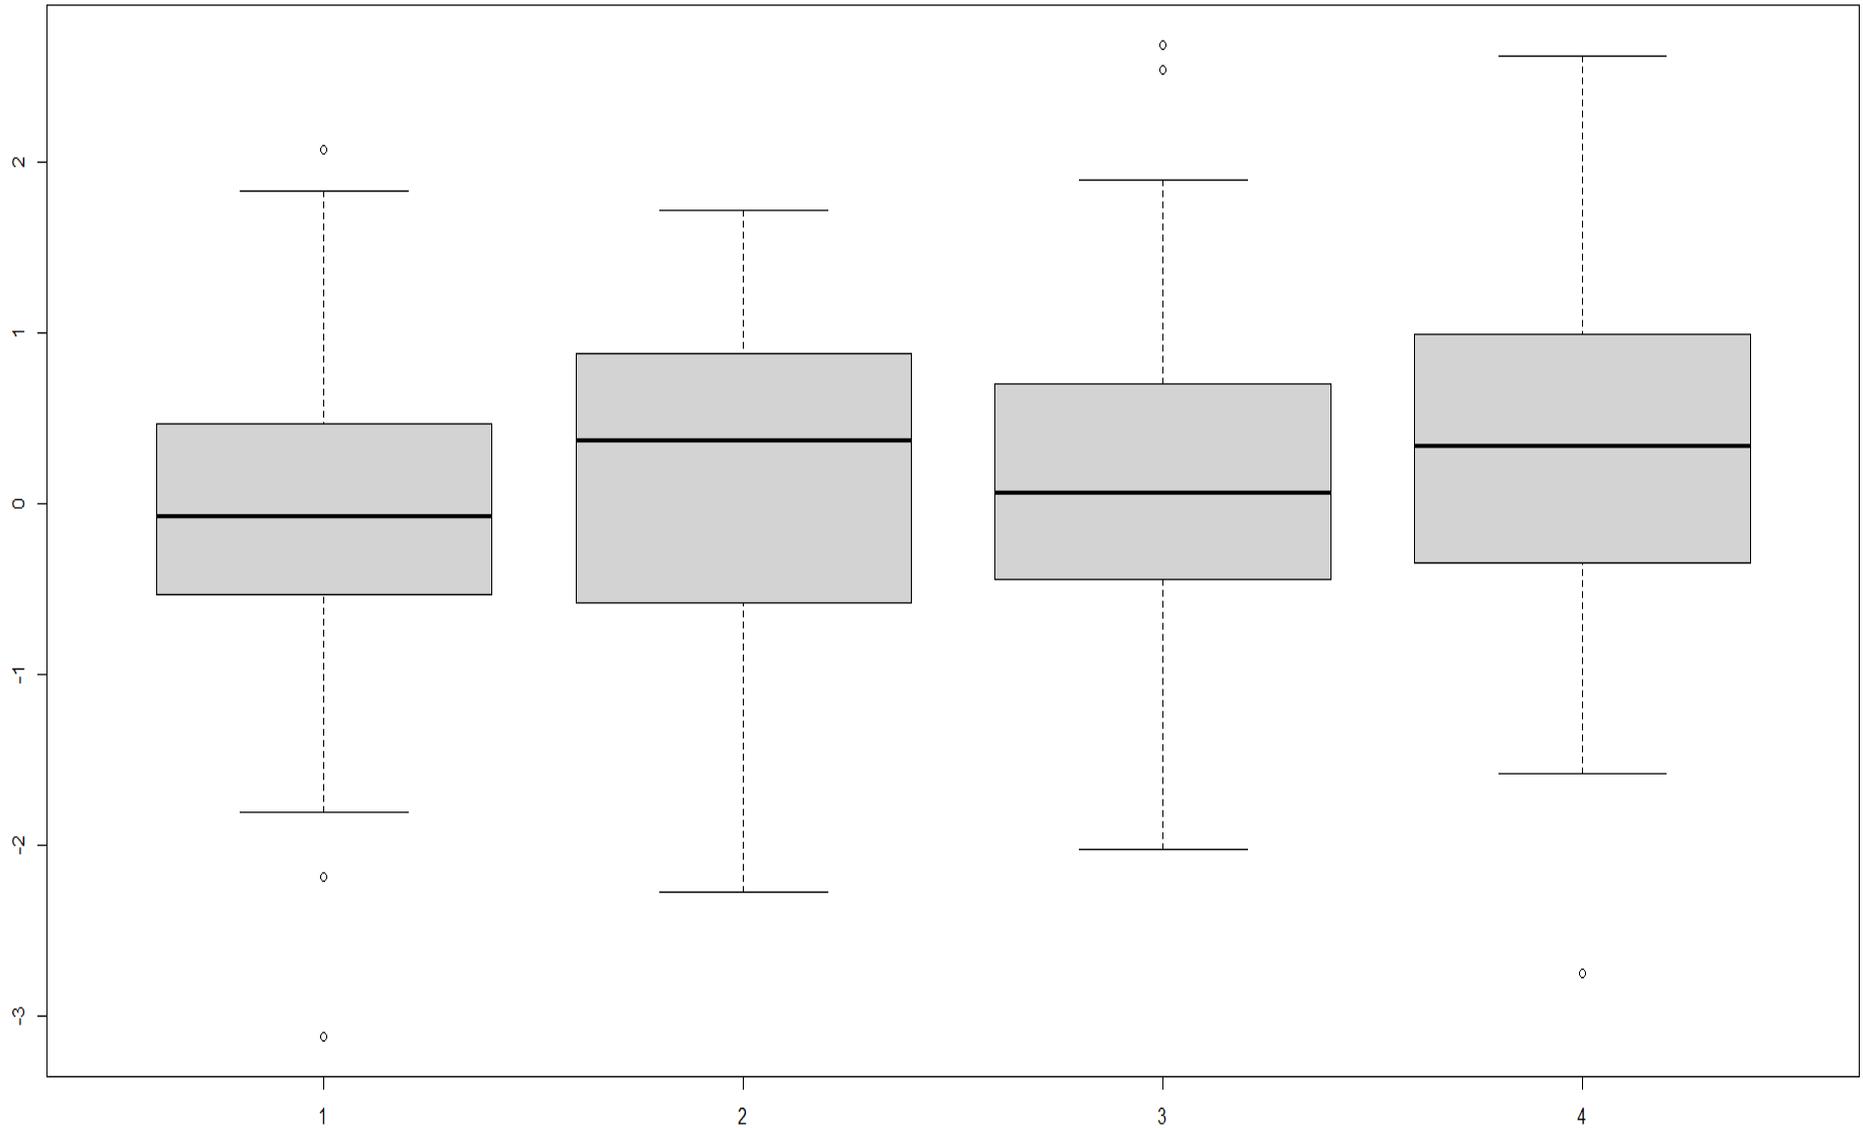
□ **Statistical thinking** is based on **probabilistic thinking**.

Learn to see probabilities everywhere and consider how you'd calculate them. Get rid of deterministic thinking altogether. Deterministic thinking is encapsulated by the phrase "everything happens for a reason." Probabilistic thinking's motto is "stuff happens." If you arise in the morning with a head cold, don't try to identify who gave it to you. It's a probabilistic event, so treat it as such.

Dropping a pencil, stopping at an ATM that is out of order, finding a prime parking spot, all are probabilities. See all things in your life as events. ---by Tim Altom

來源：<https://www.quora.com/What-are-some-examples-of-statistical-thinking>

統計思維的範例



分析結果

- 四組資料為 $N(\mu, 1)$ 的100筆亂數，期望值分別為0、0.1、0.2、0.3。
 - 兩兩 t 檢定的p-value，僅有第一組及第四組有差異（p-value < 0.01）。
- 遞移律未必成立（ $\mu_1 = \mu_2$ & $\mu_2 = \mu_3 \rightarrow \mu_1 = \mu_3$ ）
 - 統計數值不是必然結果，其中隱含不確定性，無法套用一般數學計算的規則！
- 延伸問題：如何由統計表達「 $\mu_1 > \mu_2$ 」？

柯侯5:侯柯2

11/15 美麗島73波



侯柯配+1

11/14 ETtoday



侯柯配+1

11/14 聯合報

誤差2.9%，柯領先3%

柯侯配+1

11/14 美麗島72波

重複，採納最新版11/15

ETtoday是採網路問卷，主動填寫回覆民調，容易有灌票可能，也非經驗證的科學民調

11/13 匯流

柯侯配+1

11/11 美麗島71波

重複，採納最新版11/15

11/10 美麗島70波

重複，採納最新版11/15

11/9 美麗島69波

重複，採納最新版11/15

11/9 ETtoday

重複，採納最新版11/14

11/8 美麗島68波

重複，採納最新版11/15

11/8 趨勢

柯侯配+1

11/8 世新大學

柯侯配+1

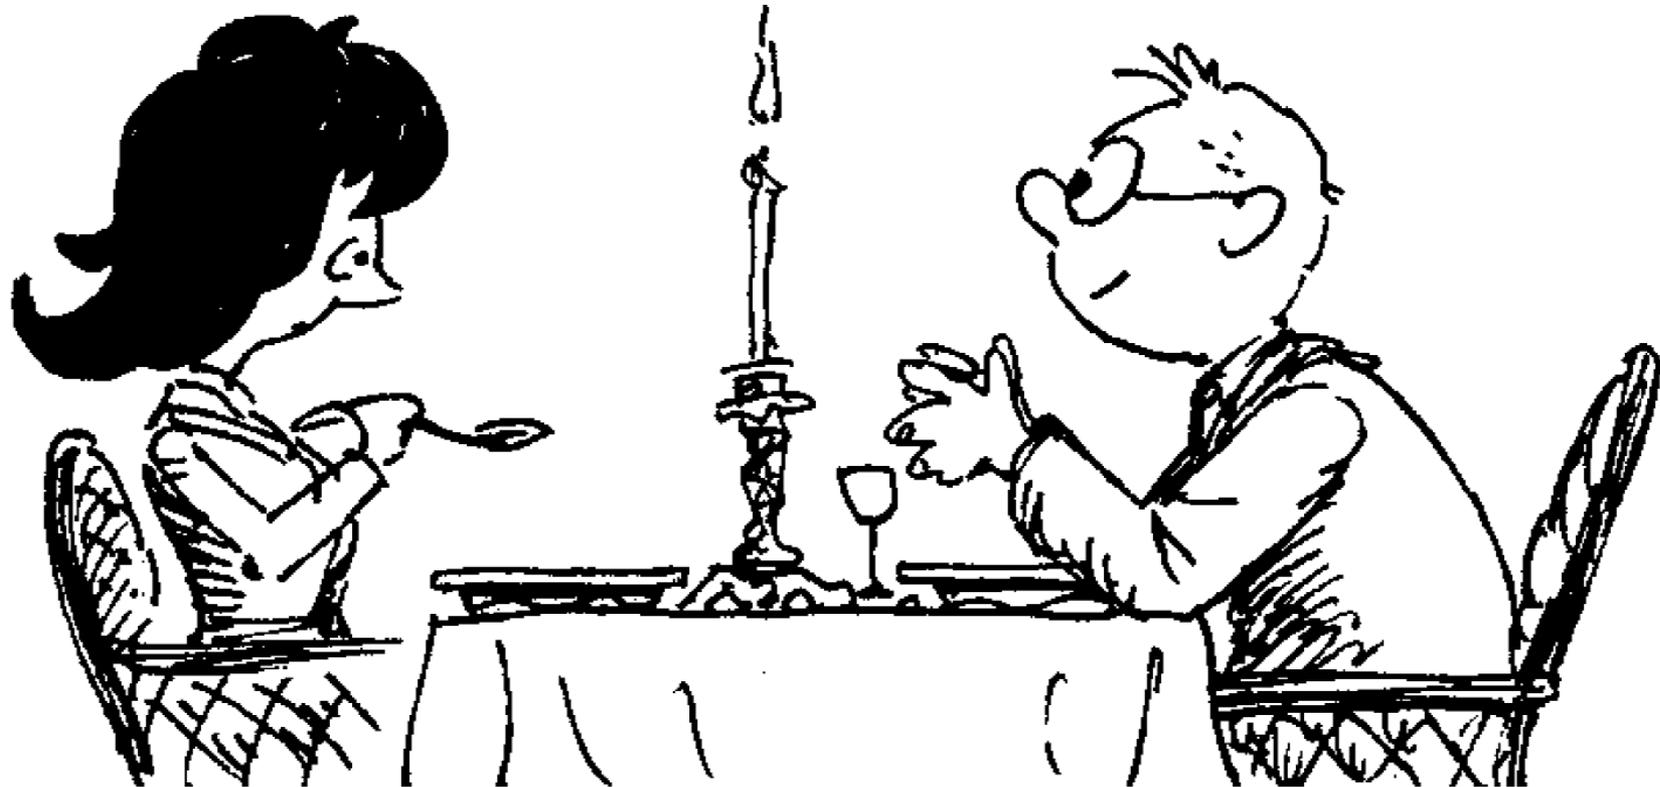
11/8 求真

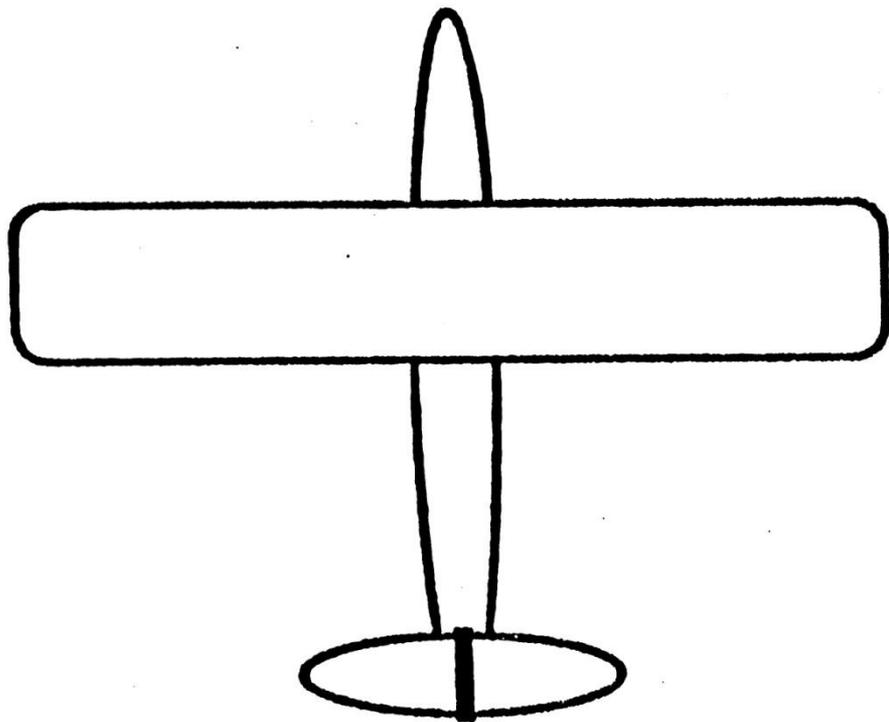
柯侯配+1

11/7 美麗島67波

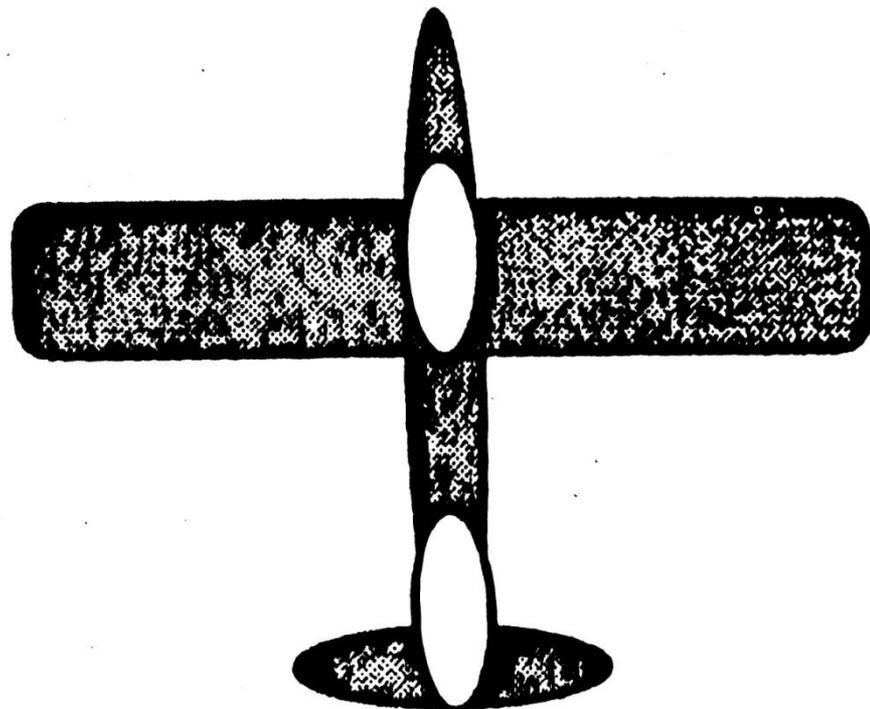
重複，採納最新版11/15

GOOD CHOICE! I'M 95%
CONFIDENT THAT TONIGHT'S
SOUP HAS PROBABILITY
BETWEEN 73% AND 77% OF
BEING REALLY DELICIOUS!



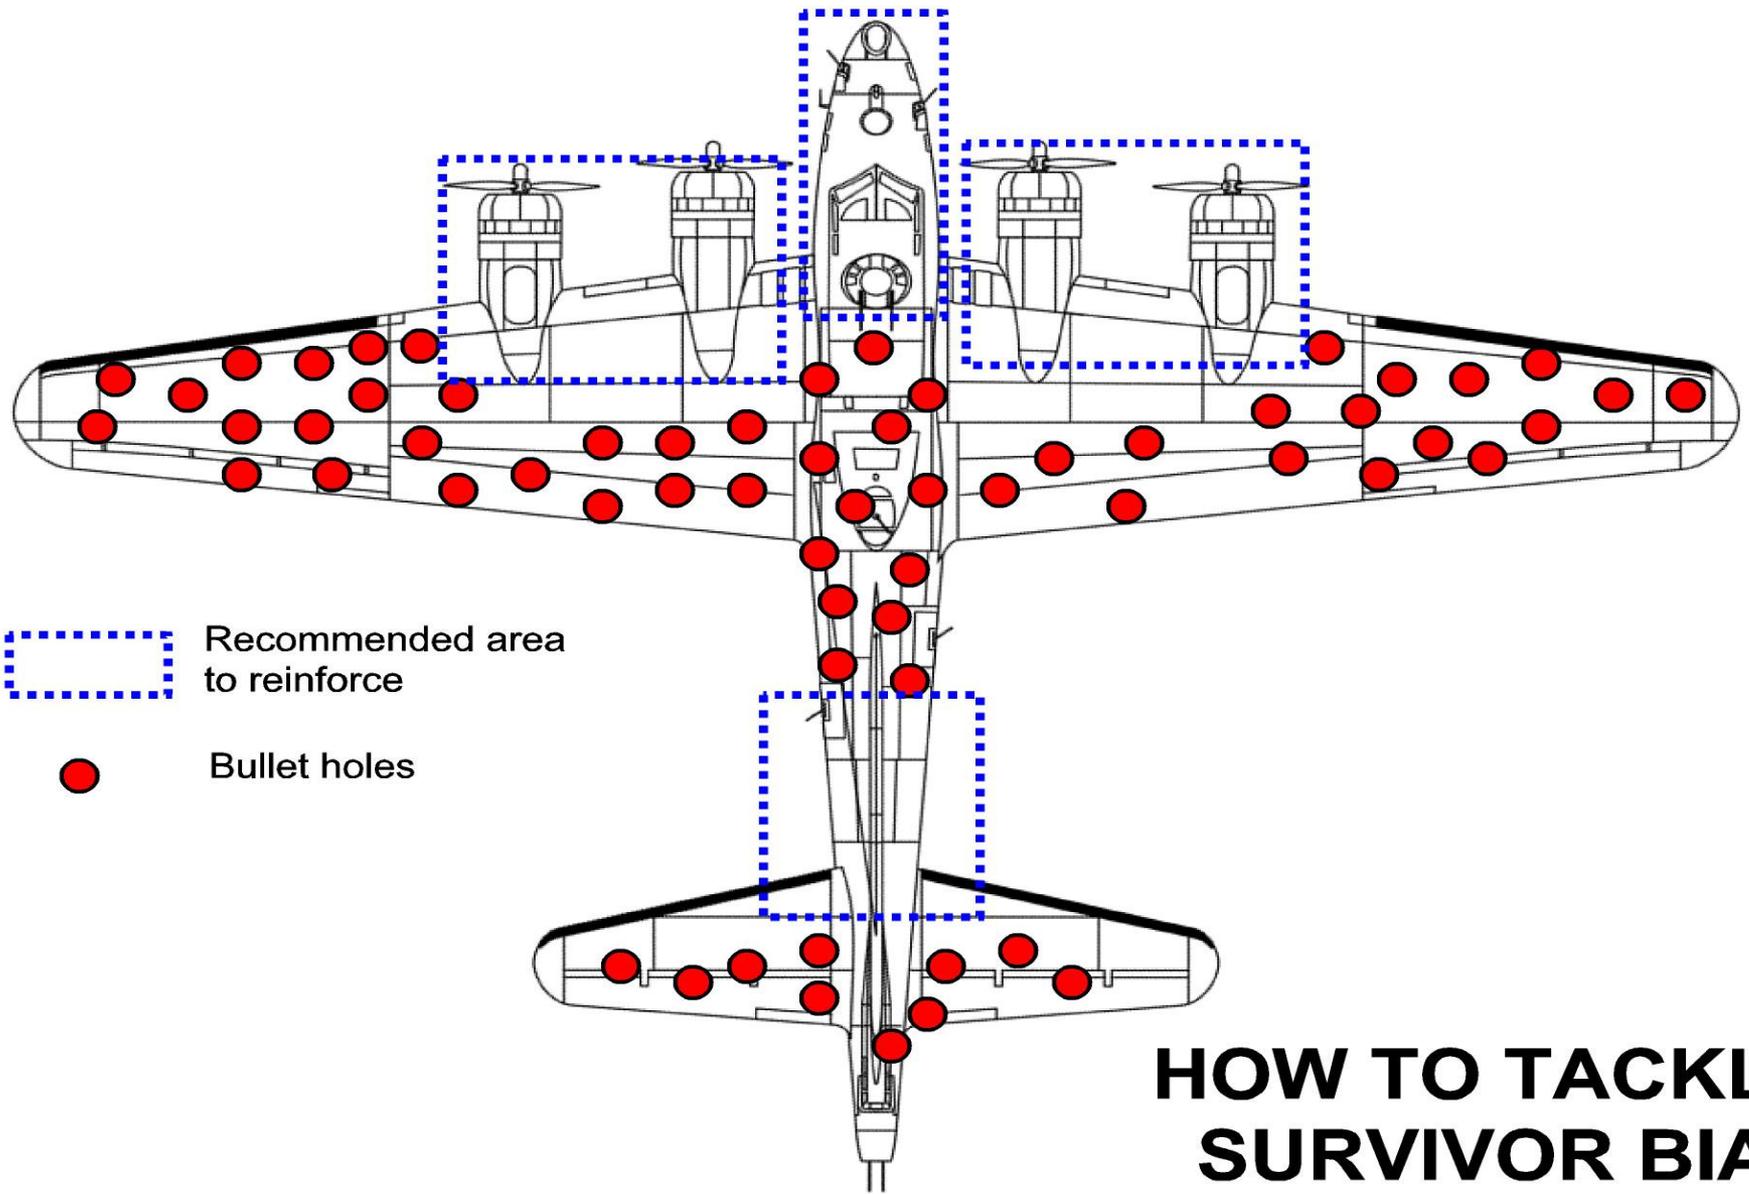


Before



After

A graphical depiction of Wald's bullethole data.



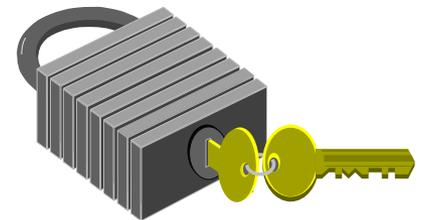
**HOW TO TACKLE
SURVIVOR BIAS**

倖存者偏差 (Survivorship Bias)



什麼是統計？

- 統計學是在資料分析的基礎上，研究測定、收集、整理、歸納和分析反映數據資料，以便給出正確訊息的科學。（維基百科）
- 統計學是研究定義問題、運用資料蒐集、整理、陳示、分析與推論等科學方法，在不確定(Uncertainty)情況下，做出合理決策的科學。（我的詮釋！）





<https://www.facebook.com/Dironetv/>

統計—21世紀的明星產業

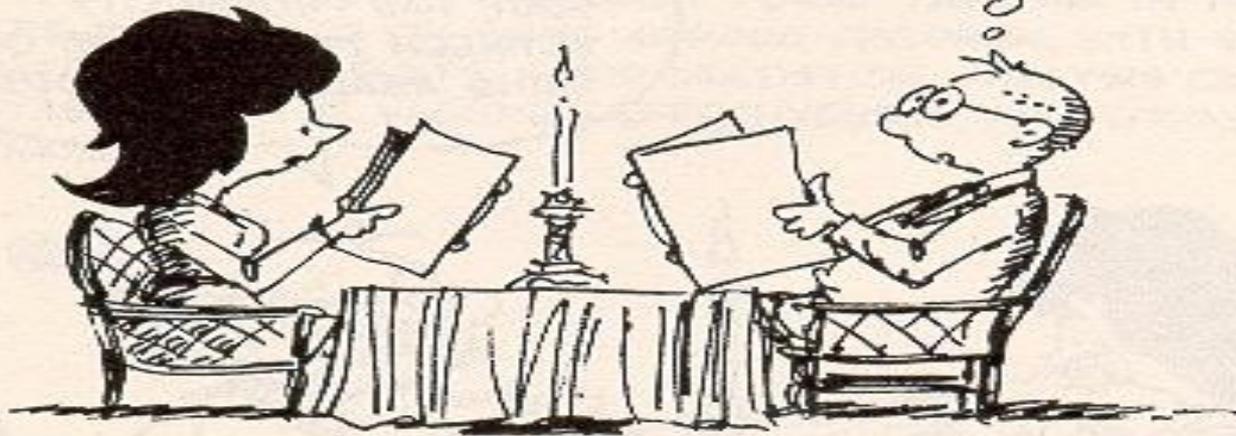
- 大數據的興起（IBM, 2010），激盪出新一波知識革命及產業。
 - 大數據似乎無所不在（無所不能），但其中也存在許多迷思。（請同學舉例？）
- 問題：在大數據時代裡，統計憑藉哪些本領、可以創造哪些價值？
 - 統計專業人員必須具備哪些技能與知識，以因應大數據帶來的挑戰？

WHAT IS STATISTICS?

WE MUDDLE THROUGH LIFE MAKING CHOICES
BASED ON INCOMPLETE INFORMATION...

SHOULD I HAVE THE SOUP?
EVERYTHING ELSE IS SO
EXPENSIVE, AND I DON'T
KNOW WHO'S PAYING... ARE
STATISTICIANS STINGY? I'VE
NEVER GONE OUT WITH
ONE BEFORE... THOUGH I
ONCE KNEW A VERY
GENEROUS ACCOUNTANT...

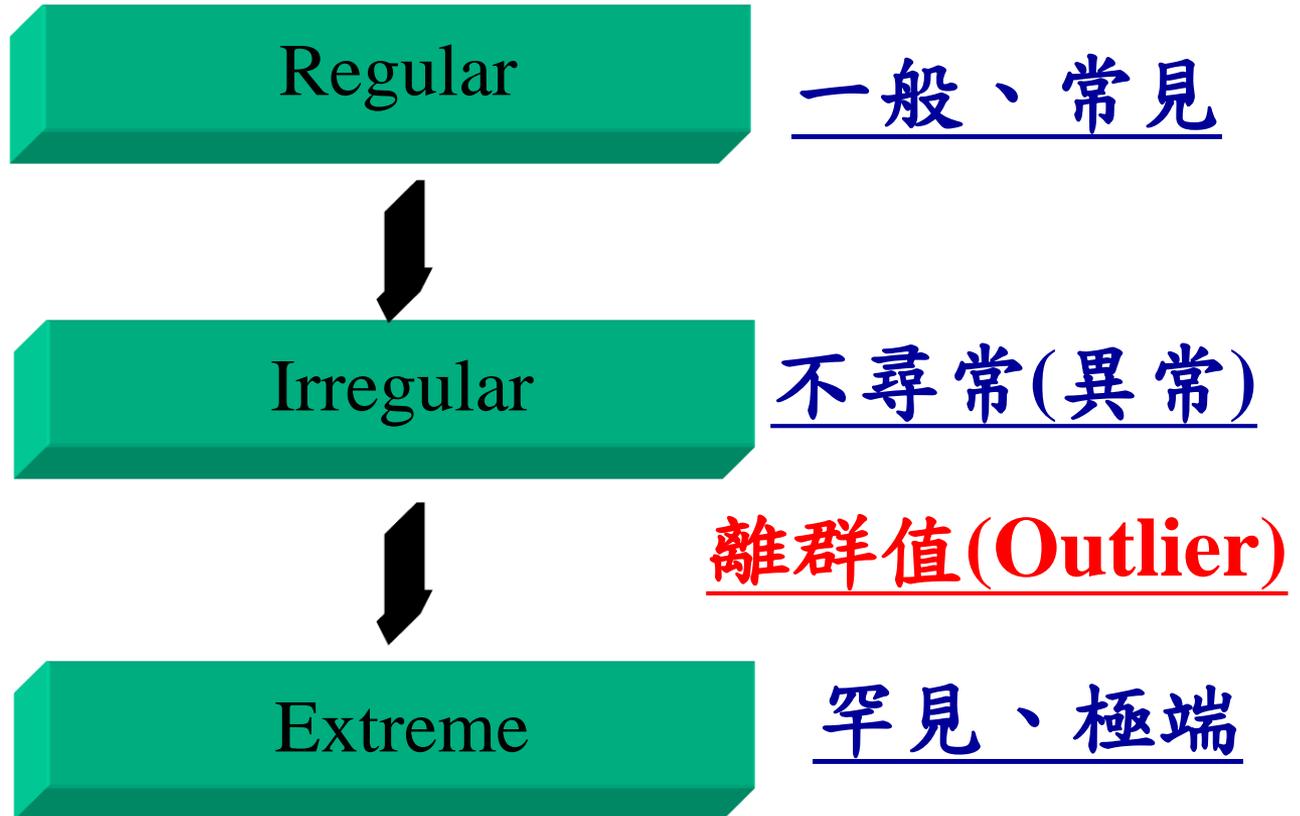
SHOULD I HAVE THE SOUP?
27 OUT OF THE 36 TIMES
I'VE HAD IT, IT WAS PRETTY
GOOD... BUT IS MONDAY THE
REGULAR CHEF'S NIGHT
OFF? AND WHAT IF ALL THE
AIR MOLECULES IN THE
ROOM SUDDENLY FLY UP TO
THE CEILING?

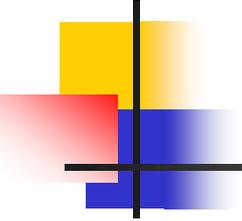


統計與知識

- 統計分析屬於歸納法(Induction)，從龐雜資料找出共同趨勢，區分資料哪一種特性：

特例





數據 (Data)

資訊 (Information)

事實 (Fact)

知識 (Knowledge)



商學院有3G（三「計」）

會計——很快忘記！

經濟——經常忘記！！

統計——通通忘記！！！！

註：為什麼這三門課特別棘手，統計似乎最難上手？



馬克吐溫對統計的想法

There are three kinds of lies:

Lies,

Damned lies,

and **Statistics!!**



FINALLY, IN DISCUSSING STATISTICS, IT'S HARD TO AVOID MENTIONING ONE OTHER THING: THE WIDESPREAD MISTRUST OF STATISTICS IN THE WORLD TODAY. EVERYONE KNOWS ABOUT "LYING WITH STATISTICS," WHILE GOOD STATISTICAL ANALYSIS IS NEARLY IMPOSSIBLE TO FIND IN DAILY LIFE. WHAT'S ONE TO DO?

3 OUT OF 4 DOCTORS RECOMMEND NOT BELIEVING ANY STATEMENT BEGINNING WITH "3 OUT OF 4 DOCTORS..."

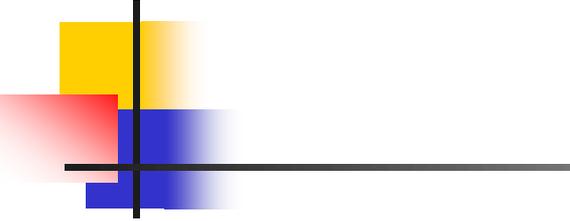


如何解決問題？



- 解決問題(Problem Solving)的訓練，關鍵因素在於問題定義(Problem Definition)。
 - 《你拿什麼定義自己？：組織大師韓第的生命故事》
- 定義問題，需要背景相關知識及協助判斷的資訊，探索性資料分析可提供協助。
 - 《統計，改變了世界》
 - 《統計能為你做些什麼》

解決問題(Problem Solving)的流程



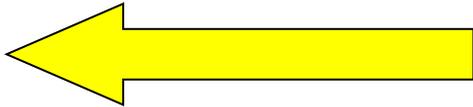
定義問題

蒐集資料



分析資料

詮釋結果



絕大多數的
統計教學重心

資訊與知識的價值

- 資料挖掘(Data Mining)的範例：\$ \$ \$ \$
- 協助超級市場促銷及陳設商品。

Milk, eggs, sugar,
bread



Customer1

Milk, eggs, cereal, bread



Customer2

Eggs, sugar



Customer3

沃馬特量販店(Wal-Mart)

□ 沃馬特最先蒐集、分析顧客資料，並以整理所得的資訊，提高銷售業績。

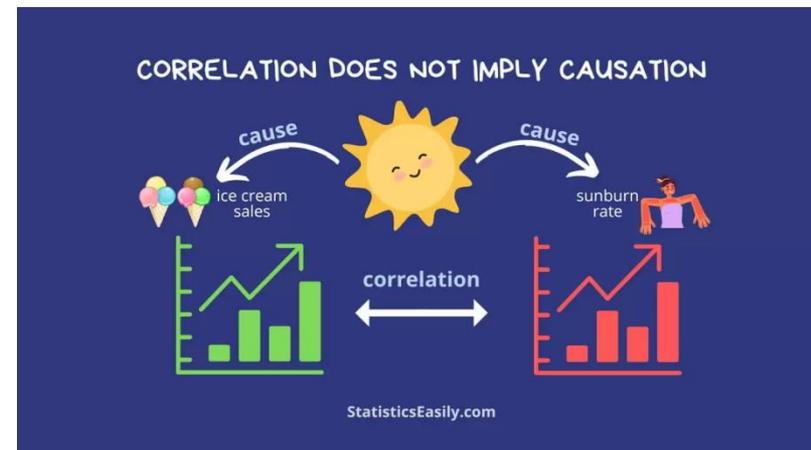
→ 不少美國消費者週末同時購買尿布及啤酒。

□ 問題：為什麼這兩種商品會一起購買？如何將這份資訊轉變為業績？

註：沃馬特從美國西南部發跡，剛開始只是一家五金行，現在是全美最大百貨零售業者。

「尿布與啤酒」的延伸價值

- ❑ 問題：尿布與啤酒屬於關聯性 (Association) 關係或是大家有興趣的因果關係 (Causality)？
- ❑ 關聯性的價值未必低於因果關係，像是尿布與啤酒的關連，可用於：
 - 商品定價與促銷；
 - 商品擺設（商場動線）；
 - 商品倉儲。



寶可夢旋風也能帶來商機嗎？



參考資料：<https://tw.news.yahoo.com/%E5%8F%B0%E5%8D%97%E5%A1%9E%E7%88%86-%E5%B0%8F%E9%BB%83%E7%B4%99%E6%A2%9D%E6%9B%9D-%E9%BE%9C%E9%80%9F%E5%8E%9F%E5%9B%A0-%E7%B6%B2%E7%AC%91-%E4%B8%8D%E5%8F%AD%E4%BD%A0%E4%BA%86-143342818.html>



「Pokémon GO Safari Zone in Tainan」今（1）日早上10點半開始將連續5天展開，而這場寶可夢盛會預計帶來的人潮預估將有20萬，各大飯店民宿住房率超過8成，甚至有業者開心表示，「比陸客來台還有用！」

三立新聞網 2018年11月1日 上午11:06

Pokémon GO Safari Zone in Tainan (寶可夢台南狩獵區)：估計主場都會公園奇美博物館有8萬人，大台南全區16萬人，連續五天活動總計主場有56萬人次，台南全區100萬人次。 六億商機！！
今日新聞NOWnews 記者陳聖璋 2018年11月5日



統計與理性判斷

A patient takes a lab test and the result comes back positive. The test returns a correct positive result in 99% of the cases in which the disease is actually present, and a correct negative result in 98% of the cases in which the disease is not present. Furthermore, .001 of all people have this cancer.

$$P(\text{cancer}) = .001 \quad P(\sim \text{cancer}) = .999$$

$$P(+ | \text{cancer}) = .99 \quad P(- | \text{cancer}) = .01$$

$$P(+ | \sim \text{cancer}) = .02 \quad P(- | \sim \text{cancer}) = .98$$

$$P(\text{cancer} | +) = \frac{P(+ | \text{cancer}) P(\text{cancer})}{P(+)} = \mathbf{.047}$$

計算細節



□ 假設某地區有一百萬人：

→ 999,000人健康，1,000人罹患癌症

→ 檢查出陽性反應者：

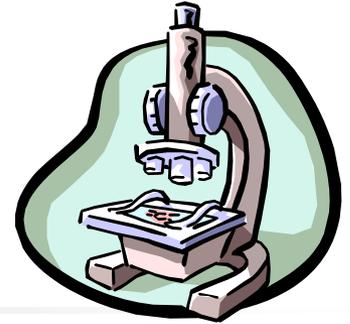
(1) 健康者中有 $999,000 \times 2\% = 19,980$

(2) 癌症患者中有 $1,000 \times 99\% = 990$

因此，癌症患者佔陽性反應者的比例：

$$P(\text{cancer} | +) = \frac{990}{19,980 + 990} = \frac{990}{20,970} \cong 4.72\%$$

第二意見(second opinion)



Suppose a second test for the same patient returns a positive result as well. What are the posterior probabilities for cancer?

$$P(\text{cancer}) = .001$$

$$P(\sim\text{cancer}) = .999$$

$$P(+ \mid \text{cancer}) = .99$$

$$P(- \mid \text{cancer}) = .01$$

$$P(+ \mid \sim\text{cancer}) = .02$$

$$P(- \mid \sim\text{cancer}) = .98$$

$$P(\text{cancer} \mid +_1+_2) = \frac{P(+_1+_2 \mid \text{cancer}) P(\text{cancer})}{P(+_1+_2)} = .710$$

□ 健康檢查時經常會抽血、驗尿、或萃取某個身體組織附近的樣本，再從檢體中判定是否罹患某種疾病。

→ 檢查的結果以圖像表示較為清楚，例如：下圖即為中風病人的檢查結果。

<https://www.linkedin.com/pulse/brain-stroke-detection-using-deep-learning-infogen-labs->



Figure 1. Abnormal Axial Images

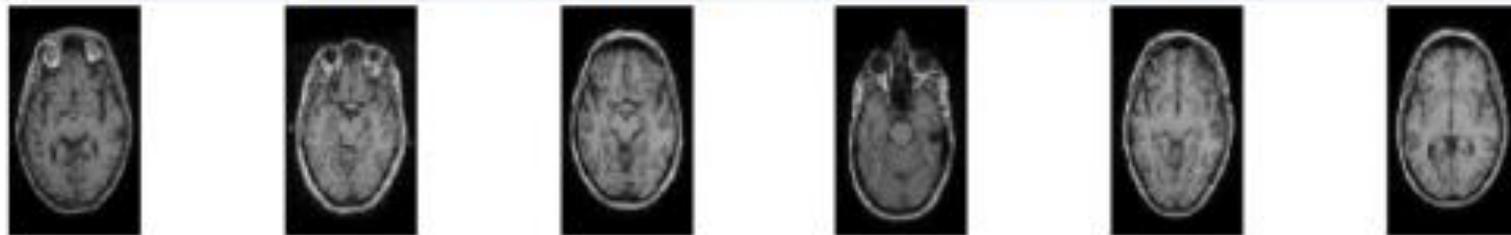
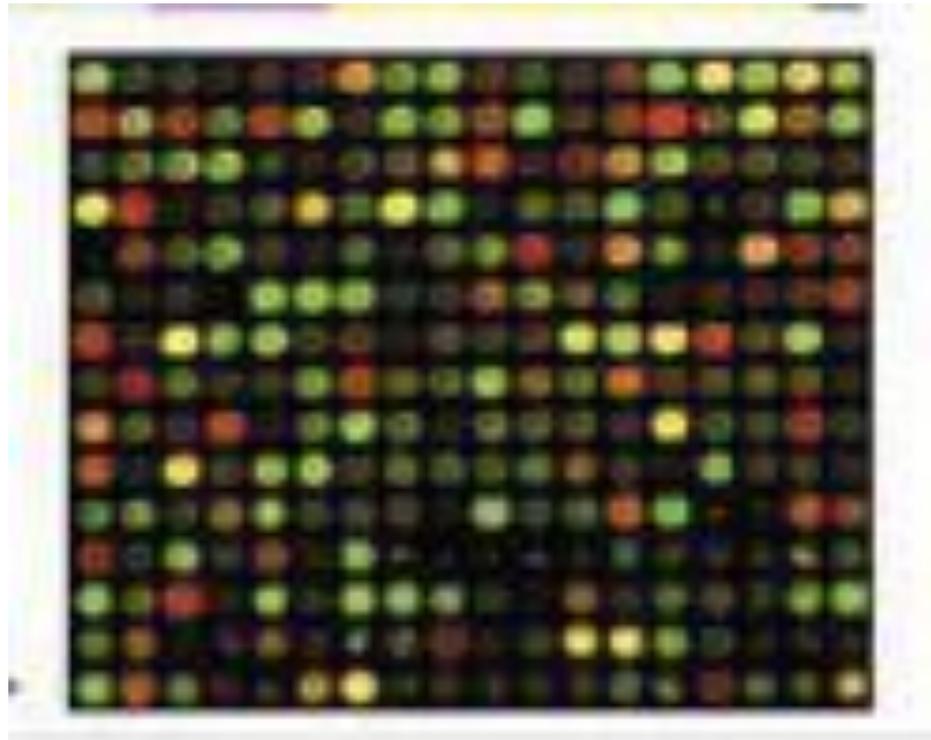


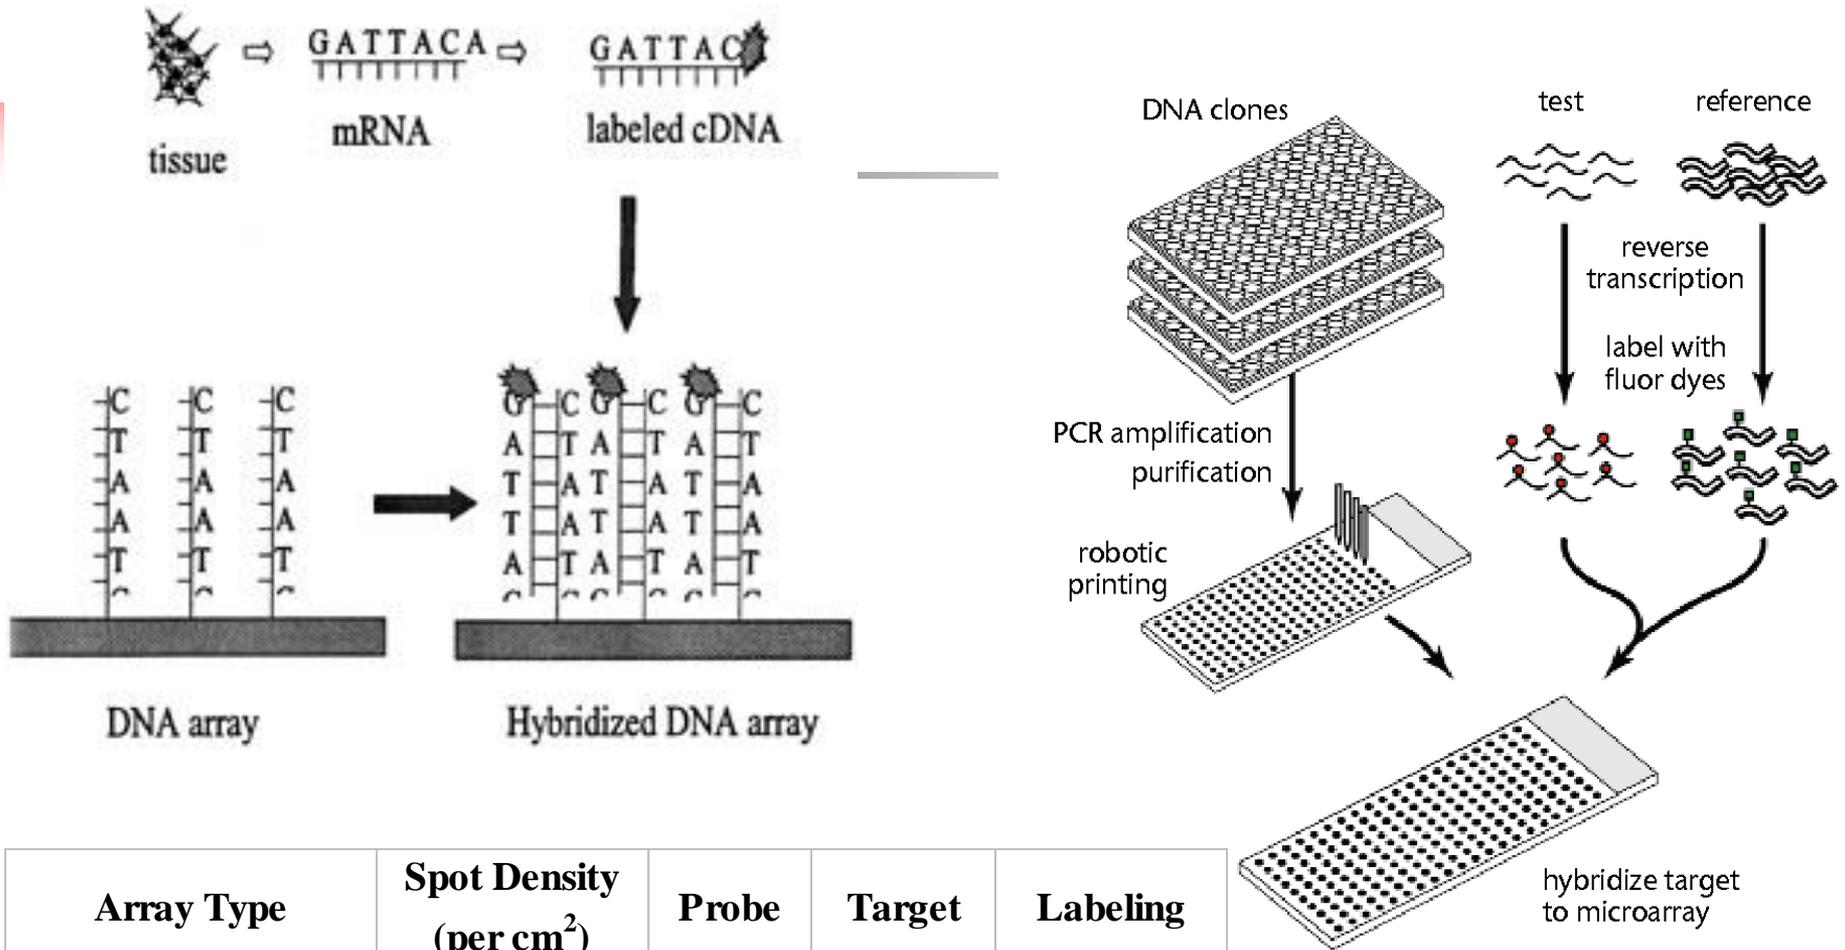
Figure 2. Normal Axial Images

生物晶片 (Micro-array Chips)



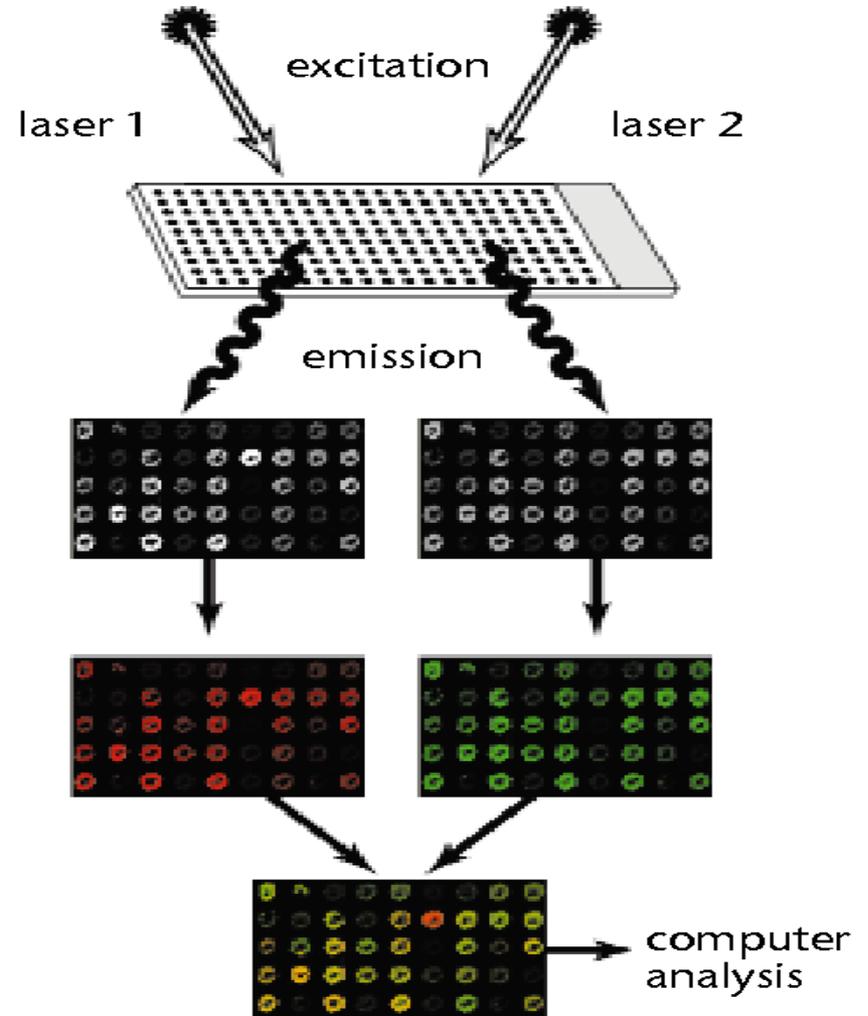
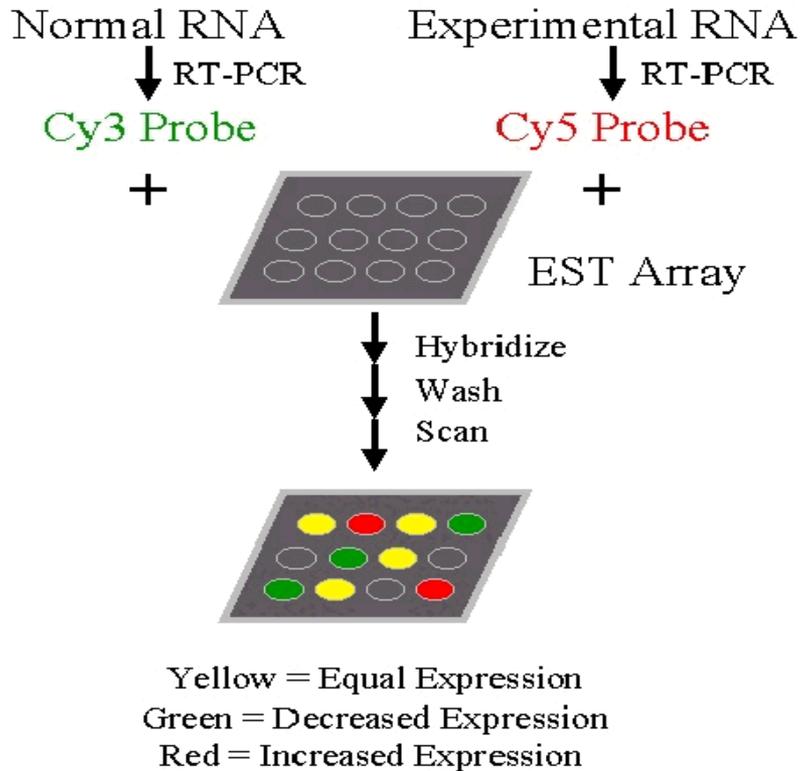
約 2 cm x 2 cm

Microarray technology

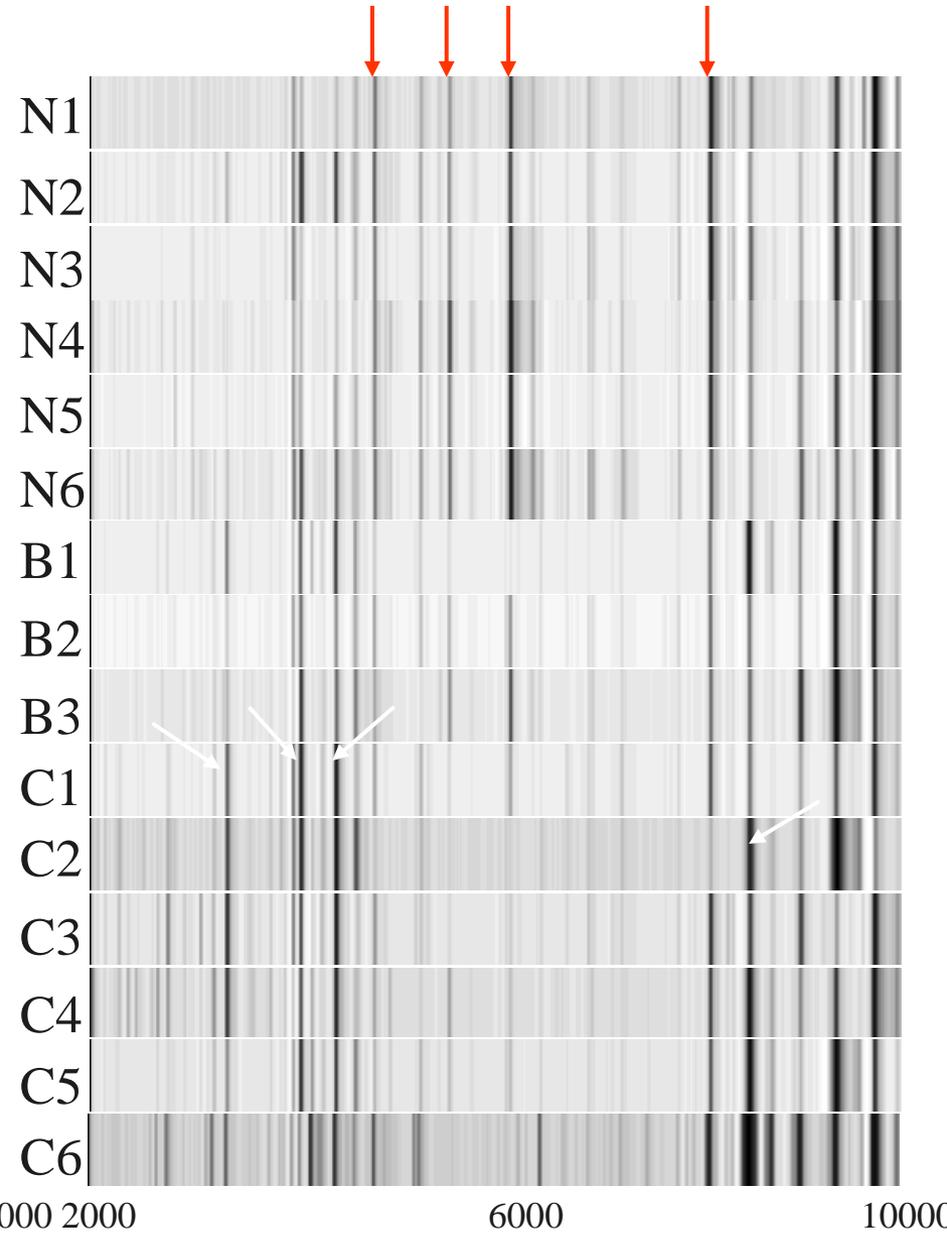
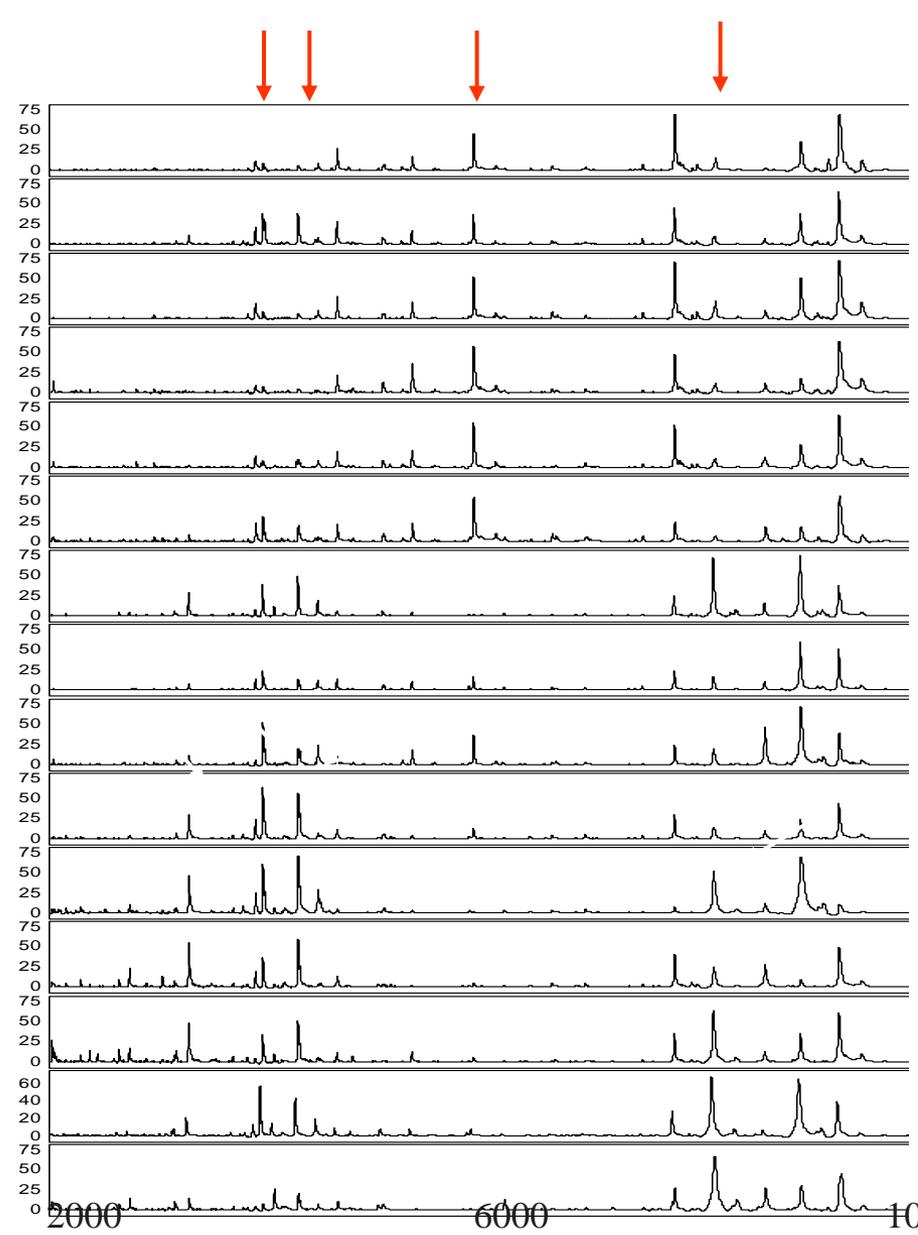


Array Type	Spot Density (per cm ²)	Probe	Target	Labeling
Nylon Macroarrays	< 100	cDNA	RNA	Radio
Nylon Microarrays	< 5000	cDNA	mRNA	Radio/Fluor
Glass Microarrays	< 10,000	cDNA	mRNA	Fluor
Oligonucleotide Chips	<250,000	oligo's	mRNA	Fluor

Microarray scanner

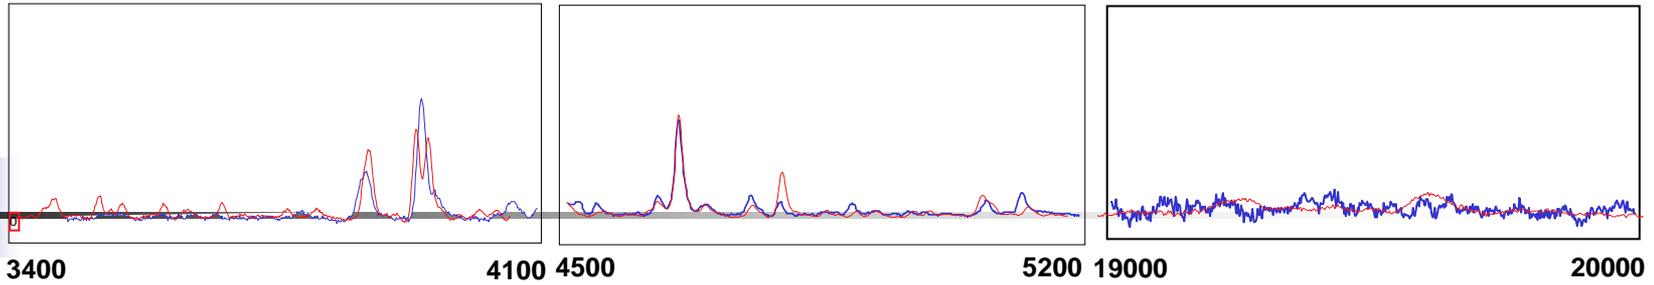


SELDI Serum Protein Profile Analysis-Prostate Cancer



Proteomic Pattern of Sera from Patient

Stage 1
Profile

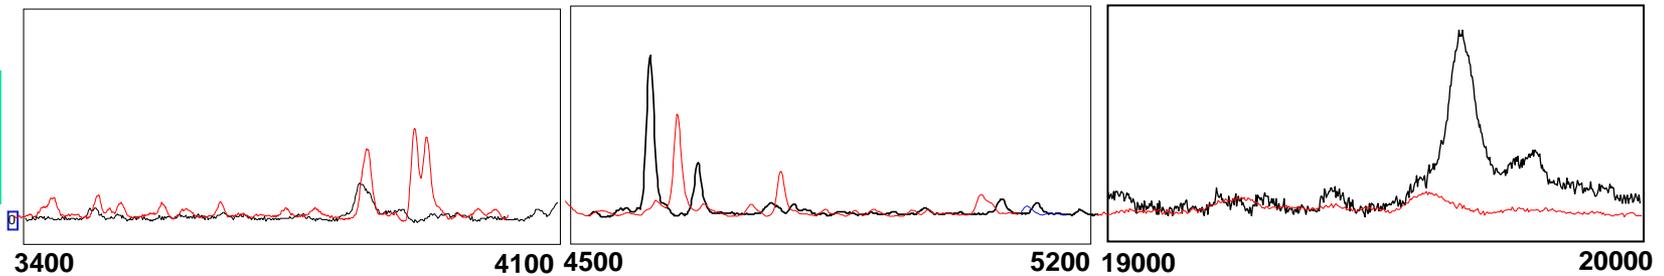


Sample



not a S2 pattern

Stage 2
Profile



統計可用於規避風險

□ 1986年美國挑戰者號太空梭的爆炸

→ O形環(O-Ring)在低溫下無法正常運作，造成燃料外洩而爆炸。

→ 分析過去各種溫度下的失敗比例

(羅吉士迴歸；logistic regression)

(參考書籍：天下文化

「你管別人怎麼想」→費曼)

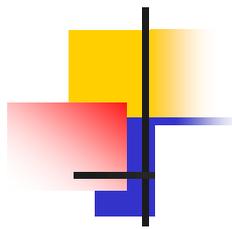
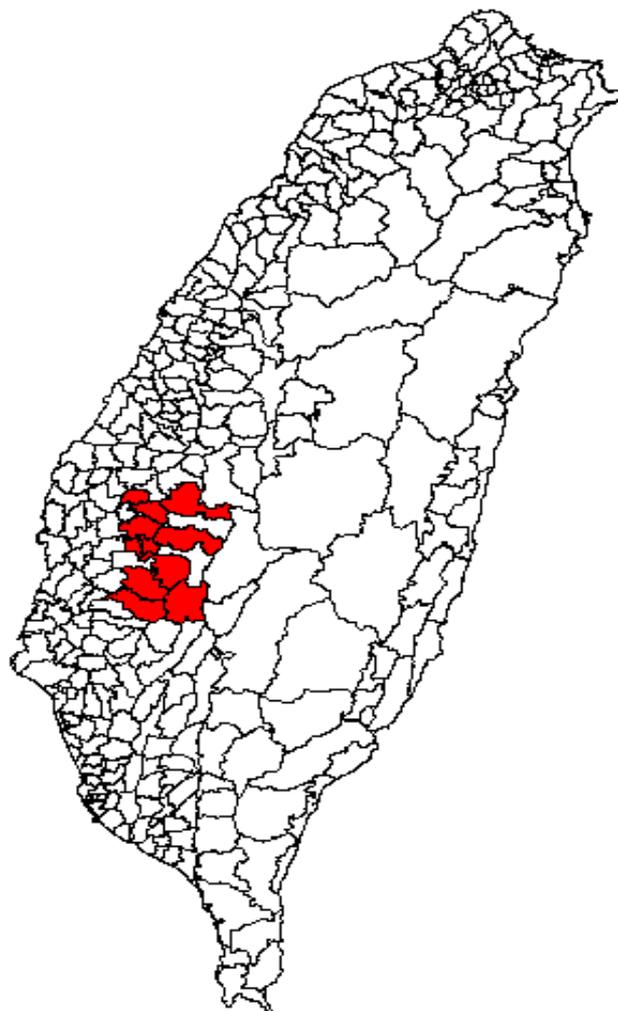


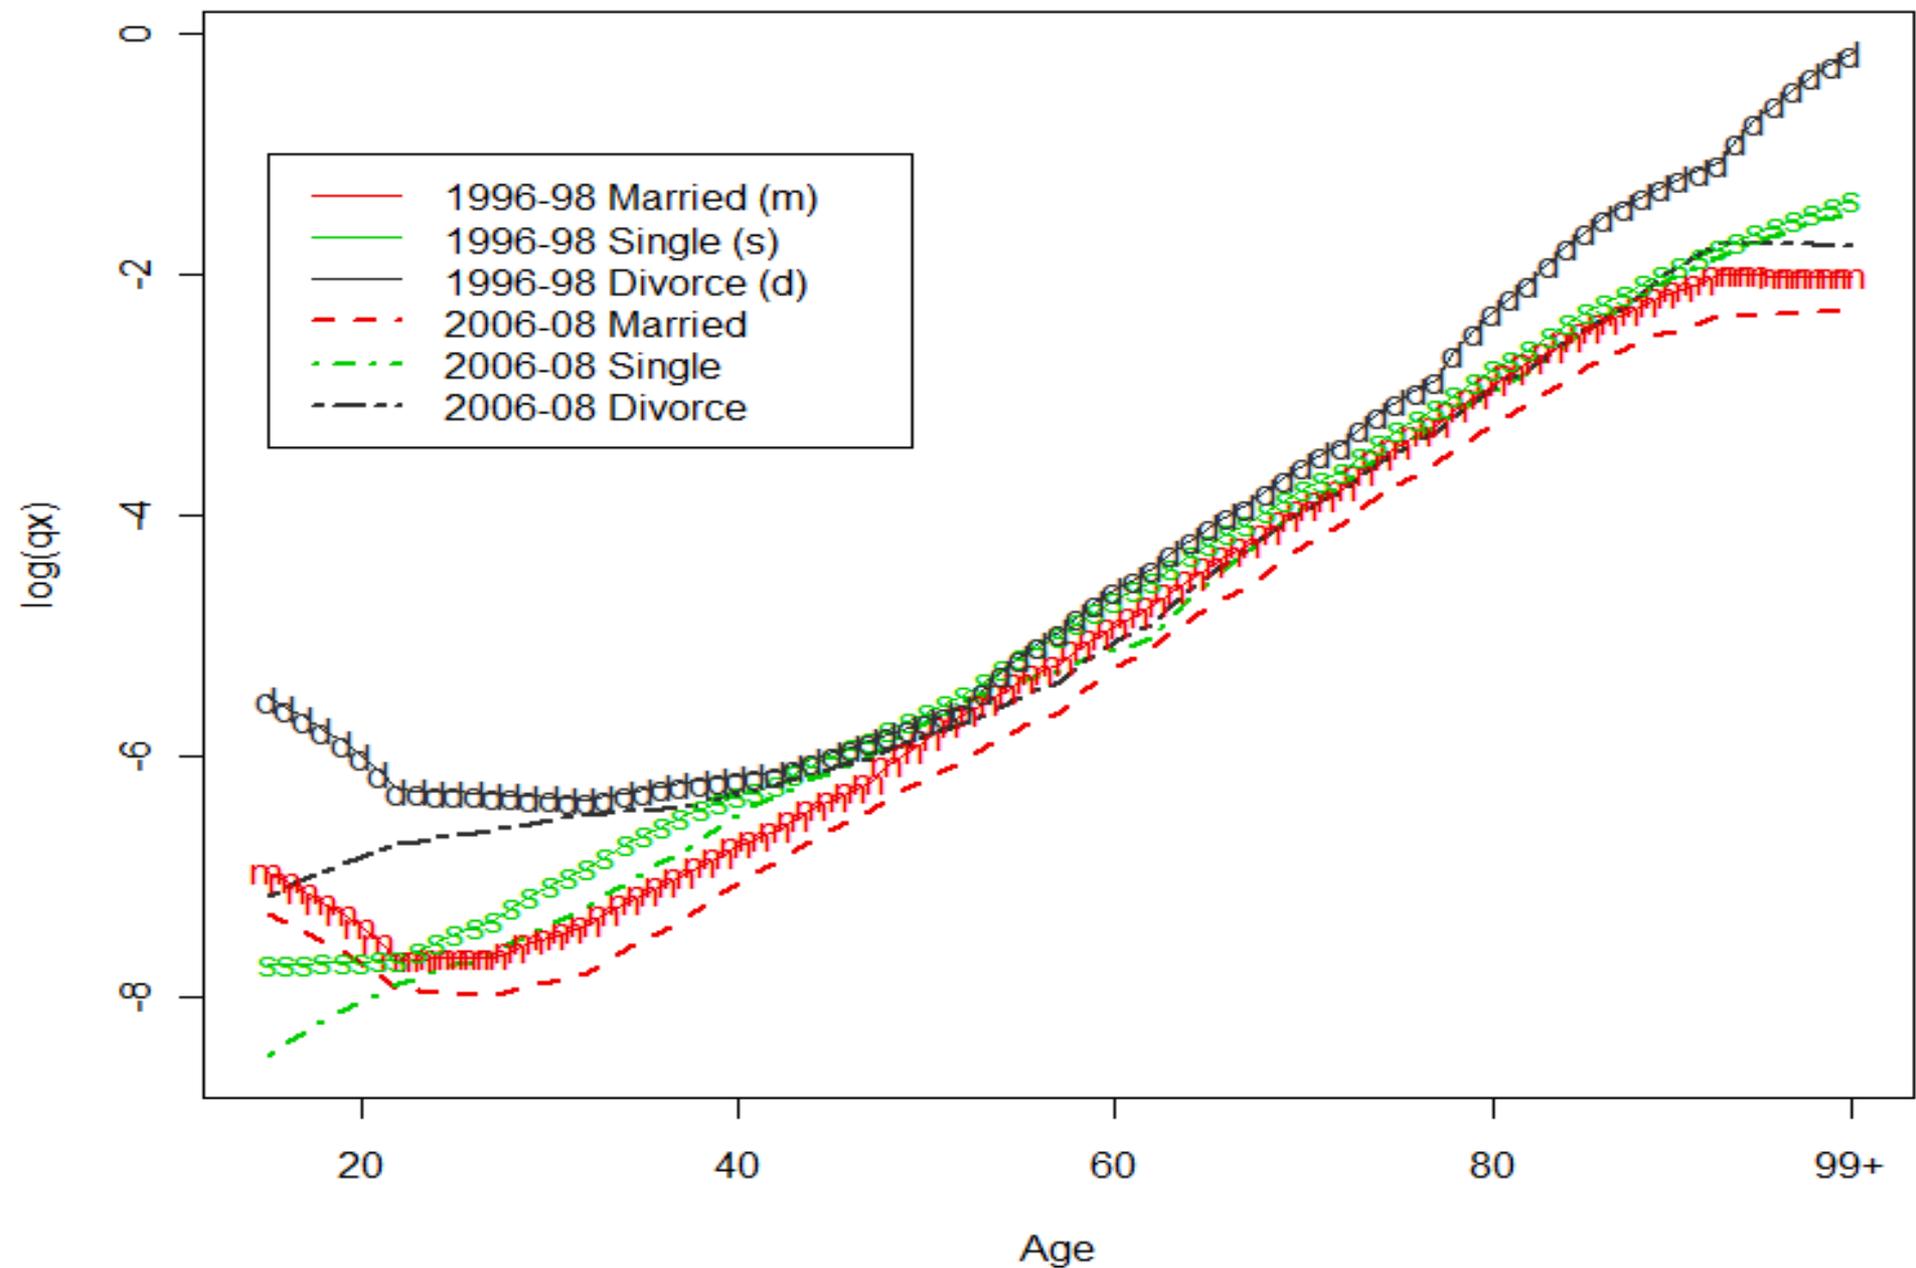
台灣地區全體人口門診次數顯著群聚圖

顯著增加



顯著減少





Taiwan's Marital Mortality Rates (Female)

美國職業運動

- 山姆大叔(Uncle Sam)應該是全世界使用統計數據最頻繁的國家，由他們職業運動統計數字的多樣性、詳細程度可見一斑。
- 以風靡全台的美國職棒為例，你們覺得有那些資料會在統計之列？
- 例如：有人認為王建民應該獲得賽揚獎，你們覺得哪些項目應該列入評比、比重又是多少？

Sortable Stats: Pitching

League Leaders

Stats by Position

Batting Pitching Fielding

Filter:

AL

2006 Season

	Name	Team	G	GS	W	L	SV	CG	SHO	IP	H	R	ER	HR	BB	K	ERA	WHIP	BAA
<input type="checkbox"/>	Johan Santana	MIN	34	34	19	6	0	1	0	233.2	186	79	72	24	47	245	2.77	1.00	.216
<input type="checkbox"/>	Chien-Ming Wang	NYY	34	33	19	6	1	2	1	218.0	233	92	88	12	52	76	3.63	1.31	.277
<input type="checkbox"/>	Jon Garland	CWS	33	32	18	7	0	1	1	211.1	247	112	106	26	41	112	4.51	1.36	.294
<input type="checkbox"/>	Kenny Rogers	DET	34	33	17	8	0	0	0	204.0	195	97	87	23	62	99	3.84	1.26	.253
<input type="checkbox"/>	Justin Verlander	DET	30	30	17	9	0	1	1	186.0	187	78	75	21	60	124	3.63	1.33	.266
<input type="checkbox"/>	Freddy García	PHI	33	33	17	9	0	1	0	216.1	228	116	109	32	48	135	4.53	1.28	.267
<input type="checkbox"/>	Randy Johnson	ARI	33	33	17	11	0	2	0	205.0	194	125	114	28	60	172	5.00	1.24	.250
<input type="checkbox"/>	Kevin Millwood	TEX	34	34	16	12	0	2	0	215.0	228	114	108	23	53	157	4.52	1.31	.272
<input type="checkbox"/>	Ervin Santana	LAA	33	33	16	8	0	0	0	204.0	181	106	97	21	70	141	4.28	1.23	.241
<input type="checkbox"/>	Josh Beckett	BOS	33	33	16	11	0	0	0	204.2	191	120	114	36	74	158	5.01	1.29	.245

註：WHIP代表Walk & Hit per Inning Pitched, 一般 $1 \leq \text{WHIP} \leq 1.75$ 。

Sortable Stats: Batting

League Leaders

Stats by Position

AVG Leaders: Minimum 490 plate appearances

Batting Pitching Fielding

Filter:

Qualified leaders

AL

2007 Season

	Name	Team	G	AB	R	H	2B	3B	HR	RBI	BB	K	SB	CS	AVG	OBP	SLG	OPS
<input type="checkbox"/>	Magglio Ordóñez	DET	155	587	116	211	52	0	28	136	75	79	4	1	.359	.430	.591	1.022
<input type="checkbox"/>	Ichiro Suzuki	SEA	157	662	110	232	22	7	6	68	48	75	37	7	.350	.396	.432	.828
<input type="checkbox"/>	Plácido Polanco	DET	139	577	104	196	35	3	9	66	37	29	7	3	.340	.388	.458	.845
<input type="checkbox"/>	Jorge Posada	NYN	142	500	90	168	42	1	20	89	72	97	2	0	.336	.423	.544	.967
<input type="checkbox"/>	Chone Figgins	LAA	112	434	79	146	24	6	3	58	49	78	40	12	.336	.397	.440	.837
<input type="checkbox"/>	Mike Lowell	BOS	150	573	75	187	36	2	20	116	53	69	3	2	.326	.381	.501	.882
<input type="checkbox"/>	David Ortiz	BOS	146	539	112	175	50	1	33	114	109	101	3	1	.325	.440	.605	1.045
<input type="checkbox"/>	Derek Jeter	NYN	154	631	100	203	38	3	12	71	55	97	14	8	.322	.387	.448	.836
<input type="checkbox"/>	Vladimir Guerrero	LAA	149	572	88	184	45	1	26	123	71	62	2	3	.322	.401	.540	.941
<input type="checkbox"/>	Dustin Pedroia	BOS	135	508	86	161	38	1	8	50	47	42	6	1	.317	.381	.443	.824

註：SLG = total bases / at bats、OPS = OBP + SLG。

統計在金融保險的應用

- 投資目的不外是報酬率最大、風險最小，但天下沒有白吃的午餐，這兩者很難兼顧。以符號表示，就是希望期望值最大，變異數最小，即在固定風險值下求取最佳的報酬：

$$\text{Max} \sum_i w_i X_i, \quad \text{given} \quad \text{Var}(\sum_i w_i X_i) \leq C$$

- Value at Risk (VaR)：譯作風險值，是統計應用於財務金融的熱門範例，

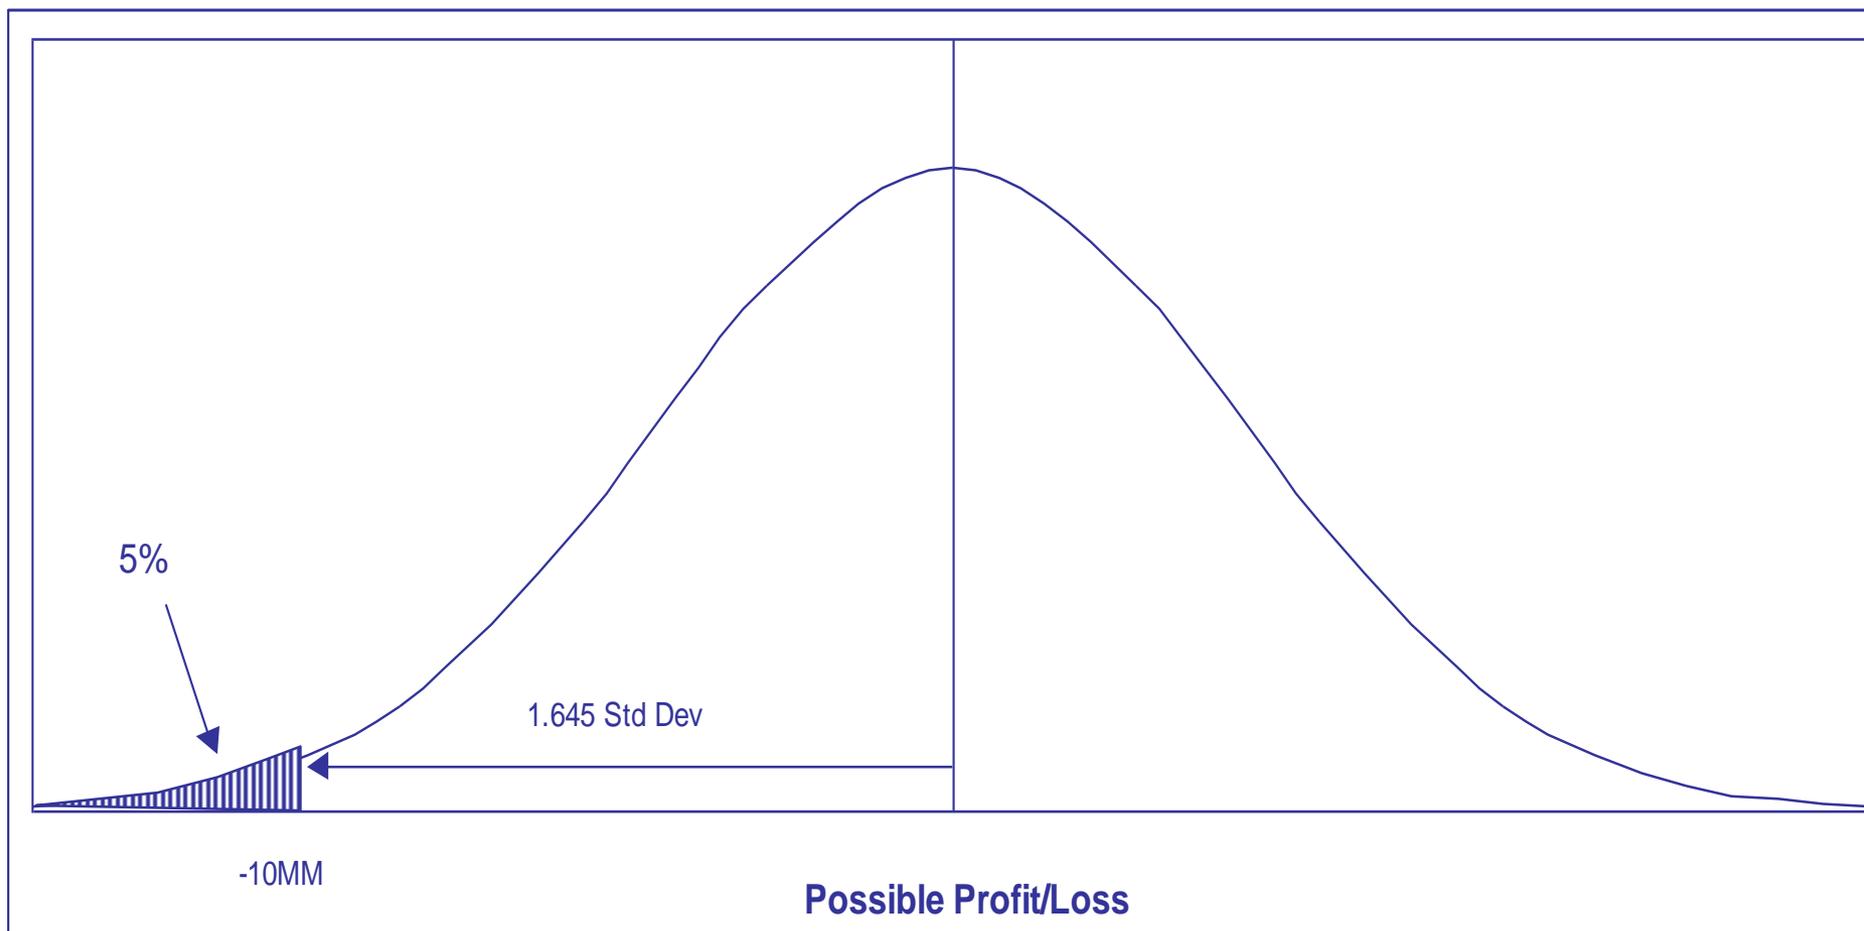
Value at Risk: Definition

The value at risk (VaR) of a portfolio is the loss in value in the portfolio that can be expected over a given period of time (e.g., 1-Day) with a probability not exceeding a given number (e.g., 5%).

$$\text{Probability (Portfolio Loss} \leq -\text{VaR)} = K$$

K = Given Probability

□ A one day VAR of \$10mm using a probability of 5% means that there is a 5% chance that the portfolio could lose more than \$10m in the next trading day.



其他金融保險的範例

- 避免信用不佳客戶的用卡核准，以減少發卡銀行損失。（預測瑕疵戶）
 - 舊卡戶在使用終止後是否發給新卡
 - 考慮發新卡的對象
- 盜刷信用卡，尋找異常(Irregularities)現象。
- 銀行為了尋找自己的競爭利基，需要找出可以為自己保留顧客，甚至挖掘潛在顧客的關鍵資訊。

❑ 問題：假設你/妳是審查信用卡申請，或是審核消費性貸款(無抵押品)的負責人，必須考慮需要蒐集哪些個人項目？

→ 貸款若有抵押品，問題相同嗎？

→ 如果考慮的不是個人，而是中小型企業貸款，需要蒐集哪些資訊？

註：消費金融 vs. 企業金融

❑ 問題：實務上與統計分析有關的領域？



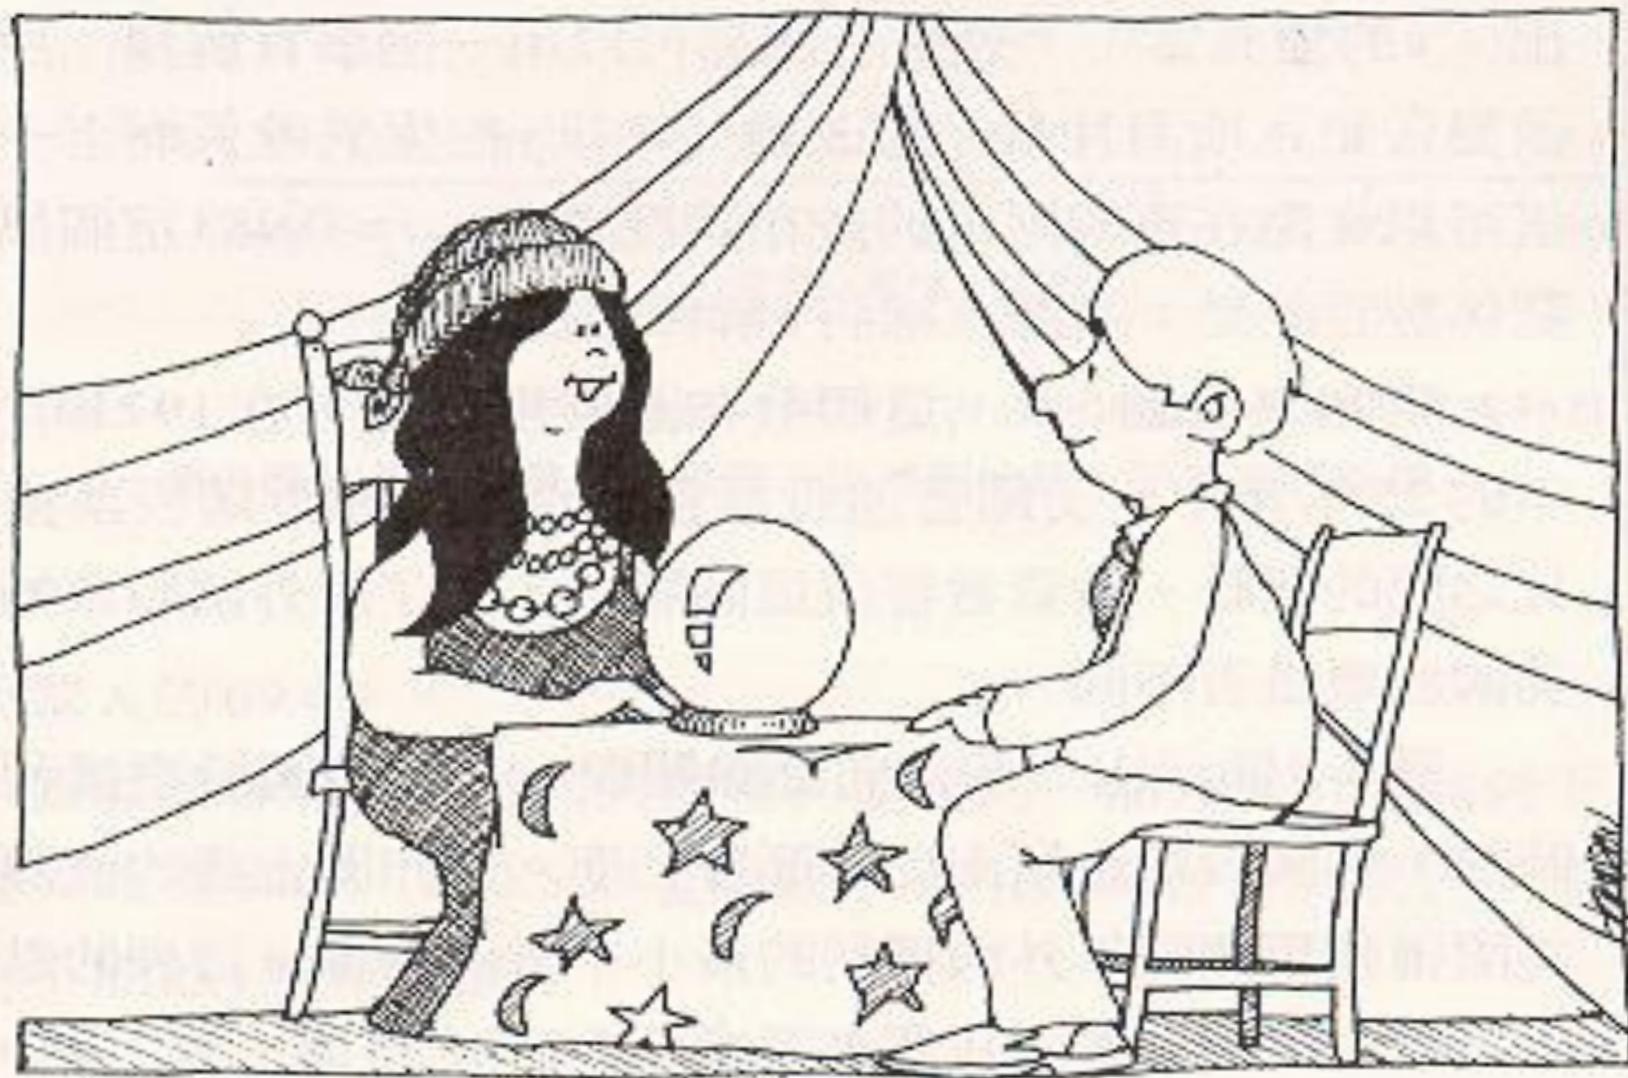
https://www.youtube.com/watch?app=desktop&v=_W_LDp735ms&ab_channel=LawShelf

金融產品三大類



<https://careerdonclub.weebly.com/370963385326684/day07>





「我怎麼會從事這一行的？是這樣的，讀大學的時候我搞不懂迴歸和相關係數，所以只好來做這種預測啦。」