

# 修勻學(Graduation) — Bayesian Graduation

授課教師：余清祥教授

課程日期：2024年11月06日

資料下載：

<http://csyue.nccu.edu.tw>



# 貝氏(Bayesian)修勻



- 貝氏理論(Bayesian Theory)是統計學中重要的領域，由Thomas Bayes於1763年發表的貝氏定理而得名。由於貝氏理論可合併過去經驗，近年愈受重視，在精算保險的應用更為廣泛。雖然貝氏修勻的開始時間較MWA、Whittaker修勻晚了數十年，由於電腦科技進步降低了門檻，近二十年的修勻新方法中，貝氏修勻佔了相當高的比例。

- 貝氏方法將過去經驗作為先驗資訊(Prior Information)，結合本次蒐集的資料(Data)，綜合可得新的經驗(驗後結果, Posterior)：

**先驗資訊 + 實驗結果 → 驗後結果**  
**(Prior + Data → Posterior)**

→ 貝氏方法用於修勻，可將過去的理賠經驗或是整個業界的經驗費率作為先驗資訊，過去一年的理賠經驗視為實驗結果，修勻後的結果可得出新的經驗費率。



# 貝氏(Bayesian)定理

$$f(\theta | D) = \frac{f(D | \theta)f(\theta)}{f(D)} = \frac{f(D | \theta)f(\theta)}{\int f(D | \theta')f(\theta')d\theta'}$$

- 問題：初統、數統等課程裡的統計分析觀點，和貝氏觀點的主要差異是什麼？  
→ 兩者在觀念、分析、解釋上的特色？

- 範例一、某君投擲一硬幣100次，出現42次正面；第二天再投擲同一硬幣100次，出現52次正面。檢驗此硬幣是否為公平硬幣。

→ 投擲硬幣100次，出現正面的次數可視為二項分配的變數，與觀察某地區同年齡居民在一年內的死亡人數類似，投擲兩天就像是觀察連續兩年的死亡率。

→ 以估算死亡率的角度來看，我們應該使用第一年、第二年、或是兩年合併的資料估計出現正面的機率，又該如何合併兩年的資料？  
（例如：加權平均、直接相加？）

- 範例一(續)、你/妳覺得硬幣出現正面的機會( $p$ )等於多少？ $X \sim B(100, p)$

→ 只使用第一天資料， $\hat{p} = \frac{42}{100} = 0.42$ 。

→ 只使用第二天資料， $\hat{p} = \frac{52}{100} = 0.52$ 。

→ 兩天資料相加， $\hat{p} = \frac{42 + 52}{100 + 100} = \frac{94}{200} = 0.47$ 。

- 以死亡率的角度來看，第二天的權重是否應該較重？



## 貝氏分析

---

■ 若無特別指定，貝氏分析原則上將所有資料直接合併，也就是平均加權。

→ 如果先驗與驗後屬於同一類型的分配，稱為共軛先驗分配(Conjugate Prior Distribution)，常見的例子有：

Beta + 二項分配 → Beta

Gamma + Poisson → Gamma

Normal + Normal → Normal

Dirichlet + 多項分配 → Dirichlet

- 以範例一為例，硬幣出現正面的次數大多視為二項分配，如果假設正面出現的機會服從Beta分配，則在加入資料的分析後，出現正面的機會仍舊服從驗後Beta分配。

→ 正面、反面個數分別相加。

$$p \sim \text{Beta}(\alpha, \beta) \Rightarrow \pi(p) = \frac{\Gamma(\alpha + \beta)}{\Gamma(\alpha)\Gamma(\beta)} p^{\alpha-1} (1-p)^{\beta-1}$$

$$X \sim B(n, p) \Rightarrow f(x | p) = \frac{n!}{x!(n-x)!} p^x (1-p)^{n-x}$$

$$p | x \sim \text{Beta}(\alpha + x, \beta + n - x) \Rightarrow \pi(p | x) \propto p^{\alpha+x-1} (1-p)^{\beta+n-x-1}$$



- 上述的先驗Beta分配中，參數 $\alpha$ 及 $\beta$ 可視為過去的經驗中，正面及反面出現的次數，因此驗後Beta分配中的參數，可解釋為累積的正面及反面出現次數。

→ Beta分配的期望值滿足  $E(p) = \alpha/(\alpha+\beta)$ ，因此

$$\begin{aligned} E(p | x) &= \frac{\alpha + x}{\alpha + \beta + n} \\ &= \frac{\alpha + \beta}{\alpha + \beta + n} \cdot \frac{\alpha}{\alpha + \beta} + \frac{n}{\alpha + \beta + n} \cdot \frac{x}{n} \end{aligned}$$


為先驗分配及實驗結果的加權平均，權數為個別的樣本數。

- 如果過去經驗記為  $s_x$  (標準生命表的數值)，死亡率的觀察值為  $u_x$ ，範例一可視為：


$$v_x = \frac{\alpha + \beta}{\alpha + \beta + n} \cdot s_x + \frac{n}{\alpha + \beta + n} \cdot u_x$$

修勻值為經驗值與死亡觀察值的加權平均。過去經驗的樣本數如果較多，則修勻值較接近經驗值；反之，如果本次蒐集的資料比數較多 ( $n$  較大)，最近的經驗佔較大的比重，甚至可推翻過去的經驗。（「三人成虎」！）


## Posterior Density (Coin Tossing)




**Beta(2.5,7.5) & 1 Heads, 1 Tail**




**Beta(25,75) & 1 Heads, 1 Tail**



**Beta(2.5,7.5) & 10 Heads, 10 Tails**

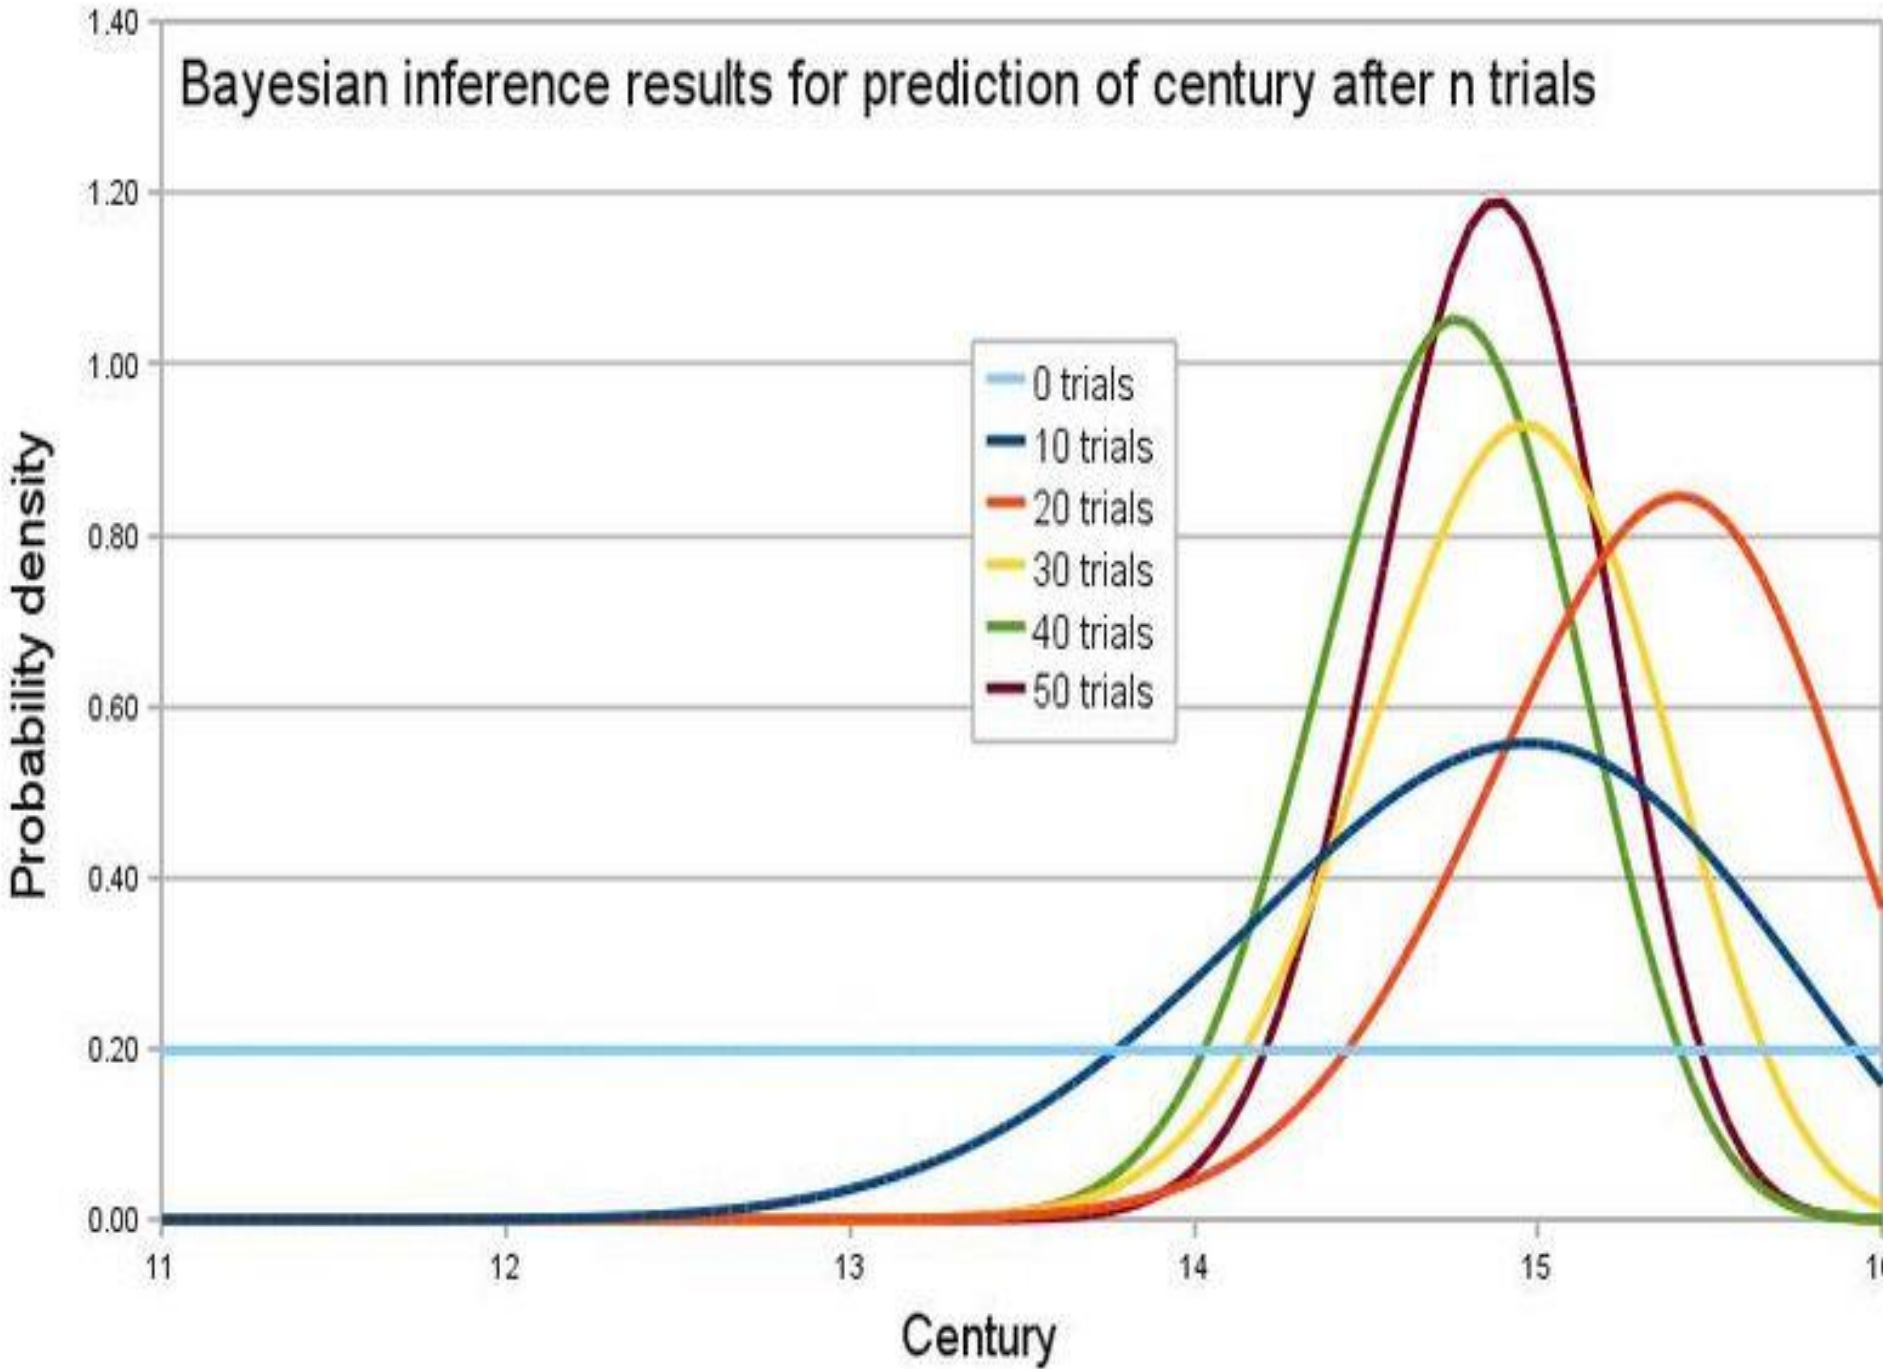


**Beta(2.5,7.5) & 100 Heads, 100 Tails**




**Prior與Data的樣本數對Posterior的影響**


Bayesian inference results for prediction of century after n trials



### Prior



### Posterior



**Data樣本數夠大就能扭轉Prior的影響！**



# 貝氏分析的理念

- 一般對參數的假設是「未知但固定」，貝氏則認為參數「具有某種分配」，對參數的瞭解通常隨著樣本數增加而更確定。
- 以上述投擲硬幣為例，正面出現機會的驗後分配，滿足變異數

$$\text{Var}(p | x) = \frac{(\alpha + x)(\beta + n - x)}{(\alpha + \beta + n + 1)(\alpha + \beta + n)^2}$$

隨著樣本數增加趨近於0，即收斂至一點。

## 貝氏分析的理念(續)

- 如果缺乏過去經驗，先驗分配可假設無資訊的先驗分配(Non-informative Prior)，意謂先驗分配對整體的影響力極小。

→ 出現正面機會中的先驗Beta分配，一般會給定均勻分配 $U(0,1) = \text{Beta}(1,1)$ 為無資訊先驗分配，也就是過去只有一次正面、一次反面的經驗。因此驗後期望值為  $\frac{x+1}{n+2}$ ，與最大

概似估計量MLE  $\frac{x}{n}$  非常接近。



# 貝氏分析的理念(續)

- 常態分配是另一個常見的共軛先驗分配，因為各年齡的人數動輒以萬計算，以常態分配近似還算適當。(註：死亡率大小?)

→ 假設某年齡的死亡率滿足  $\theta \sim N(\mu, \tau^2)$ ，而某年度蒐集的該年齡死亡資料也滿足  $X | \theta \sim N(\theta, \sigma^2)$ ，則死亡率的驗後分配

服從  $\theta | X = x \sim N\left(\frac{\sigma^2 \mu + \tau^2 x}{\tau^2 + \sigma^2}, \frac{\tau^2 \sigma^2}{\tau^2 + \sigma^2}\right)$

或是  $E(\theta | X = x) = \frac{1/\tau^2}{1/\sigma^2 + 1/\tau^2} \mu + \frac{1/\sigma^2}{1/\sigma^2 + 1/\tau^2} x$ 。



## Kimeldorf-Jones 法

---

- 常態分配的共軛先驗分配在統計早已使用多年，保險應用一直到1967年才由Kimeldorf及Jones提出。

→ 若真實死亡率的先驗分配滿足  $\underline{t} \sim N(\underline{m}, A)$

觀察的死亡率服從常態分配  $\underline{u} | \underline{t} \sim N(\underline{t}, B)$

$$\pi(\underline{t}) = k_1 \cdot \exp\left[-\frac{1}{2}(\underline{t} - \underline{m})' A^{-1}(\underline{t} - \underline{m})\right]$$

$$f(\underline{u} | \underline{t}) = k_1 \cdot \exp\left[-\frac{1}{2}(\underline{u} - \underline{t})' B^{-1}(\underline{u} - \underline{t})\right]$$

- 驗後分配需要先計算出  $\underline{u}$  的邊際分配 (Marginal distribution)  $f(\underline{u})$ ，藉由

$$f(\underline{t}, \underline{u}) = \pi(\underline{t}) \cdot f(\underline{u} | \underline{t}) = f(\underline{u}) \cdot \pi(\underline{t} | \underline{u})$$

算出真實死亡率的驗後分配。

- 因為計算不易，一般只考慮與  $\underline{t}$  有關的項次，或是令  $\underline{t} | \underline{u} \sim N(\underline{v}, C)$ ，其中

$$(\underline{t} - \underline{v})' C^{-1} (\underline{t} - \underline{v}) \propto$$

$$(\underline{t} - \underline{m})' A^{-1} (\underline{t} - \underline{m}) + (\underline{u} - \underline{t})' B^{-1} (\underline{u} - \underline{t})$$

$$C^{-1} = A^{-1} + B^{-1}$$

- 上式對  $\underline{t}$  微分可得

$$2C^{-1}(\underline{t} - \underline{v}) = 2A^{-1}(\underline{t} - \underline{m}) + 2B^{-1}(\underline{u} - \underline{t})$$

或是修勻值  $\underline{v} = C(A^{-1}\underline{m} + B^{-1}\underline{u})$ 。

- 重新排列，令  $I$  為單位矩陣，修勻值可表達為  $\underline{v} = \underline{u} + (I + AB^{-1})^{-1}(\underline{m} - \underline{u})$ ，也就是根據觀察死亡率  $\underline{u}$ ，再加入經驗值  $\underline{m}$  的效果來修勻。同理，也可以經驗值再加入觀察死亡率來調整  $\underline{v} = \underline{m} + (I + BA^{-1})^{-1}(\underline{u} - \underline{m})$ 。



## 參數 $m$ 、A與B的選取

- 先驗分配中的參數  $m$  及 A 對結果有相當的影響，以下列出參數選擇的建議：
  - $m$  的選擇大多是經驗中最有可能的數值。以修勻今年生命表為例，通常會以上一次、或是去年死亡經驗當作經驗值。
  - 因為A代表各年齡死亡率間的關係，一般會先決定每個年齡變異數，再藉由年齡間的相關程度決定共變異數。



## 參數 $m$ 、A與B的選取(續)

→ 共變數矩陣A需要滿足

(i) 正定、對稱矩陣 (ii) 可逆矩陣

建議可選取  $A_{xy} = \sqrt{A_{xx}} \sqrt{A_{yy}} r^{|x-y|}$ ,  $0 \leq r < 1$

其中  $A_{xx}$  及  $A_{yy}$  為  $x$  歲及  $y$  歲死亡率的變異數。

→ 因為原始死亡率服從二項分配，變異數矩陣B通常假設為對角矩陣，各年齡死亡率的

變異數為  $B_{xx} = \text{Var}(u_x) = \frac{t_x(1-t_x)}{n_x} \cong \frac{m_x(1-m_x)}{n_x}$



# Correlation Matrix (Positive Definite)

```
PDM=function(n,rho) {  
  A=NULL  
  j=c(1:n)  
  for (i in 1:n) {  
    A=rbind(A,rho^abs(i-j))  
  }  
  return(A)  
}
```

```
#
```

```
# Use “eigen” to check the result.
```

```
eigen(PDM(5,0.9))
```

```
$values
```

```
[1] 4.26213409 0.45446614 0.14592141 0.07943386 0.05804450
```

# 參數A與B的特例

→ 共變數矩陣A與B均為對角矩陣

$$v_x = \frac{b_{xx}}{a_{xx} + b_{xx}} m_x + \frac{a_{xx}}{a_{xx} + b_{xx}} u_x$$

→ 如果

$$A = \underline{\underline{1}} \underline{\underline{1}}' \sigma^2 = \begin{bmatrix} 1 & 1 & \cdot & \cdot & 1 \\ 1 & 1 & \cdot & \cdot & 1 \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ 1 & 1 & \cdot & \cdot & 1 \end{bmatrix} \sigma^2, \quad B = I_{n \times n}$$

$$\Rightarrow E(\underline{\underline{t}} | \underline{\underline{u}}) = \underline{\underline{m}} + \mu \underline{\underline{1}}, \quad \mu = \frac{1}{2} \left( \underline{\underline{1}} B^{-1} \underline{\underline{1}} + \frac{n^2}{\sigma^2} \right) \underline{\underline{1}}' B^{-1} (\underline{\underline{u}} - \underline{\underline{m}})$$



## 貝氏與Whittaker修勻

- Whittaker修勻可視為貝氏修勻的特例，其中平滑性函數可視為先驗分配：

$$f(\underline{t}) = k_1 \cdot \exp[-\frac{1}{2} hS], \quad S = \sum_x (\Delta^z t_x)^2$$

或是  $S \sim \text{Exp}(h/2)$ ，因此可得出

$$\begin{cases} C = (B^{-1} + h k_z' k_z)^{-1} \\ \underline{v} = (B^{-1} + h k_z' k_z)^{-1} (B^{-1} \underline{u} + h k_z' k_z \underline{0}) \end{cases}$$


即是令先驗的  $\underline{m} = \underline{0}$

範例二、以1994年台灣地區單齡的簡易生命表為先驗資訊，原始死亡率則參照2004年的實際數值。

→ A 及 B 的樣本數採用實際觀察的樣本數，A 矩陣的  $r$  選擇 0.9、0.5。

→ 2004年修勻後死亡率的形狀，與1994年的死亡率曲線類似， $r = 0.9$  的曲線與1994年比較接近，也比較平滑。貝氏修勻值不見得介於經驗值與觀察值之間，以  $r = 0.9$  修勻值在10歲為例。

台灣2004年男性死亡率(Bayesian修勻)




範例三、仿造範例二，假設死亡人數服從2004年的死亡率觀察值，但總人數只有原先的1/10。  
(死亡人數以模擬產生。)


→ 觀察值的樣本數只有1/10，A 矩陣的  $r$  選擇同樣是0.9、0.5。

→ 因為觀察值樣本數較少，修勻後死亡率更接近1994年的死亡率，而且曲線形狀大致相同。與之前一樣， $r = 0.9$  的曲線與1994年比較接近，也比較平滑；貝氏修勻值不見得介於經驗值與觀察值之間。

# 台灣2004年男性死亡率(Bayesian, 1/10樣本)



## Bayesian Graduation




**Prior and Weight Can Influence the Graduation!**

範例四、以Whittaker方法修勻2003與2004年死亡資料，與2003年為先驗資訊、2004年為資料的貝氏修勻比較。

→因為死亡資料為五齡組，我們將0歲至99歲每五個年齡分成一組，總共有20組，直接考慮20組的修勻。

→這兩種方法的結果在多數年齡組差距不大，只有在5~9歲、10~14歲、15~19歲、95~99歲這四組有較不同的結果。(Whittaker的參數為 $z = 3$ ,  $h = 100,000$ ，Bayesian的參數  $r = 0.9$ 、 $0.5$ )

## Whittaker與Bayesian的比較





## 其它共轭贝氏修匀

- 死亡率除了假设常态分配，常见的是令其服从多项分配，

$$f(d_1, d_2, \dots, d_k | \underline{t}) = \frac{d!}{\prod_{i=1}^k d_i!} \prod_{i=1}^k t_i^{d_i}$$

其中 $d$ 为所有死亡人数， $d_i$ 为第 $i$ 年龄组死亡人数。

→ 如果死亡率服从Dirichlet假设，记为

$$\underline{t} = (t_1, t_2, \dots, t_k) \sim \text{Dirichlet}(a_1, a_2, \dots, a_k)$$

## 其它共軛貝氏修勻(續)

→ Dirichlet分配的密度函數為


$$f(t_1, t_2, \dots, t_k) = \frac{\Gamma(\sum_{i=1}^k a_i)}{\prod_{i=1}^k \Gamma(a_i)} \prod_{i=1}^k t_i^{a_i-1}$$

驗後的分配變成

$$\underline{t} \mid \underline{d} \sim \text{Dirichlet}(a_1 + d_1, a_2 + d_2, \dots, a_k + d_k)$$

→ 其中第*i*組死亡率的修勻值滿足

$$v_i = \frac{a}{a+d} \cdot \frac{a_i}{a} + \frac{d}{a+d} \cdot \frac{d_i}{d}$$



## 非共軛貝氏修勻

---

- 共軛分配可簡化計算，但也限制貝氏分析的應用範圍，只要先驗分配與假設略有差異，計算複雜度將大為提高。
- 近年電腦科技進步快速，貝氏分析因為蒙地卡羅馬可夫鏈(Monte Carlo Markov Chain ; MCMC)而更為可行，不需要共軛分配假設、或是事先指定先驗分配。




# MCMC方法簡介

---


- 若先驗分配與驗後分配函數屬於不同形式，必須仰賴數值積分(Numerical Integration)求出驗後機率，MCMC可簡化運算。
- MCMC基本上使用Markov Chain作蒙地卡羅積分，原理為從一個Markov Chain抽取樣本，再由樣本去估計期望值；不同的MCMC法主要的區別在於建構Markov Chain的方法。

# 關於貝氏分析

- 透過貝氏計算可估計出參數的驗後分配。
  - 根據經驗值決定先驗分配，或是使用無資訊先驗分配 (Non-informative Prior) ;
- 經驗貝氏 (Empirical Bayes) : 可將資料拆成兩部分，一部份用於估計先驗分配。
- MCMC 是近年常見的貝氏計算方法，透過多次遞迴的電腦模擬，估計出參數的驗後分配。




Posterior of a




True value = red line

Posterior of b




True value = red line

Posterior of sd



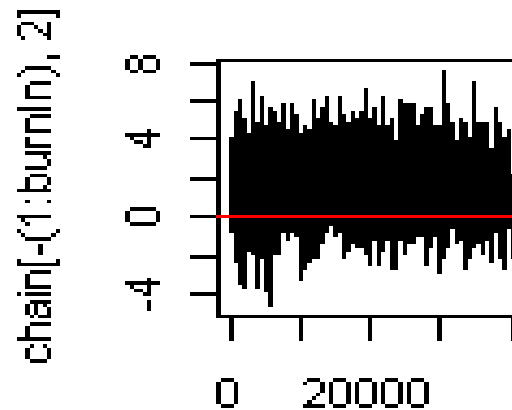
True value = red line

Chain values of a



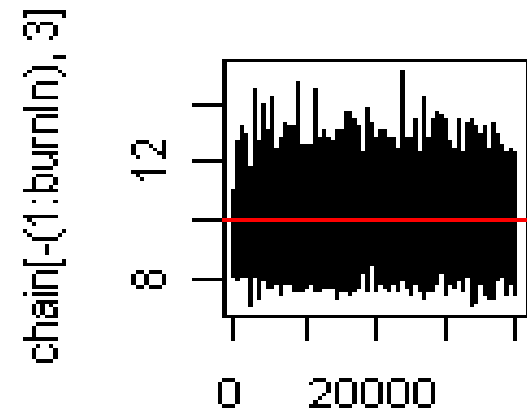
True value = red line

Chain values of b



True value = red line

Chain values of sd




True value = red line

# An Example MCMC – Simple Linear Regression

# 範例：簡單線性迴歸

■ X與Y似乎存有線性關係

→ 由散佈圖判斷X與Y呈現線性關係。



```
library(devtools)
library(ggplot2)
library(HDIInterval)
library(MCMCpack)
library(mcmc)
library(mcmcse)
library(Rcpp)
library(RcppArmadillo)
library(stableGR)
```


```
#
```

```
line = list(X = c(-2,-1,0,1,2), Y = c(1,3,3,3,5))
posterior = MCMCregress(Y~X, b0=0, B0 = 0.1,
                        sigma.mu = 5, sigma.var = 25, data=line, verbose=1000)
plot(posterior)
raftery.diag(posterior)
summary(posterior)
```


```
#           2.5%    25%    50%    75%    97.5%
# Intercept = 3    1.3085  2.3765  2.8594  3.3180  3.3290
# Slope = 0.8     -0.3465  0.4353  0.7788  1.1100  1.8460
# Sigma = 0.7303   1.1552  1,8859  2.5745  3.6240  7.8270
```




Trace of (Intercept)




Density of (Intercept)




Trace of X




Density of X



Trace of sigma2




Density of sigma2




# MCMC方法簡介(續)

- MCMC的關鍵之一在於如何透過馬可夫鏈，遞迴產生近似驗後分配的觀察值。  
→ 為了確保MCMC產生的亂數是否平穩，通常捨棄較前面的觀察值(Burn-in sample)。  
例如：從5萬個MCMC樣本前面2萬個，以之後的3萬個觀察值估計參數，也可建立Credible Set、類似信賴區間的區間估計值。



# MCMC—以馬可夫鏈遞迴式的產生亂數

Given target distribution  $S_0$ , design transitions s.t.  $p_t(\theta_t) \rightarrow S_0$  as  $t \rightarrow \infty$



Q：如何檢查MCMC樣本  
本和平穩性？



$$I = \langle f \rangle_{S_0} \approx \hat{I} = \frac{1}{T} \sum_{t=1}^T f(\theta_t)$$

$$\text{Bias}(\hat{I}) = \mathbb{E}[\hat{I} - I] = 0$$


$$\text{Var}(\hat{I}) = \tau \frac{\text{Var}(f)}{T}$$

Auto correlation time

Diagnostics for x






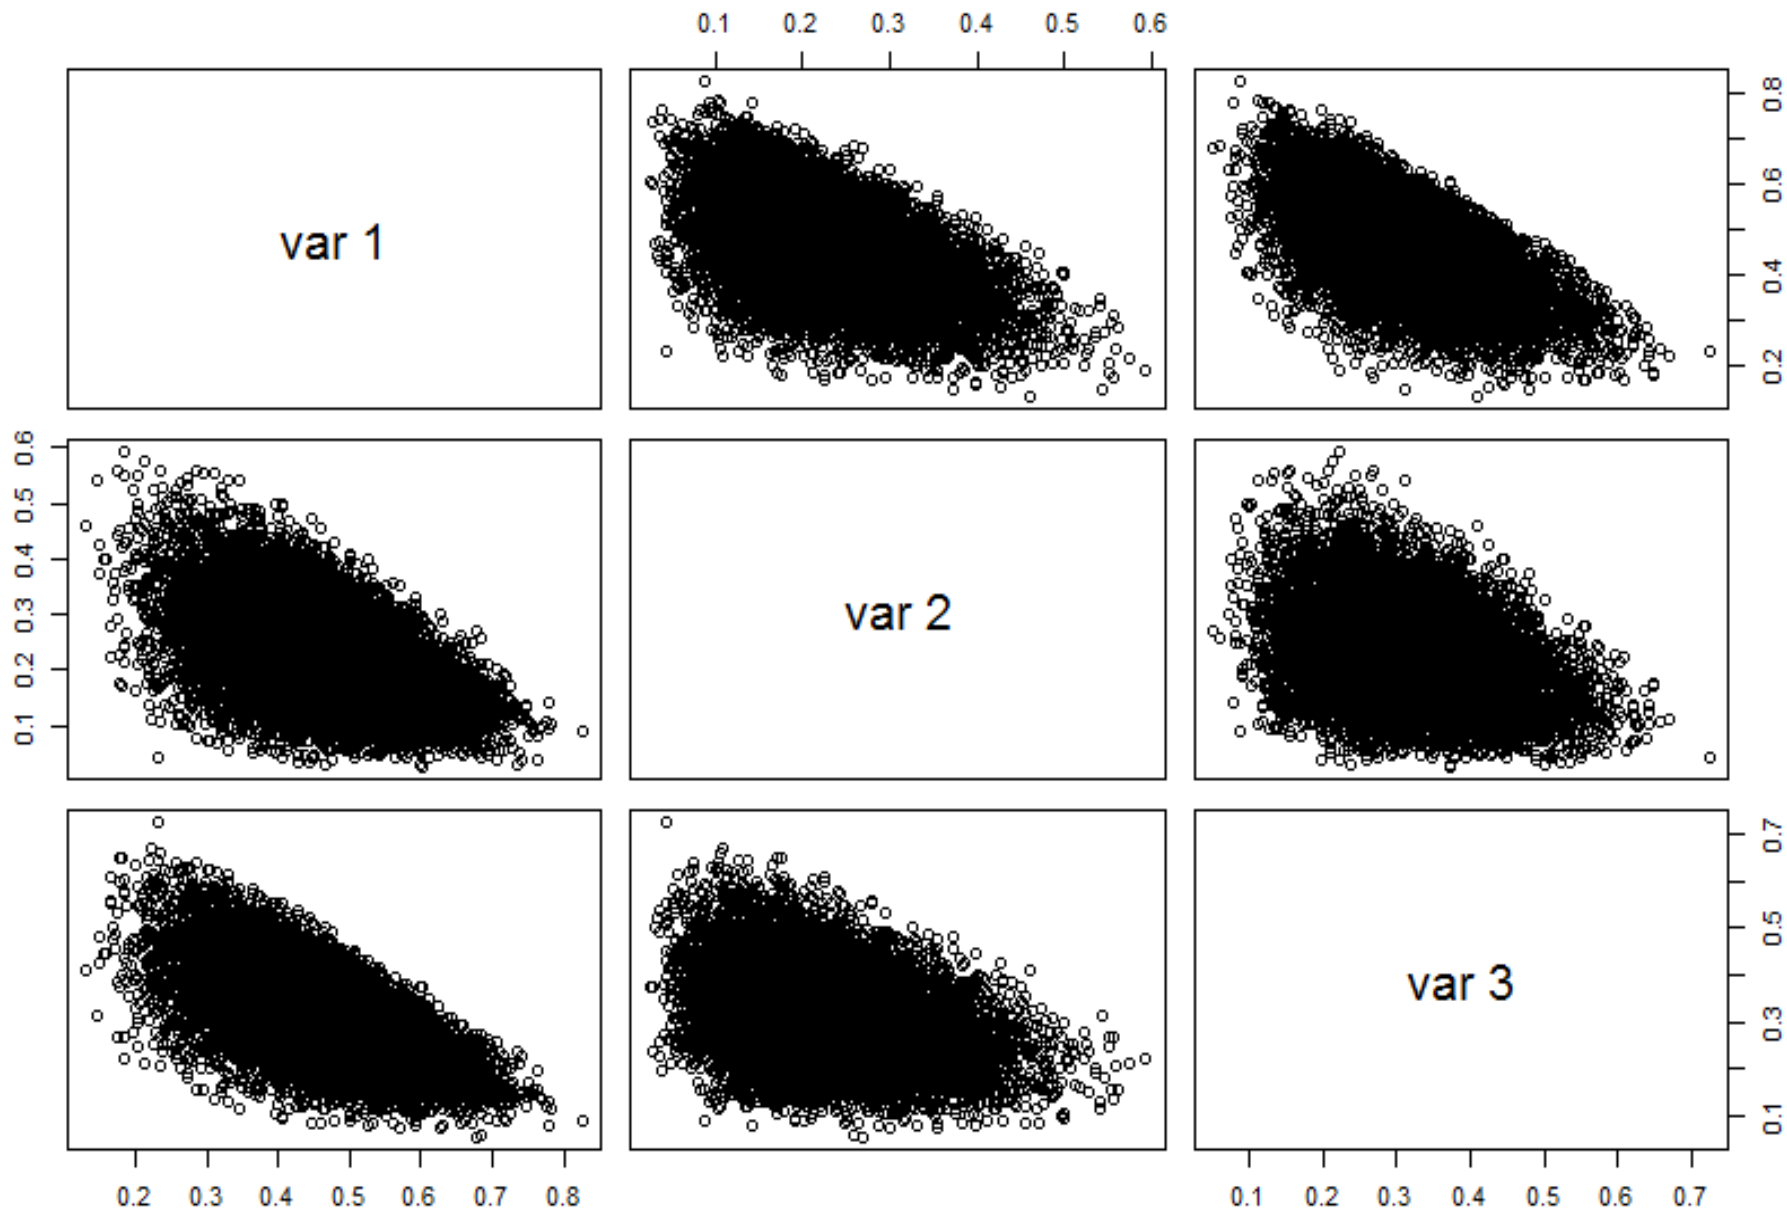
Iteration



MCMC樣本平穩性-需符合亂數(Randomness)特性

# 關於 Burn-in Sample ○ ○ ○





以MCMC計算Dirichlet驗後分佈, data=(10, 5, 7)

# 貝氏修勻的使用建議

- 貝氏修勻可以結合過去經驗與觀察值，同時也可將限制式。
  - 根據經驗值、觀察值的樣本人數決定共變異數矩陣，以Kimeldorf-Jones法修勻。
  - 如果過去資訊不足，或是確定死亡資料與常態分配差異很大時，或可使用MCMC電腦模擬，但建議模擬次數較長(至少去掉一萬個Burn-in Sample)。