

3 Dirichlet 過程參數 (α_0, G_0) 探討

由於 (α_0, G_0) 對我們估計 λ 有重要的影響，本節就 α_0 、 G_0 一些性質做探討，進一步給它們先驗分配，結合資料 \mathbf{Y} 來計算 (α_0, G_0) 的後驗分配。

3.1 參數 α_0 的討論

如前所述，Dirichlet 過程的參數 α_0 代表 G 和 G_0 的相似程度，由 Polya urn 的抽樣結構知，如果 α_0 大， λ_i 從 G_0 抽出來的機率 $\alpha_0/(\alpha_0 + i - 1)$ 較高；反之，如果 α_0 小， λ_i 將有較高的機率等同於已存在的值 $\lambda_1, \dots, \lambda_{i-1}$ 。若用 $\lambda_n = (\lambda_1, \dots, \lambda_n)$ 代表 Polya urn 從第 1 次抽到第 n 次的結果，當 α_0 很大， λ_n 約有 n 種相異的值；當 α_0 很小，約所有 λ_n 都為同一種值。若定義隨機變數 (Antoniak (1974))

$$W_i = \begin{cases} 1, & \text{第 } i \text{ 次的 Polya urn 抽樣值為一新值,} \\ 0, & \text{第 } i \text{ 次的 Polya urn 抽樣值等於已存在的某一值,} \end{cases} \quad i = 1, \dots, n,$$

則隨機變數 $K_n = \sum_{i=1}^n W_i$ ，代表 Polya urn 抽取至 n 次時， λ_n 有幾種值，也就是第二節所提到的群數，且 K_n 的期望值

$$E[K_n] = \sum_{i=1}^n \left[\frac{\alpha_0}{\alpha_0 + i - 1} \times 1 + \frac{i - 1}{\alpha_0 + i - 1} \times 0 \right] = \sum_{i=1}^n \frac{\alpha_0}{\alpha_0 + i - 1}. \quad (3.1)$$

如此一來，只要給定 α_0 值，我們可以估算在此 α_0 的 Polya urn 結構下，抽樣 n 次的預期群數。為了進一步瞭解 α_0 和群數的關係，我們仿照 Escobar (1994, p271) 探討 α_0 和群數的關係，固定 Polya urn 抽樣次數 n ，設定 7 個不同的 α_0 值，利用 (3.1) 式分別估算抽樣 n 次的預期群數，列表如下：

表1. 固定 *Polya urn* 抽樣次數 n ，在7個不同的 α_0 下，預期的群數 $E[K_n]$

$n \backslash \alpha_0$ $E[K_n]$	n^{-3}	n^{-2}	n^{-1}	n^0	n^1	n^2	n^3
15	1.0	1.0	1.2	3.3	10.7	14.6	15.0
30	1.0	1.0	1.1	4.0	21.0	29.5	30.0
50	1.0	1.0	1.1	4.5	34.9	49.5	50.0
100	1.0	1.0	1.1	5.2	69.6	99.5	100.0
500	1.0	1.0	1.0	6.8	346.8	499.5	500.0

由表1可知，當 $\alpha_0 \leq n^{-1}$ ，*Polya urn* 抽樣結果約為一群，如果套用第2節坐圓桌例子的說法，此 n 位客人，大概都坐在同一餐桌；當 $\alpha_0 \geq n^2$ ， n 位客人約坐成了 n 張餐桌，而 $\alpha_0 = n^0$ 及 $\alpha_0 = n^1$ 分別表示約坐成了少數幾張餐桌及許多張餐桌。

有了 α_0 和群數關係認知後，我們在決定參數 α_0 時，便有了一些依據。當觀察值 \mathbf{Y} 「很」集中，我們認為這些觀察值 \mathbf{Y} 皆來自於相同均數的卜瓦松分配，也就是認定 $\lambda_1, \dots, \lambda_n$ 值都相同，則給定 $\alpha_0 = n^{-1}$ ；當觀察值 \mathbf{Y} 「很」分散，我們認為這些觀察值 \mathbf{Y} 來自於 n 種不同均數的卜瓦松分配，則給定 $\alpha_0 = n^2$ 。但在大部分情況下，要從觀察值 \mathbf{Y} 判斷出 λ 的群數並不容易，這導致我們很難選定一個最佳的 α_0 值。

Escobar (1994) 根據表1，設定四種 α_0 可能值 $\{n^{-1}, n^0, n^1, n^2\}$ ，分別表示選擇 λ 為一群、少數幾群、許多群及 n 個群，然後在給定觀察值 \mathbf{Y} 下，算出 α_0 在這四種可能值的機率，以幫助選擇 α_0 值。計算 α_0 後驗機率的方法將於3.3節介紹。

3.2 參數 G_0 的討論

Dirichlet 過程的參數 G_0 代表混合分配 G 最接近的分配型式。為了實際計算上的可行性，我們常常使用伽瑪分配（卜瓦松的共軛先驗分配）或均勻分配當成 G_0 的型式。

在決定 Dirichlet 過程參數的過程中，如果利用資料 \mathbf{Y} 來決定 G_0 的分配，其實就

是運用了EB法則。若進一步的將 G_0 設為伽瑪分配的形式，再用資料 \mathbf{Y} 估計此伽瑪分配的參數，便是採用PEB法則；除了共軛先驗分配， G_0 還有一種可選擇的形式，非正常先驗分配(improper prior)，即給定 λ_i 所有可能值相同權重來計算後驗分配。然而卜瓦松均數 λ_i 的範圍介於0和 ∞ 之間，採用非正常先驗分配將導致後驗分配積分上的困難。為了避免此一困難，我們使用有限範圍的均勻分配來取代之，藉由 Y_1, \dots, Y_n 的最大、最小值幫助決定均勻分配的範圍。

第4節的模擬研究中，我們將 G_0 設為均勻分配的形式。若 $u_1 = \min(Y_1, \dots, Y_n)$ ， $u_2 = \max(Y_1, \dots, Y_n)$ ，我們選定 $U(u_1, u_2)$ 、 $U(u_1 - 1, u_2 + 1)$ 、 $U(u_1 - 2, u_2 + 2)$ 以及 $U(u_1 - 3, u_2 + 3)$ 四種不同範圍的均勻分配，當成 G_0 的可能分配。

3.3 (α_0, G_0) 的先驗和後驗分配

相互搭配3.1節的四種 α_0 及3.2節的四種 G_0 ，我們得到下表16組參數 (α_0, G_0) 的可能值：

$\alpha_0 \backslash G_0$	$U(u_1, u_2)$	$U(u_1 - 1, u_2 + 1)$	$U(u_1 - 2, u_2 + 2)$	$U(u_1 - 3, u_2 + 3)$
n^{-1}	(α_1, G_1)	(α_1, G_2)	(α_1, G_3)	(α_1, G_4)
n^0	(α_2, G_1)	(α_2, G_2)	(α_2, G_3)	(α_2, G_4)
n^1	(α_3, G_1)	(α_3, G_2)	(α_3, G_3)	(α_3, G_4)
n^2	(α_4, G_1)	(α_4, G_2)	(α_4, G_3)	(α_4, G_4)

其中 $(\alpha_1, G_1) = (n^{-1}, U(u_1, u_2))$ ， $(\alpha_2, G_1) = (n^0, U(u_1, u_2))$ ，依此類推。

運用貝氏定理，我們給這16組 (α_i, G_j) 同樣的權重當成其先驗分配，即

$$g(\alpha_i, G_j) = \frac{1}{16}, \quad i, j = 1, 2, 3, 4. \quad (3.2)$$

將(3.2)式乘上 (α_0, G_0) 對觀察值 \mathbf{Y} 的概似函數

$$l\{(\alpha_0, G_0) | \mathbf{Y}\} = \int \prod_{i=1}^n e^{-\lambda_i} \frac{\lambda_i^{Y_i}}{Y_i} dF[\boldsymbol{\lambda} | (\alpha_0, G_0)], \quad (3.3)$$

其中， $dF[\boldsymbol{\lambda} | (\alpha_0, G_0)]$ 的定義與(2.1)式同。

如此一來，參數 (α_0, G_0) 的離散型後驗分配有以下的型式：

$$P\{(\alpha_i, G_j) | \mathbf{Y}\} = \frac{l\{(\alpha_0, G_0) = (\alpha_i, G_j) | \mathbf{Y}\} \cdot g(\alpha_i, G_j)}{\sum_{i=1}^4 \sum_{j=1}^4 l\{(\alpha_0, G_0) = (\alpha_i, G_j) | \mathbf{Y}\} \cdot g(\alpha_i, G_j)}, \quad i, j = 1, 2, 3, 4. \quad (3.4)$$

在實際計算上，由於積分的困難，我們無法直接將16組 (α_i, G_j) 代入(3.3)式求值，也導致(3.4)式後驗分配計算上的困難。為了解決積分問題，Escobar (1995)提供了一個類似Polya urn的重要抽樣方法，幫助完成(3.3)式的估算。

以 $(\alpha_0, G_0) = (\alpha_1, G_1)$ 為例，依序抽取 $\lambda_1, \dots, \lambda_n$ 如下：

$$i = 1$$

$$\lambda_i \sim F_{G_1}(\lambda_i | Y_i),$$

$$i = 2, \dots, n$$

$$\lambda_i | \lambda_1, \dots, \lambda_{i-1} \left\{ \begin{array}{ll} \sim F_{G_1}(\lambda_i | Y_i), & \text{機率正比於 } q_{i,0}, \\ = \lambda_1, & \text{機率正比於 } q_{i,1}, \\ = \lambda_2, & \text{機率正比於 } q_{i,2}, \\ \vdots & \vdots \\ = \lambda_{i-1}, & \text{機率正比於 } q_{i,i-1}, \end{array} \right.$$

其中， $dF_{G_1}(\lambda_i | Y_i) \propto \lambda_i^{(Y_i+1)-1} e^{-\lambda_i} / \Gamma(Y_i + 1)$ ， $u_1 < \lambda_i < u_2$ ，表示先驗分配為均勻分配 G_1 下， λ_i 的後驗分配，是一有界的伽碼分配； $q_{i0} = \alpha_0 \int_{u_1}^{u_2} [\lambda_i^{(Y_i+1)-1} e^{-\lambda_i} / \Gamma(Y_i + 1)] d\lambda_i$ 表示 α_0 乘上 $dF_{G_1}(\lambda_i | Y_i)$ 的標準化常數，且 $q_{ij} = \lambda_j^{Y_i} e^{-\lambda_j} / Y_i$ ，表示將觀察值 Y_i 帶入分別以 λ_j ($j = 1, 2, \dots, i-1$)當均數之卜瓦松分配的機率值。

重複此抽樣方法 K 次後，得到 K 組 $\boldsymbol{\lambda} = (\lambda_1, \dots, \lambda_n)$ ，記為 $\boldsymbol{\lambda}_{(k)} = (\lambda_{1(k)}, \dots, \lambda_{n(k)})$ ， $k = 1, \dots, K$ 。Escobar (1995)利用 $\boldsymbol{\lambda}_{(k)}$ ，提出 $l\{(\alpha_0, G_0) = (\alpha_1, G_1) | \mathbf{Y}\}$ 的估計式為

$$\hat{l}\{(\alpha_0, G_0) = (\alpha_1, G_1) | \mathbf{Y}\} = \frac{1}{K} \sum_{k=1}^K \prod_{i=1}^n \frac{q_{i0} + \sum_{j=1}^{i-1} q_{ij}^{(k)}}{\alpha + i - 1}, \quad (3.5)$$

其中， q_{i0} 的定義如上； $q_{ij}^{(k)}$ 為 q_{ij} 中的 λ_j 以第 k 組抽樣的 $\lambda_{j(k)}$ 代入的結果。

利用相同方法分別算出其餘 15 組 $l\{(\alpha_i, G_j) \mid \mathbf{Y}\}$ 的估計值，配合 (3.2) 式相同權重的先驗分配，便可得到 (3.4) 式離散型後驗分配的估計。有了此離散型後驗分配，我們對第 2 節的吉氏取樣稍做調整，在執行步驟 2. 之前，先依照 (3.4) 式 (α_0, G_0) 的後驗機率分配抽取一組 (α_0, G_0) ，在此組 (α_0, G_0) 值下，再進行步驟 2. 的過程，最後得到一組 $(\lambda_1, \dots, \lambda_n)$ 。

直接由觀察值 \mathbf{Y} 將 $\boldsymbol{\lambda}$ 分群並不容易，只給 G_0 唯一型式也非易事，之前我們想找一組最佳的 (α_0, G_0) 來執行吉氏取樣，顯得不太可行。 (α_0, G_0) 的離散型後驗分配讓此兩個重要參數在決定上有更多選擇，且幫我們對決定的參數做一檢視，當某一組 (α_0, G_0) 的後驗分配機率太小，甚至接近零，我們可猜想那是不適合的。

4 無母數經驗貝氏估計法和母數經驗貝氏估計法

本節將以往估計卜瓦松均數 $\boldsymbol{\lambda} = (\lambda_1, \dots, \lambda_n)$ 的方法，做一整理介紹，在第 5 節的模擬研究，我們會拿這些估計方法和本文提出的 Dirichlet 過程做比較。

4.1 Robbins 的估計法

Robbin's (1955) 提供了一個在 G 不知道的情況下估計卜瓦松均數的方法，他將 (1.2) 式中的 $m(Y_i)$ 、 $m(Y_i + 1)$ ，以 \mathbf{Y} 中等同於 Y_i 值及 $Y_i + 1$ 值的個數來做估計，即

$$\hat{\lambda}_i = (Y_i + 1) \frac{\#\{Y_k : Y_k = Y_i + 1, k = 1, \dots, n\}}{\#\{Y_k : Y_k = Y_i, k = 1, \dots, n\}}. \quad (4.1)$$

並證明，當 $n \rightarrow \infty$ ，此估計式的貝氏風險會趨近 G 為已知型式下的貝氏風險。然而，在下一節的模擬，我們可以看出，此估計法的估計並不理想。