

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  $(\alpha_0, G_0)$  的後驗機率分配抽取一組  $(\alpha_0, G_0)$ ，在此組  $(\alpha_0, G_0)$  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  $\lambda$  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  $(\alpha_0, G_0)$  來執行吉氏取樣，顯得不太可行。 $(\alpha_0, G_0)$  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  $(\alpha_0, G_0)$  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  $\lambda = (\lambda_1, \dots, \lambda_n)$  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。

## 4.2 無母數最大概似估計法

在(1.1)卜瓦松模型

$$Y_i | \lambda_i \sim \text{Poisson}(\lambda_i), \quad i = 1, \dots, n,$$

$$\lambda_i \sim G.$$

之下，觀察值  $\mathbf{Y}$  的邊際分配為

$$m(\mathbf{Y}) = \prod_{i=1}^k m_i(Y_i), \quad (4.2)$$

其中  $m_i(Y_i) = \int f(Y_i | \lambda_i) dG(\lambda_i)$ 。

Laird (1978) 證明使(4.2)有最大值的  $G$  可用少於或等於  $n$  個退化點分配的混合型式來表現，即使  $G$  是一個連續的分配。以下介紹無母數最大概似估計法 (NPML) 估計  $G$  的方法。

步驟1. 設定  $\boldsymbol{\lambda}^{(0)} = (\lambda_1^{(0)}, \dots, \lambda_n^{(0)}) = (Y_1, \dots, Y_n)$  和其對應機率  $\boldsymbol{\pi}^{(0)} = (\pi_1^{(0)}, \dots, \pi_n^{(0)}) = (\frac{1}{n}, \dots, \frac{1}{n})$ ，當成估計先驗分配  $\hat{G}$  的初始值。

步驟2. 對於每一個  $i$ ， $i = 1, \dots, n$ ，

$$w_{ij}^{(1)} \propto \pi_j^{(0)} f(Y_i | \lambda_j^{(0)}) = \pi_j^{(0)} e^{-\lambda_j^{(0)}} \frac{\lambda_j^{(0) Y_i}}{Y_i!}, \quad j = 1, \dots, n,$$

且  $\sum_{j=1}^n w_{ij} = 1$ 。

步驟3. 更新  $\boldsymbol{\lambda}$  及  $\boldsymbol{\pi}$ 。

$$\pi_j^{(1)} = w_{+j}^{(1)}, \quad j = 1, \dots, n,$$

$$\lambda_j^{(1)} = \frac{\sum_{i=1}^n w_{+j}^{(1)} Y_i}{\sum_{i=1}^n w_{ij}^{(1)}}, \quad j = 1, \dots, n.$$

重複  $m$  次步驟2、步驟3後，我們得到  $\boldsymbol{\lambda}^{(m)} = (\lambda_1^{(m)}, \dots, \lambda_n^{(m)})$  及  $\boldsymbol{\pi}^{(m)} = (\pi_1^{(m)}, \dots, \pi_n^{(m)})$ 。當  $m \rightarrow \infty$ ， $\boldsymbol{\lambda}^{(m)} = (\lambda_1^{(m)}, \dots, \lambda_n^{(m)})$  的值會收斂到幾個特定的值，記為  $\lambda_1^*, \dots, \lambda_k^*$ ，( $k \leq n$ )，且將其相對應的機率收集起來，記為  $\pi_1^*, \dots, \pi_k^*$ ，以此當作先驗分配  $G$  的估

計，即

$$\hat{g}(\lambda_i) = \begin{cases} \pi_j^*, & \lambda_i = \lambda_j^*, j = 1, \dots, k, \\ 0, & \text{otherwise} \circ \end{cases}$$

有了估計先驗分配  $\hat{G}$ ， $\lambda_i$  的後驗分配為

$$h(\lambda_i | Y_i) \propto l(\lambda_i | Y_i) \cdot \hat{g}(\lambda_j) = \begin{cases} e^{-\lambda_i} \frac{\lambda_i^{Y_i}}{Y_i!} \cdot \pi_j^*, & \lambda_i = \lambda_j^*, j = 1, \dots, k, \\ 0, & \text{otherwise} \circ \end{cases} \quad (4.3)$$

在損失函數  $L(\hat{\lambda}_i, \lambda_i) = (\hat{\lambda}_i - \lambda_i)^2$  之下， $\lambda_i$  的貝氏估計量為後驗分配 (4.3) 式的期望值

$$\hat{\lambda}_i^{NPEB} = \frac{1}{A} \sum_{j=1}^k \lambda_j^* \left[ e^{-\lambda_j^*} \frac{\lambda_j^{*Y_i}}{Y_i!} \cdot \pi_j^* \right], \quad (4.4)$$

其中  $A = \sum_{j=1}^k e^{-\lambda_j^*} \frac{\lambda_j^{*Y_i}}{Y_i!} \cdot \pi_j^*$ 。

### 4.3 母數經驗貝氏估計法

如前所述，假設分配  $G$  的型式為已知，只是參數未定，以觀察值  $\mathbf{Y}$  來估計未知參數進而得到  $G$  的估計分配，稱為母數經驗貝氏估計法 (PEB)。在卜瓦松的模型下，為了計算的可行性，我們往往假設  $G$  為卜瓦松的共軛分配，亦即伽瑪分配，在此假設之下，(1.1) 式的卜瓦松模型有下列型式：

$$\begin{aligned} Y_i | \lambda_i &\sim \text{Poisson}(\lambda_i), \quad i = 1, \dots, n, \\ \lambda_i &\sim \Gamma(a, b), \end{aligned} \quad (4.5)$$

運用條件期望值和條件變異數的觀念，我們可以找到伽瑪分配參數  $a$ 、 $b$  和隨機變數  $Y_i$  的關係，即

$$E(Y_i) = E[E(Y_i | \lambda_i)] = E[\lambda_i] = ab, \quad (4.6)$$

$$\text{Var}(Y_i) = \text{Var}[E(Y_i | \lambda_i)] + E[\text{Var}(Y_i | \lambda_i)] = \text{Var}[\lambda_i] + E[\lambda_i] = ab^2 + ab \circ$$

當我們得到觀察值  $\mathbf{Y}$  後，便可利用觀察值的均數  $\bar{Y}$  和變異數  $S^2$ ，估計參數  $a$ 、 $b$ 。

令  $\bar{Y} = E(Y_i)$ 、 $S^2 = \text{Var}(Y_i)$ ，我們得到

$$\hat{b} = \frac{S^2 - \bar{Y}}{\bar{Y}} \quad \text{且} \quad \hat{a} = \frac{\bar{Y}}{\hat{b}} \circ$$

有了  $\lambda_i$  的估計先驗分配  $\Gamma(\hat{a}, \hat{b})$ ，接著再利用貝氏定理，我們得到  $\lambda_i$  的後驗分配

$$\begin{aligned}
 h(\lambda_i | Y_i) &\propto l(\lambda_i | Y_i) \cdot g(\lambda_i) \\
 &\propto e^{-\lambda_i} \frac{\lambda_i^{Y_i}}{Y_i!} \cdot \frac{\lambda_i^{\hat{a}-1} e^{-\lambda_i/\hat{b}}}{\Gamma(\hat{a}) \hat{b}^{\hat{a}}} \\
 &\propto \lambda_i^{(\hat{a}+Y_i)-1} e^{-\lambda_i/(\frac{\hat{b}}{1+\hat{b}})} \\
 &\equiv \Gamma\left(\hat{a} + Y_i, \frac{\hat{b}}{1+\hat{b}}\right) .
 \end{aligned} \tag{4.7}$$

同樣地，我們求 (4.7) 式的期望值，並將之當成  $\lambda_i$  的貝氏估計量

$$\hat{\lambda}_i^{PEB} = E(\lambda_i | Y_i) = \frac{(\hat{a}+Y_i)\hat{b}}{1+\hat{b}} = \frac{\hat{a}\hat{b}}{1+\hat{b}} + \frac{Y_i\hat{b}}{1+\hat{b}} = \frac{1}{1+\hat{b}}\bar{Y} + \frac{\hat{b}}{1+\hat{b}}Y_i . \tag{4.8}$$

由 (4.8) 式可知， $\lambda_i$  的 PEB 估計量為所有觀察值平均  $\bar{Y}$  和  $Y_i$  加權平均的結果，其權重分別為  $1/(1+\hat{b})$ 、 $\hat{b}/(1+\hat{b})$ ，且和為 1。當資料  $\mathbf{Y}$  很集中時，變異數  $S^2$  小， $\hat{b}$  跟著小， $1/(1+\hat{b})$  相對較大，此時用較多其他觀察值的資訊來幫助估計  $\lambda_i$ ；當資料  $\mathbf{Y}$  較分散時， $1/(1+\hat{b})$  相對較小，此時相信  $\lambda_i$  應該和  $Y_i$  以外的觀察值關係不大。

## 5 模擬研究和實例探討

### 5.1 模擬研究

從已知分配  $G$  中抽取  $\lambda_i$ ，再以此  $\lambda_i$  當成卜瓦松的參數，抽取  $Y_i$  值，其中  $i = 1, \dots, n$ 。為了不讓估計方法受限於特定的觀察值，我們取  $n = 15, 30, 50$  三種樣本大小，且分別討論  $G$  為「伽瑪分配」及「特定伯努力分配」的狀況，型式如下：

表 2.  $G$  為伽瑪分配以及特定伯努力分配的機率密度函數

$G$ 為伽瑪分配	$G$ 為特定伯努力分配
$f(\lambda_i) = \frac{\lambda_i^{1-1} e^{-\lambda_i/b}}{\Gamma(1)b^1},$	$P(\lambda_i) = \begin{cases} 0.8, & \lambda_i = 0.5, \\ 0.2, & \lambda_i = c, \\ 0, & \text{otherwise,} \end{cases}$
其中， $b = 1, 2, 3.16$ 。	其中， $c = 1.5, 5.5, 10.5$ 。