

單元 23: 分層取樣

(課本 §8.4)

一有限容量佇列系統 (a finite capacity queueing system) 的假設為

- (1) 每天結束時, 倒空系統, 第二天重新開始.
- (2) 顧客的到達時間 $\sim PP(\lambda_i)$, 其中對於 $i = 1, 2, 3$,

$$P(\text{到達率} = \lambda_i) = \frac{1}{3}$$

且天與天之間的到達率相互獨立.

- (3) 隨機變數 L 為一天的顧客流失數.

問. 如何估計 $E(L)$?

答 1. 一個直接的作法為, 先考慮下述的

演算法 1:

(1) 生成一仿隨機數 U .

(2) 令

$$I = \text{Int}(3U) + 1$$

亦即,

$$I \sim \text{unif}(\{1, 2, 3\})$$

(3) 以 λ_I 為到達率, 生成卜松過程, 並求得原始輸出資料 L .

接著, 重覆演算法 1 n 次, 得

$$L_1, \dots, L_n$$

最後, 根據 SLLN, 以原始估計量 (raw estimator)

$$\bar{L} = \frac{1}{n} \sum_{i=1}^n L_i$$

模擬 $E(L)$.

答 2. 因為此系統的顧客到達率不是事前就確定的, 而是先根據一機率分布的選取而確定, 故可根據此特性, 改良

前述未用到此特性的演算法 1. 首先, 對於 $i = 1, 2, 3$, 令

$$L_i^* \stackrel{\text{def}}{=} L|\lambda_i$$

表示在給定到達率 λ_i 時, 一天的顧客流失數.

接著, 考慮輸出資料為

$$\frac{1}{3}L_1^* + \frac{1}{3}L_2^* + \frac{1}{3}L_3^*$$

則

(1) 輸出資料的期望值

$$E \left[\frac{1}{3}(L_1^* + L_2^* + L_3^*) \right] = E(L)$$

亦即, 輸出資料

$$\frac{1}{3}(L_1^* + L_2^* + L_3^*)$$

為 $E(L)$ 的不偏估計量.

(2) 針對變異數,

$$\frac{1}{3}\text{Var}(L_1^* + L_2^* + L_3^*) \leq \text{Var}(L) \quad (1)$$

由此可導出輸出資料的變異數

$$\begin{aligned}\text{Var} \left[\frac{1}{3}(L_1^* + L_2^* + L_3^*) \right] \\ &= \frac{1}{9} \text{Var}(L_1^* + L_2^* + L_3^*) \leq \frac{1}{3} \text{Var}(L) \\ &< \text{Var}(L)\end{aligned}$$

故有較小的變異數，比原始資料變異數的 $\frac{1}{3}$ 還小。

為何如此？

(1) 令隨機變數 I 為到達率的下標，則根據假設，

$$I \sim \text{unif}(\{1, 2, 3\})$$

因此，以隨機變數 I 條件化，並根據 I 的分布， L_i^* 的定義，以及期望值的線性性質，得

$$\begin{aligned}E(L) &= \sum_{i=1}^3 E(L|I=i)P(I=i) \\ &= \sum_{i=1}^3 E(L_i^*) \cdot \frac{1}{3} \\ &= E\left(\frac{1}{3}L_1^* + \frac{1}{3}L_2^* + \frac{1}{3}L_3^*\right)\end{aligned}$$

得證。

(2) 由條件變異數的公式

$$\text{Var}(X) = E[\text{Var}(X|Y)] + \text{Var}[E(X|Y)]$$

知,

$$\text{Var}(X) \geq E[\text{Var}(X|Y)]$$

因為條件變異數公式的等號右邊二項均為非負。

因此, 根據上式, 隨機變數的函數的期望值公式, 條件變異數的定義, 以及 I 的分布, 得

$$\begin{aligned} \text{Var}(L) &\geq E[\text{Var}(L|I)] \\ &= \sum_{i=1}^3 \text{Var}(L|I=i)P(I=i) \\ &= \frac{1}{3} \sum_{i=1}^3 \text{Var}(L|I=i) \end{aligned}$$

又因為 I 為到達率的下標, 故事件 $\{I=i\}$ 乃相當於事件 $\{\lambda=\lambda_i\}$, 再根據 L_i^* 的定義, 以及天與天之間的獨立性, 由上式得

$$\begin{aligned} \text{Var}(L) &\geq \frac{1}{3} \sum_{i=1}^3 \text{Var}(L|\lambda_i) \\ &= \frac{1}{3} \text{Var}(L_1^* + L_2^* + L_3^*) \end{aligned}$$

得證.

所以, 可考慮以

$$\frac{1}{3}(L_1^* + L_2^* + L_3^*)$$

作為模擬 $E(L)$ 的輸出資料, 並得對應的

演算法 2:

(1) 對於 $i = 1, 2, 3$, 各自生成 $\frac{n}{3}$ 個

$$L_i^{*1}, \dots, L_i^{*(n/3)}$$

(2) 對於 $i = 1, 2, 3$, 令

$$\overline{L}_i^* = \frac{3}{n} \sum_{k=1}^{n/3} L_i^{*k}$$

亦即, \overline{L}_i^* 是 L_i^* 的樣本期望值.

(3) 以分層估計量 (stratified estimator)

$$\frac{1}{3}(\overline{L}_1^* + \overline{L}_2^* + \overline{L}_3^*)$$

模擬 $E(L)$.

比較. 演算法 1 需生成 n 個原始輸出資料 L , 且原始估計量 \bar{L} 的變異數

$$\text{Var}(\bar{L}) = \frac{1}{n} \text{Var}(L)$$

演算法 2 需對於 $i = 1, 2, 3$, 各自生成 $\frac{n}{3}$ 個分層輸出資料 L_i^* , 共 n 個分層輸出資料, 且分層估計量

$$\frac{1}{3}(\bar{L}_1^* + \bar{L}_2^* + \bar{L}_3^*)$$

的變異數

$$\begin{aligned} & \text{Var} \left[\frac{1}{3}(\bar{L}_1^* + \bar{L}_2^* + \bar{L}_3^*) \right] \\ &= \frac{1}{9} \text{Var}(\bar{L}_1^* + \bar{L}_2^* + \bar{L}_3^*) \\ &= \frac{1}{9} \cdot \frac{3}{n} \text{Var}(L_1^* + L_2^* + L_3^*) \\ &= \frac{1}{n} \cdot \frac{1}{3} \text{Var}(L_1^* + L_2^* + L_3^*) \\ &\leq \frac{1}{n} \text{Var}(L) = \text{Var}(\bar{L}) \end{aligned}$$

其中第二等號成立乃因為對於 $i = 1, 2, 3$, \bar{L}_i^* 分別是大為 $\frac{n}{3}$ 的 L_i^* 的樣本期望值, 故經由累加和的運算性質,

得

$$\overline{L_1^*} + \overline{L_2^*} + \overline{L_3^*}$$

是大小為 $\frac{n}{3}$ 的

$$L_1^* + L_2^* + L_3^*$$

的樣本期望值，並根據樣本期望值的變異數公式所致；第四個小於或等於符號乃根據 (1) 式所致。

因此，以演算法 2 模擬，會得到較小的變異數。

例 1. 一無限多服務員佇列系統 (an infinite server queueing system) 的假設為

(1) 顧客的到達時間乃根據一個卜松過程 (PP)，其

$$\text{到達率} = \begin{cases} 12, & \text{好日子,} \\ 4, & \text{一般日子.} \end{cases}$$

且好日子與一般日子乃相互獨立，以及

$$P(\text{好日子}) = \frac{1}{2}$$

(2) 在所有的日子，顧客接受的

$$\text{服務時間} \sim \exp(1)$$

- (3) 在 $t = 10$ 時, 系統關閉, 所有未完成服務的顧客均需離開. 令 L 為在隨機選中的一天內, 未完成服務的顧客數.

試比較 $E(L)$ 的原始估計量與分層估計量間的差異.

<解> 令隨機變數

$$L_g \stackrel{\text{def}}{=} L | \text{好日子} = L | (\lambda = 12)$$

表示在好日子的未完成服務的顧客數, 且隨機變數

$$L_o \stackrel{\text{def}}{=} L | \text{一般日子} = L | (\lambda = 4)$$

表示在一般日子的未完成服務的顧客數.

接著, 敘述二個事實

$$L_g \sim \text{Poisson}[12(1 - e^{-10})]$$

以及

$$L_o \sim \text{Poisson}[4(1 - e^{-10})]$$

並分別探討下述的兩種情況.

情況 1. 原始估計量.

以日子的種類條件化，並根據 L_g 與 L_o 的定義，日子種類的分布，以及上述的事實，得 L 的期望值

$$\begin{aligned}
 E(L) &= E(L|\text{好日子})P(\text{好日子}) + \\
 &\quad E(L|\text{一般日子})P(\text{一般日子}) \\
 &= \frac{1}{2}E(L_g) + \frac{1}{2}E(L_o) \\
 &= \frac{1}{2}(12 + 4)(1 - e^{-10}) \\
 &\approx \frac{1}{2}(12 + 4) = 8
 \end{aligned}$$

又根據變異數的公式，上述的事實，以及卜松分布的變異數等於期望值的性質，得 L_g^2 的二階動差

$$\begin{aligned}
 E(L_g^2) &= \text{Var}(L_g) + [E(L_g)]^2 \\
 &= E(L_g) + [E(L_g)]^2 \\
 &= 12(1 - e^{-10}) + [12(1 - e^{-10})]^2 \\
 &\approx 12 + (12)^2 = 156
 \end{aligned}$$

同理，得 L_o 的二階動差

$$\begin{aligned}
 E(L_o^2) &= \text{Var}(L_o) + [E(L_o)]^2 \\
 &= 4(1 - e^{-10}) + [4(1 - e^{-10})]^2 \\
 &\approx 4 + 4^2 = 20
 \end{aligned}$$

最後，以日子的種類條件化，並根據 L_g 與 L_o 的定義，日子種類的分布，以及上述 L_g 與 L_o 的二階動差，得 L 的二階動差

$$\begin{aligned} E(L^2) &= E(L^2|\text{好日子})P(\text{好日子}) + \\ &\quad E(L^2|\text{一般日子})P(\text{一般日子}) \\ &= \frac{1}{2}E(L_g^2) + \frac{1}{2}E(L_o^2) \\ &\approx \frac{1}{2}(156 + 20) = 88 \end{aligned}$$

故， L 的變異數

$$\begin{aligned} \text{Var}(L) &= E(L^2) - [E(L)]^2 \\ &\approx 88 - 8^2 = 24 \end{aligned}$$

因此，模擬的過程為，生成原始輸出資料

$$L_1, \dots, L_n$$

得原始估計量

$$\bar{L} = \frac{1}{n} \sum_{i=1}^n L_i$$

以及

$$\text{Var}(\bar{L}) = \frac{1}{n} \text{Var}(L) \approx \frac{24}{n} \quad (2)$$

情況 2. 分層估計量.

因爲

$$P(\text{好日子}) = \frac{1}{2}$$

故可考慮以

$$\frac{1}{2}(L_g + L_o)$$

作爲模擬 $E(L)$ 的輸出資料.

又根據變異數的純量乘積公式, 好日子與一般日子的獨立性假設, 上述的事實, 以及卜松分布的性質, 得分層輸出資料的變異數

$$\begin{aligned}\text{Var} \left[\frac{1}{2}(L_g + L_o) \right] &= \frac{1}{4}[\text{Var}(L_g) + \text{Var}(L_o)] \\ &= \frac{1}{4}[E(L_g) + E(L_o)] \\ &\approx \frac{1}{4}(12 + 4) = 4 \quad (3)\end{aligned}$$

因此, 分層模擬法爲, 生成 $\frac{n}{2}$ 個

$$L_{g,1}, \dots, L_{g,n/2}$$

以及 $\frac{n}{2}$ 個

$$L_{o,1}, \dots, L_{o,n/2}$$

得分層估計量

$$\frac{1}{2}\overline{L}_g + \frac{1}{2}\overline{L}_o$$

其中

$$\overline{L}_g = \frac{2}{n} \sum_{i=1}^{n/2} L_{g,i}$$

且

$$\overline{L}_o = \frac{2}{n} \sum_{i=1}^{n/2} L_{o,i}$$

另外，根據累加和的運算性質以及 (3) 式，得

$$\begin{aligned} \text{Var} \left[\frac{1}{2}(\overline{L}_g + \overline{L}_o) \right] &= \frac{2}{n} \text{Var} \left[\frac{1}{2}(L_g + L_o) \right] \\ &\approx \frac{2}{n} \cdot 4 = \frac{8}{n} \end{aligned} \quad (4)$$

最後，綜合 (2) 式與 (4) 式，得

$$\text{Var}(\text{原始估計量}) \approx 3 \cdot \text{Var}(\text{分層估計量})$$

註 1. 推廣. 設有 k 種到達率

$$\lambda_i, \quad i = 1, \dots, k$$

且對於 $i = 1, \dots, k$,

$$P(\text{到達率} = \lambda_i) = p_i$$

以及

$$\sum_{i=1}^k p_i = 1$$

對於 $i = 1, \dots, k$, 令隨機變數

$$L_i^* = L | \lambda_i$$

分層法 (stratified approach) 為

(1) 對於 $i = 1, \dots, k$, 各自生成

$$n_i \stackrel{\text{def}}{=} np_i$$

個 L_i^* , 並求樣本期望值

$$\overline{L_i^*}$$

(2) 以分層估計量

$$\hat{\theta} \stackrel{\text{def}}{=} \sum_{i=1}^k p_i \overline{L_i^*}$$

估計 $\theta = E(L)$.

為何可行?

(a) $\hat{\theta}$ 為 θ 的不偏估計量.

根據期望值的線性性質, 樣本期望值 \overline{L}_i^* 的不偏性, 隨機變數 L_i^* 的定義, 到達率的分布, 以及期望值的條件化公式,

$$\begin{aligned} E(\hat{\theta}) &= \sum_{i=1}^k p_i E(\overline{L}_i^*) = \sum_{i=1}^k p_i E(L_i^*) \\ &= \sum_{i=1}^k E(L|\lambda_i) P(\text{到達率} = \lambda_i) \\ &= E(L) = \theta \end{aligned}$$

得證.

(b) $\hat{\theta}$ 有較小的變異數.

根據樣本期望值 \overline{L}_i^* 間的獨立性, 變異數的純量乘積公式, 樣本期望值 \overline{L}_i^* 的變異數公式, 得

$$\begin{aligned} \text{Var}(\hat{\theta}) &= \sum_{i=1}^k p_i^2 \text{Var}(\overline{L}_i^*) \\ &= \sum_{i=1}^k p_i^2 \cdot \frac{1}{n_i} \text{Var}(L_i^*) \end{aligned}$$

再根據 n_i 的定義, 以及 L_i 的定義, 由上式得

$$\begin{aligned}\text{Var}(\hat{\theta}) &= \sum_{i=1}^k p_i^2 \cdot \frac{1}{np_i} \text{Var}(L_i^*) \\ &= \frac{1}{n} \sum_{i=1}^k p_i \text{Var}(L_i^*) \\ &= \frac{1}{n} \sum_{i=1}^k \text{Var}(L|\lambda_i) P(\text{到達率} = \lambda_i) \quad (5)\end{aligned}$$

又令隨機變數 I 滿足, 對於 $i = 1, \dots, k$,

$$P(I = i) = p_i$$

且

$$\{I = i\} = \{\text{到達率} = \lambda_i\}$$

則將 (5) 式改寫並根據條件變異數的期望值公式, 得

$$\begin{aligned}\text{Var}(\hat{\theta}) &= \frac{1}{n} \sum_{i=1}^k \text{Var}(L|I = i) P(I = i) \\ &= \frac{1}{n} E[\text{Var}(L|I)] \quad (6)\end{aligned}$$

最後, 根據熟知的條件期望值的變異數與原隨機變數的變異數的公式

$$\text{Var}(L) = E[\text{Var}(L|I)] + \text{Var}[E(L|I)]$$

知, 上式等號右邊的兩項均為非負, 故由 (6) 式, 上式, 以及樣本期望值的變異數公式, 得

$$\text{Var}(\hat{\theta}) \leq \frac{1}{n} \text{Var}(L) = \text{Var}(\bar{L})$$

得證.

因此, 分層估計量

$$\hat{\theta} = \sum_{i=1}^k p_i \bar{L}_i^*$$

是 θ 的不偏估計量, 並較原始估計量 \bar{L} 有較小的變異數, 而得上述可行的推廣型分層法.

註 2. 通常 $\text{Var}(L_i^*)$ 未知, 所以可用

$$\sum_{i=1}^k p_i^2 \cdot \frac{S_i^2}{n_i}$$

估計

$$\text{Var}(\hat{\theta}) = \sum_{i=1}^k p_i^2 \cdot \frac{\text{Var}(L_i^*)}{n_i}$$

其中 S_i^2 為 L_i^* 的樣本變異數.

問. 取 $n_i = np_i$ 時, $\text{Var}(\hat{\theta})$ 是否為最小?

此問題乃相當於如何選取 n_i 使得

$$\hat{\theta} = \sum_{i=1}^k p_i \overline{L_i^*}$$

有最小的變異數?

答. 對於 $i = 1, \dots, k$, 令任意的 $n_i \geq 0$ 且滿足

$$\sum_{i=1}^k n_i = n$$

則生成 n_i 個 L_i^* 後, 並考慮

$$\sum_{i=1}^k p_i \overline{L_i^*}$$

得

(a) 隨機變數

$$\sum_{i=1}^k p_i \overline{L_i^*}$$

為 $E(L)$ 的不偏估計量.

為何如此? 因為 $\overline{L_i^*}$ 為 L_i^* 的樣本期望值, 故根據期望值的線性性質, 樣本期望值的不偏性, 以及期望值的條件

化公式,

$$\begin{aligned} E\left(\sum_{i=1}^k p_i \bar{L}_i^*\right) &= \sum_{i=1}^k p_i E(\bar{L}_i^*) \\ &= \sum_{i=1}^k p_i E(L_i^*) \\ &= E(L) \end{aligned}$$

得證.

(b) 變異數

$$\text{Var}\left(\sum_{i=1}^k p_i \bar{L}_i^*\right) = \sum_{i=1}^k p_i^2 \cdot \frac{\text{Var}(L_i^*)}{n_i}$$

此乃因爲 \bar{L}_i^* 間的獨立性, 變異數的線性組合公式, 以及樣本期望值的變異數公式所致.

因此, 綜合上述的 (a) 與 (b) 得知, 對於 $i = 1, \dots, k$, 模擬 S_i^2 估計 $\text{Var}(L_i^*)$ 後, 對任意非負的

$$n_1, \dots, n_k$$

滿足

$$\sum_{i=1}^k n_i = n$$

均得到

$$\sum_{i=1}^k p_i \overline{L}_i^*$$

爲 $E(L)$ 的不偏估計量, 且

$$\text{Var} \left(\sum_{i=1}^k p_i \overline{L}_i^* \right) \approx \sum_{i=1}^k p_i^2 \cdot \frac{S_i^2}{n_i}$$

所以, 前述如何選取 n_i 的問題, 乃相當於一個最佳化問題 (optimization problem):

最小化 (minimize)

$$\sum_{i=1}^k p_i^2 \cdot \frac{S_i^2}{n_i}$$

受制於 (subject to)

$$n_i \geq 0 \text{ 且 } \sum_{i=1}^k n_i = n$$

因此, 根據最佳化問題而解得的 n_i , 所產生的估計量

$$\sum_{i=1}^k p_i \overline{L}_i^*$$

會比取 $n_i = np_i$, 有較小的變異數.

例. 接續例 1 的無窮服務員佇列系統, 其中到達率的種類數 $k = 2$ 且產生的機率均為 $p = \frac{1}{2}$. 對於 $0 \leq x \leq 1$, 生成 $n_1 = nx$ 個 L_g 及 $n_2 = n(1 - x)$ 個 L_o .

又根據前述的兩個事實

$$L_g \sim \text{Poisson}[12(1 - e^{-10})]$$

以及

$$L_o \sim \text{Poisson}[4(1 - e^{-10})]$$

得

$$S_1^2 \approx \text{Var}(L_g) \approx 12$$

且

$$S_2^2 \approx \text{Var}(L_o) \approx 4$$

故, 根據註 2, 最佳的 n_1 與 n_2 乃相當於求

$$\min_{0 \leq x \leq 1} \left[\left(\frac{1}{2}\right)^2 \frac{S_1^2}{nx} + \left(\frac{1}{2}\right)^2 \frac{S_2^2}{n(1-x)} \right]$$

代入 S_1^2 與 S_2^2 的估計值, 消去不影響極值的

$$\left(\frac{1}{2}\right)^2 \frac{1}{n}$$

後，亦相當於求

$$\min_{0 \leq x \leq 1} \left(\frac{12}{x} + \frac{4}{1-x} \right)$$

亦相當於再除以 4，並令

$$f(x) = \frac{3}{x} + \frac{1}{1-x}$$

且由

$$\begin{aligned} f'(x) &= -\frac{3}{x^2} + \frac{1}{(1-x)^2} \\ &= \frac{-3 + 6x - 2x^2}{x^2(1-x)^2} = 0 \end{aligned}$$

得臨界數 (critical numbers)

$$x = \frac{-6 \pm \sqrt{36 - 24}}{-4} = \frac{3 \mp \sqrt{3}}{2}$$

其中 " + " 不合，因為大於 1，不在求極值的範圍內。

再根據 f' 的分子為一開口向下的拋物線，可計算出 f' 在此一臨界數所分隔的兩個子區間內的符號及對應的遞增遞減性為

$$\left(0, \frac{3-\sqrt{3}}{2} \right): f' = \frac{(-)}{(+)} = (-), \text{ 遞減};$$

$$\left(\frac{3-\sqrt{3}}{2}, 1\right): f' = \frac{(+)}{(+)} = (+), \text{遞增.}$$

故, 根據一階導函數檢定法,

$$f(x) = \frac{3}{x} + \frac{1}{1-x}$$

在

$$x = \frac{3-\sqrt{3}}{2} \approx 0.634$$

有最小值.

因此, 生成 $(0.634)n$ 個 L_g 以及 $(0.366)n$ 個 L_o , 並以

$$\frac{1}{2}L_g + \frac{1}{2}L_o$$

估計 $E(L)$ 會有最小的變異數.

定義. 設隨機變數 X 的值需先由另一隨機變數 S , 其已知分布為

$$P(S = i), \quad i = 1, \dots, k$$

所決定, 則不先模擬 S , 而先對於 $i = 1, \dots, k$, 分別模擬

$$X|S = i$$

並求出對應的樣本期望值 \bar{X}_i 且以

$$\sum_{i=1}^k \bar{X}_i P(S = i)$$

估計

$$E(X) = \sum_{i=1}^k E(X|S = i)P(S = i)$$

的方法稱為分層取樣法 (stratified sampling).

註. 由上述期望值的條件期望值表示法知, 分層取樣法的關鍵就在於將條件期望值 $E(X|S = i)$ 以 $X|S = i$ 的樣本期望值 \bar{X}_i 所估計與取代.

例 2. 試以分層取樣法模擬

$$\theta = \int_0^1 h(x)dx$$

<解> (a) 一般方法. 令隨機變數

$$U \sim \text{unif}(0, 1)$$

則根據隨機變數的函數的期望值公式,

$$E[h(U)] = \int_0^1 h(u) \cdot 1 du = \theta$$

剛好就是欲估計的值.

故根據蒙地卡羅法, 考慮

演算法 1:

(1) 生成一個仿隨機數 U .

(2) 生成輸出資料 $h(U)$.

接著, 重覆演算法 1 n 次, 得

$$h(U_1), \dots, h(U_n)$$

最後, 根據 SLLN, 以原始估計量 (raw estimator)

$$\overline{h(U)} \stackrel{\text{def}}{=} \frac{1}{n} \sum_{i=1}^n h(U_i)$$

估計 $E[h(U)] = \theta$.

(b) 分層取樣. 將區間 $(0, 1]$ n 等分, 得

$$(0, 1] = \bigcup_{i=1}^n \left(\frac{i-1}{n}, \frac{i}{n} \right]$$

則上述演算法 1 中的步驟 (1) 生成 U , 乃相當於隨機選取一個子區間及其中的一值 U ; 步驟 (2) 生成 $h(U)$, 乃相當於在選中的子區間內製造 $h(U)$. 此乃類似於前述例子, 先隨機選定到達率, 再求得對應輸出資料的兩步驟模擬過程, 故可考慮以分層取樣的方式改良演算法 1.

如何分層? 因為共有 n 個子區間, 且每一子區間被選中的機率均為 $\frac{1}{n}$, 故可分成 n 層如下,

(1) 對於 $i = 1, \dots, n$, 定義子區間的指標 (index)

$$I = i, \text{ 若 } \frac{i-1}{n} < U \leq \frac{i}{n}$$

由此導出

$$P(I = i) = P\left(\frac{i-1}{n} < U \leq \frac{i}{n}\right) = \frac{1}{n}$$

故

$$I \sim \text{unif}(\{1, \dots, n\})$$

如所求.

(2) 對於 $i = 1, \dots, n$, 給定 $I = i$ 時, 定義

$$U_i^* \stackrel{\text{def}}{=} U|I = i$$

則顯然地 (自行驗證),

$$U_i^* \sim \text{unif} \left\{ \left(\frac{i-1}{n}, \frac{i}{n} \right] \right\} \quad (7)$$

爲何如此? 對於任意固定的 $i = 1, \dots, n$, 以及對於所有的 $-\infty < x < \infty$, 根據 U_i^* 的定義, I 的定義, 以及條件機率的定義, 得分布函數

$$\begin{aligned} P(U_i^* \leq x) &= P(U \leq x | I = i) \\ &= P\left(U \leq x \mid \frac{i-1}{n} < U \leq \frac{i}{n}\right) \\ &= \frac{P\left(U \leq x, \frac{i-1}{n} < U \leq \frac{i}{n}\right)}{P\left(\frac{i-1}{n} < U \leq \frac{i}{n}\right)} \end{aligned} \quad (8)$$

另外, 根據 U 在 $(0, 1)$ 的均勻分布, (8) 的分母

$$P\left(\frac{i-1}{n} < U \leq \frac{i}{n}\right) = \frac{i}{n} - \frac{i-1}{n} = \frac{1}{n} \quad (9)$$

故, 當 $x \leq \frac{i-1}{n}$ 時, 事件

$$\left(U \leq x, \frac{i-1}{n} < U \leq \frac{i}{n}\right) = \emptyset$$

故由 (8) 式與 (9) 式, 得

$$P(U_i^* \leq x) = n \cdot P(\emptyset) = n \cdot 0 = 0$$

當 $\frac{i-1}{n} < x \leq \frac{i}{n}$ 時, 事件

$$\left(U \leq x, \frac{i-1}{n} < U \leq \frac{i}{n} \right) = \left(\frac{i-1}{n} < U \leq x \right)$$

故由 (8) 式, (9) 式, 以及 U 的均勻性, 得

$$\begin{aligned} P(U_i^* \leq x) &= n \cdot P\left(\frac{i-1}{n} < U \leq x\right) \\ &= n \left(x - \frac{i-1}{n}\right) \end{aligned}$$

當 $x > \frac{i}{n}$ 時, 事件

$$\left(U \leq x, \frac{i-1}{n} < U \leq \frac{i}{n} \right) = \left(\frac{i-1}{n} < U \leq \frac{i}{n} \right)$$

故由 (8) 式, (9) 式, 以及 U 的均勻性, 得

$$\begin{aligned} P(U_i^* \leq x) &= n \cdot P\left(\frac{i-1}{n} < U \leq \frac{i}{n}\right) \\ &= n \cdot \frac{1}{n} = 1 \end{aligned}$$

因此, 綜合上述, 得 U_i^* 的分布函數

$$P(U_i^* \leq x) = \begin{cases} 0, & \text{若 } x \leq \frac{i-1}{n}, \\ n \left(x - \frac{i-1}{n}\right), & \text{若 } \frac{i-1}{n} < x \leq \frac{i}{n}, \\ 1, & \text{若 } x > \frac{i}{n}. \end{cases}$$

最後，將分布函數對 x 微分，得 U_i^* 的 pdf

$$f_{U_i^*}(x) = \begin{cases} n, & \text{若 } \frac{i-1}{n} < x < \frac{i}{n}, \\ 0, & \text{其它.} \end{cases}$$

故，

$$U_i^* \sim \text{unif} \left\{ \left(\frac{i-1}{n}, \frac{i}{n} \right] \right\}$$

得證.

(3) 以分層估計量

$$\frac{1}{n} \sum_{i=1}^n h(U_i^*)$$

估計 θ .

對於 $i = 1, \dots, n$ ，如何生成 U_i^* ? 令

$$X \sim \text{unif}(0, 1)$$

則

$$\frac{1}{n}(i-1+X) \sim \text{unif} \left(\frac{i-1}{n}, \frac{i}{n} \right) \quad (10)$$

(自行驗證)，故得對應的

演算法 2:

(1) 生成 n 個仿隨機數

$$U_1, \dots, U_n$$

(2) 以分層估計量

$$\hat{\theta} \stackrel{\text{def}}{=} \frac{1}{n} \sum_{i=1}^n h \left[\frac{1}{n}(i-1 + U_i) \right]$$

估計 θ .

註. 對於 $i = 1, \dots, n$, 根據分布,

$$\frac{1}{n}(i-1 + U_i) \sim \text{unif} \left(\frac{i-1}{n}, \frac{i}{n} \right)$$

扮演 U_i^* 的角色, 且 U_i^* 間相互獨立. 另外, 分層估計量 $\hat{\theta}$ 更接近 (或就是) 黎曼和 (Rieman sum).

為何分層估計量 $\hat{\theta}$ 是一個估計 θ 的好的估計量?

首先, 根據期望值的線性性質, I 的分布, 得

$$\begin{aligned} E(\hat{\theta}) &= \frac{1}{n} \sum_{i=1}^n E \left\{ h \left[\frac{1}{n}(i-1 + U_i) \right] \right\} \\ &= \sum_{i=1}^n E \left\{ h \left[\frac{1}{n}(i-1 + U_i) \right] \right\} P(I = i) \end{aligned}$$

再根據 (7) 式與 (10) 式, 亦即, 對於 $i = 1, \dots, n$,

$$\frac{1}{n}(i - 1 + U_i)$$

與

$$U|I = i$$

有相同的分布, 以及條件化的公式, 由上式得

$$\begin{aligned} E(\hat{\theta}) &= \sum_{i=1}^n E[h(U)|I = i]P(I = i) \\ &= E[h(U)] = \theta \end{aligned}$$

亦即, 分層估計量 $\hat{\theta}$ 為不偏估計量.

又根據 U_i 間的獨立性, 獨立隨機變數線性組合的變異數公式, I 的分布, 上述的同分布性質, 以及隨機變數函數的期望值公式, 得

$$\begin{aligned} \text{Var}(\hat{\theta}) &= \frac{1}{n^2} \sum_{i=1}^n \text{Var} \left\{ h \left[\frac{1}{n}(i - 1 + U_i) \right] \right\} \\ &= \frac{1}{n} \sum_{i=1}^n \text{Var} \left\{ h \left[\frac{1}{n}(i - 1 + U_i) \right] \right\} P(I = i) \\ &= \frac{1}{n} \sum_{i=1}^n \text{Var}[h(U)|I = i]P(I = i) \\ &= \frac{1}{n} E\{\text{Var}[h(U)|I]\} \end{aligned}$$

其中最後一個等號成立乃因為 $\text{Var}[h(U)|I]$ 為一 I 的函數所致.

再根據一再應用的變異數不等式, 以及樣本期望值的變異數公式, 由上式得

$$\begin{aligned}\text{Var}(\hat{\theta}) &\leq \frac{1}{n} \text{Var}[h(U)] \\ &= \text{Var}[\overline{h(U)}]\end{aligned}$$

所以, 分層估計量

$$\hat{\theta} = \frac{1}{n} \sum_{i=1}^n h \left[\frac{1}{n}(i-1 + U_i) \right]$$

比原始估計量

$$\overline{h(U)} = \frac{1}{n} \sum_{i=1}^n h(U_i)$$

有較小的變異數.

例 3. 因為

$$\begin{aligned}\frac{\pi}{4} &= \text{在 } [0, 1] \text{ 上, 函數 } y = \sqrt{1-x^2} \text{ 所圍出} \\ &\quad \text{的四分之一單位圓的面積} \\ &= \int_0^1 \sqrt{1-x^2} dx \\ &= E \left(\sqrt{1-U^2} \right)\end{aligned}$$

其中

$$U \sim \text{unif}(0, 1)$$

故由例 2, 得 π 的分層估計量

$$\frac{4}{n} \sum_{i=1}^n \sqrt{1 - \left[\frac{1}{n}(i-1 + U_i) \right]^2}$$

比原始估計量

$$\frac{4}{n} \sum_{i=1}^n \sqrt{1 - U_i^2}$$

亦可由條件化法求得, 有較小的變異數, 其中

$$U_1, \dots, U_n \stackrel{\text{iid}}{\sim} \text{unif}(0, 1)$$

由於分層估計量中,

$$\sqrt{1 - \left[\frac{1}{n}(i-1 + U) \right]^2}$$

的單調性質, 事實上為 U 的遞減函數, 故可用對偶變數法改良, 得更好的估計量

$$\hat{\pi} = \frac{4}{n} \sum_{i=1}^n \frac{1}{2} \left\{ \sqrt{1 - \left[\frac{1}{n}(i-1 + U_i) \right]^2} + \sqrt{1 - \left[\frac{1}{n}(i-1 + (1 - U_i)) \right]^2} \right\}$$

經化簡, 得

$$\hat{\pi} = \frac{2}{n} \sum_{i=1}^n \left[\sqrt{1 - \left(\frac{i-1+U_i}{n} \right)^2} + \sqrt{1 - \left(\frac{i-U_i}{n} \right)^2} \right]$$

一個模擬結果如下:

n	$\hat{\pi}$
5	3.161211
10	3.148751
100	3.141734
500	3.141615
1000	3.141601
5000	3.141593

練習題 1. 試以 $\hat{\pi}$ 模擬 π , 並驗證上述的模擬結果.

練習題 2. 試用模擬結果比較 $\hat{\pi}$, 分層估計量, 以及原始估計量.