

刀切不完全U统计量*

施锡铨

(武汉水利电力学院)

设 θ 为未知参数, $X_1, X_2, \dots, X_N$ 为来自 F_θ 的 N 个独立同分布的观察值. $f(x_1, \dots, x_m)$ ($m < N$) 为 m 元对称可测函数, $Ef(X_1, \dots, X_m) = \theta$. 定义 U 统计量为

$$U_0 = \binom{N}{m}^{-1} \sum_{1 \leq \alpha_1 < \alpha_2 < \dots < \alpha_m \leq N} f(X_{\alpha_1}, \dots, X_{\alpha_m}). \quad (1)$$

如所周知, 对于 U 统计量及它的正则函数, 文[1]研究表明, 刀切法是能获得近似置信区间的有效的非参数方法.

为了减少实用中许多不便之处, G. Blom^[2] 于 1976 年提出:

定义1 从所有 $f(X_{\alpha_1}, \dots, X_{\alpha_m})$ 中适当选择 r 个对称核 f_i , 称统计量

$$U = \sum_{i=1}^r f_i / r \quad r < \binom{N}{m} \quad (2)$$

为不完全 U 统计量 (incomplete U -statistic).

不完全 U 统计量对于 N 个观察值而言并非对称函数, 刀切法对它是否有效是个有意义的问题. 本文仅对 Brown^[3] 等人所研究的一类特殊的不完全 U 统计量用刀切法的思想进行处理, 得到与刀切 U 统计量同样的效果.

我们采用 Brown 的记号, $f(\cdot, \cdot)$ 为对称可测函数,

$$\begin{aligned} S_N &= \sum_{C_k} f(X_i, X_j), \quad \theta = Ef(X_1, X_2), \\ \sigma^2 &= \text{Var} f(X_1, X_2) > 0, \quad \rho \sigma^2 = \text{Cov}\{f(X_1, X_2), f(X_1, X_3)\}, \end{aligned} \quad (3)$$

其中 $C_k = \{(i, j): 1 \leq i < j \leq N, \text{ 每一 } \leq N \text{ 的整数恰出现 } 2k \text{ 次 } (k \text{ 固定})\}$ 故 C_k 恰有 Nk 项.

$\hat{\theta}_N \triangleq \frac{1}{Nk} S_N$ 为不完全 U 统计量, 易知

$$\text{Var } S_N = Nk\sigma^2[1 + 2(2k-1)\rho].$$

定理1 若 $Ef^2(X_i, X_j) < \infty$, 那末

$$(Nk)^{\frac{1}{2}}(\hat{\theta}_N - \theta) \rightarrow_d N(0, \sigma^2[1 + 2(2k-1)\rho]),$$

*1982年9月28日收到.

其中 $\mathcal{L}$ 表示以分布收敛. 证明详见[3].

应用刀切法的思想, 令 $\hat{\theta}_{N-1}^i$ 为这样的估计量: 它是基于 $\hat{\theta}_N$ 中所含“对”(i, j)除去含 x_i 的那些“对”后所剩下来其余“对”的全体的不完全 U 统计量, 即

$$\hat{\theta}_{N-1}^i = \frac{1}{(N-2)k} \sum_{\{C_k - \text{含 } x_i \text{ 的 } 2k \text{ 个 } (i, j)\}} f(X_i, X_j) \quad (4)$$

以 $g(\hat{\theta}_N)$ 估计 θ 的正则函数 $g(\theta)$ (即在 θ 附近有界), 则定义新的含义下的“刀切估计量”为

$$Jg(\hat{\theta}_N) = Ng(\hat{\theta}_N) - \frac{N-1}{N} \sum_{i=1}^N g(\hat{\theta}_{N-1}^i). \quad (5)$$

注意到若 $\hat{\theta}_N$ 为 U 统计量, 则两种刀切的意义恰为一致.

不失一般性, 我们假定 $\theta = 0$, 并设 $I = (-3\Delta, 3\Delta)$ ($\Delta > 0$) 为 $\theta = 0$ 的邻域, 我们有下述结论:

引理1 若 $\sigma^2 > 0$, σ^2, ρ 有限, 则成立

$$p\{\hat{\theta}_N, \hat{\theta}_{N-1}^i (i = 1, 2, \dots, N) \in I \text{ 同时发生} \} \rightarrow 1 \quad (N \rightarrow \infty).$$

定理2 若 $\sigma^2 > 0$, σ^2, ρ 有限, g 为正则函数, 那末

$$\sqrt{Nk} \{Jg(\hat{\theta}_N) - g(0)\} \rightarrow_d N\{0, \sigma^2[1 + 2(2k-1)\rho][g'(0)]^2\},$$

引理1与定理2的证明方法与[1]中刀切 U 统计量有关证明类同. 只是在证明中应注意到 $\hat{\theta}_{N-1}^i$ 与通常刀切法中相应量之间的不同性以及下述关系式即可:

$$\hat{\theta}_{N-1}^i = \frac{Nk}{(N-2)k} \left\{ \hat{\theta}_N - \frac{1}{Nk} [f(X_i, X_{a_1}) + \dots + f(X_i, X_{a_{2k}})] \right\}.$$

我们知道, 在通常刀切法作用下, 如果Tukey^[4]猜测成立, 那末可以利用虚拟值与一阶刀切的关系式来估计刀切方差. 而这里由于刀切形式的改变, 原来的那种关系式就不一定随机收敛于方差, 我们有下面的引理:

引理2 如果 $E|f(X_i, X_j)|^4 < \infty$, 那末

$$(N-1)k \sum_{i=1}^N (\hat{\theta}_{N-1}^i - \hat{\theta}_N)^2 \xrightarrow{P} \sigma^2[2 + 2(2k-1)\rho] \quad (N \rightarrow \infty). \quad (6)$$

证明 $(N-1)k \sum_{i=1}^N (\hat{\theta}_{N-1}^i - \hat{\theta}_N)^2 = (N-1)k \left\{ \frac{2 \sum_k f^2(X_i, X_j)}{(N-2)Nk^2} \right.$
 $\left. + \frac{2(N-4) \sum_{D_k} f(X_i, X_j) f(X_i, X_k)}{N(N-2)^2 k^2} - \frac{8}{N(N-2)^2 k^2} \sum_{E_k} f(X_i, X_j) f(X_k, X_l) \right\}$
 $= \frac{N-1}{N-2} \cdot 2R_N^{(1)} + \frac{(N-1)(N-4)}{(N-2)^2} \cdot 2(2k-1) R_N^{(2)} - \frac{4(N-1)(Nk-4k+1)}{(N-2)^2} R_N^{(3)}, \quad (7)$

其中 C_k 如(3)式所定义, 为 Nk 项. D_k 表示 $\{(i, j), (i, k)\}$ 的集合: i, j, k 互不相同, $(i, j), (i, k) \in C_k$, 共有 $N[k(2k-1)]$ 项. E_k 表示 $\{(i, j), (k, l)\}$ 的集合, i, j, k, l 互不相同, $(i, j), (k, l) \in C_k$, 共有 $\frac{1}{2}Nk(Nk-4k+1)$ 项.

显见 $R_N^{(1)}, R_N^{(2)}, R_N^{(3)}$ 为不完全 U 统计量, 经计算得

$$ER_N^{(1)} = \sigma^2, ER_N^{(2)} = \rho\sigma^2, ER_N^{(3)} = 0.$$

$$\text{且 } \text{Var } R_N^{(1)} \leq \frac{1}{(Nk)^2} \cdots 2Nk \cdot Ef^4(X_1, X_2) = O\left(\frac{1}{Nk}\right),$$

$$\text{故(7)式右边第一项 } \frac{N-1}{N-2} \cdot 2R_N^{(1)} \xrightarrow{P} 2\sigma^2, (N \rightarrow \infty).$$

$$\text{同理, } 2(2k-1)R_N^{(2)} \cdot \frac{(N-1)(N-4)}{(N-2)^2} \xrightarrow{P} 2(2k-1)\rho\sigma^2, (N \rightarrow \infty).$$

$$\frac{4(N-1)(Nk-4k+1)}{(N-2)^2} R_N^{(3)} \xrightarrow{P} 0, (N \rightarrow \infty).$$

$$\text{于是 } (N-1)k \sum_{i=1}^N (\hat{\theta}_{N-1}^i - \hat{\theta}_N) \xrightarrow{P} \sigma^2 [2 + 2(2k-1)\rho].$$

$$\text{令 } s_g^2 = (N-1)k \sum_{i=1}^N [g(\hat{\theta}_{N-1}^i) - \frac{1}{N} \sum_{i=1}^N g(\hat{\theta}_{N-1}^i)]^2, \quad (8)$$

利用文[1]中定理 6 的证明方法, 得到下述结论:

定理 3 若 $E|f|^4 < \infty$, $Ef(X_1, X_2) = 0$, g 为实轴函数, 在 $\theta = 0$ 的邻域内具有连续一阶导数, 那末当 $N \rightarrow \infty$ 时,

$$s_g^2 \xrightarrow{P} [g'(0)]^2 \sigma^2 [2 + 2(2k-1)\rho].$$

现在我们还需估计 $[g'(0)]^2 \sigma^2$, 取 F_N 为 (i, j) 的集合, 恰含有 $\left[\frac{N}{2}\right]$ 个对, 其中所有 i, j 均不相同. 例 $(1, 2), (3, 4), \dots$, 作 $U_{\left[\frac{N}{2}\right]} = \frac{1}{\left[\frac{N}{2}\right]} \sum_{F_N} f(X_i, X_j)$. $U_{\left[\frac{N}{2}\right]}$ 事实上可视作“二维空间”中次数为 1 的 U 统计量, 经过讨论可以得知, 通常的刀切 U 统计量结果适用于 $U_{\left[\frac{N}{2}\right]}$, 因此利用刀切 U 统计量的已知结果, 当 $N \rightarrow \infty$ 时, 有

$$s_T^2 = \frac{1}{\left[\frac{N}{2}\right] - 1} \sum_{i=1}^{\left[\frac{N}{2}\right]} [g_i^* - Jg(U_{\left[\frac{N}{2}\right]})]^2 \xrightarrow{P} [g'(0)]^2 \sigma^2, \quad (9)$$

$$\text{其中 } g_i^* = \left[\frac{N}{2}\right] g(U_{\left[\frac{N}{2}\right]}^i) - \left(\left[\frac{N}{2}\right] - 1\right) g(U_{\left[\frac{N}{2}\right]}^i - 1).$$

综上所述, 我们可以得到:

定理 4 若 g 为正态函数, $\sigma^2 > 0$, σ^2, ρ 有限, 那末

$$\frac{\sqrt{Nk} \{Jg(\hat{\theta}_N) - g(\theta)\}}{(s_g^2 - s_T^2)^{1/2}} \rightarrow \mathcal{L}N(0, 1).$$

这样, 与刀切 U 统计量的结果一样, 我们也能求得 $g(\theta)$ 的近似置信区间.

参 考 文 献

- [1] Arvesen, J., Jackknifing U-statistic, *Ann. Math. Statist.* 40., (1969), 2076—2100.
- [2] Blom, G., Some properties of incomplete U-statistics, *Biometrika*, 63 (1976) No3. 573—580.
- [3] Brown, B. M. and Kildea, D. G., Reduced U-statistics and the Hodges-Lehmann estimator, *Ann. Math. Statist.*, 6 (1978), No. 4, 828—835.
- [4] Tukey, J. W., Bias and confidence in not quite large samples (abstract), *Ann. Math. statist.*, 29 (1958), 614.

Jackknifing Incomplete U-statistics

Shi Xi-quan

(The Wuhan Institute of Hydraulic and Electric Engineering)

In this paper, we propose jackknife only for a particular class of non-symmetric statistics, which is incomplete U-statistics of significance in practice. We find that if we deal with incomplete U-statistics using a slightly modified jackknife, then Tukey's conjecture will be true, and the consistent estimator of asymptotic variance is given. Thus we obtain an approximate confidence interval for regular function $g(\theta)$.