

离散型最小和最大次序统计量相关性研究 *

梁冯珍 史道济

(天津大学理学院, 天津, 300072)

摘 要

本文研究离散型随机变量之间的相关性度量, 讨论了最小次序统计量和最大次序统计量的渐近独立性, 给出了计算最小次序统计量和最大次序统计量的Kendall和Spearman秩相关系数的公式.

关键词: 相关性度量, 次序统计量, Kendall秩相关系数, Spearman秩相关函数.

学科分类号: O212.4.

§1. 引 言

相关性和相关系数是统计、金融、保险理论中一个非常重要的概念. 在统计学中, 常常用两个变量之间的线性相关系数来度量两个变量之间的相关性, 但这种度量具有一定的局限性. 首先, 它只能度量两个变量之间的线性相关关系, 而不能度量两个变量之间的其他相关关系; 其次, 线性相关系数不仅依赖于变量的边缘分布, 而且依赖于联合分布; 第三, 在单调变换下, 线性相关系数的值常常会改变. 为了克服上述缺陷, 我们希望建立一种相关性度量, 能够满足理想的相关性度量应该具备的性质^[1]. 本文采用文献[2]、[3]中介绍的度量相关性的两种方法, 来讨论离散型最小次序统计量和最大次序统计量之间的相关性. 对于连续型随机变量, 文献[4]已经讨论了它们之间的相关性.

§2. Copula及相关性度量的概念

我们首先给出Copula的定义.

定义 2.1 如果二元函数 C 满足条件

- (1) 对任意的 $(u, v) \in I^2 = [0, 1]^2$, 都有 $0 \leq C(u, v) \leq 1$;
- (2) 对任意的 $(u, v) \in I^2$, 都有 $C(u, 0) = C(0, v) = 0$, $C(u, 1) = u$, $C(1, v) = v$;
- (3) 对任意的 $u_1, u_2, v_1, v_2 \in I$, 且 $u_1 \leq u_2$, $v_1 \leq v_2$, 都有

$$V_C([u_1, u_2] \times [v_1, v_2]) = C(u_2, v_2) - C(u_2, v_1) - C(u_1, v_2) + C(u_1, v_1) \geq 0,$$

则称函数 C 为Copula (相关结构).

*国家自然科学基金资助(70573077).

本文2005年8月11日收到, 2005年11月21日收到修改稿.

Sklar于1959年首先建立了随机向量 (X, Y) 的联合分布 H 和Copula C 之间的关系, 他将相关结构从联合分布中提取出来, 使得Copula成为度量相关性的好方法.

定理 2.1 (Sklar定理^[3]) 设随机向量 (X, Y) 的联合分布为 $H(x, y)$, 边缘分布分别为 $F(x)$ 和 $G(y)$, 则存在Copula C , 使得对于任意的 $(x, y) \in R^2$, 都有

$$H(x, y) = C(F(x), G(y)).$$

如果边缘分布函数是连续的, 则Copula C 是唯一确定的; 否则, C 在 $\text{Ran}F * \text{Ran}G$ 上是唯一确定的. 称函数 C 为随机变量 X 与 Y 的相关结构函数(Copula).

根据Sklar定理, 如果已知随机变量 X 与 Y 的联合分布, 则可得到关于 X 与 Y 的所有条件分布和Copula. 反之, 如果已知两个变量之间的Copula和边缘分布, 就可以确定它们的联合分布.

当随机变量 X 与 Y 相互独立时, Copula为 $C(u, v) = uv$, 我们称之为乘积Copula, 并记作 $\Pi(u, v)$. 下面给出度量相关性的两种方法^[2, 3].

定义 2.2 设随机向量 (X, Y) 的联合分布函数为 H , $(X_1, Y_1), (X_2, Y_2), (X_3, Y_3)$ 与 (X, Y) 独立同分布, 则称

$$P\{(X_1 - X_2)(Y_1 - Y_2) > 0\} - P\{(X_1 - X_2)(Y_1 - Y_2) < 0\}$$

为随机向量 (X, Y) (或Copula C)的Kendall秩相关系数或Kendall's τ , 记作 $\tau(X, Y)$ 或 $\tau(C)$. 称

$$3[P\{(X_1 - X_2)(Y_1 - Y_3) > 0\} - P\{(X_1 - X_2)(Y_1 - Y_3) < 0\}]$$

为随机向量 (X, Y) (或Copula C)的Spearman秩相关系数或Spearman's ρ , 记作 $\rho(X, Y)$ 或 $\rho(C)$.

Kendall秩相关系数和Spearman秩相关系数具有性质^[2, 3]: (1)在单调递增变换下, 秩相关系数保持不变; (2)当两个变量相互独立时, 秩相关系数均为0; (3)当两个变量完全正相关时, 秩相关系数均为1; 当两个变量完全负相关时, 秩相关系数均为-1. 总之, 它们满足理想相关性度量的性质.

当随机向量 (X, Y) 为连续型时, 可以证明^[2], Kendall秩相关系数和Spearman秩相关系数完全由它们的Copula决定, 而与变量的边缘分布无关. 但当随机向量 (X, Y) 为离散型时, 由于Copula函数的不惟一性, 给计算Kendall和Spearman秩相关系数都带来许多麻烦. 这里我们避开Copula, 用定义2.2计算两个秩相关系数.

§3. 离散型次序统计量的相关性

设 X_1, \dots, X_n 是独立同分布的随机变量, 共同分布为 F , 记

$$X_{(1)} = \min\{X_1, \dots, X_n\}, \quad X_{(n)} = \max\{X_1, \dots, X_n\},$$

则 $X_{(1)}$ 和 $X_{(n)}$ 的分布函数^[5]分别为

$$F_1(x) = 1 - (1 - F(x))^n, \quad F_n(y) = F^n(y),$$

$X_{(1)}$ 和 $X_{(n)}$ 的联合分布函数^[5]为

$$F_{1,n}(x, y) = \begin{cases} F^n(y) - (F(y) - F(x))^n, & x < y; \\ F^n(y), & x \geq y. \end{cases}$$

令 $u = F_1(x)$, $v = F_n(y)$, 则根据Sklar定理, 得随机变量 $X_{(1)}$ 和 $X_{(n)}$ 之间的Copula为

$$C_n(u, v) = \begin{cases} v - (v^{1/n} + (1 - u)^{1/n} - 1)^n, & v^{1/n} + (1 - u)^{1/n} > 1; \\ v, & v^{1/n} + (1 - u)^{1/n} \leq 1. \end{cases}$$

函数 $C_n(u, v)$ 具有下面的性质:

定理 3.1 对任意的 $u, v \in [0, 1]$, 有 $\lim_{n \rightarrow \infty} C_n(u, v) = \Pi(u, v)$.

证明: 因为对于Clayton copula

$$C_\theta^C(u, v) = \max\{(u^{-\theta} + v^{-\theta} - 1)^{1/\theta}, 0\}$$

有结论^[6] $\lim_{\theta \rightarrow 0} C_\theta^C(u, v) = uv$, 而 $X_{(1)}$ 和 $X_{(n)}$ 的Copula $C_n(u, v)$ 与Clayton copula C_θ^C 之间具有关系式

$$C_n(u, v) = v - C_{-1/n}^C(1 - u, v).$$

所以

$$\lim_{n \rightarrow \infty} C_n(u, v) = v - (1 - u)v = uv = \Pi(u, v).$$

□

该定理说明, 当样本容量 n 很大时, 最小次序统计量 $X_{(1)}$ 和最大次序统计量 $X_{(n)}$ 是渐近独立的.

设 (X, Y) 是离散型随机向量, 联合概率分布列为

$$P\{X = x_i, Y = y_j\} = p_{ij}, \quad i, j = 0, 1, \dots,$$

分布函数为

$$H(x, y) = \sum_{i,j} p_{ij} I_{\{x_i \leq x, y_j \leq y\}}.$$

定理 3.2 设离散型随机向量 (X, Y) 的分布函数为 $H(x, y)$, 边缘分布函数分别为 $F(x)$ 和 $G(y)$, 则

$$\tau(X, Y) = EH(X, Y) + EH(X, Y_{-1}) + EH(X_{-1}, Y) + EH(X_{-1}, Y_{-1}) - 1, \quad (3.1)$$

$$\begin{aligned} \rho(X, Y) = & 3\{E[F(X)G(Y)] + E[F(X)G(Y_{-1})] \\ & + E[F(X_{-1})G(Y)] + E[F(X_{-1})G(Y_{-1})] - 1\}. \end{aligned} \quad (3.2)$$

其中变量 X_{-1}, Y_{-1} 的含义为: 当 $X = x_i, Y = y_j$ 时, $X_{-1} = x_{i-1}, Y_{-1} = y_{j-1}$.

证明: 设离散型随机向量 $(X_1, Y_1), (X_2, Y_2), (X_3, Y_3)$ 与 (X, Y) 独立同分布, 因为

$$\begin{aligned}
 \tau(X, Y) &= P\{(X_1 - X_2)(Y_1 - Y_2) > 0\} - P\{(X_1 - X_2)(Y_1 - Y_2) < 0\} \\
 &= P\{X_1 - X_2 > 0, Y_1 - Y_2 > 0\} + P\{X_1 - X_2 < 0, Y_1 - Y_2 < 0\} \\
 &\quad - P\{X_1 - X_2 > 0, Y_1 - Y_2 < 0\} - P\{X_1 - X_2 < 0, Y_1 - Y_2 > 0\} \\
 &= \sum_{i,j} P\{X_1 = x_i, Y_1 = y_j\} P\{X_2 < x_i, Y_2 < y_j\} \\
 &\quad + \sum_{i,j} P\{X_1 = x_i, Y_1 = y_j\} P\{X_2 > x_i, Y_2 > y_j\} \\
 &\quad - \sum_{i,j} P\{X_1 = x_i, Y_1 = y_j\} P\{X_2 < x_i, Y_2 > y_j\} \\
 &\quad - \sum_{i,j} P\{X_1 = x_i, Y_1 = y_j\} P\{X_2 > x_i, Y_2 < y_j\} \\
 &= \sum_{i,j} p_{ij} \{H(x_{i-1}, y_{j-1}) + [1 - F(x_i) - G(y_j) + H(x_i, y_j)]\} \\
 &\quad - \sum_{i,j} p_{ij} \{[1 - G(y_j) - H(x_{i-1}, y_j)] + [1 - F(x_i) - H(x_i, y_{j-1})]\} \\
 &= \sum_{i,j} p_{ij} [H(x_i, y_j) + H(x_i, y_{j-1}) + H(x_{i-1}, y_j) + H(x_{i-1}, y_{j-1})] - 1 \\
 &= EH(X, Y) + EH(X, Y_{-1}) + EH(X_{-1}, Y) + EH(X_{-1}, Y_{-1}) - 1.
 \end{aligned}$$

所以, (3.1)式成立. 同理可证(3.2)式. \square

定理3.2适用于任何两个离散型随机变量之间的秩相关系数的计算. 但对于次序统计量来说, 秩相关系数有着更简单的计算公式.

设 X_1, \dots, X_n 是与 X 独立同分布的离散型随机变量, 概率分布列为

$$P\{X = x_i\} = p_i, \quad i = 0, 1, \dots,$$

分布函数为 $F(x) = P\{X \leq x\} = \sum_i p_i I_{\{x_i \leq x\}}$, 特别地, $F(x_k) = \sum_{i=0}^k p_i$. 当 $x = x_i, y = x_j$ 时, 随机变量 $X_{(1)}, X_{(n)}$ 以及 $(X_{(1)}, X_{(n)})$ 的分布函数值分别为

$$\begin{aligned}
 F_1(x_i) &= 1 - (1 - F(x_i))^n, \quad i = 0, 1, \dots; \\
 F_n(x_j) &= F^n(x_j), \quad j = 0, 1, \dots; \\
 F_{1,n}(x_i, x_j) &= \begin{cases} F^n(x_j) - [F(x_j) - F(x_i)]^n, & i < j; \\ F^n(x_j), & i \geq j. \end{cases} \quad i, j = 0, 1, \dots.
 \end{aligned}$$

下面给出秩相关系数的计算方法.

定理 3.3 设 X_1, \dots, X_n 是与 X 独立同分布的离散型随机变量, 概率分布列为

$$P\{X = x_i\} = p_i, \quad i = 0, 1, \dots,$$

分布函数在点 $x = x_j$ 的值为 $F(x_j) = \sum_{i=0}^j p_i$, $j = 0, 1, \dots$. 则 $X_{(1)}$ 和 $X_{(n)}$ 之间的Kendall秩相关系数为

$$\begin{aligned} \tau(X_{(1)}, X_{(n)}) &= 2 \sum_{j=1}^{\infty} \sum_{i=0}^{j-1} \{ [F(x_j) - F(x_i)]^n [F(x_{j-1}) - F(x_{i-1})]^n \\ &\quad - [F(x_j) - F(x_{i-1})]^n [F(x_{j-1}) - F(x_i)]^n \}. \end{aligned} \quad (3.3)$$

证明: 令 $a_j = F(x_j)$, $H(i, j) = H(x_i, x_j) = F_{1,n}(x_i, x_j)$, $p_{ij} = P(X_{(1)} = x_i, X_n = x_j)$, 则

$$p_{ij} = H(i, j) + H(i-1, j-1) - H(i-1, j) - H(i, j-1),$$

根据(3.1)式得

$$\begin{aligned} \tau + 1 &= \sum_{i,j} p_{ij} (H(i, j) + H(i, j-1) + H(i-1, j) + H(i-1, j-1)) \\ &= \sum_{i,j} [H^2(i, j) + H^2(i-1, j-1) - H^2(i-1, j) - H^2(i, j-1) \\ &\quad + 2H(i, j)H(i-1, j-1) - 2H(i-1, j)H(i, j-1)] \\ &= \sum_{j=0}^{\infty} \sum_{i=0}^{j-1} \{ [a_j^n - (a_j - a_i)^n]^2 + [a_{j-1}^n - (a_{j-1} - a_{i-1})^n]^2 \\ &\quad - [a_j^n - (a_j - a_{i-1})^n]^2 - [a_{j-1}^n - (a_{j-1} - a_i)^n]^2 \\ &\quad + 2[a_j^n - (a_j - a_i)^n][a_{j-1}^n - (a_{j-1} - a_{i-1})^n] \\ &\quad - 2[a_j^n - (a_j - a_{i-1})^n][a_{j-1}^n - (a_{j-1} - a_i)^n] \} \\ &\quad + \sum_{j=0}^{\infty} \{ a_j^{2n} - [a_j^n - (a_j - a_{j-1})^n]^2 + 2a_j^n a_{j-1}^n - 2[a_j^n - (a_j - a_{j-1})^n]a_{j-1}^n \} \\ &= \sum_{j=0}^{\infty} \sum_{i=0}^{j-1} \{ -2a_j^n (a_j - a_i)^n + (a_j - a_i)^{2n} - 2a_{j-1}^n (a_{j-1} - a_{i-1})^n + (a_{j-1} - a_{i-1})^{2n} \\ &\quad + 2a_j^n (a_j - a_{i-1})^n - (a_j - a_{i-1})^{2n} + 2a_{j-1}^n (a_{j-1} - a_i)^n - (a_{j-1} - a_i)^{2n} \\ &\quad + 2(a_j - a_i)^n (a_{j-1} - a_{i-1})^n - 2a_{j-1}^n (a_j - a_i)^n - 2a_j^n (a_{j-1} - a_{i-1})^n \\ &\quad - 2(a_j - a_{i-1})^n (a_{j-1} - a_i)^n + 2a_{j-1}^n (a_j - a_{i-1})^n + 2a_j^n (a_{j-1} - a_i)^n \} \\ &\quad + \sum_{j=0}^{\infty} \{ 2a_j^n (a_j - a_{j-1})^n - (a_j - a_{j-1})^{2n} + 2a_{j-1}^n (a_j - a_{j-1})^n \} \\ &= \sum_{j=0}^{\infty} \sum_{i=0}^{j-1} \{ [(a_j - a_i)^{2n} - (a_j - a_{i-1})^{2n}] + [(a_{j-1} - a_{i-1})^{2n} - (a_{j-1} - a_i)^{2n}] \\ &\quad - 2a_j^n [(a_j - a_i)^n - (a_j - a_{i-1})^n] + 2a_{j-1}^n [(a_{j-1} - a_i)^n - (a_{j-1} - a_{i-1})^n] \\ &\quad + 2a_j^n [(a_{j-1} - a_i)^n - (a_{j-1} - a_{i-1})^n] - 2a_{j-1}^n [(a_j - a_i)^n - (a_j - a_{i-1})^n] \\ &\quad + 2(a_j - a_i)^n (a_{j-1} - a_{i-1})^n - 2(a_j - a_{i-1})^n (a_{j-1} - a_i)^n \} \\ &\quad + \sum_{j=0}^{\infty} \{ 2a_j^n (a_j - a_{j-1})^n - (a_j - a_{j-1})^{2n} + 2a_{j-1}^n (a_j - a_{j-1})^n \} \end{aligned}$$

$$\begin{aligned}
&= \sum_{j=0}^{\infty} \{ (a_j - a_{j-1})^{2n} - a_j^{2n} + a_{j-1}^{2n} - 2a_j^n [(a_j - a_{j-1})^n + a_j^n] \\
&\quad + 2a_{j-1}^n (-a_{j-1}^n) + 2a_j^n (-a_{j-1}^n) - 2a_{j-1}^n [(a_j - a_{j-1})^n - a_j^n] \} \\
&\quad + 2 \sum_{j=0}^{\infty} \sum_{i=0}^{j-1} [(a_j - a_i)^n (a_{j-1} - a_{i-1})^n - (a_j - a_{i-1})^n (a_{j-1} - a_i)^n] \\
&\quad + \sum_{j=0}^{\infty} \{ 2a_j^n (a_j - a_{j-1})^n - (a_j - a_{j-1})^{2n} + 2a_{j-1}^n (a_j - a_{j-1})^n \} \\
&= \sum_{j=0}^{\infty} [(a_j - a_{j-1})^{2n} + a_j^{2n} - a_{j-1}^{2n} - 2a_j^n (a_j - a_{j-1})^n - 2a_{j-1}^n (a_j - a_{j-1})^n] \\
&\quad - 2 \sum_{j=0}^{\infty} \sum_{i=0}^{j-1} [(a_j - a_{i-1})^n (a_{j-1} - a_i)^n - (a_j - a_i)^n (a_{j-1} - a_{i-1})^n] \\
&\quad + \sum_{j=0}^{\infty} \{ 2a_j^n (a_j - a_{j-1})^n - (a_j - a_{j-1})^{2n} + 2a_{j-1}^n (a_j - a_{j-1})^n \} \\
&= 1 - 2 \sum_{j=0}^{\infty} \sum_{i=0}^{j-1} [(a_j - a_{i-1})^n (a_{j-1} - a_i)^n - (a_j - a_i)^n (a_{j-1} - a_{i-1})^n] \\
&= 1 + 2 \sum_{j=1}^{\infty} \sum_{i=0}^{j-1} [(a_j - a_i)^n (a_{j-1} - a_{i-1})^n - (a_j - a_{i-1})^n (a_{j-1} - a_i)^n].
\end{aligned}$$

所以, 将 $a_j = F(x_j)$ 代入上式, 则可得(3.3)式成立. \square

定理 3.4 设 X_1, \dots, X_n 是与 X 独立同分布的离散型随机变量, 概率分布列为

$$P\{X = x_i\} = p_i, \quad i = 0, 1, \dots,$$

分布函数在点 $x = x_j$ 的值为 $F(x_j) = \sum_{i=0}^j p_i, j = 0, 1, \dots$. 则 $X_{(1)}$ 和 $X_{(n)}$ 之间的Spearman秩相关系数为

$$\begin{aligned}
&\rho(X_{(1)}, X_{(n)}) \\
&= 3 \sum_{j=2}^{\infty} \sum_{i=0}^{j-2} \{ [\bar{F}^n(x_{i+1}) - \bar{F}^n(x_{i-1})] [F(x_j) - F(x_i)]^n [F^n(X_{j+1}) - F^n(x_{j-1})] \} \\
&\quad - 3 \sum_{j=0}^{\infty} \{ [\bar{F}^n(x_j) - \bar{F}^n(x_{j-2})] F^n(x_{j-1}) [F(x_j) - F(x_{j-1})]^n \}. \tag{3.4}
\end{aligned}$$

其中 $\bar{F}(x) = 1 - F(x)$.

该定理的证明与定理3.3类似, 只需按部就班的计算即可.

例 设随机变量 X 服从两点分布 $b(1, p)$, X_1, \dots, X_n 是来自总体 X 的样本, 由于 $F(0) = 1-p, F(1) = 1$, 则根据(3.3)与(3.4)式得, $X_{(1)}$ 和 $X_{(n)}$ 之间的Kendall秩相关系数和Spearman秩相关系数分别为

$$\tau(X_{(1)}, X_{(n)}) = 2p^n(1-p)^n, \quad \rho(X_{(1)}, X_{(n)}) = 3p^n(1-p)^n.$$

用定义2.2和(3.1)、(3.2)式分别计算, 所得结果与上面的计算结果一致.

综上, 我们用具有良好性质的两种度量相关性的方法, 讨论了离散型最小次序统计量和最大次序统计量之间的相关性. 定理3.2给出了任何两个离散型随机变量之间的Kendall和Spearman秩相关系数的计算公式; 而定理3.3和定理3.4则分别给出了次序统计量 $X_{(1)}$ 和 $X_{(n)}$ 之间的Kendall和Spearman秩相关系数的计算公式, 虽然结论是以级数的形式给出, 但由于计算软件的普及和计算机运算速度的提高, 利用该结论计算秩相关系数还是简单可行的. 当然, 任何两个次序统计量之间的相关性度量还有待于进一步研究.

参 考 文 献

- [1] 史道济, 相关系数与相关性, 统计科学与实践, 4(2002), 22–24.
- [2] Nelsen, R.B., *An Introduction to Copulas*, Springer, New York, 1999.
- [3] Joe, H., *Multivariate Models and Dependence Concepts*, Chapman and Hall, London, 1997.
- [4] Averous, J., Genest, C. and Kochar, S.C., On the dependence structure of order statistics, *Journal of Multivariate Analysis*, 94(2005), 159–171.
- [5] 茆诗松, 王静龙, 濮晓龙, 高等数理统计, 高等教育出版社, 1998.
- [6] Cook, R.D., Johson, M.E., A family of distributions for modeling non-elliptically symmetric multivariate data, *J. Roy. Statist. Soc. B*, 43(2)(1981), 210–218.

The Dependence Analysis between Minimum and Maximum Order Statistics

LIANG FENGZHEN SHI DAOJI

(Department of Mathematics, Institute of Science, Tianjin University, Tianjin, 300072)

The dependence measures are discussed for the discrete random variables in this paper. It is proved that the asymptotic independence of the minimum and maximum of n i.i.d. random variables, and explicit expressions are given for the value of Kendall's and Spearman's rank correlation coefficient between minimum and maximum order statistics.

Keywords: Dependence measures, order statistics, Kendall's rank correlation coefficient, Spearman's rank correlation coefficient.

AMS Subject Classification: 62H20.