

Лекція 3. Порядкові статистики та варіаційні ряди

Нехай x_1, x_2, \dots, x_n – вибірка, що отримана шляхом простого випадкового вибору S із генеральної сукупності G . Упорядкуємо її у зростаючому порядку:

$$x_{k_1} \leq x_{k_2} \leq \dots \leq x_{k_n},$$

де $k_i = \overline{1, n}, i = \overline{1, n}$. Позначимо $x_{(1)} = x_{k_1}, x_{(2)} = x_{k_2}, \dots, x_{(n)} = x_{k_n}$. Тоді $x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n)}$. Випадкові величини $x_{(i)} = x_{k_i}$ називаються порядковими статистиками, а послідовність $x_{(1)}, x_{(2)}, \dots, x_{(n)}$ – варіаційним рядом. Отже, порядкові статистики $x_{(i)}, i = \overline{1, n}$ є членами варіаційного ряду. Очевидно, що $x_{(1)}$ є мінімальною порядковою статистикою, а $x_{(n)}$ – максимальною.

Порядкові статистики $x_{(1)}, x_{(2)}, \dots, x_{(n)}$, на відміну від вибірових значень, є залежними і мають різні функції розподілу. Легко бачити, що функція розподілу $F_k(x)$ k -ї порядкової статистики $x_{(k)}$ має такий вигляд:

$$F_k(u) = \sum_{i=k}^n C_n^i [F(u)]^i [1-F(u)]^{n-i},$$

де $F(u) = p(x \leq u)$. Випадкова величина x називається неперервною, якщо її функція розподілу є абсолютно неперервною для будь-якого $u \in R^1$. Використовуючи наведену формулу, можна довести, що для будь-якої неперервної випадкової величини x із генеральної сукупності G , ймовірність того, що вона потрапить в інтервал $J = (x_{(i)}, x_{(j)})$ утворений i -ю і j -ю порядковими статистиками ($i < j$), не залежить від функції розподілу $F(u)$ і дорівнює

$$p(x \in (x_{(i)}, x_{(j)})) = \frac{j-i}{n+1}.$$

Дійсно, якщо випадкові величини ξ і η є незалежними, то

$$p(\xi < \eta) = \int_{-\infty}^{\infty} F_{\xi}(u) dF_{\eta}(u),$$

де $F_{\xi}(u)$ і $F_{\eta}(u)$ є функціями розподілу випадкових величин ξ і η відповідно.

Щільність розподілу i -ї порядкової статистики обчислюється так:

$$F_k(u) = \sum_{i=k}^n C_n^i [F(u)]^i [1-F(u)]^{n-i} = \sum_{i=k}^n G_i(u),$$

$$F'_k(u) = \sum_{i=k}^n G'_i(u),$$

$$G'_k(u) = \left[C_n^k \left((F(u))^k (1-F(u))^{n-k} - (F(u))^k (n-k)(1-F(u))^{n-k-1} \right) f(u) \right]$$

$$\begin{aligned} G'_{k+1}(u) &= \left[C_n^{k+1} (F(u))^{k+1} (1-F(u))^{n-k-1} \right]' = \\ &= C_n^{k+1} \left[((k+1)(F(u))^k (1-F(u))^{n-k-1} - (F(u))^{k+1} (1-F(u))^{n-k-2} (n-k-1)) f(u) \right] \end{aligned}$$

Другий доданок в попередньому виразі скорочується із першим доданком у наступному виразі.

$$\begin{aligned} &-C_n^k (n-k) + C_n^{k+1} (k+1) = \\ &= -\frac{n!(n-k)}{(n-k)!k!} + \frac{n!(k+1)}{(n-k-1)!(k+1)!} = \\ &= -\frac{n!}{(n-k-1)!k!} + \frac{n!}{(n-k-1)!k!} = 0. \end{aligned}$$

Зважимо на те, що

$$\begin{aligned}
kC_n^k &= \frac{n!k}{(n-k)k!} = \frac{(n-1)!nk}{(n-k-1)!(n-k)(k-1)!k} = \\
&= \frac{(n-1)!}{(n-k)!(k-1)!} = nC_{n-1}^{k-1} = \frac{1}{B(k, n-k+1)}.
\end{aligned}$$

Останній член останнього доданка дорівнює нулю.

$$(F(u))^n (1-F(u))^0 (n-n) f(u) = 0.$$

Отже,

$$f_k(u) = nC_{n-1}^{k-1} [F(u)]^{k-1} [1-F(u)]^{n-k} f(u).$$

Обчислимо ймовірності $p(x < x^{(i)})$ і $p(x < x^{(j)})$.

Використовуючи наведені вище формули, отримаємо

$$\begin{aligned}
p(x < x_{(i)}) &= \int_{-\infty}^{\infty} F(u) dF_i(u) = nC_{n-1}^{i-1} \int_{-\infty}^{\infty} [F(u)]^i [1-F(u)]^{n-i} dF(u) = \\
&= nC_{n-1}^{i-1} \int_0^1 v^i (1-v)^{n-i} dv.
\end{aligned}$$

Як відомо,

$$\int_0^1 x^{p-1} (1-x)^{q-1} dx = \frac{\Gamma(p)\Gamma(q)}{\Gamma(p+q-1)} = \frac{(p-1)!(q-1)!}{(p+q-1)!}.$$

Отже,

$$\begin{aligned}
\int_0^1 x^{i+1-1} (1-x)^{n-i+1-1} dx &= B(i+1, n-i+1) = \\
&= \frac{\Gamma(i+1)\Gamma(n-i+1)}{\Gamma(i+1+n+1-i)} = \frac{\Gamma(i+1)\Gamma(n-i+1)}{\Gamma(n+2)} = \frac{i!(n-i)!}{(n+1)!}
\end{aligned}$$

$$\begin{aligned}
p(x < x_{(i)}) &= n C_{n-1}^{i-1} \frac{i!(n-i)!}{(n+1)!} = \\
&= n \frac{(n-1)!i!(n-i)!}{(n-1-i+1)!(i-1)!(n+1)!} = \\
&= \frac{n(n-1)!(i-1)!i!(n-i)!}{(n-i)!(i-1)!n(n+1)(n-1)!} = \frac{i}{n+1}.
\end{aligned}$$

Звідси випливає, що

$$\begin{aligned}
p(x \in (x_{(i)}, x_{(j)})) &= p(x_{n+1} < x_j) - p(x_{n+1} < x_i) = \\
&= \frac{j}{n+1} - \frac{i}{n+1} = \frac{j-i}{n+1}.
\end{aligned}$$

Таким чином, якщо випадкова величина x не залежить від вибірки x_1, x_2, \dots, x_n , отриманої простим випадковим вибором S із генеральної сукупності G із абсолютно неперервною функцією розподілу $F(u)$, то

$$p(x \in (x_{(1)}, x_{(n)})) = \frac{n-1}{n+1}.$$

Цей факт дозволяє побудувати довірчий інтервал для основної розподіленої маси генеральної сукупності із точно визначеним довірчим рівнем. Дійсно, оскільки довірчий рівень довірчого інтервалу $J = (x_{(1)}, x_{(n)})$ дорівнює $\frac{n-1}{n+1}$, то для $n \geq 39$ рівень значущості цього інтервалу не перевищує 0,05.