

Л. В. РЫКОВА

НЕПАРАМЕТРИЧЕСКИЙ КРИТЕРИЙ КОЛМОГорова — Смирнова для выборок из конечных совокупностей

(Представлено академиком А. Н. Колмогоровым 22 X 1973)

Для проверки однородности двух выборок Н. В. Смирновым ⁽¹⁾ были введены статистики

$$D_{m,n}^+ = \sup_x [F_n(x) - G_m(x)], \quad D_{m,n}^- = -\inf_x [G_m(x) - F_n(x)],$$

$$D_{m,n} = \sup_x |F_n(x) - G_m(x)|, \quad (1)$$

где $F_n(x)$ и $G_m(x)$ — эмпирические функции распределения (э.ф.р.), построенные по результатам двух выборок ξ_1, \dots, ξ_n и η_1, \dots, η_m объема n и m соответственно. При этом предполагалось, что ξ_1, \dots, ξ_n (η_1, \dots, η_m) — взаимно независимые случайные величины с функцией распределения $F(x)$ ($G(x)$). С помощью (1) можно проверять гипотезу о совпадении функций распределения $F(x)$ и $G(x)$.

В данной работе исследуются свойства аналогичных статистик, которыми можно пользоваться при изучении конечной совокупности без предположения взаимной независимости наблюдений.

Пусть \mathfrak{F} — конечная совокупность объектов O_i , каждому из которых сопоставляется скалярная величина X_i , $i=1, \dots, N$. Предположим, что $X_i \neq X_j$, $i \neq j$, и объекты занумерованы в порядке возрастания величин X_i , т. е. $X_1 < X_2 < \dots < X_N$. Совокупность \mathfrak{F} будем характеризовать э.ф.р. $F_N(x) = l/N$, где l — число таких объектов, у которых $X_i \leq x$.

Из совокупности \mathfrak{F} берутся две случайные выборки без возвращения объема n_1 и n_2 . Результатам выборок сопоставим э.ф.р. $F_{n_1}(x) = k_1/n_1$ и $F_{n_2}(x) = k_2/n_2$ соответственно, где k_1 (k_2) равно числу объектов, попавших в первую (вторую) выборку, у которых $X_i \leq x$. Ниже будет показано, что при $n_i \rightarrow \infty$, $(n_i/N) \rightarrow v_i$, $0 < v_i < 1$, $i=1, 2$,

$$P \left\{ \sup_x \left(\frac{N-1}{N} \frac{n_1 n_2}{n_1 + n_2} \right)^{1/2} |F_{n_1}(x) - F_{n_2}(x)| < z \right\} \rightarrow K(z) = \sum_k (-1)^k e^{-2k^2 z^2}. \quad (2)$$

Случай $v_2=0$ ($v_1=0$) идентичен рассмотренному ранее ⁽²⁾.

Определим величину

$$\rho_{n_1, n_2, N} = \sup_x \left(\frac{N-1}{N} \frac{n_1 n_2}{n_1 + n_2} \right)^{1/2} |F_{n_1}(x) - F_{n_2}(x)|. \quad (3)$$

Поскольку $F_{n_1}(x)$ и $F_{n_2}(x)$ постоянны на $[X_i, X_{i+1})$, $i=1, \dots, N-1$, и имеют скачки $1/n_1$ и $1/n_2$ соответственно, в точках X_i , $i=1, \dots, N$, то отображение X_i в точку i/N отрезка $[0, 1]$ не изменит величины (3). Поэтому распределение величины (3) совпадает с распределением

$$\rho_{n_1, n_2, N} = \max_{1 \leq i \leq N} \left(\frac{N-1}{N} \frac{n_1 n_2}{n_1 + n_2} \right)^{1/2} \left| \frac{\kappa_1(i)}{n_1} - \frac{\kappa_2(i)}{n_2} \right|,$$

где $\kappa_i(l)$ равно числу объектов в i -й выборке, $i=1, 2$, номера которых меньше l .

Теорема 1. Двумерный процесс $(\kappa_1(l), \kappa_2(l))$ является двумерным марковским процессом с вероятностями переходов

$$\begin{aligned} p_1 &= P\{\kappa_1(l+1)=k_1+1, \kappa_2(l+1)=k_2 | \kappa_1(l)=k_1, \kappa_2(l)=k_2\} = (n_1-k_1)/(N-l), \\ p_2 &= P\{\kappa_1(l+1)=k_1, \kappa_2(l+1)=k_2+1 | \kappa_1(l)=k_1, \kappa_2(l)=k_2\} = (n_2-k_2)/(N-l), \\ p &= P\{\kappa_1(l+1)=k_1, \kappa_2(l+1)=k_2 | \kappa_1(l)=k_1, \kappa_2(l)=k_2\} = 1-p_1-p_2. \end{aligned} \quad (4)$$

Доказательство теоремы состоит в проверке совпадения вероятностей отбора объектов с номерами l_1, l_2, \dots, l_{n_1} и m_1, m_2, \dots, m_{n_2} в первую и вторую выборки соответственно и вероятностей скачков процесса с вероятностями переходов (4) в тех же точках.

Поскольку для любых l_1, l_2

$$P\{\kappa_1(l_1, l_2)=d_1, \kappa_2(l_1, l_2)=d_2\} = h_{N, l_2-d_1}^{n_1, d_1} h_{N-n_1, l_2-l_1-d_1}^{n_1, d_1}, \quad (5)$$

где $h_{N, M}^m = \binom{M}{m} \binom{N-M}{n-m} / \binom{N}{n}$ — гипергеометрические вероятности,

$\kappa_i(l, m) = \kappa_i(m) - \kappa_i(l)$, то процесс $(\kappa_1(l), \kappa_2(l))$ естественно называть двумерным гипергеометрическим процессом.

Лемма 1. Пусть m, n, M, N — целые числа, $m \leq M \leq N$, $m \leq n \leq N$, $b(n, N) = n(N-n)/N$, $0 < \varepsilon < \Delta < \bar{\varepsilon} < 1$,

$$\nu_+ = \overline{\lim}_{n \rightarrow \infty} (n/N) < 1, \quad |M/N - \Delta| < 1/N, \quad \frac{|m - nM/N|^3}{b^2(n, N)} = \alpha_{N, M}^{n, m} \rightarrow 0$$

при $n \rightarrow \infty$.

Тогда для любого $\varepsilon > 0$

$$h_{N, M}^{n, m} = \frac{\exp\{- (m - n\Delta)^2 / [2b(n, N)\Delta(1-\Delta)]\}}{[2\pi b(n, N)\Delta(1-\Delta)]^{1/2}} (1 + o_{N, M}^{n, m}),$$

где

$$|o_{N, M}^{n, m}| < \gamma_{N, M}^{n, m} / [\Delta(1-\Delta)(1-\nu_+)(1-\varepsilon)]^2,$$

$$\gamma_{N, M}^{n, m} = \min(\alpha_{N, M}^{n, m}, n^{-1/5}).$$

Рассмотрим процесс $\beta_{n_1, n_2}(l_1/N, l_2/N) = (\xi_{n_1, n_2}^{(1)}(l_1/N), \xi_{n_1, n_2}^{(2)}(l_2/N))$, где

$$\xi_{n_1, n_2}^{(i)}\left(\frac{l}{N}\right) = \left(\frac{N-1}{N} \frac{n_1 n_2}{n_1 + n_2}\right)^{1/2} \left[\frac{\kappa_i(l)}{n_i} - \frac{l}{N}\right].$$

Легко проверить, что $E\beta_{n_1, n_2}(l_1/N, l_2/N) = 0$,

$$S = \|a_{ij}\| = \begin{pmatrix} \frac{(N-n_1)n_2}{N(n_1+n_2)} \frac{l_1}{N} \left(1 - \frac{l_2}{N}\right), & -\frac{n_1 n_2}{(n_1+n_2)N} \frac{l_1}{N} \left(1 - \frac{l_2}{N}\right) \\ -\frac{n_1 n_2}{(n_1+n_2)N} \frac{l_1}{N} \left(1 - \frac{l_2}{N}\right), & \frac{(N-n_2)n_1}{(n_1+n_2)N} \frac{l_1}{N} \left(1 - \frac{l_2}{N}\right) \end{pmatrix},$$

где

$$a_{ij} = E\xi_{n_1, n_2}^{(i)}(l_1/N) \xi_{n_1, n_2}^{(j)}(l_2/N), \quad i, j=1, 2.$$

Теорема 2. При $n_i \rightarrow \infty$, $i=1, 2$, $\overline{\lim}_{n_i \rightarrow \infty} (n_i/N) = \nu_i < 1$ конечномерные распределения процесса $\beta_{n_1, n_2}(l_1/N, l_2/N)$ сходятся к конечномерным распре-

лениям двумерного гауссовского процесса $\beta(t, s) = (\beta_1(t), \beta_2(s))$ с нулевым математическим ожиданием и ковариационной матрицей

$$Q = \begin{pmatrix} \frac{v_2(1-v_1)t(1-s)}{v_1+v_2} & -\frac{v_1v_2t(1-s)}{v_1+v_2} \\ -\frac{v_1v_2t(1-s)}{v_1+v_2} & \frac{v_1(1-v_2)t(1-s)}{v_1+v_2} \end{pmatrix}, \quad t < s.$$

При доказательстве теоремы надо воспользоваться марковскими свойствами процесса $\beta_{n_1, n_2}(l_1/N, l_2/N)$, равенством (5), леммой 1 и методом интегральных сумм ((³), стр. 188).

Лемма 2. Для любых t_1 и t_2 из $[0, 1]$, всех N и n_i таких, что $0 < \underline{v} \leq n_i/N \leq \bar{v} < 1$ существует такая $H = H(\underline{v}, \bar{v}) > 0$, что

$$\mu_4^{(i)} = E|\xi_{n_1, n_2}^{(i)}(t_1) - \xi_{n_1, n_2}^{(i)}(t_2)|^4 \leq H|t_1 - t_2|^2, \quad i=1, 2. \quad (6)$$

Неравенство (6) получается как следствие гипергеометричности распределения приращений процесса $\kappa_i(l)$.

Выполнение условий теоремы 2 и леммы 2 дает возможность воспользоваться теоремой (⁴) о том, что для всех непрерывных на $C_{[0, 1]}$ функционалов f распределение $f(\beta_{n_1, n_2}(l_1/N, l_1/N))$ будет сходиться к распределению $f(\beta(t, t))$, $C_{[0, 1]}$ — пространство всех непрерывных на $[0, 1]$ функций с метрикой

$$\rho(x, y) = \sup_{0 \leq t \leq 1} |x(t) - y(t)|.$$

В частности, распределение

$$f(\beta_{n_1, n_2}(l_1/N, l_1/N)) = \max_{1 \leq l \leq N} |\xi_{n_1, n_2}^{(1)}(l/N) - \xi_{n_1, n_2}^{(2)}(l/N)| = \rho_{n_1, n_2, N}$$

будет сходиться к распределению

$$f(\beta(t, t)) = \max_{0 \leq t \leq 1} |\beta_1(t) - \beta_2(t)| = \max_{0 \leq t \leq 1} |\beta_0(t)|.$$

Поскольку $E\beta_0(t) = 0$, $E\beta_0(t)\beta_0(s) = t(1-s)$, $t < s$, то $\beta_0(t)$ является условным винеровским процессом на $[0, 1]$ с закрепленными концами $\beta_0(0) = \beta_0(1) = 1$, а распределение $\max_{0 \leq t \leq 1} |\beta_0(t)|$ является известным распределением Колмогорова $K(z)$. Таким образом, верна

Теорема 3. При $n_i \rightarrow \infty$, $\lim_{n_i \rightarrow \infty} (n_i/N) = v_i$, $0 \leq v_i < 1$, $i=1, 2$, распределение $\rho_{n_1, n_2, N}$ сходится к распределению $\beta_0 = \max_{0 \leq x \leq 1} |\beta_0(t)|$, т. е. справедливо соотношение (2).

Статистика $\rho_{n_1, n_2, N}$ может быть использована в следующих математических моделях:

а) Объекты совокупности \mathfrak{F} характеризуются скалярными величинами $X_i = X_i(s)$, вообще говоря зависящими от времени (хранения) s , $s \geq 0$. Для проверки гипотезы о неизменности характеристик, т. е. гипотезы $H_0 = \{X_i(s_1) = X_i(s_2), i \in [1, 2, \dots, N]\}$, в два момента времени $s_1 < s_2$ берутся две случайные выборки без возвращения объемов n_1, n_2 . Если $n_i \gg 1$, $i=1, 2$, $N \gg 1$, $n_i/N \leq \bar{v}_i < 1$, то при тестовой статистике $\rho_{n_1, n_2, N}$ критическое множество с уровнем значимости, близким к α , имеет вид

$$\rho_{n_1, n_2, N} > z_{1-\alpha}, \quad K(z_{1-\alpha}) = 1 - \alpha. \quad (7)$$

б) Выясняется вопрос о различии влияния двух типов воздействия на характеристики объектов O_i конечной совокупности \mathfrak{F} , $i=1, \dots, N$. Для

этого объекты \mathfrak{F} разбиваются на три группы объемом n_1 , n_2 и $N - (n_1 + n_2)$ на основе случайных выборок без возвращения объема n_1 и n_2 . На объекты, составляющие первую выборку, оказывается воздействие первого типа, на объекты, составляющие вторую выборку, оказывается воздействие второго типа. За нулевую гипотезу принимается идентичность воздействия обоих типов или отсутствие его. Тестовая статистика $\rho_{n_1, n_2, N}$ имеет то же критическое множество (7). Отбор объектов для проверки идентичности воздействий можно проводить с постоянной вероятностью. При этом объемы выборок n_1 и n_2 будут случайными величинами.

Заметим, что относительно предельных распределений статистик

$$\rho_{n_1, n_2, N}^+ = \sup_x [F_{n_1}(x) - F_{n_2}(x)], \quad \rho_{n_1, n_2, N}^- = -\inf_x [F_{n_2}(x) - F_{n_1}(x)],$$

$$T = \int_{-\infty}^{\infty} [F_{n_1}(x) - F_{n_2}(x)]^2 dH_{n_1+n_2}(x),$$

где

$$H_{n_1+n_2}(x) = \varphi_1(n_1, n_2, N) F_{n_1}(x) + \varphi_2(n_1, n_2, N) F_{n_2}(x),$$

будут справедливы утверждения, аналогичные теореме 3, вследствие непрерывности этих статистик, рассматриваемых как функционалы от траекторий гипергеометрических процессов.

Московский государственный университет
им. М. В. Ломоносова

Поступило
4 X 1973

ЦИТИРОВАННАЯ ЛИТЕРАТУРА

¹ Н. В. Смирнов, Бюлл. Моск. ун-в., сер. А, 2, 3 (1939). ² Ю. К. Беляев, Л. В. Рыкова, ДАН, 210, № 6 (1973). ³ В. Феллер, Введение в теорию вероятностей, 1, М., 1967. ⁴ И. И. Гихман, А. В. Скороход, Введение в теорию случайных процессов, «Наука», 1965.