

**Е. Л. Емельянова** (Самара, СГАУ). **О группировке эмпирических данных с использованием равномерно распределенных последовательностей случайных чисел.**

Пусть наблюдается случайная величина  $X$  с неизвестной функцией распределения  $F(x)$ ,  $\bar{X} = (X_1, X_2, \dots, X_n)$  — некоторая отвечающая ей случайная выборка и  $\omega = (X_1, X_2, \dots, X_n)$  — реализация этой выборки. Если объем выборки  $\bar{X}$  велик, то, прежде чем исследовать эту выборку по существу, сначала разбивают вариационный ряд на части и производят осреднение элементов в каждой части. Естественно, эта процедура, привнося влияние посторонних факторов методического плана, ухудшает качество исходной выборки. Ниже предлагается методика группировки элементов выборки  $\bar{X}$ , уменьшающая влияние таких факторов.

Возьмем произвольно целое число  $q \geq 2$  и равномерно распределенную в промежутке  $[0, 1)$  последовательность случайных чисел

$$\alpha_\ell = 0, \delta_\ell \delta_{\ell-1} \delta_{\ell-2} \dots \quad (\ell = 1, 2, \dots), \quad (1)$$

записанных в  $q$ -ичной системе счисления, т. е. такую, что для любого промежутка  $\Delta \subset [0, 1)$  длины  $|\Delta| < 1$  и любого натурального числа  $\ell$  при  $P \rightarrow \infty$  выполняется соотношение

$$N_P^{(\ell)}(\Delta) = |\Delta|P + o(P), \quad (2)$$

где  $N_P^{(\ell)}(\Delta)$  — количество чисел  $\alpha_{\ell-1+i}$ ,  $i = 1, 2, \dots, P$ , попавших в промежуток  $\Delta$ . При построении чисел (1) с  $q = 10$  можно использовать, например, табл. 7 на с. 240 книги [1]; для решения стандартных практических задач этого вполне достаточно.

Взяв, далее, произвольно целое число  $k \geq 2$ , например,  $k \in [n/h, n/h + 1)$ , где  $h = (x_{\max} - x_{\min}) / (1 + 3,322 \lg n)$  есть число Стэрджесса, для каждого  $s = 1, 2, \dots, k$  положим  $\Delta_s = [(s-1)/k, s/k)$  и определим функцию  $f_s(t)$ ,  $0 \leq t < 1$ , равенствами

$$f_s(t) = \chi_{\Delta_s}(t) = \begin{cases} 1 & \text{при } \{t\} \in \Delta_s, \\ 0 & \text{при } \{t\} \notin \Delta_s, \end{cases} \quad 0 \leq t < 1. \quad (3)$$

Образует  $k$  подвыборок  $\bar{X}_1, \bar{X}_2, \dots, \bar{X}_k$  выборки  $\bar{X}$ , относя к  $\bar{X}_s$ ,  $s = 1, 2, \dots, k$ , элементы  $X_i$  выборки  $\bar{X}$  с номерами  $i$ , для которых  $\alpha_{s-1+i} \in \Delta_s$ . Очевидно, подвыборки  $\bar{X}_1, \bar{X}_2, \dots, \bar{X}_k$  попарно не пересекаются, а их объединение дает всю выборку  $\bar{X}$ . Разбиение выборки  $\bar{X}$  на  $k$  частей  $\bar{X}_1, \bar{X}_2, \dots, \bar{X}_k$  естественным образом порождает и разбиение набора  $\omega$  на части  $\omega_1, \omega_2, \dots, \omega_k$ , являющиеся реализациями подвыборок  $\bar{X}_1, \bar{X}_2, \dots, \bar{X}_k$ , соответственно. Пусть  $F_n^*(x)$  — эмпирическая функция распределения случайной величины  $X$ , построенная по реализации  $\omega$  случайной выборки  $\bar{X}$ , а при  $s = 1, 2, \dots, k$  функция  $F_{n,s}^*(x)$  — эмпирическая функция распределения случайной величины  $X$ , построенная по реализации  $\omega_s$  случайной подвыборки  $\bar{X}_s$ . Легко видеть, что

$$F_n^*(x) = \frac{1}{k} \sum_{s=1}^k F_{n,s}^*(x), \quad -\infty < x < \infty. \quad (4)$$

Если  $v_s$  — объем подвыборки  $\bar{X}_s$ , то в силу соотношений (3) и (2), при всех  $s = 1, 2, \dots, k$

$$v_s = \sum_{i=1}^n f_s(\alpha_{s-1+i}) = \frac{n}{k} + o(n),$$

когда  $n \rightarrow \infty$ , т. е.  $v_s \approx [n/k]$ , причем последнее приближенное равенство тем точнее, чем меньше модуль остаточного члена в соотношении (2).

В силу свойств последовательности (1), подвыборки  $\bar{X}_1, \bar{X}_2, \dots, \bar{X}_k$  можно рассматривать как почти независимые случайные выборки, отвечающие случайной величине  $X$ , причем качество независимости определяется скоростью стремления к

нулю остаточного члена в соотношении (2). В связи с этим важную роль здесь могут сыграть построенные в теории чисел последовательности (в частности, последовательности дробных долей показательной функции с целым основанием  $q \geq 2$ ) с быстрым равномерным распределением в промежутке  $[0, 1)$ , ведущие себя как почти независимые случайные величины в соответствующем вероятностном пространстве (см. [2]–[5]).

Описанный метод разбиения случайной выборки  $\bar{X}$  на части уменьшает влияние посторонних факторов методического плана (например, когда объединяются в группы соседние члены выборки  $\bar{X}$ ) и, как следствие, повышает, в частности, надежность критериев согласия при проверке статистических гипотез, делая эти критерии менее чувствительными по отношению к процедуре группировки опытных данных. Поэтому, проверяя согласие непрерывной гипотетической функции распределения  $F(x)$  с опытными данными, например, с помощью критерия А. Н. Колмогорова, целесообразно наряду с классической статистикой этого критерия

$$D_n(\bar{X}) = \sqrt{n} \sup_{-\infty < x < \infty} |F_n^*(x) - F(x)| \quad (5)$$

использовать также модифицированные статистики

$$D_n^{(k)}(\bar{X}) = \frac{1}{k} \sum_{s=1}^k \sqrt{\frac{n}{k}} \sup_{-\infty < x < \infty} |F_{n,s}^*(x) - F(x)|, \quad (6)$$

имеющие при каждом целом  $k \geq 2$  то же самое предельное при  $n \rightarrow \infty$  распределение, что и классическая статистика  $D_n(\bar{X})$ . Вследствие равенств (5) и (4),

$$D_n(\bar{X}) = \sqrt{n} \sup_{-\infty < x < \infty} \left| \frac{1}{k} \sum_{s=1}^k (F_{n,s}^*(x) - F(x)) \right|. \quad (7)$$

Поэтому, сравнивая соотношения (6) и (7), мы видим, что  $D_n^{(k)}(\bar{X})$  ( $k = 2, 3, \dots$ ) — это существенно другие статистики, нежели  $D_n(\bar{X})$ , хотя они и имеют такое же предельное при  $n \rightarrow \infty$  распределение.

#### СПИСОК ЛИТЕРАТУРЫ

1. Чистяков В. П. Курс теории вероятностей. М.: Наука, 1982.
2. Коробов Н. М. О распределении дробных долей показательных функций. — Вестник МГУ, серия матем., мех., 1966, № 4, с. 42–46.
3. Усольцев Л. П. Задача на построение, связанная с равномерным распределением дробных долей показательных функций. — Известия ВУЗов, серия матем., 1967, № 12 (67), с. 75–83.
4. Усольцев Л. П., Емельянова Е. Л. Модификация статистики Пирсона. — Обозрение прикл. и промышл. матем., 2005, т. 12, в. 2, с. 535–537.
5. Емельянова Е. Л. Теоретико-числовая модификация статистики А. Н. Колмогорова. — Обозрение прикл. и промышл. матем., 2005, т. 12, в. 4, с. 854–856.