

Г. И. ЕГУДИН

**НЕКОТОРЫЕ СООТНОШЕНИЯ МЕЖДУ МОМЕНТАМИ
РАСПРЕДЕЛЕНИЯ КРАЙНИХ ЗНАЧЕНИЙ
В СЛУЧАЙНЫХ ВЫБОРКАХ**

(Представлено академиком А. Н. Колмогоровым 29 VII 1947)

За последнее время появилось много работ, относящихся к изучению законов распределения крайних значений и размаха (ранга) в выборках данного объема, главным образом из нормальной совокупности (1-6). Содержащиеся в этих работах вычисления некоторых констант, между прочим, весьма существенны для целей статконтроля*.

Если установить и ввести в рассмотрение законы распределения не только крайних, но и всех промежуточных значений, то, помимо некоторых общих соотношений, можно установить рекуррентные формулы, связывающие между собой константы, о которых сказано выше, и значительно облегчающие их вычисление. Эти же формулы могут быть рассматриваемы и как соотношения между интегралами определенных типов.

Пусть из генеральной совокупности, интегральный закон распределения которой $F(x)$, производится случайная повторная, а в случае бесконечной генеральной совокупности и бесповторная, выборка объема n . Обозначим $X_{1,n}, X_{2,n}, \dots, X_{n,n}$ случайные переменные, представляющие в возрастающем (не убывающем) порядке значения величины X , образующие каждую из производимых выборок объема n : $X_{1,n} < X_{2,n} < \dots < X_{n,n}$.


Тогда легко вывести $F_{k,n}(x) = \text{вер} \{X_{k,n} < x\}$ — интегральный закон распределения величины $X_{k,n}$. Действительно, величина $X_{k,n}$ будет меньше x в одном из $n-k+1$ следующих несовместимых случаев: 1) когда все n значений X , образовавших выборку, будут меньше x ; 2) когда $n-1$ значений X меньше x , а одно значение больше x ; ...; $n-k+1$; 3) когда k значений X меньше x , а остальные $n-k$ его значений больше x . Вероятность того, что в выборке объема n ровно i определенных (скажем, первых) значений X будут меньше x , а остальные $n-i$ значений будут больше x , равна $[\text{вер} \{X < x\}]^i \times [\text{вер} \{X > x\}]^{n-i} = [F(x)]^i [1 - F(x)]^{n-i}$.

Вероятность же того, что в такой выборке i любых значений X будут меньше x , а остальные $n-i$ значений будут больше x , очевидно, равна $C_n^i [F(x)]^i [1 - F(x)]^{n-i}$.

Таким образом, искомая вероятность $F_{k,n}(x)$ будет:

$$F_{k,n}(x) = \sum_{i=k}^n C_n^i [F(x)]^i [1 - F(x)]^{n-i}. \quad (1)$$

* Они, например, необходимы при «размаховом» методе статконтроля, рекомендуемом в (7).



Пусть, далее, для некоторых целых положительных значений r существуют интегралы

$$\bar{X}_{k,n}^r = \int_{-\infty}^{\infty} x^r dF_{k,n}(x)$$

■

$$\bar{X}_s^r = \int_{-\infty}^{\infty} x^r d[F(x)]^s = \int_{-\infty}^{\infty} x^r dF_{s,s}(x) \quad (s = \overline{1, n}),$$

г. е. \bar{X}_s^r — начальный момент порядка r наибольшего значения в выборке объема s . Тогда (1) дает

$$\bar{X}_{k,n}^r = \sum_{i=k}^n C_n^i \sum_{l=0}^{n-i} C_{n-i}^l (-1)^l \bar{X}_{i+l}^r. \quad (2)$$

Докажем теперь следующее предложение:

Средняя арифметическая начальных моментов порядка r величин $X_{1,n}, X_{2,n}, \dots, X_{n,n}$ равна начальному моменту того же порядка генеральной совокупности. Т. е.

$$\frac{1}{n} \sum_{k=1}^n \bar{X}_{k,n}^r = \frac{1}{n} \sum_{k=1}^n \int_{-\infty}^{\infty} x^r dF_{k,n}(x) = \int_{-\infty}^{\infty} x^r dF(x)^*. \quad (3)$$

Для доказательства (3), очевидно, достаточно показать, что

$$\frac{1}{n} \sum_{k=1}^n dF_{k,n}(x) = dF(x). \quad (4)$$

Из (1)

$$\sum_{k=1}^n dF_{k,n}(x) = \left\{ \sum_{k=1}^n \sum_{i=k}^n [C_n^i i [F(x)]^{i-1} [1 - F(x)]^{n-i} - C_n^i (n-i) [F(x)]^i [1 - F(x)]^{n-i-1}] \right\} dF(x).$$

Внутренняя сумма может быть преобразована:

$$C_n^k k [F(x)]^{k-1} [1 - F(x)] + \sum_{i=k+1}^n C_n^i i [F(x)]^{i-1} [1 - F(x)]^{n-i} - \\ - \sum_{i=k}^n C_n^i (n-i) [F(x)]^i [1 - F(x)]^{n-i-1} = C_n^k k [F(x)]^{k-1} [1 - F(x)]^{n-k}.$$

Значит,

$$\sum_{k=1}^n dF_{k,n}(x) = \sum_{k=1}^n C_n^k k [F(x)]^{k-1} [1 - F(x)]^{n-k} = \\ = \sum_{k=1}^{n-1} C_n^k k [F(x)]^{k-1} [1 - F(x)]^{n-k} + n [F(x)]^{n-1} =$$

* Теорема верна не только для начальных моментов, но, как следует из доказательства, для математических ожиданий произвольных функций.

$$\begin{aligned}
 &= n \sum_{k=1}^{n-1} C_{n-1}^{k-1} [F(x)]^{k-1} [1 - F(x)]^{n-k} + n [F(x)]^{n-1} = \\
 &= n [F(x)]^{n-1} + n [F(x)] + [1 - F(x)]^{n-1} - n [F(x)]^{n-1} = n,
 \end{aligned}$$

что и доказывает (4), а следовательно, и (3).

Заметим, что равенство (3) есть, конечно, распространение на рассматриваемый случай известного свойства ассоциативности средней арифметической n величин.

Используя (2), можно записать вместо (3)

$$\sum_{k=1}^n \sum_{i=k}^n C_n^i \sum_{l=0}^{n-i} C_{n-i}^l (-1)^l \bar{X}_{i+l}^r = n m_r(X), \quad (5)$$

где через $m_r(X)$ обозначен начальный момент порядка r генеральной совокупности.

Если, в частности, закон распределения генеральной совокупности нормален, то, считая центр распределения равным нулю:

$$F(x) = \frac{1}{\sqrt{2\pi\sigma}} \int_{-\infty}^x e^{-x^2/2\sigma^2} dx. \quad (6)$$

Тогда

$$\bar{X}_s^r = \frac{s}{\sqrt{2\pi\sigma}} \int_{-\infty}^{\infty} x^r e^{-x^2/2\sigma^2} \left[\frac{1}{\sqrt{2\pi\sigma}} \int_{-\infty}^x e^{-t^2/2\sigma^2} dt \right]^{s-1} dx = a_{s,r} \sigma^r, \quad (7)$$

где $a_{s,r}$, зависящие от s и r , и являются теми величинами, знание которых, во всяком случае для $r=1, 2, 3, 4$, для различных n необходимо в статистических приложениях.

Для генеральной совокупности (6) при всех нечетных r $m_r(X)=0$ и $\bar{X}_{\frac{n+1}{2}+h}^r = \bar{X}_{\frac{n+1}{2}-h}^r$. Поэтому (5) дает следующее рекуррентное соотношение между величинами $a_{n,r}$ при различных n и фиксированном r

$$\sum_{i=\frac{n+1}{2}}^n C_n^i \sum_{l=0}^{n-i} C_{n-i}^l (-1)^l a_{i+l,r} = 0. \quad (8)$$

Очевидно, что это равенство может рассматриваться и как рекуррентное соотношение между интегралами типа (7) при нечетных r *

При четных r $\bar{X}_{\frac{n}{2}-h}^r = \bar{X}_{\frac{n}{2}+h}^r$ и (5) дает следующее рекуррентное

соотношение между величинами $a_{n,r}$ при различных h и любом фиксированном r :

$$\sum_{k=\frac{n}{2}+1}^n \sum_{i=k}^n C_n^i \sum_{l=0}^{n-i} C_{n-i}^l (-1)^l a_{i+l,r} = \frac{n}{2}. \quad (9)$$

Очевидно, что и это равенство устанавливает соотношение между интегралами типа (7) при четных r .

Если обозначить $\sigma^2(X_n) = \bar{X}_n^2 - (\bar{X}_n)^2 = (a_{n,2} - a_{n,1}^2) \sigma^2 = \beta_n^2 \sigma^2$, то

$$a_{n,2} = \beta_n^2 + a_{n,1}^2,$$

* В. И. Романовский⁽⁸⁾, рассматривая интегралы (7) при $r=1$, установил между ними соотношение, содержащееся в (8).

и (9) вместе с (8) дает рекуррентные соотношения между дисперсиями распределений наибольших (наименьших) значений в выборках различных объемов из нормальной совокупности.

Статистическое значение констант a_n, r очевидно. Пусть произведено m случайных выборок, объемом n каждая, из нормальной генеральной совокупности. Обозначим через \bar{X}_n и \bar{X}_n^2 статистики, представляющие собой, соответственно, первый и второй выборочные начальные моменты наибольшего значения, т. е. средние арифметические, соответственно, первых и вторых степеней наблюдаемых наибольших значений в каждой из m произведенных выборок одного и того же объема n . Тогда, если известно, что центр генерального распределения равен нулю, то согласной оценкой σ^2 дисперсии генеральной совокупности будет, как это следует из (7), величина

$$\frac{1}{a_{n,r}} \bar{X}_n^2. \quad (10)$$

Если нормальная генеральная совокупность имеет неизвестный центр распределения, равный \bar{X} , то согласной оценкой этого параметра будет, очевидно, величина $\frac{1}{2} (\bar{X}_n + \bar{X}_{1,n})$ *. Здесь $\bar{X}_{1,n}$ — выборочная средняя наименьшего значения, т. е. средняя арифметическая m наблюдаемых в каждой из произведенных выборок наименьших значений. В этом случае (10) не может служить оценкой дисперсии генеральной совокупности σ^2 . Помимо очевидной оценки σ^2 через размах выборки можно и теперь построить оценки параметров генеральной совокупности σ^2 и \bar{X} , не вводя в рассмотрение наименьших наблюдаемых значений в произведенных выборках, а оперируя только наибольшими выборочными значениями \bar{X}_n . В этом случае в качестве оценки σ^2 следует принять величину $\frac{1}{\beta_n^2} \frac{m}{m-1} [\bar{X}_n^2 - (\bar{X}_n)^2]$, математическое ожидание которой как раз равно σ^2 .

Кроме того, если \bar{X} — центр распределения генеральной совокупности, то $\bar{X}_n = a_{n,1} \sigma + \bar{X}$. Следовательно, в качестве оценки (не согласной) величины \bar{X} можно принять

$$\bar{X}_n - \frac{a_{n,1}}{\beta_n} \sqrt{\frac{m}{m-1} [\bar{X}_n^2 - (\bar{X}_n)^2]}.$$

Сказанное в сноске в еще большей степени распространяется на эту оценку.

Поступило
29 VII 1947

ЦИТИРОВАННАЯ ЛИТЕРАТУРА

- ¹ L. H. Tippett, *Biometrika*, 17, 364 (1925). ² E. S. Pearson, *Biometrika*, 18, 173 (1926). ³ E. S. Pearson, *Biometrika*, 24, 404 (1932). ⁴ A. T. McKay and E. S. Pearson, *Biometrika*, 25, 415 (1933). ⁵ D. Neuman, *Biometrika*, 31, 10 (1939). ⁶ E. S. Pearson, *Biometrika*, 32, 100 (1942). ⁷ B. P. Pudding and W. J. Jennet, *Quality Control Charts* B. S. 600 R, 1942. ⁸ V. Romanovskiy, *Biometrika*, 25, 195 (1933).

* Подсчет стандартной ошибки приближения, даваемого такой оценкой, показывает, что, например, в тех случаях, когда исследователь при определении генеральной средней по выборке лимитируется не столько объемом выборки, сколько трудностью производства замеров (что часто имеет место в индустриальных приложениях), можно, не уменьшая точности приближения, значительно уменьшить число таких замеров. Вместо измерений всех N единиц выборки, требуемых обычным способом измерения средней, следует, несколько увеличив N — объем всей выборки, подразделить его на m групп объемом n каждая и произвести всего $2m$ измерений крайних значений в каждой из групп. Отбор крайних образцов часто возможен без их измерения.