

А. А. ПЕТРОВ

ПРОВЕРКА ГИПОТЕЗЫ О НОРМАЛЬНОСТИ РАСПРЕДЕЛЕНИЙ
ПО МАЛЫМ ВЫБОРКАМ

(Представлено академиком А. Н. Колмогоровым 29 XI 1950)

1. Пусть дана совокупность из N выборок объема n

$$\begin{aligned} x_{11}, \dots, x_{1n}, \\ \dots \dots \dots \\ x_{N1}, \dots, x_{Nn}. \end{aligned}$$

Ставится вопрос: допустимо ли предположение, что i -я выборка (при любом i) получена случайным выбором из бесконечной совокупности, имеющей интегральную функцию распределения $F(a_i x + b_i)$, где F — заданная функция, одна и та же для всех выборок, а параметры a_i и b_i могут быть различными для различных выборок и нам неизвестны. (Это предположение в дальнейшем будет называться гипотезой F .) В частности, допустимо ли предположение, что каждая из наших выборок взята из нормально распределенной совокупности с различными для разных выборок математическими ожиданиями и дисперсиями.

Для проверки высказанной гипотезы естественно рассматривать те или иные функции $\eta(x_1, x_2, \dots, x_n)$, распределения которых, вычисленные в предположении, что x_1, \dots, x_n независимы и подчинены функции распределения $F(ax + b)$, не зависят от a и b . Можно рассматривать, например, величины

$$\eta' = \frac{x_{\max} - \bar{x}}{s}, \quad \eta'' = \frac{x_{\min} - \bar{x}}{s},$$

распределение которых в случае нормального закона F было изучено Н. В. Смирновым ⁽¹⁾. Другой метод, отправляющийся от распределения величин $\eta_i = \frac{x_i - \bar{x}}{s}$, рассмотренного впервые Томпсоном ⁽²⁾, предложен Арлеем и Бухом ^(3, 4). Предлагаемый далее метод имеет то преимущество, что не требует вычисления средних квадратических s . Кроме того, он дает $n-2$ отдельные кривые для сравнения и может поэтому являться более мощным средством различия типов распределений.

2. Пусть X есть случайная величина, имеющая распределение непрерывного типа ⁽⁵⁾ с функцией распределения F и плотностью вероятности $f = F'$, а $x'_1 \leq x'_2 \leq \dots \leq x'_n$ есть последовательность n независимых наблюдений случайной величины X , упорядоченная в порядке возрастания. Рассмотрим отношения

$$\xi_k = \frac{x'_k - x'_1}{x'_n - x'_1} \quad (\text{где } 1 < k < n).$$

Эти величины инвариантны относительно выбора масштаба и начала координат, и поэтому их функции распределения будут одинаковыми для всех функций распределения $F(ax + b)$, отличающихся от $F(x)$ только значениями параметров a и b .

Можно доказать, что функция распределения случайной величины ξ_k есть

$$F_k(t) = \frac{n!}{(k-2)!(n-k-1)!} \iiint_G [F(y) - F(x)]^{k-2} [F(z) - F(y)]^{n-k-1} \times \\ \times f(x)f(y)f(z) dx dy dz, \quad (1)$$




Рис. 1. $F_2(t)$

где интегрирование производится по области G , определяемой неравенствами

$$x \leq y \leq z, \quad \frac{y-x}{z-x} < t.$$

3. Пусть величина X распределена равномерно на отрезке $(0, 1)$. Тогда, в силу формулы (1),

$$F_k(t) = \frac{n!}{(k-2)!(n-k-1)!} \iiint_{G^*} (y-x)^{k-2} (z-y)^{n-k-1} dx dy dz, \quad (2)$$

где интегрирование производится по области G^* , определяемой неравенствами

$$0 \leq x \leq y \leq z \leq 1, \quad \frac{y-x}{z-x} < t.$$

В случае $n = 5$ получаем, например, отсюда

$$F_2(t) = 1 - (1-t)^3, \quad F_3(t) = t^2(3-2t), \quad F_4(t) = t^3.$$

4. Пусть величина X имеет непрерывную и строго монотонную функцию распределения F . С помощью подстановки $X' = F(X)$ распределение F приводится к равномерному, и функция распределения $F_k(t)$ определяется интегралом (2) по области

$$0 \leq x \leq y \leq z \leq 1, \quad \frac{F^{-1}(y) - F^{-1}(x)}{F^{-1}(z) - F^{-1}(x)} < t,$$




Рис. 2. $F_3(t)$

где F^{-1} есть функция, обратная к F . Произведя в выражении (2) интегрирование по переменной x , придем к следующей формуле, пригодной для численного интегрирования:

$$F_k(t) = \frac{n!}{(k-1)!(n-k-1)!} \int_0^1 dz \int_0^z (z-y)^{n-k-1} (y-x_0)^{k-1} dy, \quad (3)$$

где

$$x_0 = x_0(y, z, t) = F \left[\frac{F^{-1}(y) - tF^{-1}(z)}{1-t} \right].$$

5. Рекомендуемый метод проверки допустимости гипотезы F заключается в следующем. Каждая из наших N выборок дает по одному наблюденному значению для каждой из величин ξ_k . По этим N наблюденным значениям строятся эмпирические функции распределения для величин ξ_k . С помощью критерия Колмогорова (6) производится сравнение между полученными эмпирическими функциями распределения и теоретическими, вычисленными заранее по формуле (1) или (3). Если при этом обнаружатся значимые отклонения хотя бы при одном k , то испытуемая гипотеза F отвергается. В случае, когда ни при одном k таких отклонений не обнаруживается, данные, заключенные в наших выборках, хорошо согласуются с гипотезой F .

6. Для практического применения описанного метода нужно знать функции F_k , соответствующие данному значению n и испытуемой гипотезе F . Вычисления были проведены для $n = 5$ и двух гипотез — нормального и равномерного распределений.

На прилагаемых графиках приведены функции F_2 , F_3 , F_4 , вычисленные для равномерного (б) и нормального (а) распределений по формулам (2) и (3), и эмпирические функции распределения величин ξ_2 , ξ_3 , ξ_4 , построенные по выборке в 200 пятерок, взятых из таблиц




Рис. 3. $F_4(t)$

случайных чисел, подчиненных нормальному закону (?). Во всех трех случаях эмпирические функции распределения хорошо согласуются с гипотезой нормального распределения. При сравнении с гипотезой равномерного распределения в двух случаях (ξ_2 и ξ_4) получаем значимые отклонения. Эти отклонения соответствуют в первом случае уровню значимости в 0,06% и во втором — уровню значимости в 2%.

В заключение пользуясь случаем выразить А. Н. Колмогорову сердечную признательность за постановку задачи и руководство при выполнении этой работы.

Поступило
27 XI 1950

ЦИТИРОВАННАЯ ЛИТЕРАТУРА

- ¹ Н. В. Смирнов, ДАН, 33, 346 (1941). ² W. R. Thompson, Ann. Math. Statistics, 6, 214 (1935). ³ N. Arley, K. Danske, Vid. Selsk., Mat.-fys. Medd., 18, No. 3 (1940). ⁴ N. Arley and K. R. Buch, Introduction to the Theory of Probability and Statistics, 1950. ⁵ Г. Крамер, Математические методы статистики, 1948. ⁶ В. И. Романовский, Применения математической статистики в опытном деле, 1947. ⁷ H. Wold, Random Normal Deviates, Tracts for computers, No. 25, 1948.