

МАТЕМАТИКА

Н. В. СМЕРНОВ

**О ПОСТРОЕНИИ ДОВЕРИТЕЛЬНОЙ ОБЛАСТИ ДЛЯ ПЛОТНОСТИ
РАСПРЕДЕЛЕНИЯ СЛУЧАЙНОЙ ВЕЛИЧИНЫ**

(Представлено академиком А. Н. Колмогоровым 14 VII 1950)

Пусть произведено n независимых наблюдений случайной величины ξ , распределенной с непрерывной плотностью $f(x)$. Обычно практикуемый прием приближенной оценки неизвестной функции $f(x)$ по данным выборки на сегменте $[a, b]$ заключается в построении "гистограммы" частот $f_n^*(x)$. Подразделяя сегмент $[a, b]$ на s отрезков $\Delta_1, \Delta_2, \dots, \Delta_s$ равной длины $h = \frac{b-a}{s}$ и подсчитав численности m_1, m_2, \dots, m_s наблюдений, попавших на последовательные отрезки Δ_k , полагают:

$$f_n^*(x) = \frac{m_k}{nh} \text{ при } x \in \Delta_k. \quad (1)$$

Эту эмпирическую кривую сравнивают с теоретической гистограммой $\bar{f}(x)$:

$$\bar{f}(x) = \frac{p_k}{h} = \frac{1}{h} \int_{\Delta_k} f(x) dx. \quad (2)$$

Легко обнаруживается из элементарных соображений, что $f_n^*(x)$ сходится по вероятности к $\bar{f}(x)$ в каждой точке $x [a, b]$. Если при возрастании n надлежащим образом увеличивать и число s отрезков подразделения, то можно прийти к более точным выводам, впервые полученным В. И. Гливенко (1). В настоящей заметке мы формулируем теоремы, которые при известных условиях могут быть использованы для более точной и надежной оценки плотности.

Теорема 1. Если непрерывная плотность распределения $f(x)$ удовлетворяет на $[a, b]$ условиям:

$$\text{Min } \{f(x)\} = \mu > 0; \quad a \leq x \leq b, \quad (A)$$

$$\int_a^b f(x) dx = 1 - \alpha < 1, \quad (B)$$

и при возрастании n и s имеем:

$$\lim_{n \rightarrow \infty} \frac{s^3 (\ln s)^3}{n} < \infty, \quad (C)$$

то для любого λ , $-\infty < \lambda < \infty$,

$$P_n = P \left\{ \text{Max} \frac{|f_n^*(x) - f(x)|}{V \bar{f}(x)} \leq \frac{l_s + \frac{\lambda}{l_s}}{V n h} \right\} = \\ = \left[2 \Phi \left(l_s + \frac{\lambda}{l_s} \right) \right]^s + O \left(\frac{V \ln s}{s} \right) + O \left(\frac{s^{3/2}}{V n} \right) = e^{-2e^{-\lambda}} + O \left(\frac{1}{V \ln s} \right) \quad (3)$$

и

$$P_n \rightarrow e^{-2e^{-\lambda}} \quad (n \rightarrow \infty); \quad (3^1)$$

при этом

$$\Phi(x) = \frac{1}{V 2\pi} \int_0^x e^{-x^2/2} dx$$

и l_s есть корень уравнения

$$\frac{1}{2} - \Phi(x) = \frac{1}{s}. \quad (4)$$

В формулировке теоремы 1 теоретическую гистограмму $\bar{f}(x)$ нельзя заменить плотностью $f(x)$, так как (даже при наличии ограниченной производной $f'(x)$) систематическое расхождение между $\bar{f}(x)$ и $f(x)$ значительно превосходит случайную погрешность. Однако в качестве приближающей эмпирической функции берут также „полигон частот“ и соответственно заменяют $\bar{f}(x)$ теоретическим полигоном.

Эти функции определяются следующим образом.

Пусть x_k ($k = 1, 2, \dots, s$) — середины промежутков Δ_k и a_k — правые концы этих промежутков; в каждом сегменте $[x_k, x_{k+1}]$ полагаем:

$$\varphi_n^*(x) = \frac{m_k + m_{k-1}}{2nh} + (x - a_k) \frac{(m_{k+1} - m_k)}{nh^2} \quad (5^1)$$

и

$$\varphi_s(x) = \frac{p_k + p_{k+1}}{2h} + (x - a_k) \frac{(p_{k+1} - p_k)}{h^2}, \quad (5^2)$$

так что

$$\varphi_n^*(x_k) = \frac{m_k}{nh}; \quad \varphi_n^*(x_{k+1}) = \frac{m_{k+1}}{nh}; \quad \varphi_s(x_k) = \frac{p_k}{h}; \quad \varphi_s(x_{k+1}) = \frac{p_{k+1}}{h}.$$

Пусть еще

$$\psi_s(x) = \frac{\sqrt{\frac{p_k}{h}} + \sqrt{\frac{p_{k+1}}{h}}}{2} + (x - a_k) \left(\sqrt{\frac{p_{k+1}}{h}} - \sqrt{\frac{p_k}{h}} \right), \quad (6)$$

$$\psi_s(x_k) = \sqrt{\frac{p_k}{h}}; \quad \psi_s(x_{k+1}) = \sqrt{\frac{p_{k+1}}{h}}. \quad (6^1)$$

Тогда имеет место

Теорема 2. При условиях (А), (В) и (С) теоремы 1 для вероятности

$$P'_n = P \left\{ \text{Max} \frac{|\varphi_n^*(x) - \varphi_s(x)|}{\psi_s(x)}; \quad a + \frac{h}{2} \leq x \leq b - \frac{h}{2} \right\}$$

справедливы утверждения (3) и (3¹) теоремы 1.

Из теоремы 2 легко получается следующая

Теорема 3. Если $f(x)$ имеет на $[a, b]$ ограниченную вторую производную и выполняются условия (A), (B) и (C) теоремы 1 и, кроме того,

$$\frac{n \ln s}{s^5} \rightarrow 0 \quad (n \rightarrow \infty), \quad (D)$$

то

$$P \left\{ \text{Max} \frac{|\varphi_n^*(x) - f(x)|}{Vf(x)} \leq \frac{l_s + \frac{\lambda}{l_s}}{Vnh} \right\} \xrightarrow{n \rightarrow \infty} e^{-2e^{-\lambda}}. \quad (7)$$

Условиям (C) и (D) можно удовлетворить, полагая, например, $s = n^\alpha$, $\frac{1}{5} < \alpha < \frac{1}{3}$.

Теорема 3 дает возможность строить доверительные области с заданным коэффициентом довери β для оценки неизвестной плотности $f(x)$ по данным выборки.

Определив при заданном β ($0 < \beta < 1$) $\lambda = \lambda_\beta$, удовлетворяющее уравнению

$$e^{-2e^{-\lambda}} = \beta$$

(или, более точно, из уравнения $[2\Phi(l_s + \frac{\lambda}{l_s})]^s = \beta$), находим

$$\frac{l_s + \lambda_\beta / l_s}{Vnh} = t_\beta.$$

Неравенство

$$\text{Max} \frac{|\varphi_n^*(x) - f(x)|}{Vf(x)} \leq t_\beta$$

означает, что кривая $f(x)$ на всем сегменте $[a, b]$ не выходит за границы полосы \mathfrak{U}_β , ограниченной кривыми:

$$y_1(x) = \varphi_n^*(x) + \frac{t_\beta^2}{2} - t_\beta \sqrt{\varphi_n^*(x) + \frac{t_\beta^2}{4}}$$

и

$$y_2(x) = \varphi_n^*(x) + \frac{t_\beta^2}{2} + t_\beta \sqrt{\varphi_n^*(x) + \frac{t_\beta^2}{4}}.$$

Полоса \mathfrak{U}_β покрывает кривую плотности $y = f(x)$ при больших n и s при условиях теоремы 3 с вероятностью, сколь угодно близкой к β .

Поступило
4 IV 1950

ЦИТИРОВАННАЯ ЛИТЕРАТУРА

- ¹ В. И. Гливенко, Курс теории вероятностей, 1939, стр. 180.