

Здравствуйте!

## **Функция распределения и плотность вероятностей**

### **Оценка функции распределения**

Рассмотрим теперь вопросы, связанные с оценкой функции распределения случайной величины и проверки гипотез относительно её.

Пусть имеется случайная величина  $\xi$  с функцией распределения  $F(x)$ , которую мы не знаем. Нам необходимо оценить её по опытным данным.

Пусть мы провели  $n$  опытов и получили выборку  $x_1, x_2, x_3, \dots, x_n$  объёма  $n$ . Тогда в качестве оценки неизвестной функции распределения  $F(x)$  берётся так называемая **эмпирическая функция распределения**  $F_n(x)$ , которая определяется следующим образом:

$$F_n(x) = \frac{1}{n} \sum_{i=1}^n \theta(x - x_i),$$

где

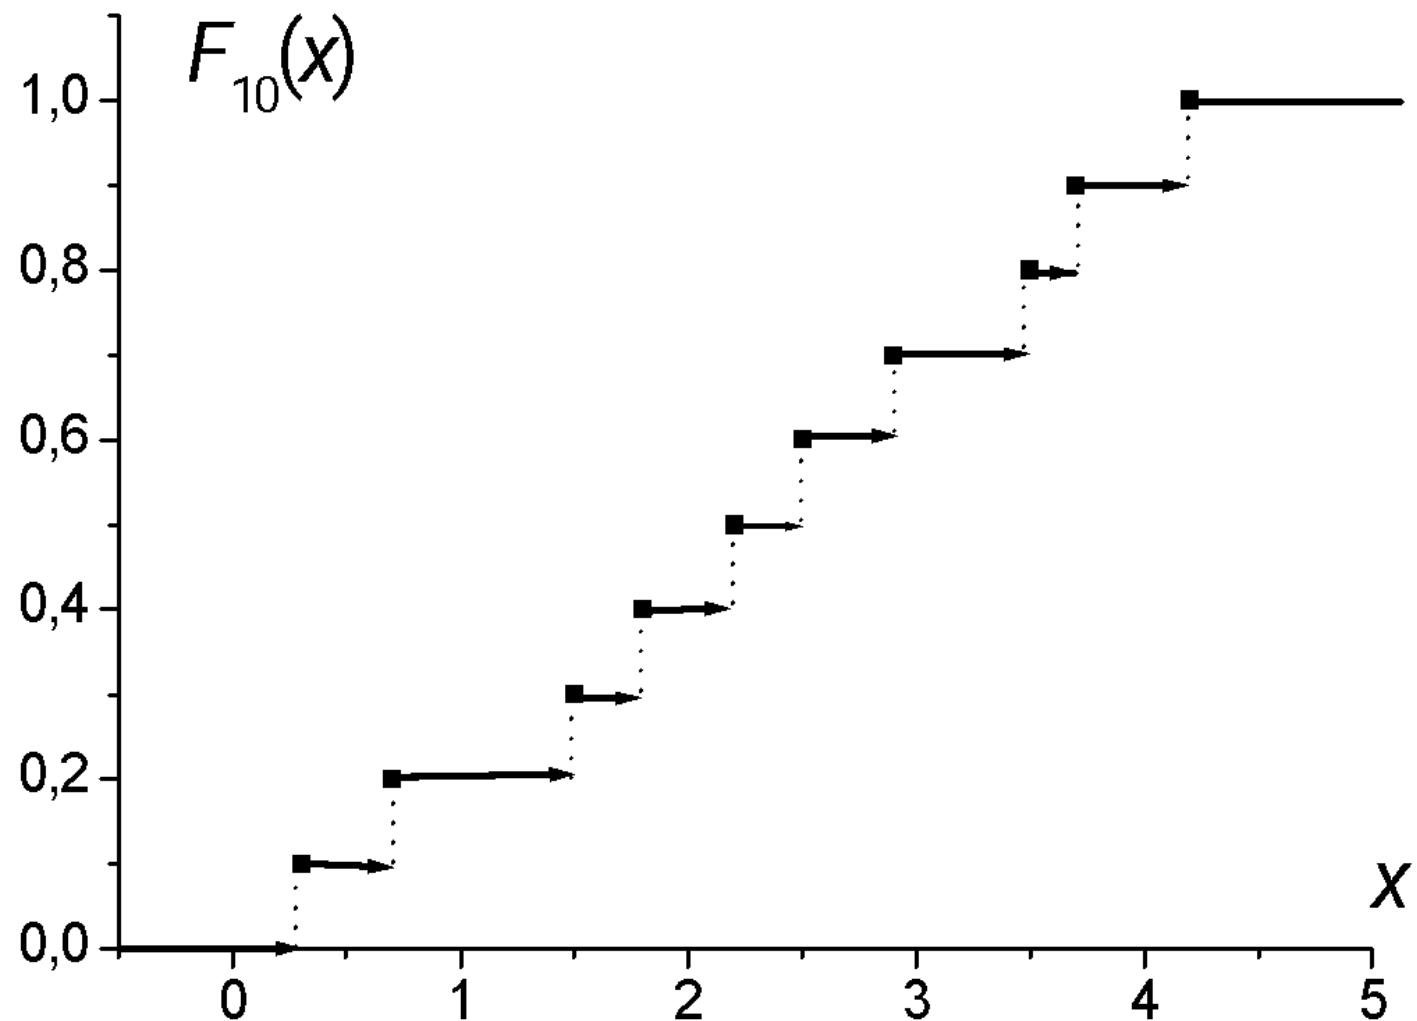
$$\theta(x) = \begin{cases} 1, & \text{если } x \geq 0, \\ 0 & \text{если } x < 0 \end{cases}$$

есть так называемая функция Хевисайда или функция единичного скачка.

Её определяют еще и следующим образом. Представим себе, что мы нашу выборку  $x_1, x_2, x_3, \dots, x_n$  упорядочили **в порядке возрастания** и получили упорядоченную выборку  $x_1^{(n)}, x_2^{(n)}, x_3^{(n)}, \dots, x_n^{(n)}$ , так что  $\forall i = \overline{1, n-1} \quad x_i^{(n)} \leq x_{i+1}^{(n)}$ . Тогда  $F_n(x)$  есть ступенчатая функция со скачками, равными  $1/n$  в точках  $x_i^{(n)}$ .

Её можно записать и так:

$$F_n(x) = \begin{cases} 0, & \text{если } x < x_1^{(n)}, \\ m/n, & \text{если } x_i^{(n)} \leq x < x_{i+1}^{(n)}, 1 \leq i \leq n-1, \\ 1, & \text{если } x \geq x_n^{(n)}. \end{cases}$$



Эта оценка обладает следующими свойствами

$$\mathbb{M}\{F_n(x)\} = F(x),$$

то есть она является несмешенной оценкой, и

$$\mathbb{D}\{F_n(x)\} = \frac{1}{n} F(x)(1 - F(x)) \xrightarrow{n \rightarrow \infty} 0,$$

то есть она сходится, по меньшей мере, в средне квадратичном смысле. Можно показать, что она сходится также и почти наверное.

### **Критерии Колмогорова и Смирнова**

Следующие две популярные задачи связаны с проверкой статистических гипотез.

Первая из них выглядит следующим образом. На основании каких-то соображений мы предполагаем, что функция распределения исследуемой случайной величины есть  $F(x)$ . Мы провели  $n$  опытов и по полученной выборке построили эмпирическую функцию распределения  $F_n(x)$ . Можно ли сказать, что наши экспериментальные данные не противоречат нашей гипотезе?

Более точно наша гипотеза имеет вид

$$H_0: \forall x M\{F_n(x)\} = F(x)$$

при альтернативе

$$H_1: \exists x M\{F_n(x)\} \neq F(x).$$

Для проверки этой гипотезы используют так называемый **критерий Колмогорова**. Согласно ему, для проверки этой гипотезы необходимо вычислить величину

$$D_n = \sup_{|x|<\infty} |F_n(x) - F(x)|.$$

Реально эта величина считается по следующим формулам

$$D_n^+ = \max_{1 \leq m \leq n} \left( \frac{m}{n} - F(x_m^{(n)}) \right),$$

$$D_n^- = \max_{1 \leq m \leq n} \left( F(x_m^{(n)}) - \frac{m-1}{n} \right),$$

$$D_n = \max(D_n^+, D_n^-).$$

Решающее правило выглядит следующим образом: если окажется, что

$$\sqrt{n}D_n \leq \lambda_\alpha,$$

то следует **принять** гипотезу  $H_0$ , то есть считать, что наши опытные данные не противоречат гипотезе о том, что функция распределения исследуемой случайной величины равна  $F(x)$ ; если же выполнено противоположное неравенство, то гипотеза должна быть **отвергнута**, то есть считается, что опытные данные ей противоречат.

Сама величина  $\lambda_\alpha$  даётся следующей таблицей:

$\alpha_0$	0,05 (5%)	0,01 (1%)	0,001 (0,1%)
$\lambda_\alpha$	1,36	1,63	1,95

Другой популярной проблемой является задача о проверке однородности двух выборок. Она ставится следующим образом. Пусть имеется две случайные величины  $\xi$  и  $\eta$  с функциями  $F(x)$  и  $G(x)$  соответственно. Необходимо проверить гипотезу

$$H_0: \forall x F(x) = G(x)$$

при альтернативе

$$H_1: \exists x F(x) \neq G(x)$$

Пусть мы провели две серии опытов и получили две выборки случайных величин  $\xi$  и  $\eta$  объёмами  $m$  и  $n$  соответственно. Представим себе, что по ним мы построили две эмпирические функции распределения  $F_m(x)$  и  $G_n(x)$ . Тогда для проверки сформулированной гипотезы надо найти величину

$$D_{mn} = \sup_{|x|<\infty} |F_m(x) - G_n(x)|,$$

и вычислить

$$\sqrt{\frac{mn}{m+n}} D_{mn}.$$

Если окажется, что эта величина не превосходит  $\lambda_\alpha$ , то следует принять гипотезу  $H_0$ , то есть считать, что опытные данные не противоречат тому, что функции распределения в обеих выборках одинаковы; при выполнении противоположного неравенства гипотеза должна быть отвергнута.

Этот критерий носит название критерия Колмогорова–Смирнова.

## **Оценка плотности вероятностей. Гистограмма**

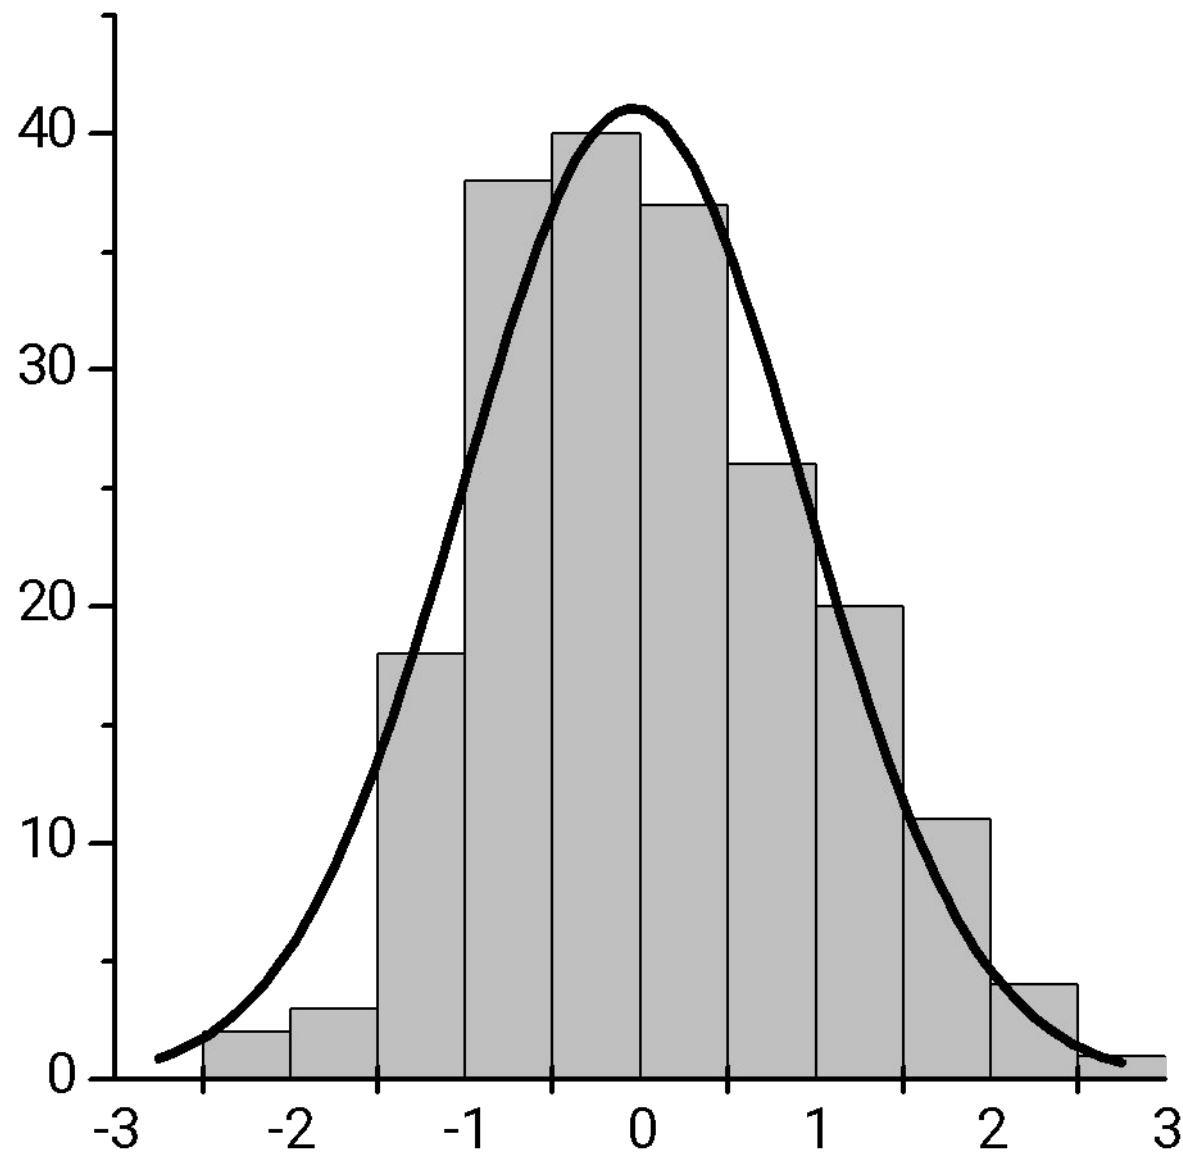
Рассмотрим, наконец, оценку плотности вероятностей случайной величины. Она выполняется с помощью так называемых гистограмм.

Пусть мы имеем выборку  $x_1, x_2, x_3, \dots, x_n$  объёма  $n$ . Разобьём всю ось  $OX$  на отрезки длиной  $h$ . Эту величину рекомендуется находить по формуле

$$h = \frac{x_{\max} - x_{\min}}{1 + 3,3 \log n},$$

округляя её до ближайшего удобного числа. Здесь  $x_{\max}$  ( $x_{\min}$ ) есть максимальное (минимальное) значение из выборочных данных.

Пусть эти отрезки (их обычно называют классами) будут  $[a, a+h]$ ,  $[a+h, a+2h]$ , … ,  $[a+(k-1)h, a+kh]$ , так что  $x_{\min}$  попадает в первый отрезок  $[a, a+h]$ , а  $x_{\max}$  – в последний,  $k$ -й отрезок  $[a+(k-1)h, a+kh]$ . После этого производится так называемая разнотска по классам. Она состоит в том, что считается, сколько выборочных значений попало на тот или иной отрезок. Пусть эти числа будут  $n_1, n_2, \dots, n_k$ . Тогда на плоскости  $XOY$  строится система прямоугольников с основаниями на выбранных отрезках и площадями, пропорциональными величинам  $n_1, n_2, \dots, n_k$ . Этот рисунок и называется гистограммой.



Эта гистограмма и является некоторым образом плотности вероятностей изучаемой случайной величины. Дальнейшая работа с ней сводится к следующему.

Обычно существуют некоторые соображения о виде этой плотности вероятностей с точностью до некоторого количества  $s$  неизвестных параметров. Тогда компьютеру поручается сделать оценку этих неизвестных параметров и построить выравнивающую кривую. В современных пакетах программ для статистической обработки данных обычно имеется большой набор подобных плотностей вероятностей.

Затем проверяется гипотеза о том, что выбранная плотность вероятностей согласуется с выборочными значениями. Для этого считаются вероятности  $p_i$  попадания в каждый класс и по ним вычисляется величина

$$\chi^2 = \sum_{i=1}^k \frac{(n_i - np_i)^2}{np_i},$$

и полученное значение сравнивается с пороговым значением  $\chi^2_\alpha$ , найденным по таблицам критерия хи-квадрат по заданному уровню значимости  $\alpha_0$  и числу степеней свободы  $k - s - 1$ . Если будет выполнено неравенство  $\chi^2 \leq \chi^2_\alpha$ , то считается, что выборочные значения не противоречат выбранной плотности вероятностей и работу можно считать законченной. При выполнении противоположного неравенства приходится выравнивать к другой кривой.