

# Курс: Статистические Методы Обработки Данных

## Лекция 2. Оценки Параметров Распределений

*Специальность: 1-53 01 02 – Автоматизированные системы обработки информации*

*УО «ГГУ им. Ф. Скорины»*

*Преподаватель: Бабич К.С, ст. преподаватель, 2016*

# Раздел 2. Оценки Параметров Распределений

## 4. Точечные оценки

Пусть дана выборка объема  $n$ .

Точечная оценка для математического ожидания (центра распределения) дается выражением:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i ,$$

Для дисперсии  $D = \sigma^2$  такая оценка дается выражением:

$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 .$$

# Раздел 2. Оценки Параметров Распределений

## 4. Точечные оценки

Величины  $\bar{x}$ ,  $S$  сами являются случайными величинами, следовательно, они тоже могут иметь разброс, который характеризуется дисперсией.  
Для  $\bar{x}$ :

$$D[\bar{x}] = \frac{S^2}{n}$$

*Средне квадратичное отклонение среднего арифметического*

Для дисперсии:

$$D[S^2] = \frac{\mu_4}{n-1} - \frac{\sigma^4(n-3)}{n(n-1)},$$

где  $\mu_4$  – четвертый алгебраический, а  $\sigma$  – второй центральный моменты.

То есть:

$$D[S^2] = \sigma^4 \left[ \frac{\varepsilon}{n-1} - \frac{n-3}{n(n-1)} \right] = \frac{\sigma^4}{n-1} \left[ \varepsilon - \frac{n-3}{n} \right].$$

# Раздел 2. Оценки Параметров Распределений

## 4. Точечные оценки

Четвертый центральный момент можно рассчитать (приблизительно для больших  $n$ ) следующим образом:

$$\mu_4^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^4.$$

С учетом предыдущего выражения при  $n > 20$  с.к.о. будет задаваться выражением ( $n - 3 \approx n - 1$ ):

$$\sigma_\sigma = \sigma \frac{\sqrt{\varepsilon - 1}}{2\sqrt{n}}.$$

Тогда относительная ошибка для с.к.о.

$$\delta_\sigma = \frac{\sigma_\sigma}{\sigma} = \frac{\sqrt{\varepsilon - 1}}{2\sqrt{n}}$$

уже не зависит от самого с.к.о.  $\sigma$ .

# Раздел 2. Оценки Параметров Распределений

## 4. Точечные оценки

Таким образом точечные оценки:

Для среднего значения	Дисперсия этой оценки	Для ц. мом. к-го пор.
$\bar{x} = \sum_{i=1}^n \frac{x_i}{n}$	$\sigma_x^2 = \frac{S^2}{n}$	$\mu_k \approx \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^k$ $\mu_4 \approx \frac{1}{n} \sum (x_i - \bar{x})^4$
Для дисперсии $D = \sigma^2$	Дисперсия дисперсии	
$S^2 = \sigma^2 = \frac{1}{n-1} \sum (x_i - \bar{x})^2$	$\sigma_{S^2}^2 = \sigma^4 \left[ \frac{\epsilon}{n-1} - \frac{n-3}{n(n-1)} \right]$	

# Раздел 2. Оценки Параметров Распределений

## 4. Точечные оценки

Дисперсия для 4-го момента  $\mu_4$  для различных законов выражается разными формулами. Так, относительные погрешности для нормального распределения для контрэксцесса  $\kappa = \frac{1}{\sqrt{\epsilon}}$

$$\delta(\kappa) = \sqrt{\frac{2}{3n}}, \quad (\epsilon = 3, \kappa \approx 0,577)$$

для равномерного распределения

$$(\epsilon = 1,8, \kappa \approx 0,74), \quad \delta(\kappa) = \sqrt{\frac{32}{315n}}$$

и т.д.

Для многих распределений эту относительную погрешность (с точностью 8-10%) можно приблизительно описать:

$$\delta(\kappa) = \sqrt[n]{\frac{(\epsilon^2 - 1)^4}{\sqrt{29n}}}.$$

# Раздел 2. Оценки Параметров Распределений

## 4.(Часть 2) - Интервальные оценки

Точечные оценки параметров случайных величин не позволяют судить о степени близости выборочных значений к оцениваемому параметру. Более содержательны процедуры оценивания параметров, связанные с построением интервала с известной степенью доверительности. Для того, чтобы перейти к тому как найти эти доверительные интервалы, рассмотрим понятие квантиля распределения. Квантилем случайной величины  $x$  уровня значимости  $\alpha$  называется величина  $x_\alpha$ , для которой имеем:

$$P(x_\alpha) \equiv P_{\text{пов}}(x \leq x_\alpha) = \int_{-\infty}^{x_\alpha} p(x) dx = 1 - \alpha$$

или

$$P_{\text{пов}}(x > x_\alpha) = \int_{x_\alpha}^{\infty} p(x) dx = \alpha$$

Точка  $x_\alpha$  называется  $100 \times \alpha$ -процентной точкой распределения с плотностью распределения  $p(x)$ .

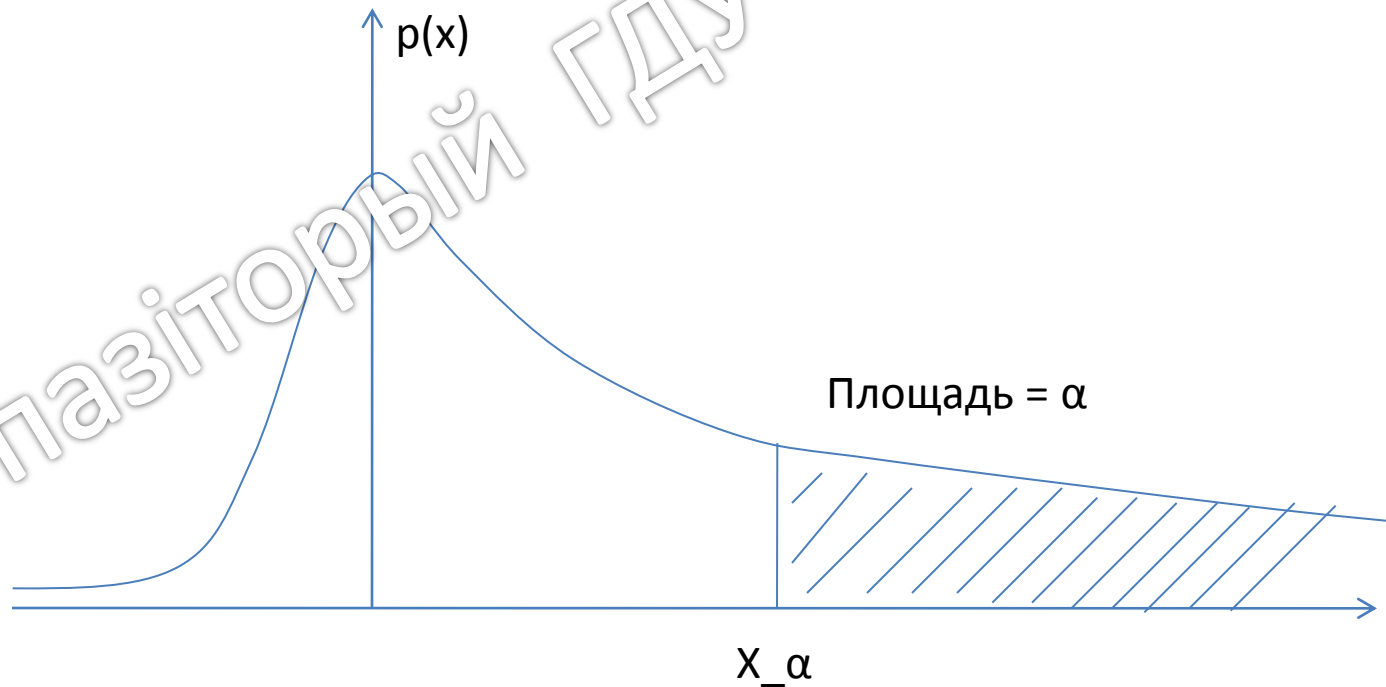
# Раздел 2. Оценки Параметров Распределений

## 4.(Часть 2) - Интервальные оценки

$$P(x_\alpha) = P_{\text{пов}}(x \leq x_\alpha) = \int_{-\infty}^{x_\alpha} p(x) dx = 1 - \alpha$$

или

$$P_{\text{пов}}(x > x_\alpha) = \int_{x_\alpha}^{\infty} p(x) dx = \alpha$$





# Раздел 2. Оценки Параметров Распределений

## 4.(Часть 2) - Интервальные оценки

Доверительный интервал для м.о.  $\mu_1$ .

$$\left[ \bar{x} - \frac{S t_{N,\alpha/2}}{\sqrt{n}} \leq \mu_1 \leq \bar{x} + \frac{S t_{N,\alpha/2}}{\sqrt{n}} \right], \quad N = n - 1$$

$t_{N,\alpha}$  определяется соотношением:

$$\int_{t_{n,\alpha}}^{\infty} p(t) dt = \alpha,$$

где

$$p(t) = \frac{\Gamma\left(\frac{n+1}{2}\right)}{\sqrt{\pi n} \Gamma\left(\frac{n}{2}\right)} \left[ 1 + \frac{t^2}{n} \right]^{-\frac{n+1}{2}}$$

распределение с  $n$  степенями свободы (распределение Стьюдента).  
Коэффициенты  $t_{N,\alpha/2}$  носят название коэффициентов Стьюдента.

*У.С. Госсет (1876 – 1937)*

# Раздел 2. Оценки Параметров Распределений

## 4.(Часть 2) - Интервальные оценки

Для дисперсии  $\sigma$

$$\left[ \frac{nS^2}{\chi_{N;\alpha/2}^2} \leq \sigma_x < \frac{nS^2}{\chi_{N;-\alpha/2}^2} \right], \quad N = n - 1$$

$\chi_{n;\alpha}^2$  - квантиль распределения  $\chi^2$ .

$$\int_{\chi_{n;\alpha}^2}^{\infty} P(\chi^2) d\chi^2 = \alpha$$

и

$$P(\chi^2) = \frac{(\chi^2)^{(\frac{n}{2}-1)} e^{-\frac{\chi^2}{2}}}{2^{\frac{n}{2}} \Gamma(\frac{n}{2})}, \quad (\chi^2 > 0) -$$

распределение  $\chi^2$ .

Значения  $\mu_1$  и  $\sigma$  лежат в интервале с доверительной вероятностью  $1 - \alpha$ .

## Раздел 2. Оценки Параметров Распределений

### Выбор доверительных интервалов

Сделаем несколько замечаний относительно доверительных интервалов.

Какую вероятность необходимо выбрать в зависимости от числа измерений  $n$ . Дело в том, что при очень малом ( $n \leq 30$ )  $\bar{x}$ ,  $S$ , входящие в формулы доверительных интервалов будут иметь сами, как случайные величины большой разброс, поэтому оценки с помощью квантилей будут иметь лишь небольшую доверительную вероятность  $1 - \alpha$ . На этот вопрос можно ответить следующим образом:

# Раздел 2. Оценки Параметров Распределений

## Выбор доверительных интервалов

1) Пусть имеем  $n$  значений случайной величины  $x$ :  $x_1, x_2, \dots, x_n$ , которые распределены в порядке возрастания  $x_1 \leq x_2 \leq x_3 \leq \dots \leq x_n$ .

2) Разобьём весь интервал вероятностей  $[0, 1]$  на  $n + 1$  интервалов с равными значениями вероятности т.е. вероятности попадания в каждый интервал  $]-\infty, x_1[$   $[x_1, x_2[$   $\dots$   $[x_n, +\infty[$  одинакова т.е.  $\frac{1}{n+1}$ ,  $x_n - \frac{1}{n+1}$  100% - квантили.

3) Если отбросим два крайних слева и справа интервала, оценка величины может быть определена с доверительной вероятностью

$$P_D \leq \frac{n-1}{n+1}.$$

## Раздел 2. Оценки Параметров Распределений

### Выбор доверительных интервалов

4) На практике отбрасывается еще  $n_{sp}$  с каждого края. Тогда

$$P_D \leq \frac{(n - 1 - n_{sp})}{n + 1}.$$

Тогда имеем:

$$n \geq (1 + P_D + 2n_{sp}) / (1 - P_D), \quad n_{sp} = 1$$

$P_D$	0,8	0,9	0,95	0,98	0,99	0,995	0,997
$n$	20	40	80	200	400	800	1333

## Раздел 2. Оценки Параметров Распределений

### Выбор доверительных интервалов

$P_D$	0,8	0,9	0,95	0,98	0,99	0,995	0,997
$n$	20	40	80	200	400	800	1333

Таким образом, по экспериментальным данным легко найти доверительный интервал лишь с доверительной вероятностью 0,95 ( $n \approx 80$ ), а более высокое  $P_D$  практически трудно допустимо.

Отметим, что выше указанные рассуждения говорят лишь о верхней границе т.е. взяв  $n = 80$  мы получим, что доверительная вероятность не может быть большей, чем 0.95, (однако нет оснований утверждать, что обязательно она должна быть равна 0.95).