

Основные понятия математической статистики: оценки параметров распределения, проверка гипотез, системы случайных величин: корреляция, регрессия

Лекция 17

Способы организации выборки

1. **Вариационный ряд** – элементы выборки упорядочивают по величине: $x^{(1)} < x^{(2)} < \dots < x^{(n)}$ \longrightarrow $x^{(1)} = \min \{x_n\}$
 $x^{(n)} = \max \{x_n\}$

2. **Размах выборки** - разность между максимальным и минимальным элементами выборки $w = x^{(n)} - x^{(1)}$

3. Пусть выборка содержит k различных элементов.

Частота элемента выборки n_i - число раз, которые данный элемент встречается в выборке

4. **Мода** – элемент выборки с наибольшей частотой

5. **Статистический ряд** – таблица: $\{x_i \rightarrow n_i\}$

			
			...	

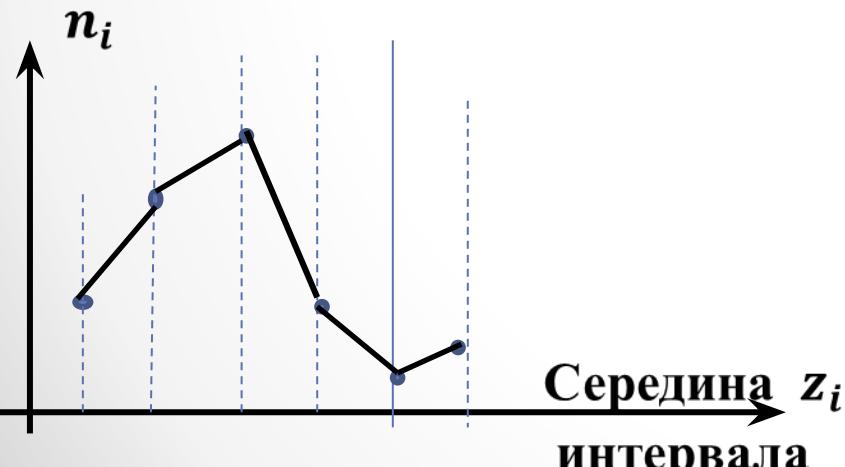
$$\sum_{i=1}^k n_i = n$$

**сумма частот всех элементов
равна объему выборки**

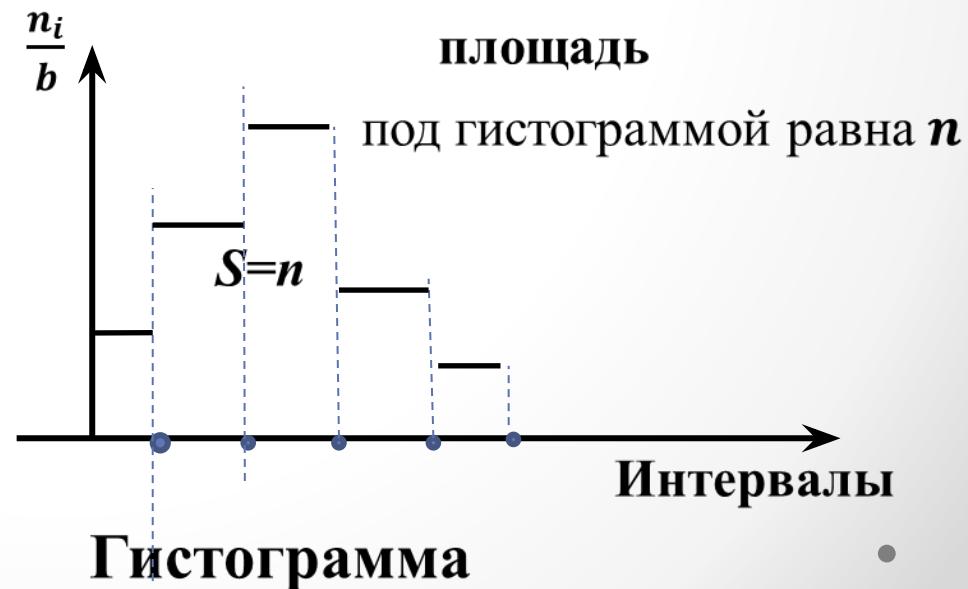
Способы описания выборки

При **большом** объеме выборки ее элементы объединяют в группы (разряды, карманы): **выбирают ширину** интервала $b = \frac{w}{k}$, где $k \approx \sqrt{n}$, или $b = \frac{w}{1+3,2\lg n}$, **а частота** n_i - количество элементов выборки, попавшее в i -й интервал (элемент, совпадающий с внешней границей интервала считают в последующем). Кроме того вычисляю **середину каждого интервала** $z_i = \frac{x_i+x_{i+1}}{2}$ и **относительную частоту** $\frac{n_i}{n}$ - *оценку вероятности* попадания значения случайной величины в данный интервал : $\sum_{i=1}^k \frac{n_i}{n} = 1$ (Образец табл. Стр. 181).

Графическое представление – полигон частот (или относительных частот) и **гистограмма** – статистические аналоги функции распределения $f(x)$



Полигон частот



Числовые характеристики выборки

Выборочное среднее $\bar{x} = \frac{\sum_{i=1}^n x_i}{n}$ или $\bar{x} = \frac{\sum_{i=1}^r n_i x_i}{n}$

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

Для выборок малого объема ($n < 30$) вводят исправленную дисперсию

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

Пример. Для выборки из 5 чисел 3, 5, 5, 8, 4 получаем

$$\bar{x} = \frac{3+5+5+8+4}{5} = 5; \quad \tilde{S}^2 = \frac{(3-5)^2 + (5-5)^2 + (5-5)^2 + (8-5)^2 + (4-5)^2}{4} = 3,5$$

- Excel надстройки «Пакет анализа» Описательная статистика

- Среднее 5

- Стандартная ошибка 0,836660027 $\varepsilon_1 = \frac{s}{\sqrt{n}}$

- Медиана 5

- Мода 5

- Стандартное отклонение 1,870828693 S

- Дисперсия выборки 3,5 S^2

- Эксцесс 2

- Асимметричность 1,145405322

- Интервал 5

- Минимум 3

- Максимум 8

- Сумма 25

- Счет 5

- Уровень надежности(95,0%) 2,322940635 - $\varepsilon = \frac{s}{\sqrt{n}} t_{0,05}(n-1)$

Статистическое оценивание. Точечные оценки

Точечной оценкой $\tilde{\Theta}$ неизвестного параметра Θ называют приближенное значение этого параметра, полученное по выборке $\tilde{\Theta} = \tilde{\Theta}(x_1, x_2, \dots, x_n)$ или «*статистика*».

Качество оценок.

1. Состоятельность. Оценка параметра сходится по вероятности к самому параметру при $n \rightarrow \infty$ $\lim_{n \rightarrow \infty} P(|\tilde{\Theta}_n - \Theta| < \varepsilon) = 1$.

Или чем больше объем выборки, тем точнее оценка

Пример. $M[X] = \bar{x}$ выборочное среднее – состоятельная оценка математического ожидания (теорема Чебышева)

2. Несмешенность. Математическое ожидание оценки параметра равно самому параметру : $M[\tilde{\Theta}] = \Theta$. **Пример 1.** Выборочное среднее является несмешенной оценкой математического ожидания. **Пример 2.** Выборочная дисперсия $S^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}$ является смещенной оценкой ($M[S^2] = \frac{n}{n-1} S^2$), а оценка $\tilde{S}^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}$ является несмешенной

3. Эффективность. Оценка должна обладать наименьшей дисперсией

Интервальные оценки. Уровень значимости

Интервальные оценки или. доверительные интервалы вводятся с целью определения *точности оценки*.

Доверительным интервалом для параметра Θ называют интервал (θ_1, θ_2) , содержащий истинное значение параметра с заданной вероятностью $P = 1 - \alpha$:

$$P(\theta_1 < \theta < \theta_2) = 1 - \alpha.$$

(1 - α) – доверительная вероятность;

α – число - вероятность , которую называют уровнем значимости, характеризует точность оценивания. Обычно выбирают α = 0,1; 0,05

Пример. Доверительный интервал для математического ожидания при неизвестной заранее дисперсии:

$$P(\bar{x} - \varepsilon < M[X] < \bar{x} + \varepsilon) = 1 - \alpha, \quad \text{где } \varepsilon = \frac{s}{\sqrt{n}} t_{1-\frac{\alpha}{2}}(n-1)$$

•Число $t_{1-\frac{\alpha}{2}}(n-1)$ - квантиль распределения Стьюдента находим по статистическим таблицам или в Excel (функции→ статистические → Стьюдентраспбр)

Чем больше уровень значимости, тем выше точность оценивания

Проверка статистических гипотез

Статистическая гипотеза H – это предположение относительно параметров или вида распределения (проверяемая гипотеза называется нулевой):

Пример 1. $H_0: M[X] = m \rightarrow H_1: M[X] \neq m$ (альтернативная гипотеза)

Пример 2. H_0 : случайная величина распределена по нормальному закону

H_1 : случайная величина не распределена поциальному закону

Критерий - правило, согласно которому принимается решение принять или отвергнуть нулевую гипотезу.

Перед проверкой задается **малая вероятность α – уровень значимости**, которая определяет размер **критической области V_k статистики критерия Z** .

Если выборочное значение статистики критерия попадает в критическую область $Z_{\text{выб}} \in V_k$, гипотеза H_0 отклоняется, то есть α – вероятность совершиить ошибку, отвергнув правильную гипотезу.

О достоверности выводов, полученных при заданном уровне значимости:

$\alpha \geq 0,1$ **высокий** уровень значимости \rightarrow данные согласуются с H_0

$\alpha = 0,05$ значимость H_0 возможна, но есть сомнения в истинности

$\alpha = 0,02$ имеют место сильные доводы против H_0

$\alpha \leq 0,01$ основная гипотеза H_0 наверняка ложная

Выборочный коэффициент корреляции. Оценка

Для системы случайных величин $\{X, Y\}$ вводится характеристика – **ковариация (корреляционный момент)**:

$$\text{cov}[X, Y] = K_{XY} = M[(X - M[X])(Y - M[Y])] = M[XY] - M[X]M[Y]$$

Для независимых X, Y ковариация $\text{cov}[X, Y] = 0$.

Коэффициент корреляции $r_{XY} = \frac{K_{XY}}{\sigma_X \sigma_Y}$ - безразмерный коэффициент, который определяет степень линейной корреляционной зависимости между случайными величинами.

Свойства r_{XY} : 1) если $Y = AX + B$, то $|r_{XY}| = 1$

2) $|r_{XY}| \leq 1$ 3) если $r_{XY} = 0$, то случайные величины X, Y

называют **некоррелированными**. Независимые случайные величины являются некоррелированными.

Оценкой коэффициента корреляции является выборочный

$$\text{коэффициент корреляции } \widetilde{r}_{XY} = \frac{\sum_{k=1}^n (x_k - \bar{x})(y_k - \bar{y})}{\sqrt{\sum_{k=1}^n (x_k - \bar{x})^2 \sum_{k=1}^n (y_k - \bar{y})^2}}$$

Excel функции статистические корреляция

Регрессионные модели

Пусть коэффициент корреляции между двумя случайными величинами **значимо отличается от нуля и близок к единице.**

Выдвигаем гипотезу: случайные величины связаны линейной корреляционной зависимостью $Y = AX + B + \varepsilon$

Это уравнение называют **уравнением линейной регрессии.**

Регрессия – оптимальная зависимость, которая обеспечивает аппроксимацию опытных данных с наибольшей точностью, то есть с минимальной случайной ошибкой ε . Наилучшие оценки для коэффициентов регрессии A , B получают по методу **наименьших квадратов** :

$$S(\tilde{A}, \tilde{B}) = \sum_{k=1}^n (y_k - (\tilde{A}x_k + \tilde{B}))^2 - \min$$

Excel → **точечная диаграмма** → **линия тренда с указанием уравнения и качества аппроксимации** - коэффициент детерминации $R^2 = \frac{\sum_{k=1}^n ((\tilde{A}x_k + \tilde{B}) - \bar{y})^2}{\sum_{k=1}^n (y_k - \bar{y})^2}$

(правой кнопкой на точку). На заключительной стадии обязательно проверяют **статистическую значимость** (можно доказать , что в доверительный интервал для коэффициента A не содержит $A = 0$) и **адекватность модели** (случайные ошибки наблюдений – остатки распределены с нулевым средним $\bar{\varepsilon} = 0$).

Excel «Анализ данных» Регрессия