



Лекция 2.

**ЭЛЕМЕНТЫ
МАТЕМАТИЧЕСКОЙ
СТАТИСТИКИ**

ПРЕДМЕТ:

Анализ
экспериментальных
данных –
значений количествен-
ного признака
(артериальное давление,
пульс).

Такой признак –
случайная
величина.

ЗАДАЧА:

изучить законы
распределения иссле-
дуемых случайных
величин,
их характеристики,
проверить ряд
гипотез,
установить, есть ли
между величинами
связь.

Часть I.

**БАЗОВЫЕ ПОНЯТИЯ
МАТЕМАТИЧЕСКОЙ
СТАТИСТИКИ**

1. ПОНЯТИЯ ГЕНЕРАЛЬНОЙ СОВОКУПНОСТИ И ВЫБОРКИ

- **ГЕНЕРАЛЬНАЯ СОВОКУПНОСТЬ** – ВСЕ МНОЖЕСТВО ОБЪЕКТОВ, ОБЛАДАЮЩИХ ДАННЫМ ПРИЗНАКОМ.
- **ВЫБОРКА** – ЧАСТЬ ГЕНЕРАЛЬНОЙ СОВОКУПНОСТИ.

- **ЭЛЕМЕНТЫ ВЫБОРКИ** – значения изучаемого признака у входящих в выборку объектов.
- **ОБЪЕМ ВЫБОРКИ n** – число элементов в ней.
- **ВАРИАНТЫ** – отличающиеся друг от друга, различные элементы выборки.

РЕПРЕЗЕНТАТИВНАЯ ВЫБОРКА

Чтобы по выборке можно было судить о генеральной совокупности, выборка должна быть **РЕПРЕЗЕНТАТИВНОЙ**.

РЕПРЕЗЕНТАТИВНОЙ называется выборка, верно отражающая основные закономерности генеральной совокупности.

Условия репрезентативности:

- случайный отбор
- достаточно большой объем

2. СПОСОБЫ ПРЕДСТАВЛЕНИЯ ВЫБОРКИ

- **ПРОСТОЙ
СТАТИСТИЧЕСКИЙ
РЯД**
- **РАНЖИРОВАННЫЙ
РЯД**
- **ВАРИАЦИОННЫЙ
РЯД**
- **ИНТЕРВАЛЬНЫЙ
РЯД**

**ПРОСТОЙ
СТАТИСТИЧЕСКИЙ
РЯД –**

**ПЕРЕЧИСЛЕНИЕ
ЭЛЕМЕНТОВ
ВЫБОРКИ
В ПОРЯДКЕ ИХ
ПОЛУЧЕНИЯ.**

ПОСТРОЕНИЕ РАНЖИРОВАННОГО И ВАРИАЦИОННОГО РЯДОВ

**РАНЖИРОВАННЫЙ
РЯД –
ПЕРЕЧИСЛЕНИЕ
ЭЛЕМЕНТОВ
ВЫБОРКИ В ПОРЯДКЕ
ИХ ВОЗРАСТАНИЯ
(ИЛИ УБЫВАНИЯ).**

**При этом каждое
значение повторяется
столько раз, сколько
оно встречается в
выборке.**

**Число появлений
данного значения, т.е.
варианты, в выборке
называется частотой
этой варианты, **n**.**

**Отношение частоты
к объему выборки
называется
относительной
частотой варианты,
 $W = n / N$.**

ВАРИАЦИОННЫЙ РЯД

ВАРИАЦИОННЫЙ РЯД –
ПЕРЕЧИСЛЕНИЕ
ВАРИАНТ
В ПОРЯДКЕ ИХ
ВОЗРАСТАНИЯ
(ИЛИ УБЫВАННЯ)
С УКАЗАНИЕМ
СООТВЕТСТВУЮЩИХ
ЧАСТОТ
ИЛИ ОТНОСИТЕЛЬНЫХ
ЧАСТОТ.

Таблица
вариационного ряда
напоминает ряд
распределения ДСВ.

Графическим
изображением
вариационного ряда
является *ПОЛИГОН*.

ТАБЛИЦА ВАРИАЦИОННОГО РЯДА

x_i	x_1	x_2	...	x_k
n_i	n_1	n_2	...	n_k
W_i	W_1	W_2	...	W_k

$$x_1 < x_2 < \dots < x_k$$

$$n_1 + n_2 + \dots + n_k = N$$

$W_1 + W_2 + \dots + W_k = 1$,
проявление УСЛОВИЯ НОРМИРОВКИ
в статистике.

ПОЛИГОН ЧАСТОТ или ОТНОСИТЕЛЬНЫХ ЧАСТОТ

- На оси абсцисс - значения x_i ,
на оси ординат - частоты n_i или
относительные частоты W_i .
- Точки с координатами (x_i, n_i) соединяются
отрезками прямых.

Полученная ломаная – полигон.

ПОСТРОЕНИЕ ИНТЕРВАЛЬНОГО РЯДА

**ЕСЛИ ОБЪЕМ ВЫБОРКИ
ВЕЛИК,
ВАРИАЦИОННЫЙ РЯД
ПРЕОБРАЗУЮТ
В ИНТЕРВАЛЬНЫЙ.**

**В этом случае не пере-
числяются все варианты,
а разбивают вариацион-
ный ряд на несколько
интервалов и указывают
число значений
в каждом из них.**

№ интер- вала, k	Грани- цы ин- тервала	Час- тота, n
1		
2		
...		
m		

Алгоритм построения интервального ряда

1. Определение разумного числа интервалов:

$$m = \log_2 N,$$

округляем до целого числа.

2. Размах распределения:

$$L = x_{\max} - x_{\min}.$$

3. Шаг разбиения, или ширина интервала:

$$h = \Delta x = L / m =$$

$$= \frac{x_{\max} - x_{\min}}{m}$$

4. Границы интервалов:

получаются добавлением шага к предыдущей границе. Граница может входить только в один интервал, предыдущий или последующий.

- [- граница включается в данный интервал;
- (- граница не включается в интервал.

5. Подсчет частоты n - числа значений, попавших в данный интервал, и относительной частоты

$$W = n / N.$$

ГИСТОГРАММА

Графическое изображение интервального ряда – **ГИСТОГРАММА**: фигура, состоящая из прямоугольников. Основание каждого прямоугольника - соответствующий интервал, высота равна частоте или относительной частоте.

Пример.

У 12 больных гриппом, прошедших предварительно вакцинацию, измерили температуру в первые сутки болезни.

Получены значения – простой статистический ряд:

37,5; 39,0; 38,1; 38,4; 37,9; 38,4;
38,4; 38,1; 38,6; 38,4; 38,6; 38,4.

Ранжированный ряд:

37,5; 37,9; 38,1; 38,1; 38,4; 38,4;
38,4; 38,4; 38,4; 38,6; 38,6; 39,0.

Вариационный ряд:

x_i	37,5	37,9	38,1	38,4	38,6	39,0
n_i	1	1	2	5	2	1
w_i	1/12	1/12	2/12	5/12	2/12	1/12

ИНТЕРВАЛЬНЫЙ РЯД:

$$m = \log_2 12 \approx 3;$$

$$L = 39,0 - 37,5 = 1,5;$$

$$\Delta x = 1,5 / 3 = 0,5.$$

Определяем границы первого интервала:

левая граница – $x_{\min} = 37,5$,

правая граница - $x_{\min} + 0,5 = 38,0$.

Левую границу включаем в первый интервал, правую – нет.

С нее начнется второй интервал.

Таблица интервального ряда

№ интервала, k	Границы интервала	Частота, n_k	Относит. частота, W_k
1	[37,5; 38,0)	2	$2/12 = 1/6$
2	[38,0; 38,5)	7	$7/12$
3	[38,5; 39,0]	3	$3/12$

3. ХАРАКТЕРИСТИКИ ВЫБОРКИ

- Средняя выборочная \bar{X}
- Выборочная дисперсия $D_B = \sigma_B^2$
- Выборочное средне-квадратическое отклонение σ_B
- *Мода* M_o
- *Медиана* M_e

СРЕДНЯЯ ВЫБОРОЧНАЯ

вариационного ряда:

$$\bar{X} = \frac{\sum x_i n_i}{N}$$

Если все $n_i = 1$, то

$$\bar{X} = \frac{\sum x_i}{N}$$

интервального ряда:

$$\bar{x}_и = \frac{\sum c_k n_k}{N}$$

Здесь c_k – середины интервалов:

$$c_k = (a + b) / 2 = a + \Delta x / 2$$

(a - левая граница интервала,
 b - правая граница интервала).

Иными словами, при вычислении характеристик интервального ряда его заменяют (приблизленно) на вариационный вида:

c_k	c_1	c_2	...	c_m
n_k	n_1	n_2	...	n_m

ВЫБОРОЧНАЯ ДИСПЕРСИЯ

вариационного ряда:

$$\sigma^2_{\text{в}} = \frac{\sum (x_i - \bar{x})^2 n_i}{N}$$

Если все $n_i = 1$, то

$$\sigma^2_{\text{в}} = \frac{\sum (x_i - \bar{x})^2}{N}$$

интервального ряда:

$$\sigma^2_{\text{в}} = \frac{\sum (c_k - \bar{x}_и)^2 n_k}{N}$$

**ВЫБОРОЧНОЕ
СРЕДНЕКВАДРАТИЧНОЕ
ОТКЛОНЕНИЕ**

$$\sigma_{\text{в}} = \sqrt{\sigma^2_{\text{в}}}$$

МОДА, МЕДИАНА

- **МОДА** – варианта с наибольшей частотой.
- **МЕДИАНА** делит вариационный ряд пополам: слева от нее столько же элементов, сколько справа.

В случае четного числа элементов медиана равна среднему арифметическому двух центральных. Определяется легко по ранжированному ряду.

В нашем примере
 $Mo = Me = 38,4.$

4. ТОЧЕЧНЫЕ ОЦЕНКИ ПАРАМЕТРОВ ГЕНЕРАЛЬНОЙ СОВОКУПНОСТИ ПО ПАРАМЕТРАМ ВЫБОРКИ

ПАРАМЕТРЫ
ГЕНЕРАЛЬНОЙ
СОВОКУПНОСТИ –
числовые
характеристики
исследуемой СВ:

- математическое ожидание (средняя генеральная, средняя теоретическая) μ
- дисперсия σ^2
- среднеквадратическое отклонение σ

ИХ ТОЧЕЧНЫЕ ОЦЕНКИ -
НАИБОЛЕЕ БЛИЗКИЕ
К НИМ (согласно теории)
ПАРАМЕТРЫ ВЫБОРКИ.

А именно:

- точечная оценка
средней
теоретической –
средняя выборочная,

$$\mu \approx \bar{x}$$

Точечные оценки

- генеральной дисперсии – *исправленная дисперсия, s^2* :

$$\sigma^2 \approx s^2$$

- среднеквадратичного отклонения – *стандартное отклонение, s* :

$$\sigma \approx s$$

Чтобы «исправить» выборочную дисперсию, нужно ввести поправочный коэффициент:

$$s^2 = \sigma^2_{\text{в}} \cdot \frac{N}{N-1}$$

Таким образом,

$$s^2 = \frac{\sum (x_i - \bar{x})^2 n_i}{N - 1}$$

$$s^2_{и} = \frac{\sum (c_k - \bar{x}_{и})^2 n_k}{N - 1}$$

Далее $s = \sqrt{s^2}$

Обратите внимание:
точечные оценки –
приблизительные

и

случайные

(так как выборка сделана из генеральной совокупности случайным образом, то ее элементы и параметры можно считать случайными величинами)

5. ИНТЕРВАЛЬНЫЕ ОЦЕНКИ ПАРАМЕТРОВ ГЕНЕРАЛЬНОЙ СОВОКУПНОСТИ

Дать

***ИНТЕРВАЛЬНУЮ
ОЦЕНКУ***

того или иного параметра генеральной совокупности –

значит указать

случайный интервал, который с заданной

вероятностью γ (гамма) содержит данный параметр.

Этот интервал называется ***ДОВЕРИТЕЛЬНЫМ***, а γ – ***ДОВЕРИТЕЛЬНОЙ ВЕРОЯТНОСТЬЮ***, или ***НАДЕЖНОСТЬЮ***.

Наряду с доверительной
вероятностью
используют также понятие
УРОВЕНЬ ЗНАЧИМОСТИ

$$\beta = 1 - \gamma,$$

т.е. вероятность того,
что доверительный интервал ***НЕ***
содержит в себе оцениваемый
параметр.

Доверительный интервал для средней теоретической нормально распределенной величины

Имеет вид

$$(\bar{x} - \Delta, \bar{x} + \Delta).$$

Здесь Δ – абсолютная
погрешность

интервальной оценки μ
по средней выборочной
 \bar{x} .

Но называть ее принято
ТОЧНОСТЬЮ оценки.

В данном случае
надежность

$$\gamma = P(\bar{x} - \Delta < \mu < \bar{x} + \Delta)$$

- вероятность того, что
доверительный
интервал будет
содержать в себе
среднюю
теоретическую.

Доверительную
вероятность задаем
сами,
обычно в медицине это
95%,
то есть $\gamma = 0,95$.

Точность Δ
рассчитывается по
формуле:

$$\Delta = \frac{ts}{\sqrt{N}}$$

Среднюю выборочную и
стандартное отклонение
находим по выборке.

t определяется по надежности γ с помощью известной формулы теории вероятности:

$$\gamma = 2\Phi(t) - 1.$$

Отсюда

$$2\Phi(t) = 1 + \gamma,$$

$$\Phi(t) = \frac{1 + \gamma}{2}$$

Зная $\Phi(t)$, по таблицам нормального распределения находим t .

Так,

если $\gamma = 0,95$, то
 $\Phi(t) = 0,975$
и $t \approx 2$.

Если объем выборки невелик, то вместо таблицы нормального распределения нужно воспользоваться таблицей

РАСПРЕДЕЛЕНИЯ СТЬЮДЕНТА.

Значение t в таблице этого распределения находят по заданным N и γ .

Запишем

АЛГОРИТМ

построения доверительного интервала для средней теоретической нормально распределенной величины.

1. Вычислить \bar{x} и s .
2. По заданной γ рассчитать $\Phi(t)$.
3. По значению $\Phi(t)$ в таблице найти значение t .
4. Рассчитать точность Δ оценки μ по \bar{x} .

5. Записать ответ в виде:

$$\bar{x} - \Delta < \mu < \bar{x} + \Delta.$$

Возможна краткая запись

$$\mu = \bar{x} \pm \Delta$$

ОПРЕДЕЛЕНИЕ МИНИМАЛЬНОГО ОБЪЕМА ВЫБОРКИ,

необходимого для достижения заданной точности
с заданной надежностью

Итак, известны γ (и t)
и Δ ,
а найти надо N .

Пользуемся формулой:

$$\Delta = \frac{ts}{\sqrt{N}}$$

Отсюда:

$$\sqrt{N} = \frac{ts}{\Delta}$$

и

$$N = \frac{t^2 s^2}{\Delta^2}$$

Округлить до
ближайшего большего
целого!