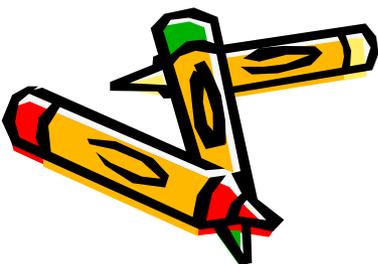
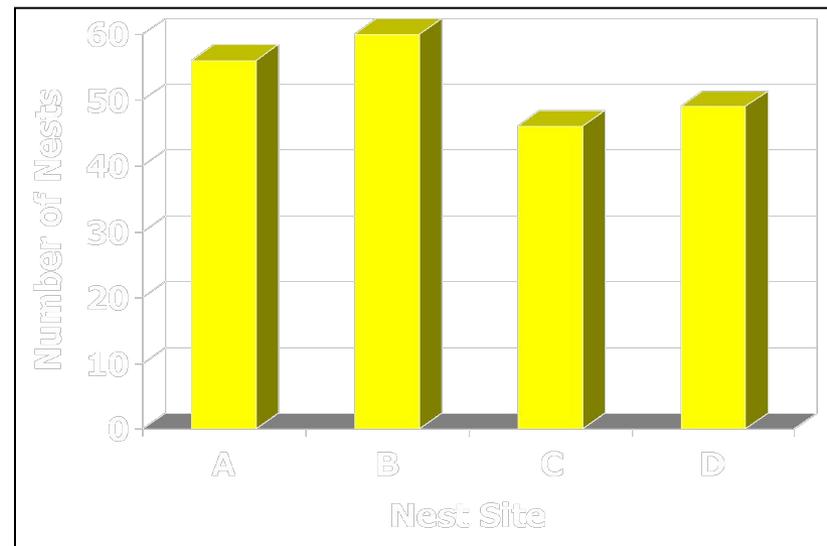
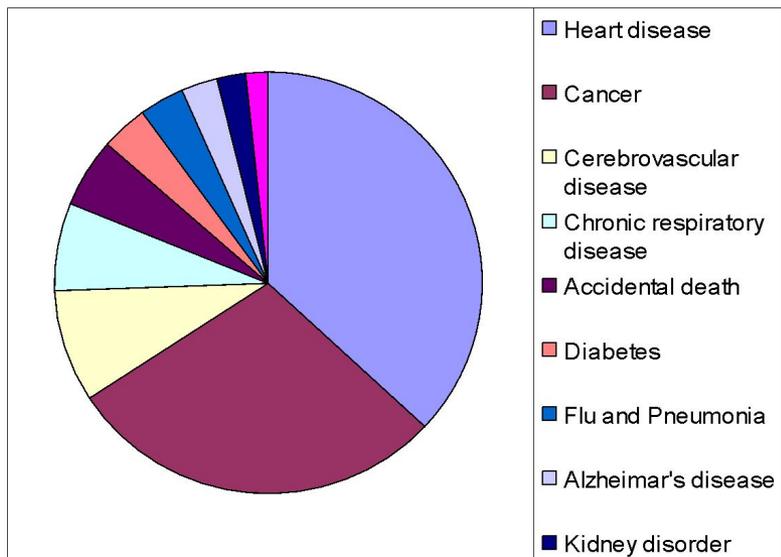
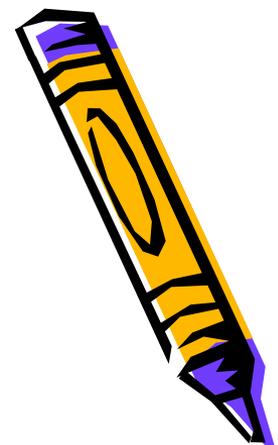


## ЛЕКЦИЯ 2



# ОПИСАТЕЛЬНАЯ СТАТИСТИКА

# 2.1. Группировка данных



Обработку данных полезно  
начать с их *группировки...*

**Группировка - это систематизация  
первичных данных, направленная  
на *извлечение заключенной в них  
информации и выявление  
закономерностей*, которым  
подчиняется изучаемое явление  
или объект.**

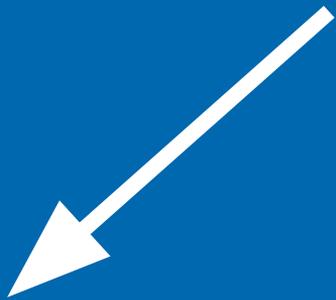
# Пример: медицинские сведения

- Пол (м, ж)
- Возраст (полных лет)
- Группа крови (I, II, III, IV)
- Систолическое давление (мм рт.ст.)
- Курильщик (да, нет)
- Рост (см)
- Вес (кг)
- ...

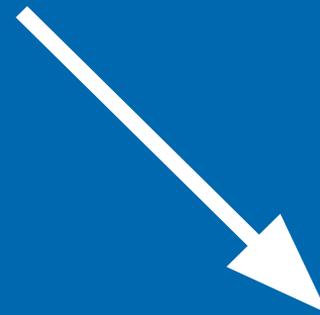
**Качественные переменные** – определяется принадлежность объекта к одной из нескольких категорий

**Количественные (непрерывные, дискретные)** – дают числовую величину; к ним применяют арифметические действия

# Группировка количественных данных :




**по значениям  
вариант**



**по классам**

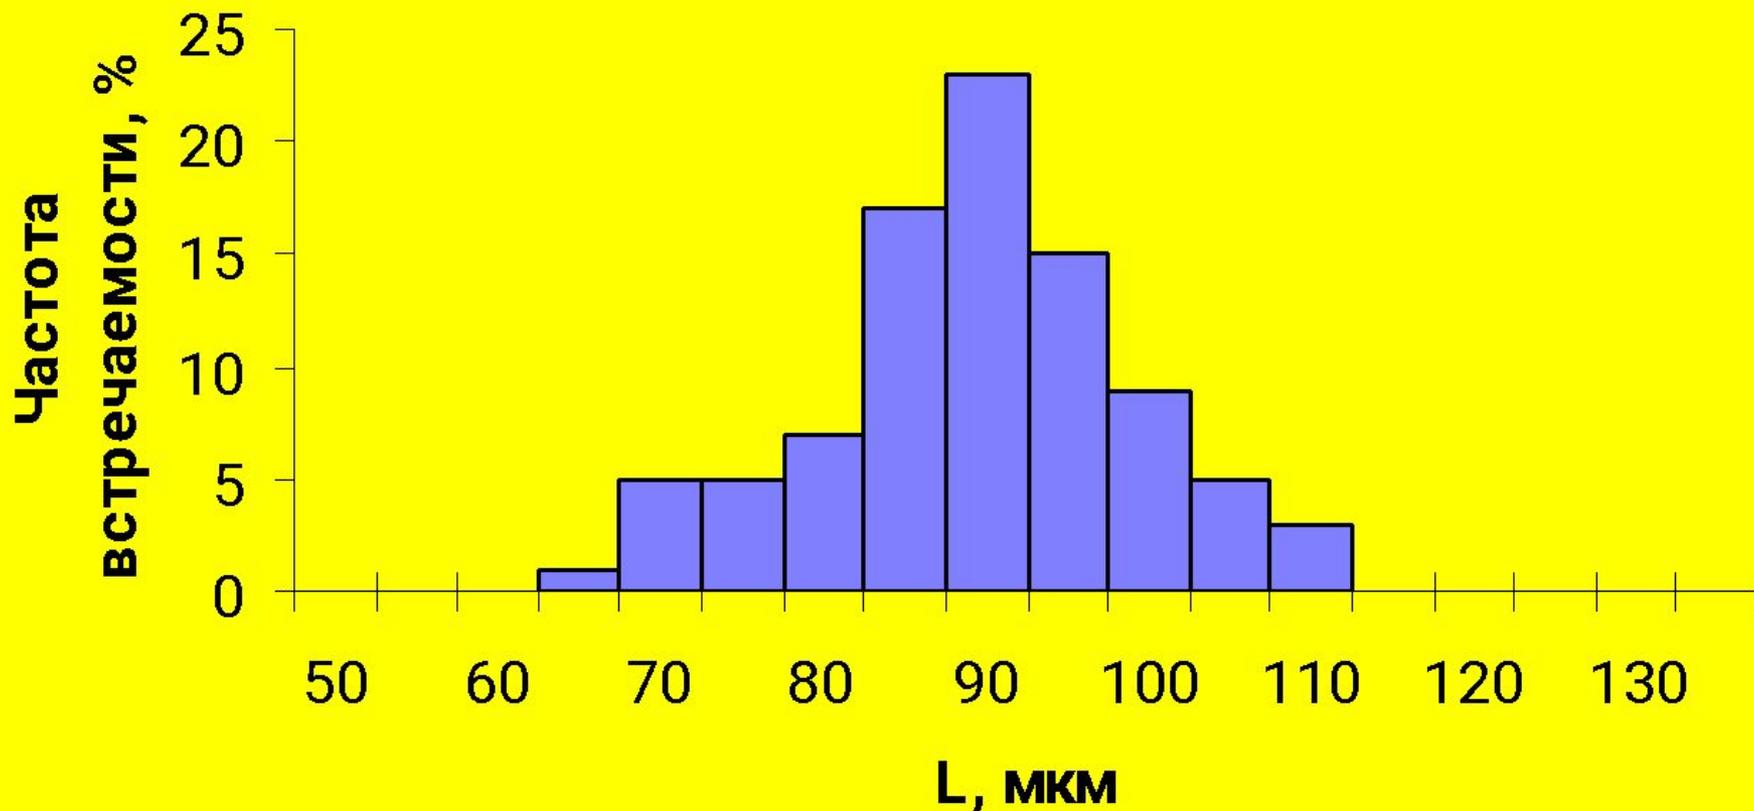
Представление частотного распределения графически

При небольшом  $n$  и незначительной вариации признака, количественные данные группируют по значениям вариантов (полигон распределения)



# Гистограмма: данные группируются по классам

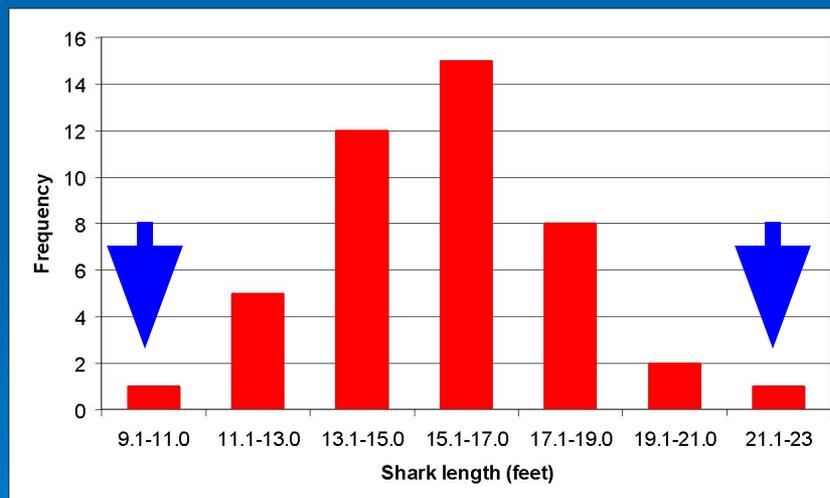
Распределение данных о длине клеток инфузории *Conchophthirus acuminatus*



# Какую информацию дает вариационный ряд и его график?

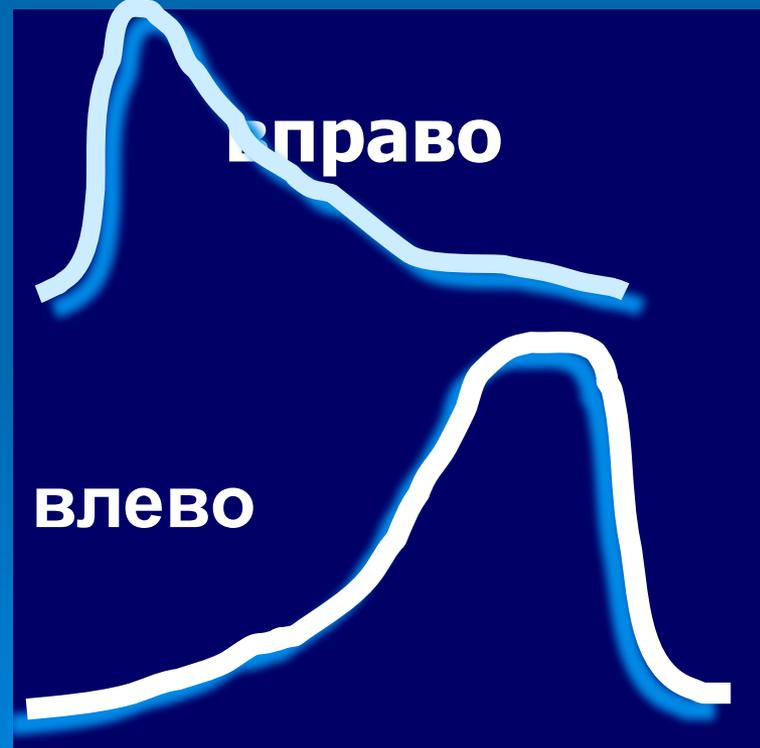
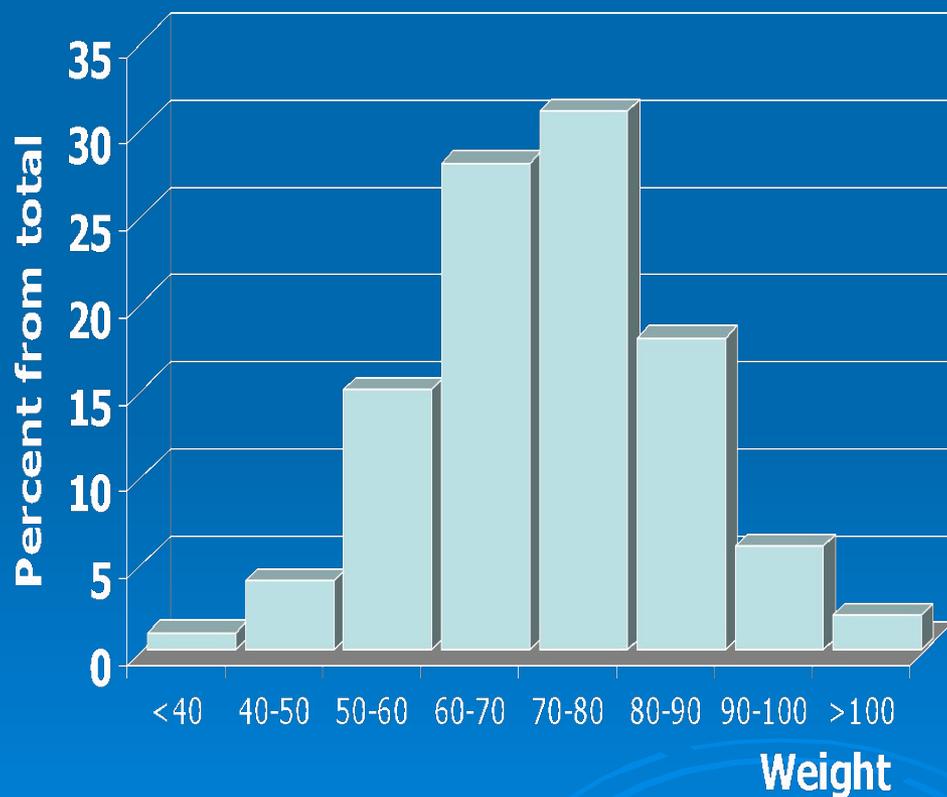
- ▣ Границы изменчивости признака: минимальное и максимальное значение вариант, или **лимиты**.

				
$(x_i)$ :	2	3	4	5
$(f_i)$ :	1	2	5	2



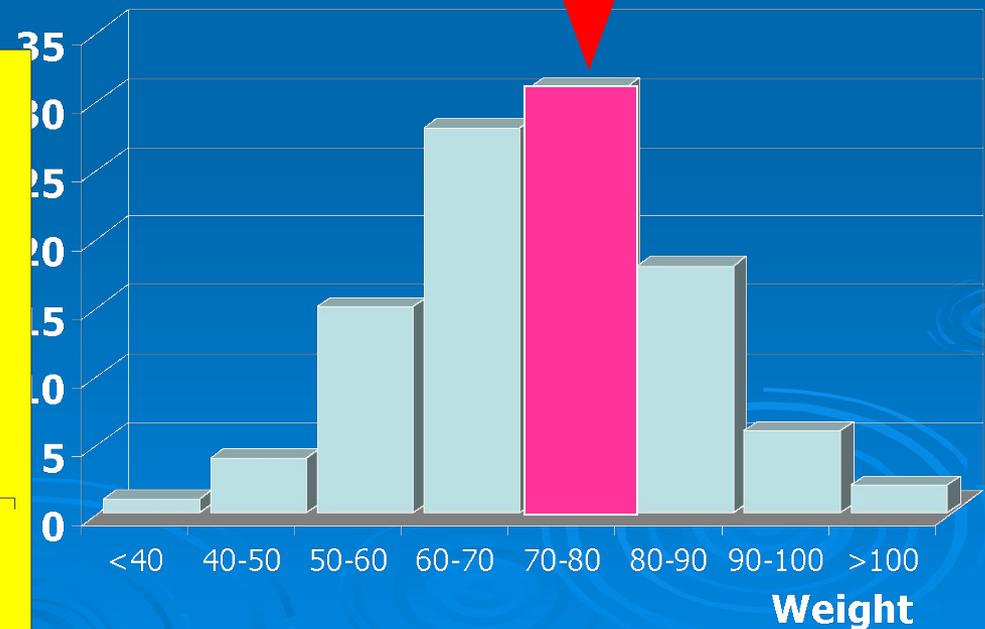
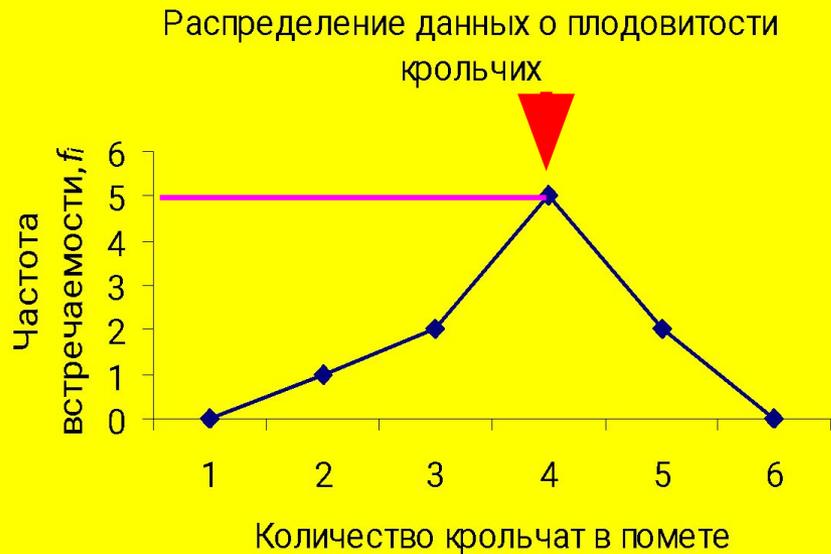
Разница между лимитами называется **размахом** выборки

- Характер вариации признака:  
исследователь может установить симметричность распределения



а также **моду** (наиболее часто встречающееся значение)

$(x_i)$ : 2 3 4 или 5 **модальный** класс  
 $(f_i)$ : 1 2 5 2



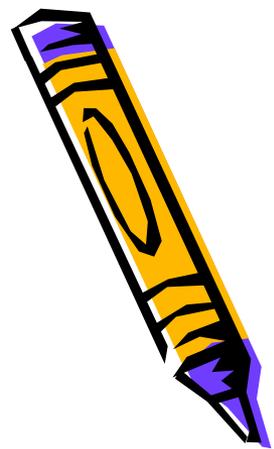
# Круговые диаграммы (*Pie chart*)

(для качественных признаков)

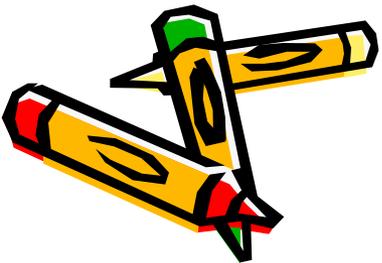
Включают все  
категории которые  
формируют  
совокупность

Используют, чтобы  
изобразить вклад  
каждой категории

Top 10 causes of death	Counts of deaths	% of top 10 case
Heart disease	700,142	37%
Cancer	553,768	29%
Cerebrovascular disease	163,538	9%
Chronic respiratory disease	123,013	6%
Accidental death	101,537	5%
Diabetes	71,537	4%
Flu and Pneumonia	62,034	3%
Alzheimer's disease	53,852	3%
Kidney disorder	39,480	2%
Septicemia	32,238	2%
	1,901,139	100%



## **2.2. Среднее значение и стандартное отклонение**



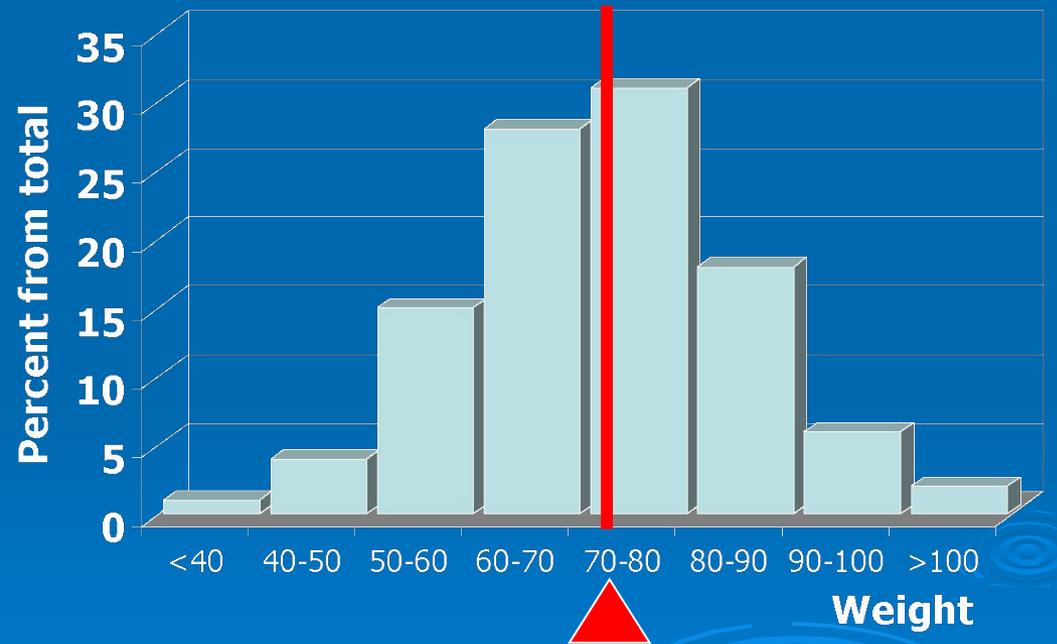
Любое нормальное распределение  
можно описать с помощью всего  
двух параметров:  
*среднего значения ( $\mu$ ) и  
стандартного отклонения ( $\sigma$ )*

# ВЫБОРОЧНАЯ СРЕДНЯЯ

(англ.: *sample mean*)

(= средняя арифметическая)

$$\bar{x} = \frac{1}{n} \sum x_i$$



# ВЗВЕШЕННАЯ СРЕДНЯЯ

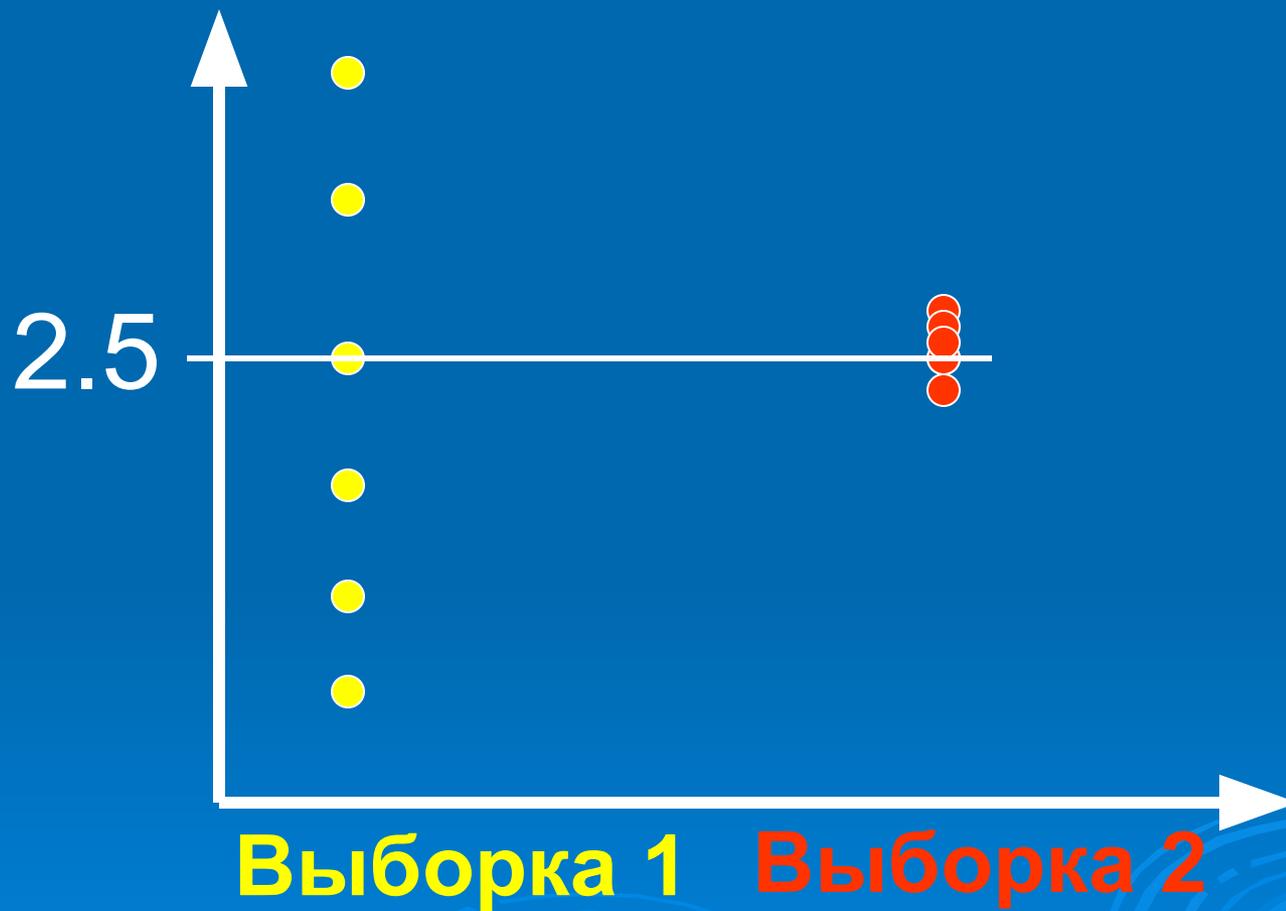
(англ.: *Weighted mean*):

$$\bar{x} = \frac{\bar{x}_1 n_1 + \bar{x}_2 n_2 + \dots + \bar{x}_k n_k}{\sum n_k}$$

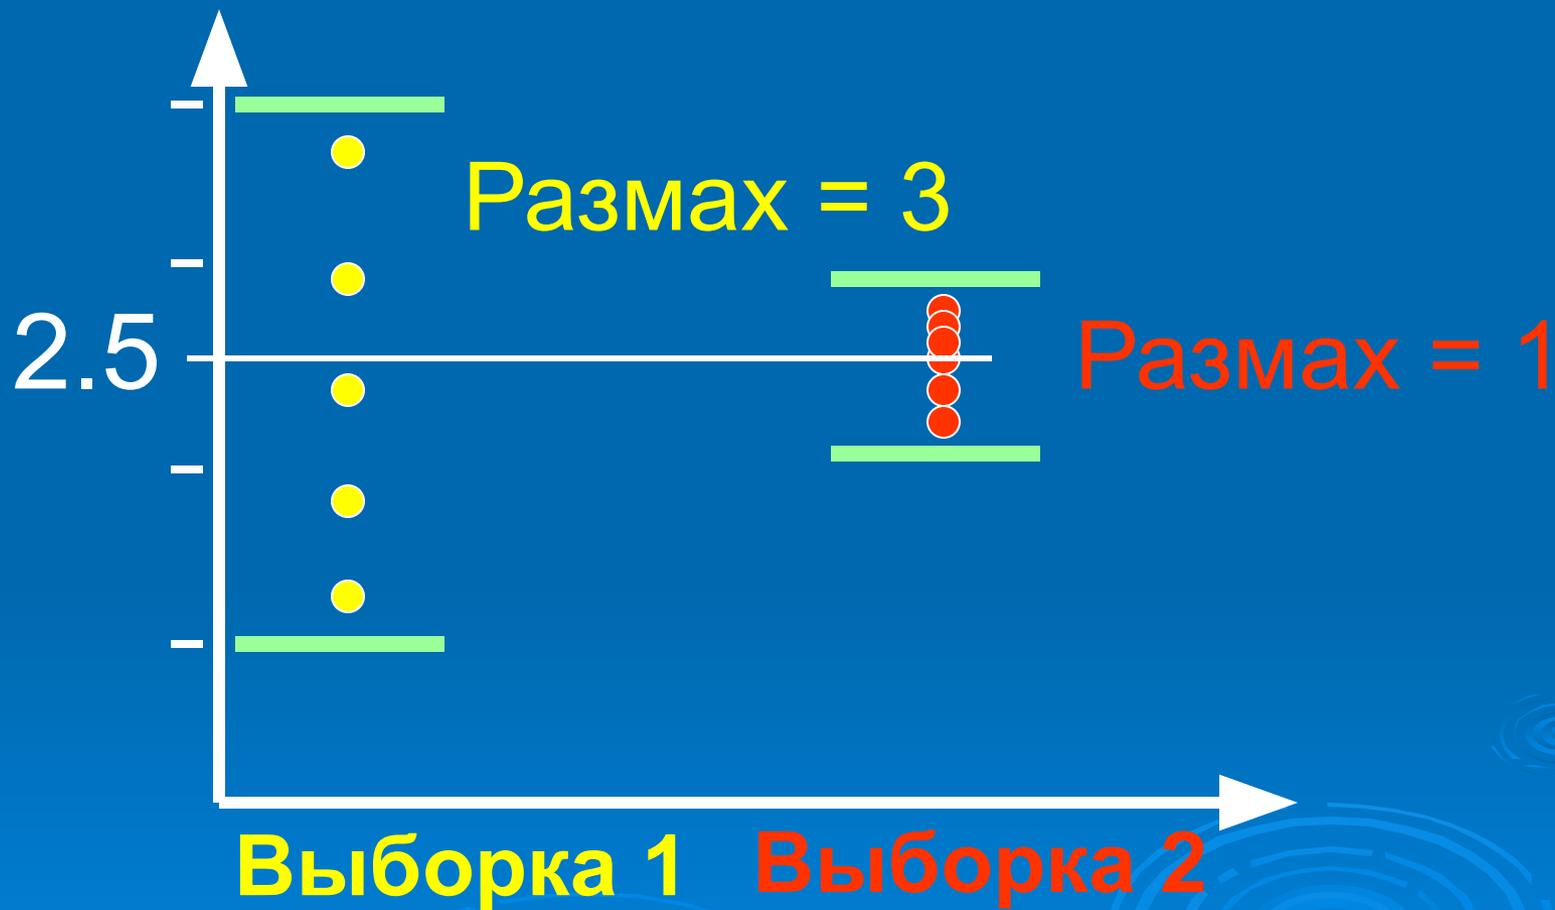
# СРЕДНЯЯ ГЕОМЕТРИЧЕСКАЯ (англ.: *Geometric mean*):

$$\bar{x}_g = \sqrt[n]{x_1 \times x_2 \dots \times x_n}$$

Одинаковы ли выборки ????????



# Размах



# Размах одинаковый

10 15 20 25 30 35 40 45 50  
10 28 28 30 30 30 32 32 50

$X = 30$ ; размах = 40

$X = 30$ , размах = 40

**Выборки различаются!**

Находим расстояние, на котором находится каждая единица изучаемой выборки от среднего значения:

$$(x_i - \bar{x})$$

Избавляемся от отрицательных значений



$$(x_i - \bar{x})^2$$

Усредняем вычисленные  
расстояния и получаем  
дисперсию (англ.: *variance*):

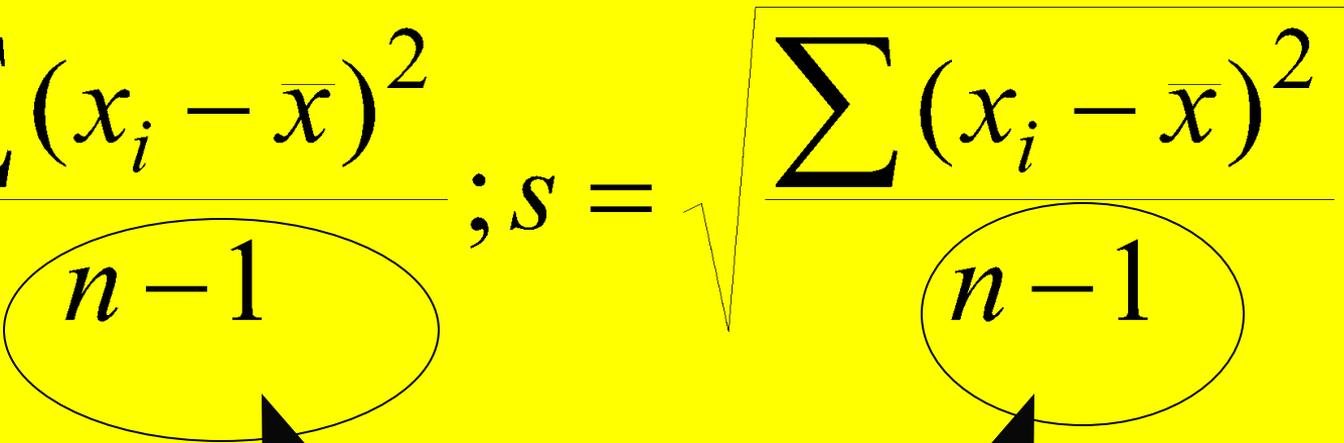
SS (sum of squares) –  
сумма квадратов

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

Извлекая корень из дисперсии,  
получаем стандартное  
отклонение (англ.: *standard*  
*deviation*; SD):

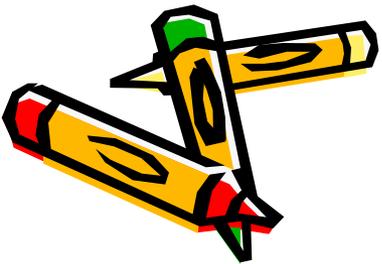
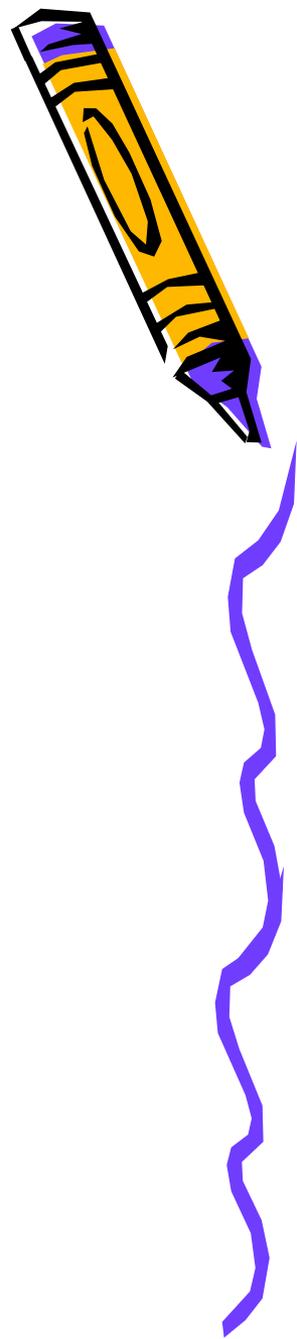
$$s = \sqrt{\frac{\sum (x_i - \bar{x})^2}{n}}$$

# Несмещенные оценки дисперсии и стандартного отклонения (для малых $n$ ):

$$s^2 = \frac{\sum (x_i - \bar{x})^2}{n-1}; s = \sqrt{\frac{\sum (x_i - \bar{x})^2}{n-1}}$$


ЧИСЛО СТЕПЕНЕЙ СВОБОДЫ ( $df$ )

## 2.3. Медиана и процентили



Медиана (*Me*; англ.: *Median*) -  
значение, которое делит  
распределение ровно пополам.

Для нахождения:

- выстроить данные  $\min \rightarrow \max$
- если  $n$  нечетное, ищем центральное значение  $(n+1)/2$
- если  $n$  четное, находим среднее между двумя центральными значениями

# Медиана

Значение, половина данных в совокупности больше которого, а половина – меньше

**n – нечетное:**

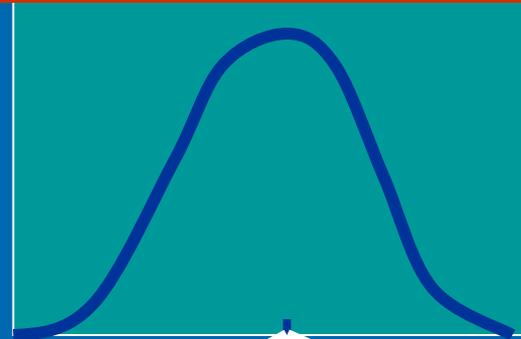
34 36 37 39 40 41 42 43 79

n=9

$Me = X_{(n+1)/2} = X_{(9+1)/2} = X_5 = 40$

$\bar{X} = 43.4$

Симметричное унимодальное



Средняя, мода, медиана

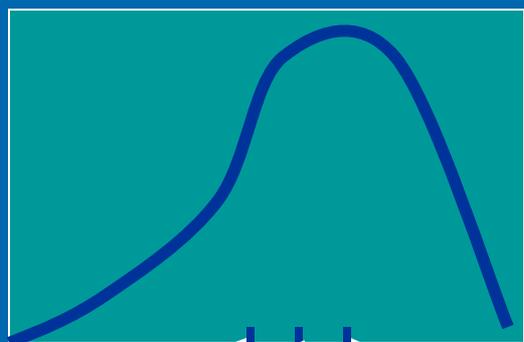
Симметричное бимодальное



Mode Mean Median Mode

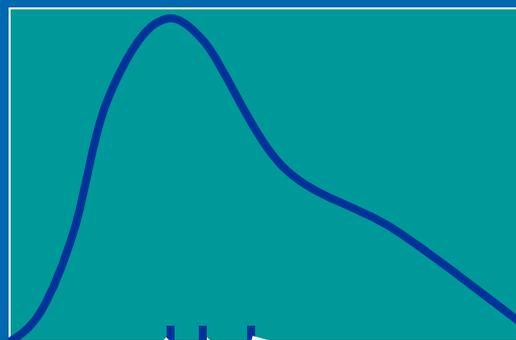
# Медиана

Скошенное влево  
распределение



Mean Median Mode

Скошенное вправо распределение



Мода Медиана Средняя

**n – четное:**

30 33 34 37 40 41 42 43 44 45

n=10

$Me = X_{(n+1)/2} = X_{(9+1)/2} = X_{5.5} =$

$(X_5 + X_6)/2 = (40 + 41)/2 = \mathbf{40.5}$

$\bar{X} = 38.9$

# ВЫВОДЫ:

- Если известно, что выборка скорее всего принадлежит к совокупности с нормальным распределением, для ее описания лучше использовать выборочное **среднее** и выборочное **стандартное отклонение**.

# ВЫВОДЫ:

- Если же известно, что распределение в совокупности отличается от нормального, следует использовать **медиану, 25-й и 75-й процентиля.**