

# СТАТИСТИЧЕСКАЯ ОБРАБОТКА ДАННЫХ.



"Статистика знает всё" известно, сколько какой пищи съедает в год средний гражданин республики: известно, сколько в стране охотников, балерин: станков, велосипедов, памятников, маяков и швейных машинок: Как много жизни, полной пыла, страстей и мысли, глядит на нас со статистических таблиц!..".

отрывок из романа Ильфа и Петрова "Двенадцать стульев"

Это ироничное описание даёт общее представление о статистике.

Термин "статистика" произошел от латинского слова "статус" (*status*), что означает "состояние и положение вещей".

# Статистическая обработка данных.

Ребята, мы переходим к изучению нового раздела, связанного с вопросами обработки данных различных экспериментов и элементов теории вероятности.

Теория вероятности и математическая статистика находят свое применение практически во всех областях жизни.

Так же заметим, что, частично, мы уже изучали данный раздел раньше, так что некоторые моменты вы можете помнить.



# Статистическая обработка данных.

Давайте рассмотрим какой-нибудь пример, где нам может пригодиться обработка информации.

Пусть у нас есть десять футболистов, основной состав некоторой команды.

Наши футболисты пробивают по десять пенальти и результаты каждого записываются.

После окончания у нас есть некоторый набор результатов, на первый взгляд просто набор чисел, но что можно сделать с этими числами? Какую пользу они нам могут принести?



# Статистическая обработка данных.

В первую очередь надо как то сгруппировать и упорядочить нашу информацию. Группировать информацию можно различными способами, все зависит от требуемой задачи. В нашем случае мы можем сгруппировать по фамилии игрока или по номеру игрока команды.

## Сгруппируем по номеру игрока.

Номер Игрока	2	3	4	5	6	7	8	9	10	11
Количество Забитых Голов	3	7	6	5	5	4	4	7	8	6

## Сгруппируем по количеству забитых голов.

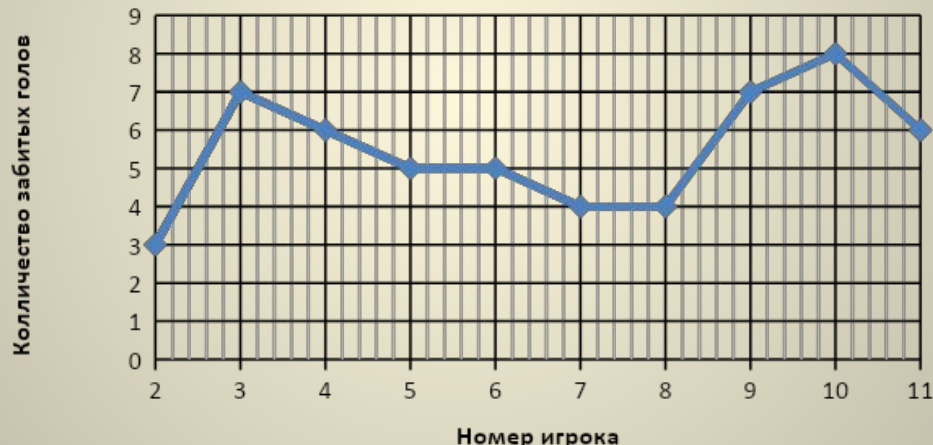
Количество Забитых Голов	0	1	2	3	4	5	6	7	8	9	10
Количество игроков забивших голы	0	0	0	1	2	2	2	2	1	0	0



# Статистическая обработка данных.

Рассмотрим, как нашу таблицу можно представить графически. В виде графиков представим первую таблицу.


На обычной координатной плоскости, по оси абсцисс отложим номер игрока, а по оси ординат - количество забитых голов.



Полученная кривая называется **полигоном частот**.

# Статистическая обработка данных.

Теперь давайте построим **гистограмму**: она позволяет так же наглядно наблюдать за значениями нашего ряда распределений. Мы строим прямоугольники с “центром” в значениях нашего ряда. Получаются такие прыгающие столбики.




# Статистическая обработка

## данных.

Нам осталось построить еще один тип диаграммы – **круговую диаграмму**. Представим, что наш круг занимает все - 100% забитых голов (55 голов), тогда игрок с номером два займет  $3/55$  площади круга, игроки с номерами 5 и 6 займут  $1/11$  часть круга, так как  $5/55=1/11$ .

Давайте построим для всех игроков круговую диаграмму.





# Статистическая обработка данных.

Ну вот, мы с вами научились немного обрабатывать данные.

Давайте напишем небольшой **алгоритм первичной обработки данных**:

- 1) Упорядочить и сгруппировать данные.
- 2) Составить таблицу распределения данных.
- 3) Графическое представление данных. В зависимости от задачи построить один из графиков распределения: **Полигон частот (относительных частот), Гистограмму или Круговую диаграмму.**



# Статистическая обработка данных.

Но на этом обработка информации не заканчивается, для нашего ряда распределения можно найти многие числовые характеристики. Давайте рассмотрим их.

Первая числовая характеристика это **объем выборки ( $N$ )**, в нашем случае он равен десяти, так как мы рассматривали десять футболистов, т.е.  $N = 10$ .

**Размах измерения** – разница между наибольшим и наименьшим значениями выборки.

Больше всего голов забил игрок под номером 10 – 8 голов. Меньше всего, игрок под номером 2 – 3 гола. Тогда размах нашего измерения:  
 $R = 8 - 3 = 5$ .

*Самое популярное или наиболее часто встречаемое значение называется **модой ( $M_0$ )** выборки.*

В нашем примере  $M_0 = 10$  – игрок забивший наибольшее количество голов. В реальности тренер команды мог назначить этого игрока штатным пенальтистом.

# Статистическая обработка данных.

**Среднее значение выборки ( $X_{cp}$ ).** Суммируя все результаты и поделив на объем выборки можно получить среднее значение.

$$X_{cp} = \frac{X_1 + X_2 + \dots + X_n}{n}$$

В нашем примере для подсчета среднего значения удобнее использовать данные второй построенной таблицы.

$$X_{cp} = \frac{0 \cdot 0 + 1 \cdot 0 + 2 \cdot 0 + 3 \cdot 1 + 4 \cdot 2 + 5 \cdot 2 + 6 \cdot 2 + 7 \cdot 2 + 8 \cdot 1 + 9 \cdot 0 + 10 \cdot 0}{10} = 5,5$$

Округлив до целого получим среднее значение равно пяти или по шесть голов. Тренер команды мог бы запомнить данное значение, и через некоторое время провести еще раз такой эксперимент и проверить растут ли показатели команды или нет.

# Статистическая обработка данных.

**Варианта измерения** – каждое число встретившееся в результате измерения. В нашем случае для первой таблицы – количество забитых голов, для второй – количество игроков забивших гол.

**Медиана измерения ( $M_e$ )** – средняя варианта встречающаяся в выборке. Она делит нашу выборку пополам.

Для второй выборки  $M_e = 5$ , так как это значение делит наш ряд ровно пополам.

Если число вариант четно, как в первой выборке, то берутся два средних значения и делятся пополам:  $M_e = (6+7)/2=6,5$ .

**Кратность или абсолютная частота варианты** – то сколько раз встречается конкретная варианта.

Для второй таблица кратность 0 равна 0, кратность 4 равна двум, кратность 8 равна единице.

# Статистическая обработка данных.

При составлении таблицы, не всегда получается, что варианты расположены через равные промежутки.

**Варианта** измерения может принимать *фактически любые значения и положительные и отрицательные.*

**Кратность варианты всегда больше нуля**, если кратность равна нулю то фактически в нашем эксперимента данное значение не встретилось, поэтому вторую таблицу распределения целесообразней записать в таком виде:

Количество Забитых Голов	3	4	5	6	7	8
Количество игроков забивших голы	1	2	2	2	2	1



# Статистическая обработка данных.

**Частота варианты** – числовая характеристика, показывающая часть или долю которую составляет варианта от всей выборки, которая рав

$$\text{Частота варианты} = \frac{\text{Кратность варианты}}{\text{Объем выборки}}$$

$$\text{Частота варианты \%} = \frac{\text{Кратность варианты}}{\text{Объем выборки}} \cdot 100\%$$

Перепишем нашу вторую таблицу с учетом частот и объема выборки:

Количество Забитых Голов	3	4	5	6	7	8	Объем
Количество игроков забивших голы	1	2	2	2	2	1	10
Частота	0,1	0,2	0,2	0,2	0,2	0,1	
Частота, %	10%	20%	20%	20%	20%	10%	

**Сумма всех частот всегда равна 1, а сумма частот в процентах всегда равна 100%.**

# Статистическая обработка данных.

Вернемся к среднему значению, данная числовая характеристика часто является очень полезной.

Но не во всех задачах имеет смысл ее вычислять.

В нашем примере эта числовая характеристика показывала, сколько в среднем забивает команда. Со временем можно делать выводы об эффективности или неэффективности методов тренировки. Если среднее значение забитых голов растет, то видимо и тренировка эффективна, если не растет, а даже падает то видимо, методы тренировки неэффективны.



# Статистическая обработка данных.

Одной из наиболее распространённых характеристик выборки значений случайной величины, чьё распределение по вероятностям известно, является *математическое ожидание (M)*.

Пусть распределение по вероятностям  $P$  значений некоторой случайной величины  $X$  задано таблицей:

$X$	$X_1$	$X_2$	$X_3$	...	$X_{n-1}$	$X_n$
$P$	$P_1$	$P_2$	$P_3$	...	$P_{n-1}$	$P_n$

тогда математическое ожидание вычисляется по формуле:

$$M = X_1 P_1 + X_2 P_2 + X_3 P_3 + \dots + X_{n-1} P_{n-1} + X_n P_n,$$

# Статистическая обработка данных.

Рассмотрим на примере вычисление математического ожидания:

$X$	1	2	3	4	5	6
$P$	0,1	0,25	0,3	0,2	0,1	0,05

Применим формулу вычисления математического ожидания

$$M = X_1 P_1 + X_2 P_2 + X_3 P_3 + \dots + X_{n-1} P_{n-1} + X_n P_n,$$

$$M = 1 \cdot 0,1 + 2 \cdot 0,25 + 3 \cdot 0,3 + 4 \cdot 0,2 + 5 \cdot 0,1 + 6 \cdot 0,05 = 3,1$$

Ответ:  $M = 3,1$

# Статистическая обработка данных.

Еще одна важная числовая характеристика — **Дисперсия**, или **разброс значений** вокруг среднего значения. Чем меньше дисперсия, тем плотнее результаты эксперимента сосредоточены около своего среднего значения.

Подсчет дисперсии довольно таки трудоемкая операция, опишем алгоритм поиска дисперсии.

Пусть нам даны данные измерений:  $x_1, x_2, \dots, x_n$ . Найдём

1. среднее значение  $X_{cp}$

$$X_{cp} = \frac{x_1 + x_2 + \dots + x_n}{n}$$

2. отклонение данных от среднего:  $x_1 - X_{cp}, x_2 - X_{cp}, \dots, x_n - X_{cp}$ ;

3. квадраты отклонений найденных на предыдущем шаге:  $(x_i - X_{cp})^2, (i = 1, \dots, n)$ ;

4. среднее значение

$$D = \frac{(x_1 - X_{cp})^2 + (x_2 - X_{cp})^2 + \dots + (x_n - X_{cp})^2}{n}$$

Д

$$\delta = \sqrt{D}$$

- среднее квадратическое отклонение



# Статистическая обработка данных.

Давайте вычислим дисперсию для нашего примера:

1. Вспомним, среднее значение у нас равнялось 5.5
2. Вычислим каждое отклонение и квадрат отклонения

Номер Игрока	2	3	4	5	6	7	8	9	10	11
Количество Забитых Голов	3	7	6	5	5	4	4	7	8	6
Отклонение от среднего	-2,5	1,5	0,5	-0,5	-0,5	-1,5	-1,5	1,5	2,5	0,5
Квадрат отклонения	6,25	2,25	0,25	0,25	0,25	2,25	2,25	2,25	6,25	0,25

3. Вычислим дисперсию

$$D = \frac{6,25 + 2,25 + 0,25 + 0,25 + 0,25 + 2,25 + 2,25 + 2,25 + 6,25 + 0,25}{10} = 2,25$$

# Статистическая обработка данных.

Методы математической статистики позволяют обрабатывать практически любые данные, главное подходить к обработке данных обдуманно и исходя из здравого смысла.



**СПАСИБО ЗА ВНИМАНИЕ !**

