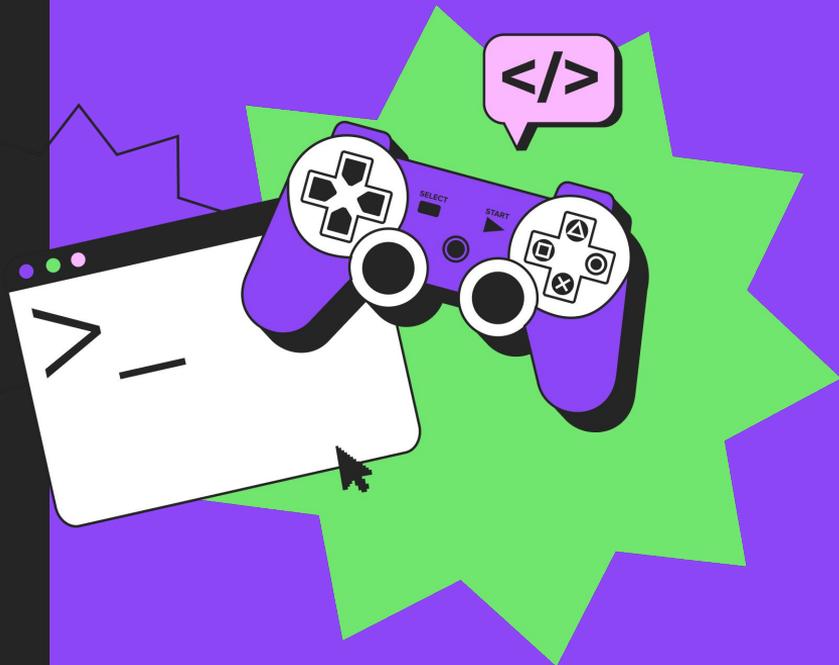


# A/B тестирование

## Урок 5

### Математическая статистика часть 1





# Математическая статистика часть 1



## На этом уроке мы разберем



Поговорим о важности статистики для A/B тестов



Пройдемся по базовым понятиям статистики



Разберем как оценивать по выборке в каких границах лежат реальные значения ваших метрик



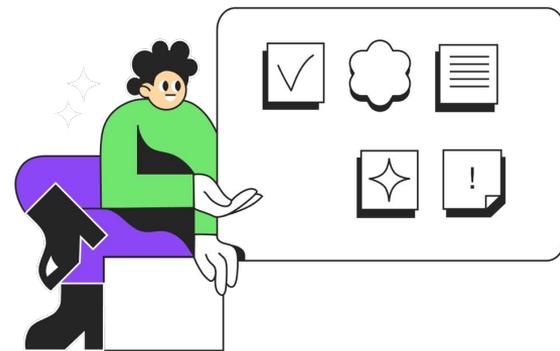
Статистические критерии



Алгоритм проверки гипотез



Обзор калькуляторов для подсчета результатов





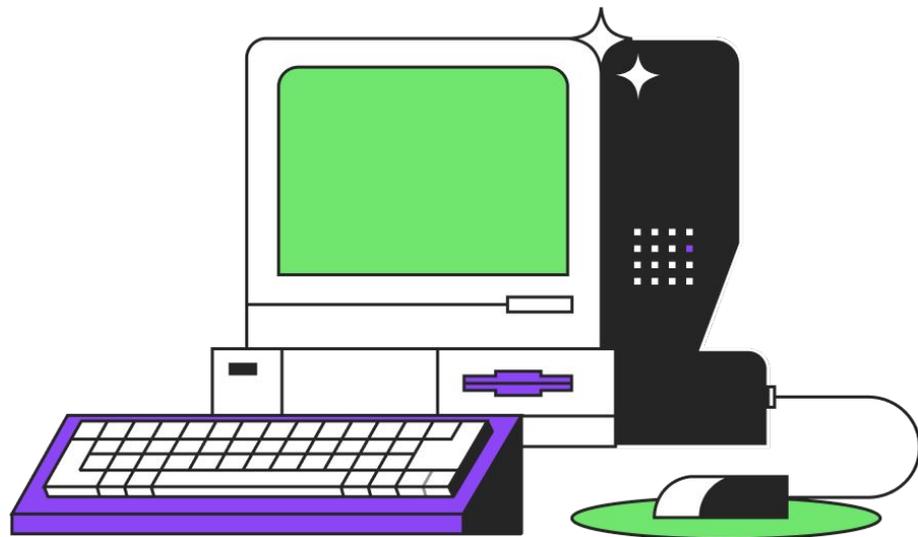
# Важность статистики в А/В-тестах

## Важность статистики в А/В-тестах

Математическая статистика

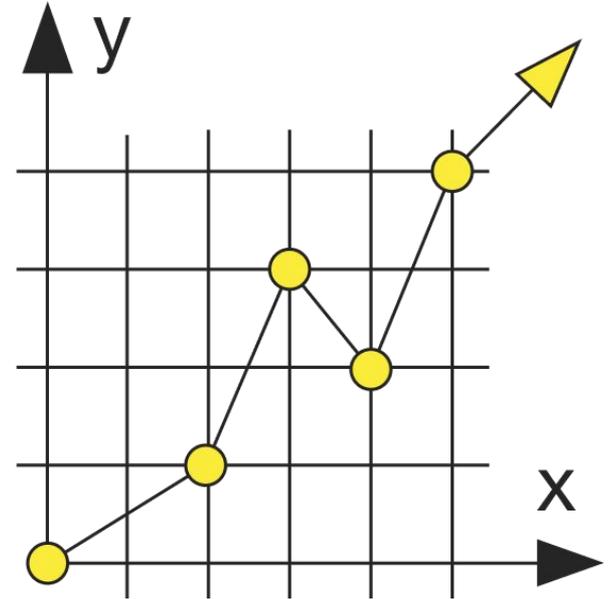
это раздел математики, в котором разрабатываются различные методы для описания и анализа наблюдений с целью использования для научных и практических выводов.

Математическая статистика - фундамент А/В тестов, без правильного понимания которого резко возрастает риск принятия неверных решений в продукте. И в этом мы ни раз убедимся в рамках курса.



## Что нужно, чтобы проводить A/B-тестирование?

1. Уметь рассчитывать размер выборки для теста
2. Понимать, что означает мощность теста
3. Понимать, насколько страшны ошибки I и II рода
4. Понимать, что означает p-value и доверительный интервал
5. Знать основные статистические критерии
6. Уметь корректно посчитать результаты теста





# Базовые понятия

## Выборка и ген.совокупность

**Генеральная совокупность** - совокупность всех объектов или наблюдений, относительно которых исследователь намерен делать выводы при решении конкретной задачи. В ее состав включаются все объекты, которые подлежат изучению.

**Выборка** - часть генеральной совокупности с помощью определённой процедуры выбранных из генеральной совокупности для участия в исследовании

Чтобы переносить выводы с выборки на генеральную совокупность, выборка должна быть **репрезентативной**, отражать пропорции и особенности генеральной совокупности.



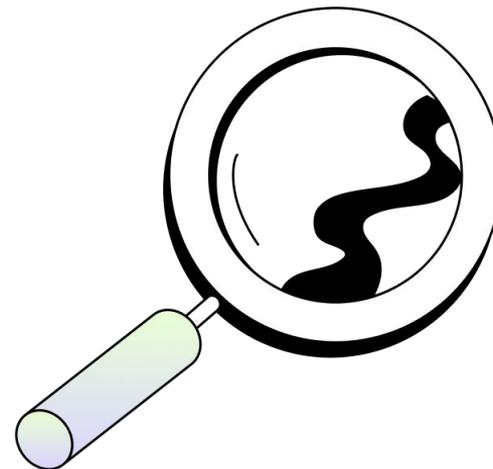
# Оценка параметров на основе выборки

**Случайная величина ( $\xi$ )** – это математическое понятие, служащее для представления **случайных явлений**, когда для них может быть определена их **вероятность**, то есть мера возможности наступления.

По сути это переменная со значениями. Для каждого значения есть своя вероятность исхода

## Примеры случайных величин:

- Оценка студента на экзамене
- Цифра выпавшая при броске игральной кости
- Время, которое провел юзер на странице за сеанс
- Цена акции на бирже



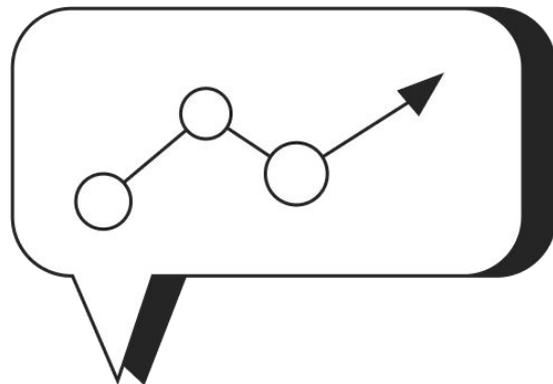
Любая выборка представляет собой значения какой-либо случайной величины.

## Оценка параметров на основе выборки

Для точечного оценивания параметров случайной величины используются различные статистики. **Статистика** — это любая измеримая функция от выборки.

Пусть дана выборка  $Y = (y_1, y_2, \dots, y_i)$  значений случайной величины

Как ее можно описать с помощью статистик?



# Оценка параметров на основе выборки.

**Математическое ожидание ( $\mu$ ,  $M$ )** (выборочное

среднее)— это среднее арифметическое значение случайной величины.

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

**Дисперсия ( $S^2$ )** – рассчитывается как среднее расстояние, на которое

значения случайной величины находятся вокруг его

математического ожидания

$$\sigma_x^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{X})^2$$

**Стандартное отклонение ( $SD$ )**— это квадратный корень от

дисперсии

$$\sigma_x = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{X})^2}$$

**Медиана** это такое значение, к которому равно

половина из элементов выборки больше него либо равна,

а другая половина меньше него либо равна.

1, 3, 5, 5, 8, 9, 11, 17, 18, 24, 77, 218, 633

Блюдо	Цена руб
1	500
2	450
3	400
4	470

Мат ожидание	Дисперсия	Стандартное отклонение
455	1 767	42

Рассчитаем дисперсию:

$$((500-455)^2 + (450-455)^2 + (400-455)^2 + (470-455)^2) / (4-1) = 1767$$

# Описательные статистики

## Меры центральной тенденции

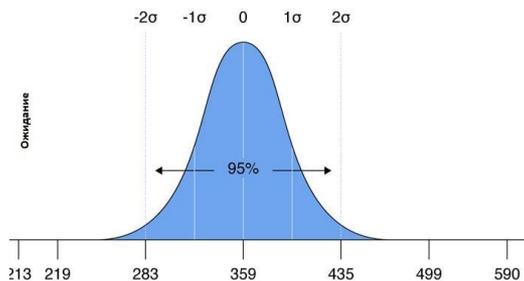
- Среднее значение
- Медиана
- Мода



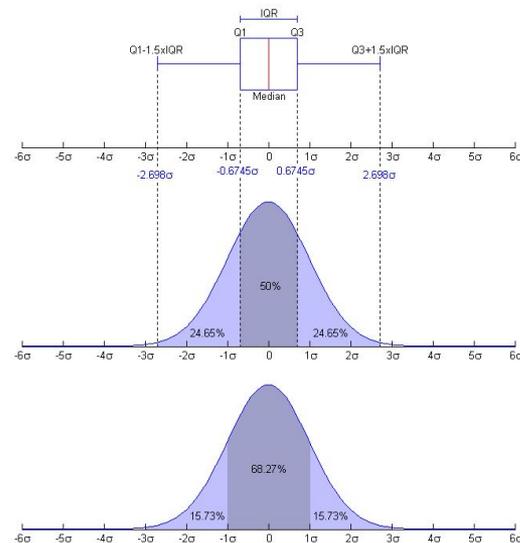
Рис. 15.2. Асимметрия распределения

## Меры разброса данных

- Дисперсия
- Стандартное отклонение



## Квантили

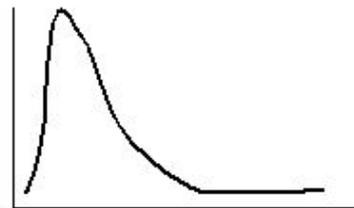


# Законы распределения

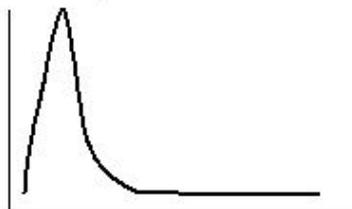
Законом распределения случайной величины называется соотношение, устанавливающее связь между возможными значениями случайной величины и соответствующими им вероятностями.



Нормальное



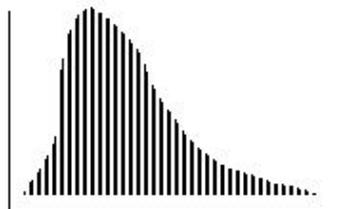
Логнормальное



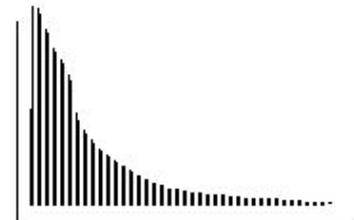
Гамма-распределение



Вейбулла



Биноминальное



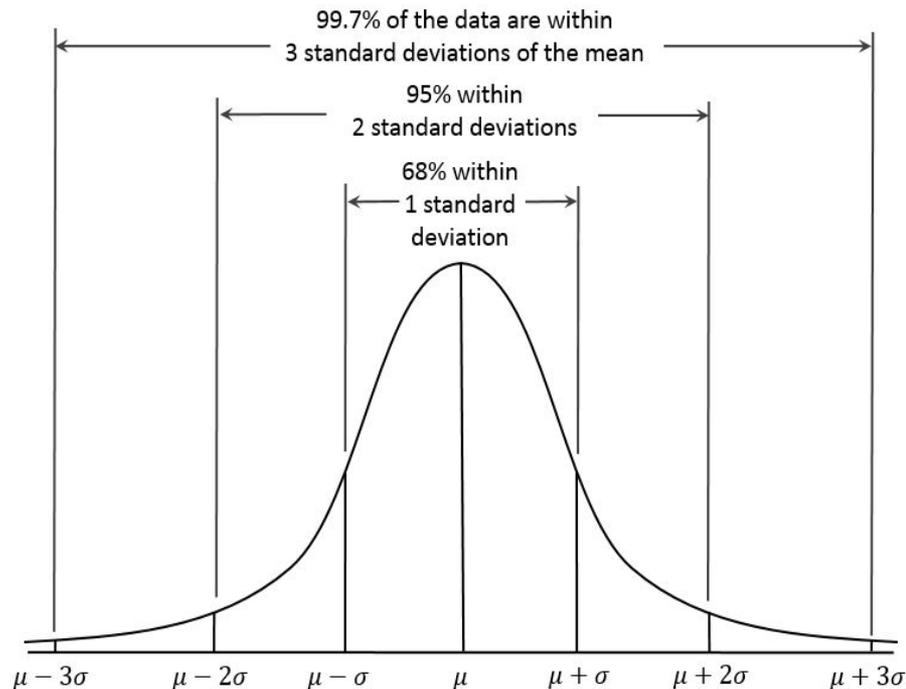
Геометрическое

# Нормальное распределение

Функция плотности распределения:

Вероятность того, что случайная величина  $X$  будет лежать в отрезке  $(x, y)$ , равна площади под графиком функции плотности  $f(x)$  в пределах от  $x$  до  $y$ .

Общая площадь под графиком функции  $f(x)$  равна 1.



# Нормальное распределение

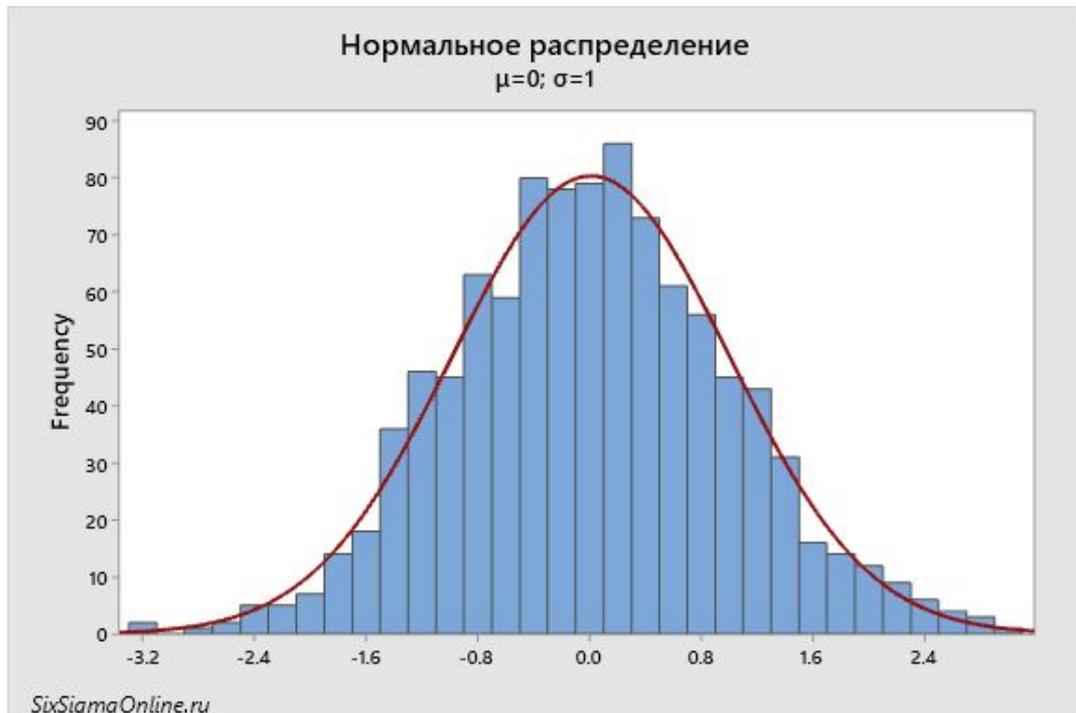
## Гистограмма распределения:

По оси  $x$  откладываются все значения выборки.

Вся ось  $x$  разбивается на заданное число одинаковых отрезков.

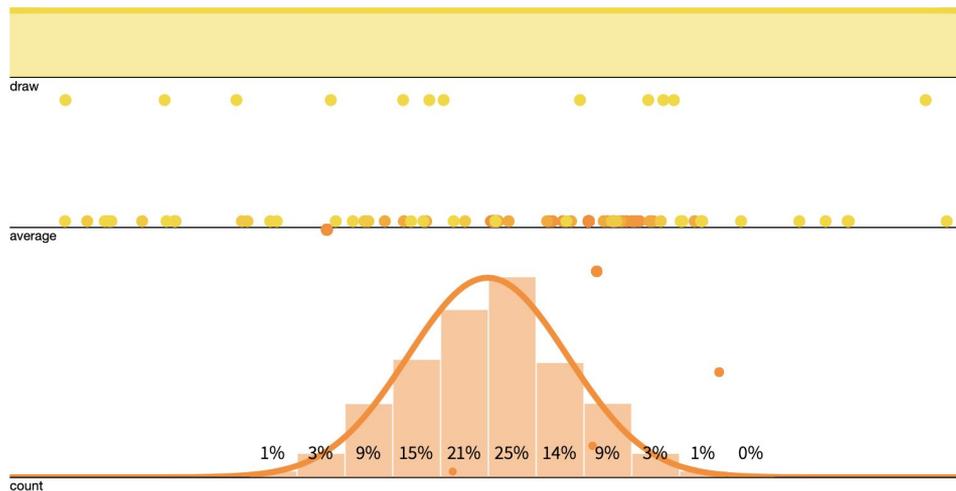
Для каждого отрезка вычисляется кол-во значений выборки, которые лежат в этом отрезке, и это кол-во откладывается по оси  $y$

Гистограмма по форме напоминает график распределения вероятностей случайной величины.



# Центральная Предельная Теорема

[ЦПТ](#) говорит, что если мы возьмем достаточно большую выборку из независимых, одинаково распределенных случайных величин ([i.i.d](#) из генеральной совокупности), то среднее значение будет [нормально распределено](#) с  $\mu$  и  $SD$ .

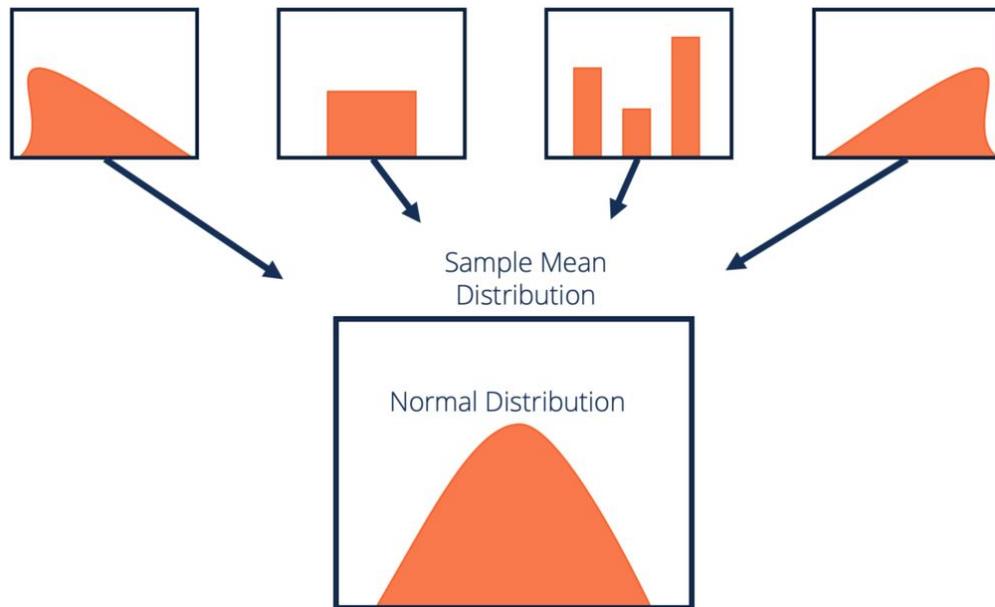


[Берем и многократно извлекаем](#) выборки определенного размера и считаем по ним среднее. Распределение средних при соблюдении предпосылок выше будет нормально распределенным и мы сможем оценивать истинное значение в ГС.

# ЦПТ

Что нам позволяет делать ЦПТ ?

ЦПТ дает возможность строить доверительные интервалы и проверять статистические гипотезы.





# Доверительный интервал

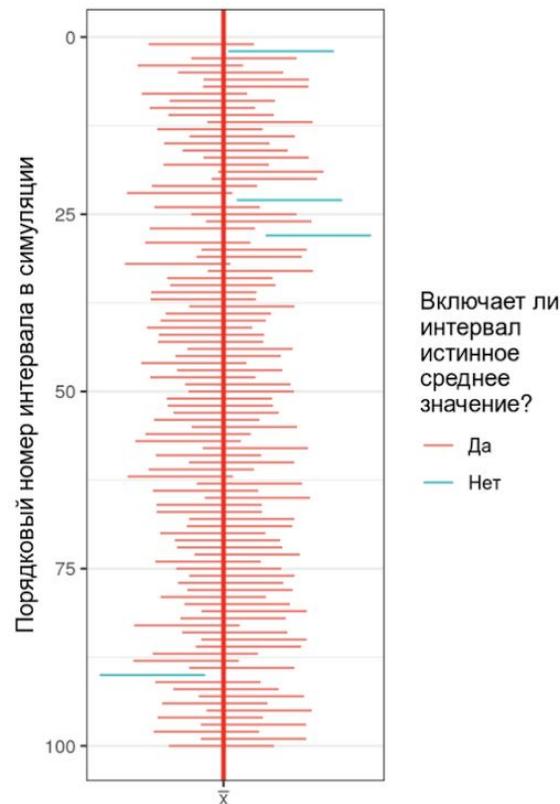
# Доверительный интервал

$$M \pm 1,96 \times (SD \div \sqrt{n})$$

**Доверительный интервал** – Что это такое ? Это способ оценки метрики, используя который, мы получим диапазон значений  $[x,y]$ , внутри которого будет лежать истинное значение метрики ГС в 95% случаев.

(Если провести очень большое количество независимых экспериментов с аналогичным построением доверительного интервала, то в 95% экспериментов доверительный интервал будет содержать оцениваемый параметр ген совокупности.

В оставшихся 5% экспериментов доверительный интервал не будет содержать параметр ген совокупности.)



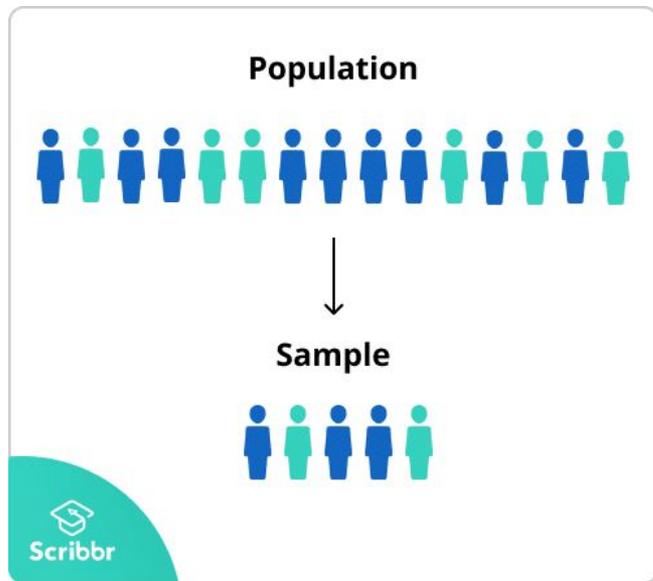
## Виды метрик

Типы метрик которые бывают в экспериментах:

- 1) Доли - (ретеншн, конверсии) [0,1,0,0,0,1]
- 2) Непрерывные - (таймспент в сек / деньги)
- 3) Отношения - (клики на сессию)



## Оценка параметров на основе выборки.



Доверительный интервал 95% для метрик долей:

$$\hat{p} \pm 1.96 * \sqrt{\frac{\hat{p}(1 - \hat{p})}{n}}$$



# Ошибки I и II рода

# Базовые определения:

**Нулевая гипотеза** – принимаемое предположение о том, что не существует связи между наблюдениями в двух (или более) событиях (выборках, феноменах, совокупностях). Гипотезу отвергают, если данные показывают разницу между выборками.

**True Positive** = говорим истина, когда по факту истина (факт)  
**True Negative** = говорим не истина, когда по факту тоже не истина (факт)

**False Positive (ошибка I рода)** = говорим истина, когда по факту не истина. Отклонение верной нулевой гипотезы. Риск совершить такую ошибку равен выбранному уровню статистической значимости (например,  $\alpha=0.05$ ) (ошиблись)

**False Negative (ошибка II рода)** = говорим не истина, когда по факту истина (ошиблись).  
Принятие неверной нулевой гипотезы. Вероятность отклонить реально работающее изменение

# Ошибки I и II рода

$H_1$ : есть беременность;  $H_0$ : нет беременности

Истинный  
позитив, верна  
 $H_1$



Ложный  
позитив,  
ошибка I  
рода,  
ложная  
тревога

Если бы влияние на конверсию было значительным, но мы это не обнаружили

Ложный  
негатив,  
ошибка II рода,  
халатная  
беспечность



Истинный  
негатив,  
верна  $H_0$



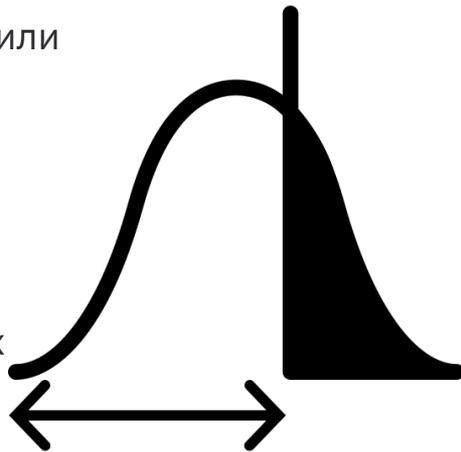
# Проверка статистических гипотез

# Основные понятия

**Статистическая гипотеза** — выдвигаемое предположение о свойствах случайной величины/виде ее распределения, которое можно подтвердить или опровергнуть на основании имеющихся данных.

## Примеры:

- Между конверсиями в покупку в двух группах нет статистически значимых различий
- Между Retention 7 дня в двух группах нет статистически значимых различий
- Случайная величина имеет нормальное распределение



## Основные шаги при проверке гипотез

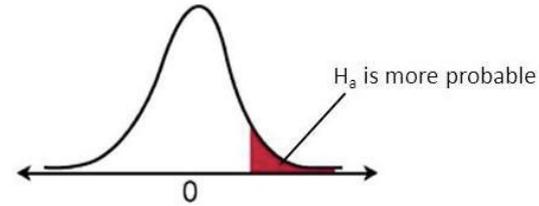
- 1) Формулируются нулевая и альтернативная гипотезы.

**Нулевая гипотеза** – принимаемое предположение о том, что не существует связи между наблюдениями в двух (или более) выборках. Гипотезу отвергают, если данные показывают разницу между выборками. (чаще всего в A/B тестах используют двухсторонние гипотезы)

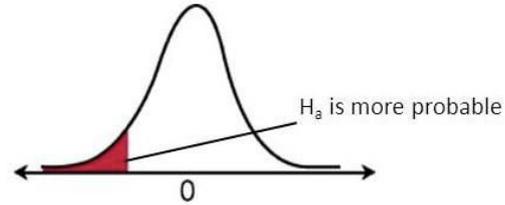
В зависимости от задачи альтернативные гипотезы бывают левосторонние, правосторонние или двухсторонние.

- 1) Задаётся статистика (функция от выборки)  $F(Y)$ , которая в условиях справедливости нулевой гипотезы  $H_0$  имеет известное распределение
- 1) Фиксируется уровень значимости  $\alpha$  (false positive) — допустимая для данной задачи вероятность ошибки первого рода (чаще всего 0.01, 0.05 или 0.1).
- 1) Проводится статистический тест: для выборки(выборок)  $Y$  считается значение  $F(Y)$ , и если оно принадлежит критической области, то заключаем, что данные противоречат гипотезе  $H_0$ , и принимается гипотеза  $H_1$ .

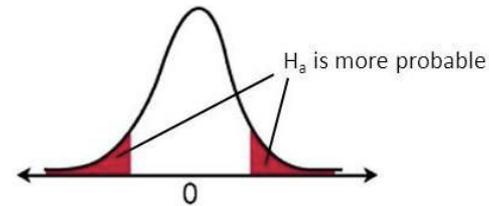
# Основные шаги при проверке гипотез



Right-tail test  
 $H_a: \mu > \text{value}$



Left-tail test  
 $H_a: \mu < \text{value}$

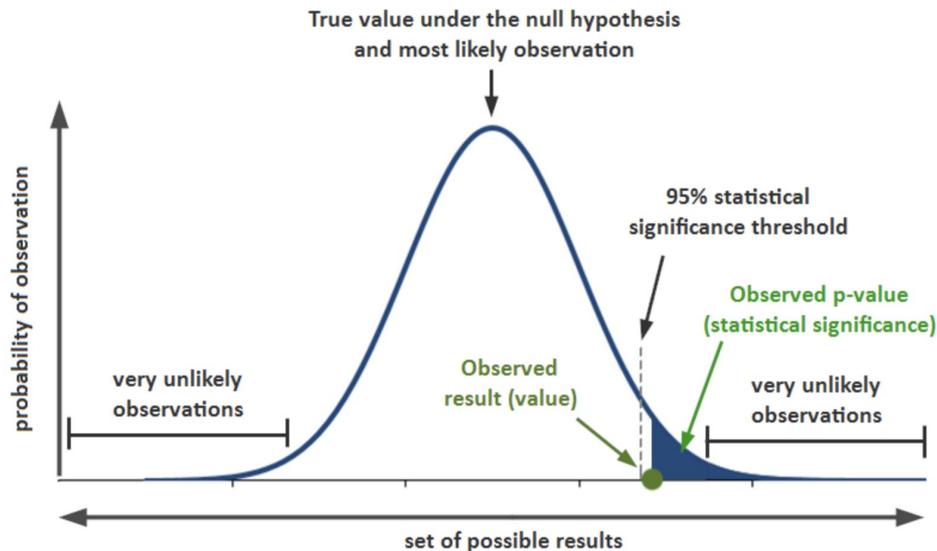


Two-tail test  
 $H_a: \mu \neq \text{value}$

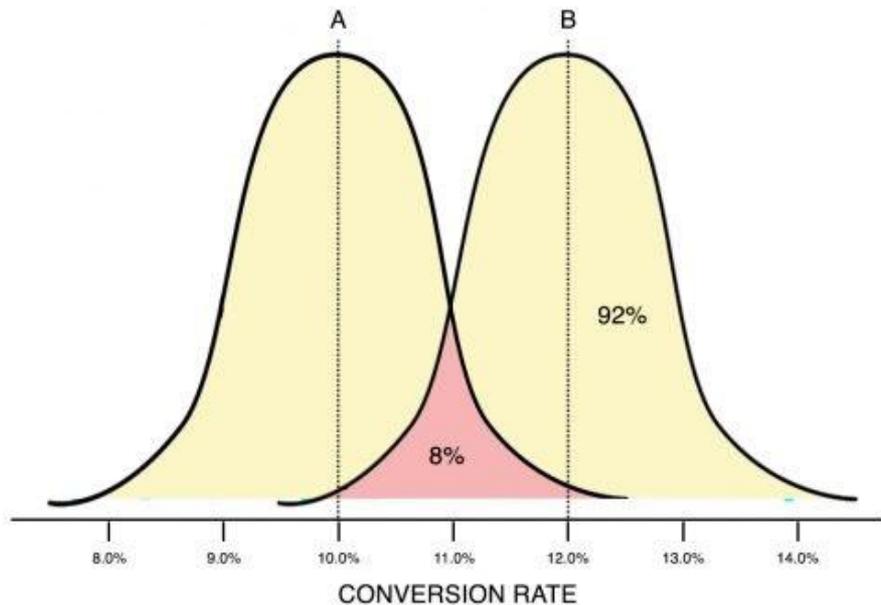
## Основные понятия

**p-value** – вероятность получить наблюдаемое или еще большее отклонение оценки от гипотезы, если она (гипотеза) верна. Геометрически это площадь под кривой, которая начинается от статистического критерия в сторону от гипотезы (от центра).

Если  $p\text{-value} < \alpha$  - нулевая гипотеза отвергается



## Сравнение средних



У каждой из метрик в двух выборках есть сигнал (разница средних) и шум (дисперсия). Мы хотим понять несмотря на наличие шума а есть ли действительная разница между средними ?

В этом нам помогают статистические критерии.

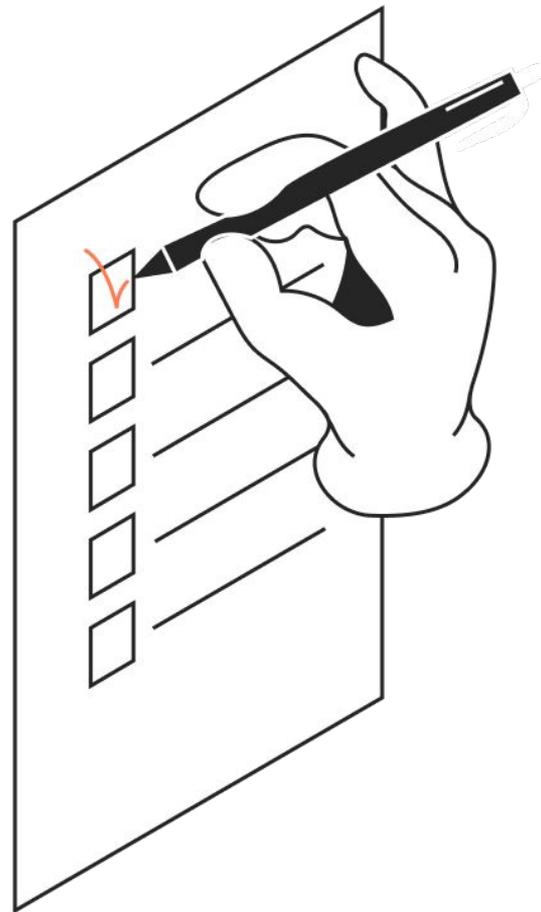
# Статистические критерии

**Статистический критерий** — математическое правило, в соответствии с которым отвергается либо не отвергается та или иная статистическая гипотеза с заданным уровнем значимости.

Для того, чтобы проверить гипотезу о равенстве показателей, применяется два типа критериев оценки: параметрические и непараметрические.

**Параметрическими** называются критерии, в которых мы можем сделать предположение о распределении, относящееся к какой-то выборке. В большинстве случаев в качестве распределения используется нормальное.

**Непараметрические** не используют предположения о распределении, а оперируют *рангами* и *частотами*.



# Основные понятия

**Статистическая мощность (True Positive)** — это вероятность, что тест правильно засечёт эффект там, где он и правда есть. (т.е.  $1-\beta$ )

Чтобы найти хороший критерий для проверки гипотезы  $H_0$  vs  $H_1$  нужно из всех корректных критериев выбрать критерий с максимальной мощностью. У непараметрических критериев мощность меньше по сравнению с параметрическими - при возможности лучше использовать параметрические критерии.

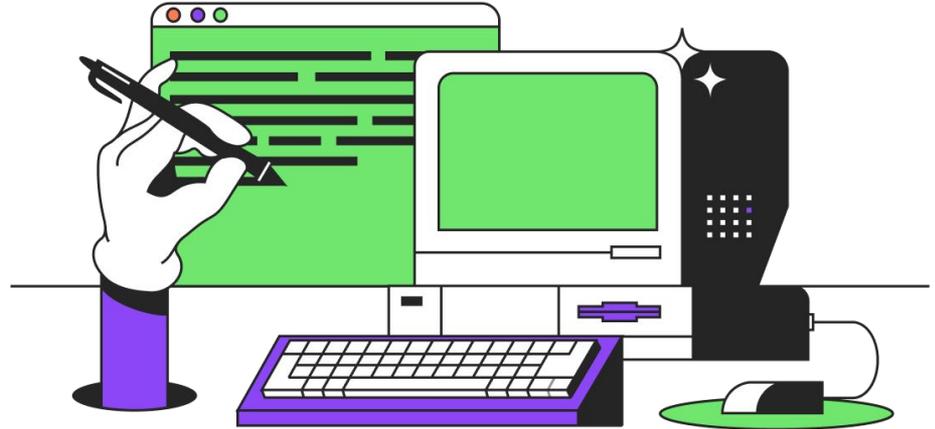
Даже при ненормальности изначального распределения - ЦПТ работает для распределения средних на больших выборках





# Выбор критерия light version

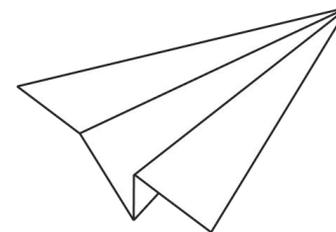
- **Конверсии** ([Хи-квадрат на однородность](#) распределения в двух ген совокупностях или [Z критерий долей](#))
- **Средние**  
если нормальное распределение то [t критерий](#)  
если не нормальное распределение то [критерий Манна-Уитни](#)



## Пример:

Допустим мы запустили эксперимент направленный на улучшение конверсии на одном из кусков сайта:

Группа	Посетители	Кликнувшие посетите...	Конверсия %
Тестовая группа	2400	178	7,42%
Контрольная группа	2400	199	8,29%



**Нулевая гипотеза** – Между конверсией в двух группах нет статистически значимых различий

**Альтернативная гипотеза** – Между конверсией в двух группах есть статистически значимые различия

$$\hat{p}_2 - \hat{p}_1 \pm 1.96 \times \sqrt{\hat{p}_1 \times (1 - \hat{p}_1) \div n_1 + \hat{p}_2 \times (1 - \hat{p}_2) \div n_2}$$

$$0.0742 - 0.0829 \pm 1.96 \times (0.0742 \times (1 - 0.0742) \div 2400 + 0.0829 \times (1 - 0.0829) \div 2400)^{1/2} = [-2.392\% ; 0.652\%]$$

0 входит в интервал - значит на основе собранных данных статистически значимой разницы между группами не обнаружено.



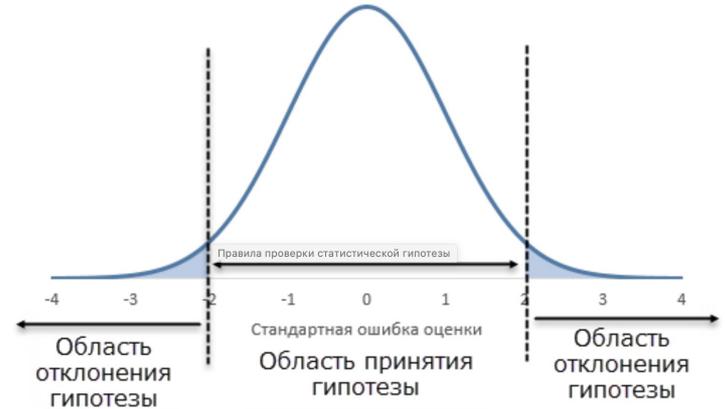
# Алгоритм проверки гипотез

# Проверка гипотез

1. Выбираем метрику и формулируем нулевую и альтернативную гипотезы
2. Выбираем параметр alpha (например 5%) равный вероятности допустить ошибку первого рода
3. Выбираем критерий, подходящий под наши условия
4. Считаем p-value и(или) доверительный интервал и делаем вывод:

Если  $p\text{-value} < \alpha$  - разница между группами стат.значима . Либо если доверительный интервал для разницы не включает 0.

5. Даем (рекомендации лицам принимающим решения /принимаем решение ) выкатывать или не выкатывать новое изменение





# Обзор калькуляторов

## Выбор критерия light version

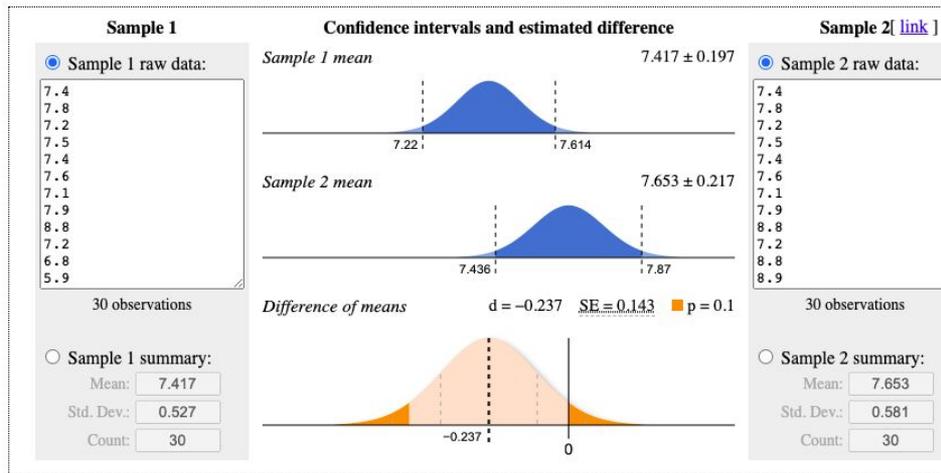
- **Конверсии** ([Хи-квадрат на однородность](#) распределения в двух ген совокупностях или [Z критерий долей](#))
- **Средние**  
если нормальное распределение то [t критерий](#)  
если не нормальное распределение то [критерий Манна-Уитни](#)

# t критерий Стьюдента

$$t = \frac{(\bar{x}_1 - \bar{x}_2)}{\sqrt{s_1^2/n_1 + s_2^2/n_2}}$$

[Sample Size Calculator](#) | [Chi-Squared Test](#) | [Sequential Sampling](#) | **2 Sample T-Test** | [Survival Times](#) | [Count Data](#)

Question: Does the average value differ across two groups?



**Verdict:** No significant difference

Hypothesis:   $d = 0$    $d \leq 0$    $d \geq 0$

Confidence:  95%

## U критерий Манна-Уитни

$$U_1 = n_1 n_2 + \frac{n_1(n_1 + 1)}{2} - R_1 \quad U_2 = n_1 n_2 + \frac{n_2(n_2 + 1)}{2} - R_2$$
$$U = \min(U_1, U_2)$$

2  
3  
4  
5  
5  
7  
9

2  
3  
4  
5  
5  
9  
9

switch groups clear content

Upload your CSV File:

Выберите файл Файл не выбран

Test variant:

$H_1 : a < b$    $H_1 : a \neq b$

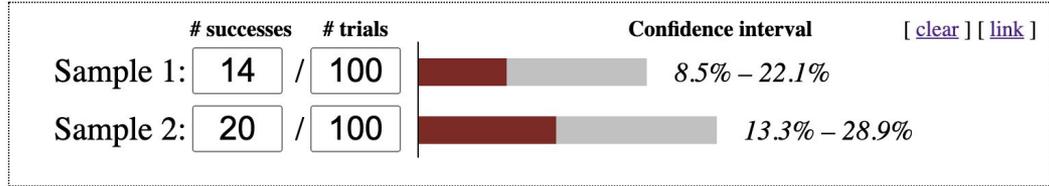
RUN

Sample sizes: m = 7, n = 7

Exact p-value: 0.96911424

## Критерий Хи-квадрат на однородность распределений

$$\chi^2 = \sum_{i=1}^R \sum_{j=1}^C \frac{(o_{ij} - e_{ij})^2}{e_{ij}}$$



*Verdict:*

No significant difference

(p = 0.26)

Confidence level:  95%

# Z test для долей

## Z-score

$$(CR_B - CR_A) / SE_{\text{difference}}$$

Pre-test analysis  
 Test evaluation

**Test data**

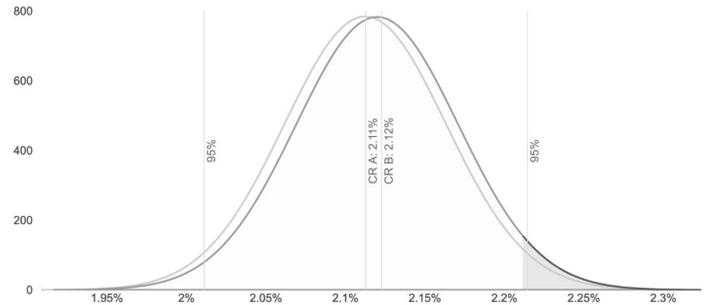
Visitors A: 80000  
Conversions A: 1690

Visitors B: 80000  
Conversions B: 1696

**Settings**

Hypothesis <sup>(?)</sup>  
 One-sided  
 Two-sided

Confidence <sup>(?)</sup>  
 90%  
 95%  
 99%



### Conversion Rate Control

Conversions A / Visitors A

2.11%

### Conversion Rate B

Conversions B / Visitors B

2.12%

### Relative uplift in Conversion Rate

$CR_B - CR_A / CR_A$

0.36%

### Observed Power

3.52%

### p value

0.4585

### Z-score

$(CR_B - CR_A) / SE_{\text{difference}}$

0.1042

### Standard error A

$(CR_A * (1 - CR_A) / \text{Visitors}_A)^{1/2}$

0.000508

### Standard error B

$(CR_B * (1 - CR_B) / \text{Visitors}_B)^{1/2}$

0.000509

### Std. Error of difference

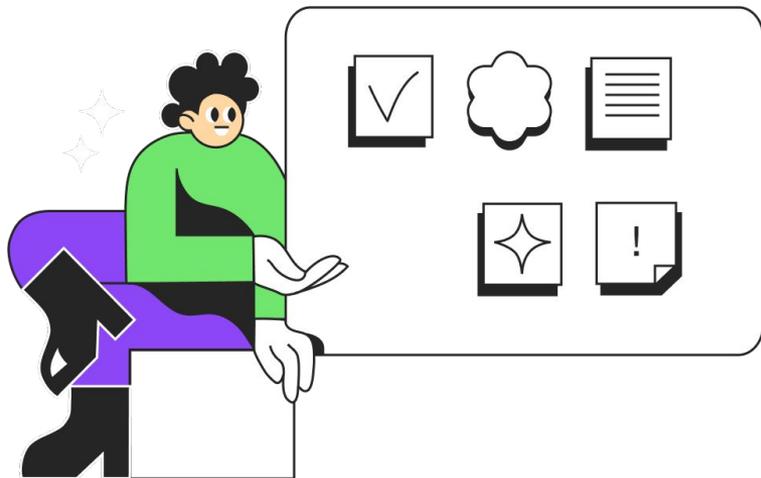
$SE_{\text{difference}} = (SE_A^2 + SE_B^2)^{1/2}$

0.00072



## На этом уроке мы разобрали

- 💡 Освежили базовые понятия из статистики
- 💡 Принцип проверки статистических гипотез
- 💡 Популярные статистические критерии





## На следующем уроке мы рассмотрим:

- Для чего рассчитывать длительность теста?
- Как понять сколько дней держать а/б тест ?
- Какой объем выборки нужен?
- Когда останавливать тест?