

Занятие 3

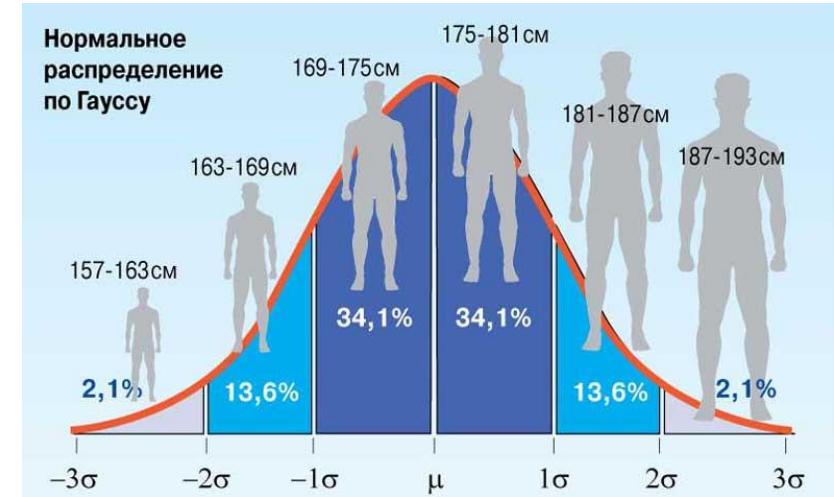
Непараметрические критерии

**С точки зрения анализа данных их удобнее
разбить на 3 группы.**

I. Качественные распределением

признаки с нормальным

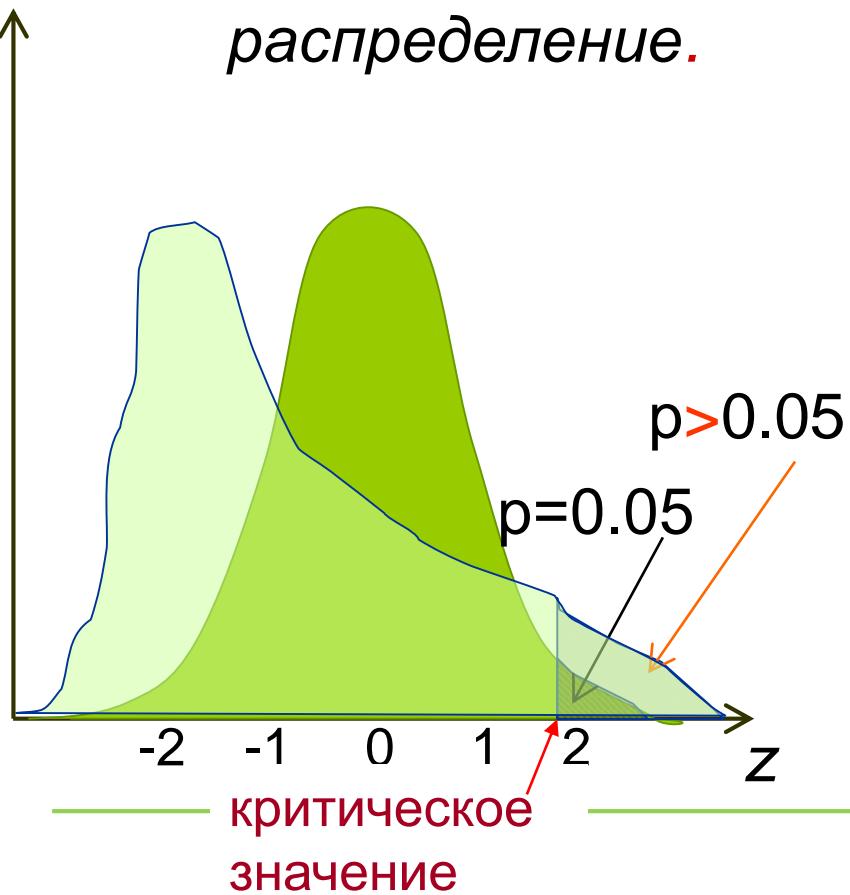
Используются для анализа
параметрические тесты



Они задействуют в расчётах **параметры** известных распределений, главным образом — параметры нормального распределения (математическое ожидаемое μ «мю» и стандартное отклонение σ «сигма»).

Почему при проведении параметрических тестов важно соблюдать **условие нормальности распределения**?

Распределение **статистики критерия не будет нормальным**, если в выборке не нормальное распределение.



Вероятность, что среднее в выборке попадёт в критическую область (рассчитанную для нормального распределения), будет выше, чем 0.05 – **увеличится ошибка 1-го рода**

Основной вывод:

пренебрежения условиями использования параметрических тестов может **увеличивать ошибку 1-го рода** (отвергнута верная нулевая гипотеза об отсутствии связи между явлениями или искомого эффекта)

(Неизвестно, насколько)

Примечание: слабые отклонения от нормального распределения не очень страшны (в силу Центральной предельной теоремы), а **для больших выборок ими можно пренебречь** (кроме регрессионного анализа).

ANOVA устойчива к отклонениям от нормального распределения, особенно если выборки одинаковы по размеру.

II. Качественные признаки с ненормальным распределением и порядковые признаки

Если нет уверенности в нормальности распределения признака или распределение неизвестно анализ данных можно провести 3-мя способами:

- 1) **нормализовать данные** с помощью преобразований шкалы (логарифмирование, преобразование арксинуса, Бокса — Кокса и др.) и использовать далее параметрические методы;
- 2) использовать **непараметрические методы**. Способ традиционен и популярен (медианы и квартили, корреляция Спирмена, критерии Уилкоксона — Манна — Уитни, Краскела — Уоллиса, Фридмана и др.).

3) работать с исходными непреобразованными данными методами, устойчивыми к отклонениям от нормальности.

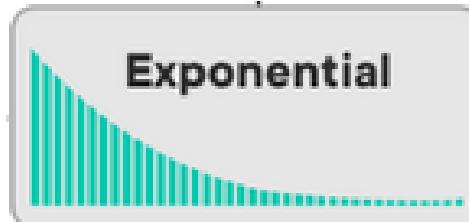
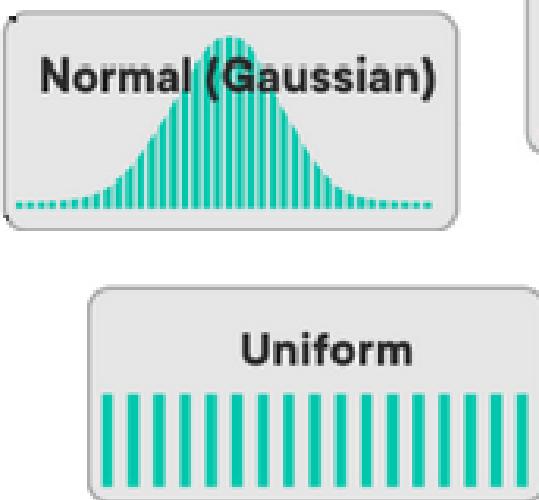
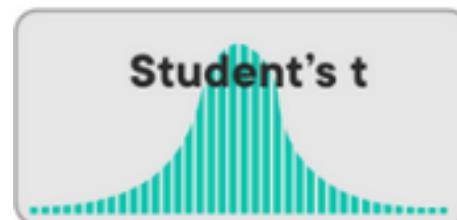
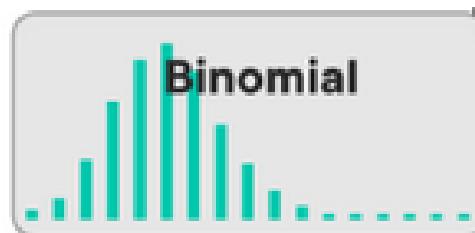
Это **методы робастной статистики** (усечённые средние или отличные от среднего М-оценки, средние абсолютные отклонения вместо среднеквадратичных и т. д.), или современные **ресэмплинг-техники**, основанные на вычислительных возможностях компьютеров (складной нож, бутстреп, *рандомизационные методы Монте-Карло*).

III. Качественные признаки (см. занятие «Анализ качественных»)

Распределения бывают

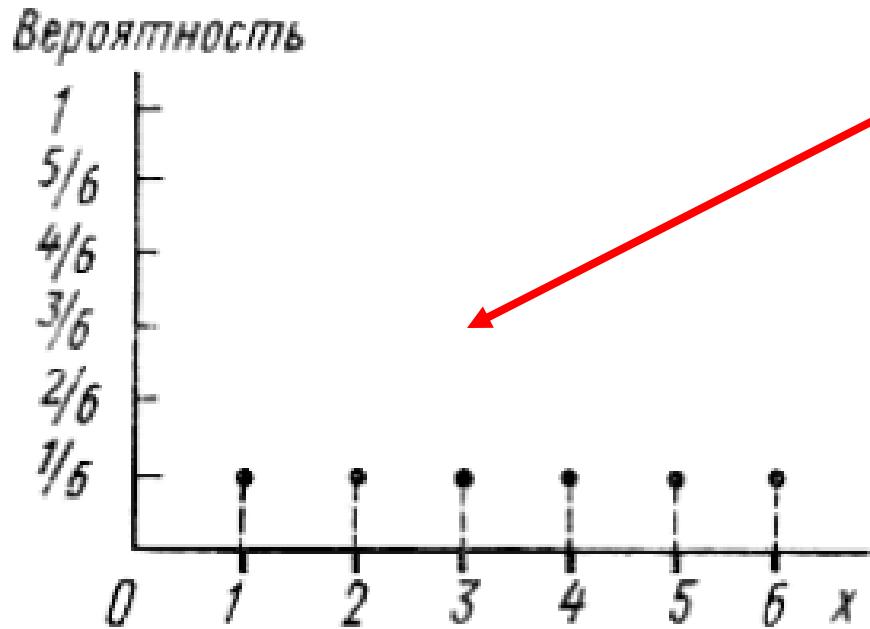
Природные (нормальное, биномиальное, Пуассона, экспоненциальное, лог-нормальное и пр.)

Распределения статистик критериев (t, F, U ...)



Равномерное (uniform)

Случайная величина имеет **дискретное равномерное распределение**, если она принимает конечное **число значений с равными вероятностями**.



Распределение вероятностей
дискретного равномерного
распределения ($n=6$).

Может быть и дискретным, и непрерывным

Биномиальное распределение

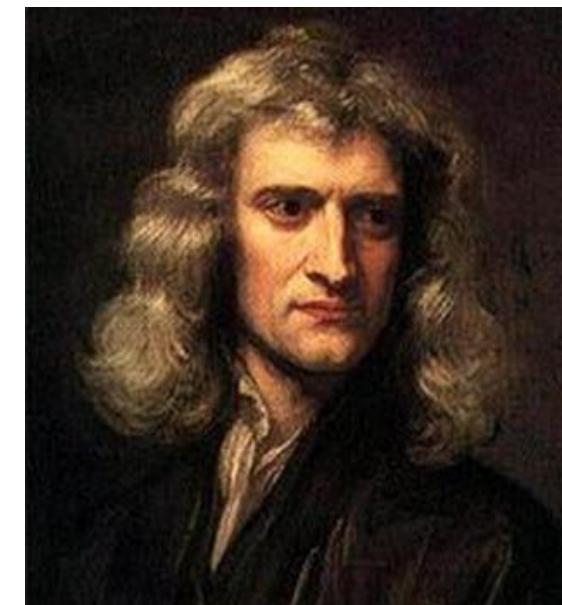
Одно из важнейших распределений вероятностей дискретно изменяющейся случайной величины. Введено в науку швейцарским математиком и одним из основателей теории вероятностей - **Якобом Бернулли** и опубликовано в **1713 году**.



Якоб Бернулли
(*Jakob Bernoulli* 1655–1705)

Вероятности
представляют собой
члены бинома
Ньютона, благодаря
чему распределение и
получило своё название.

Биномиальному
распределению обычно
соответствуют **доли**,
частоты, пропорции



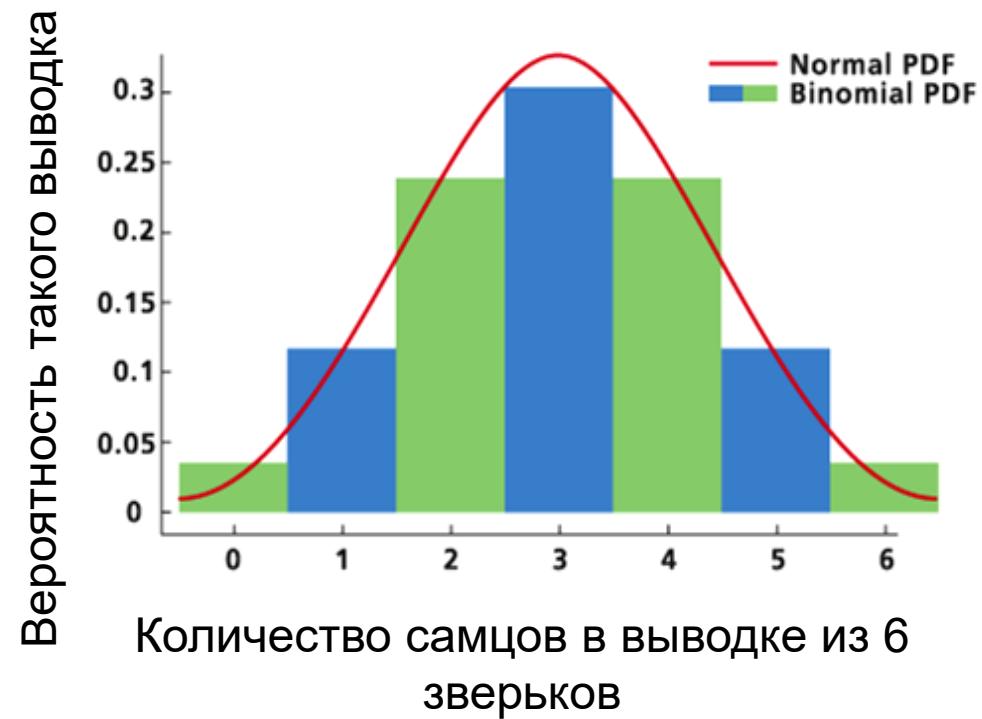
Исаак Ньютон
(*Isaac Newton* 1643-1727)

Пример: рассмотрим выводки из 6 детёнышей каждый.
Возможное соотношение самцов и самок в выводке:

6:0; 5:1; 4:2; 3:3;
2:4; 1:5; 0:6



Распределение
количество самцов в N
выводков (независимых
случайных экспериментов) из
 $n = 6$ зверьков, таких что
вероятность рождения
самца постоянна и равна
 p , а вероятность рождения
самки $q = 1 - p$.



Если p мало, ситуация лучше описывается распределением Пуассона

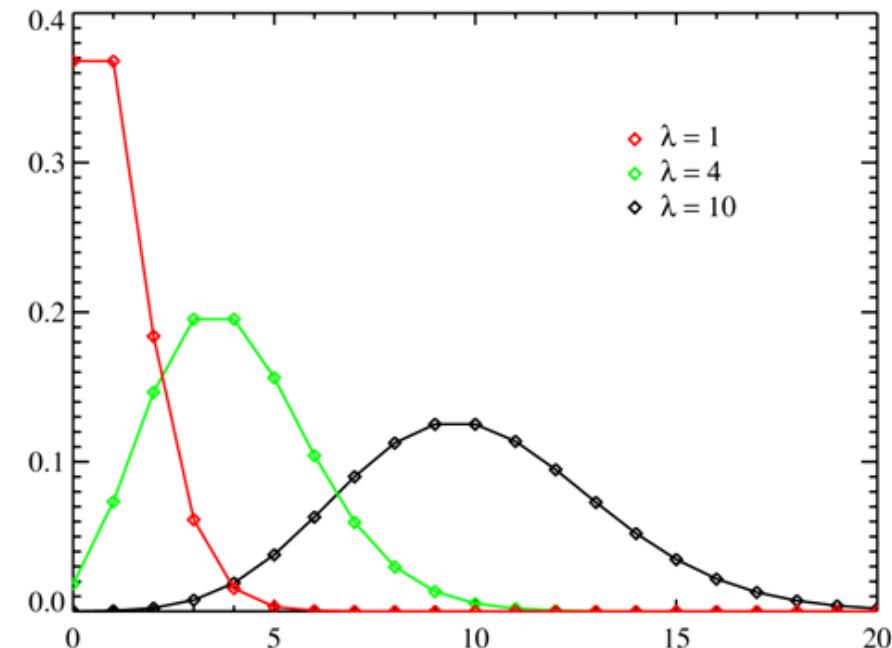
Распределение Пуассона

Показывает вероятность того или иного количества независимых друг от друга **редких и случайных** событий (особей и пр.) на заданном интервале времени (участке пространства, объёме...).



$$\mu = \sigma^2$$

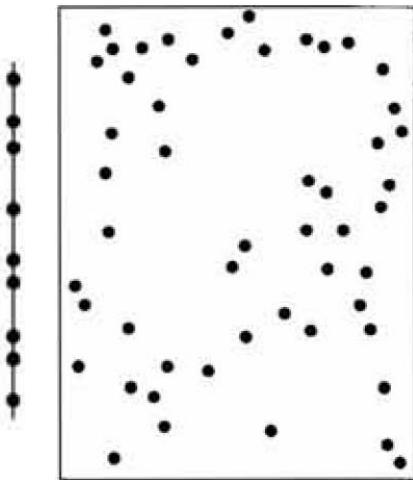
Симеон Дени Пуассон
(*Siméon Denis Poisson 1781-1840*)



Распределение имеет один **параметр λ** (греческая буква «лямбда») – **среднее количество успешных испытаний в заданной области возможных исходов.**

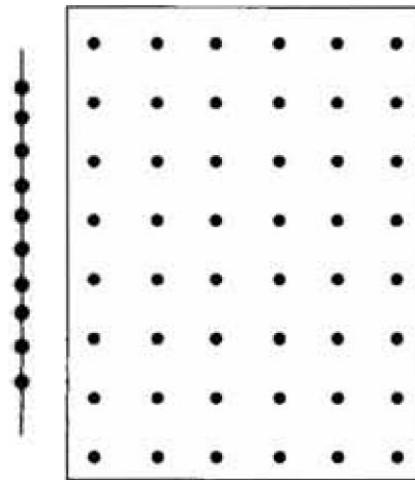
Распределению Пуассона соответствуют **частоты**, количества случайно распределённых объектов

Сравнение распределения объектов во времени и пространстве со случайным распределением (testing for randomness)



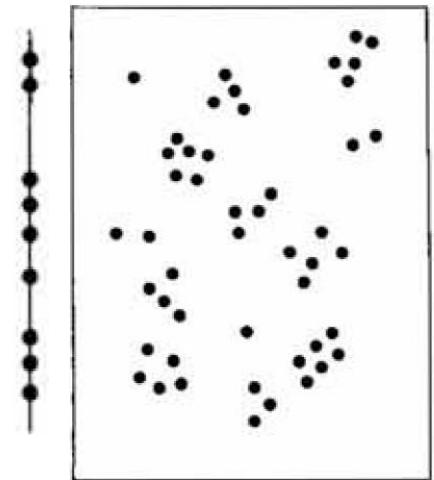
случайное

$$\sigma^2 = \mu$$



равномерное

$$\sigma^2 < \mu$$



групповое

$$\sigma^2 > \mu$$

Важно: следует задавать размер элементарной единицы пространства (времени и пр.), напр., квадрата, так, чтобы $\mu \approx 1$

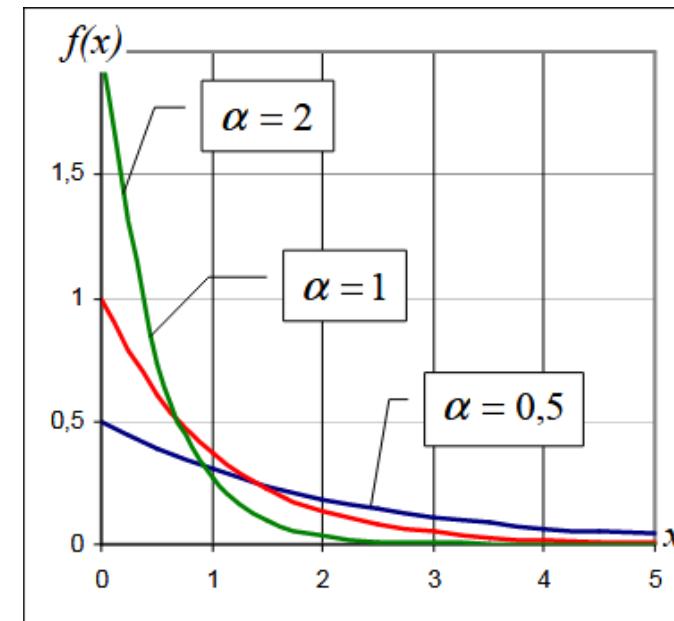
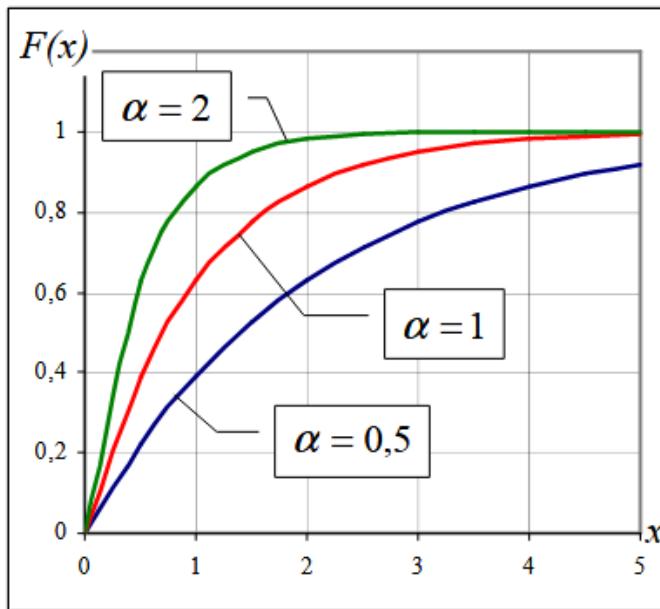
Экспоненциальное распределение

Хорошо описывает распределение промежутков времени (расстояний) между случайными событиями с заданной средней частотой событий.

$$F(x) = 1 - e^{-\alpha x},$$

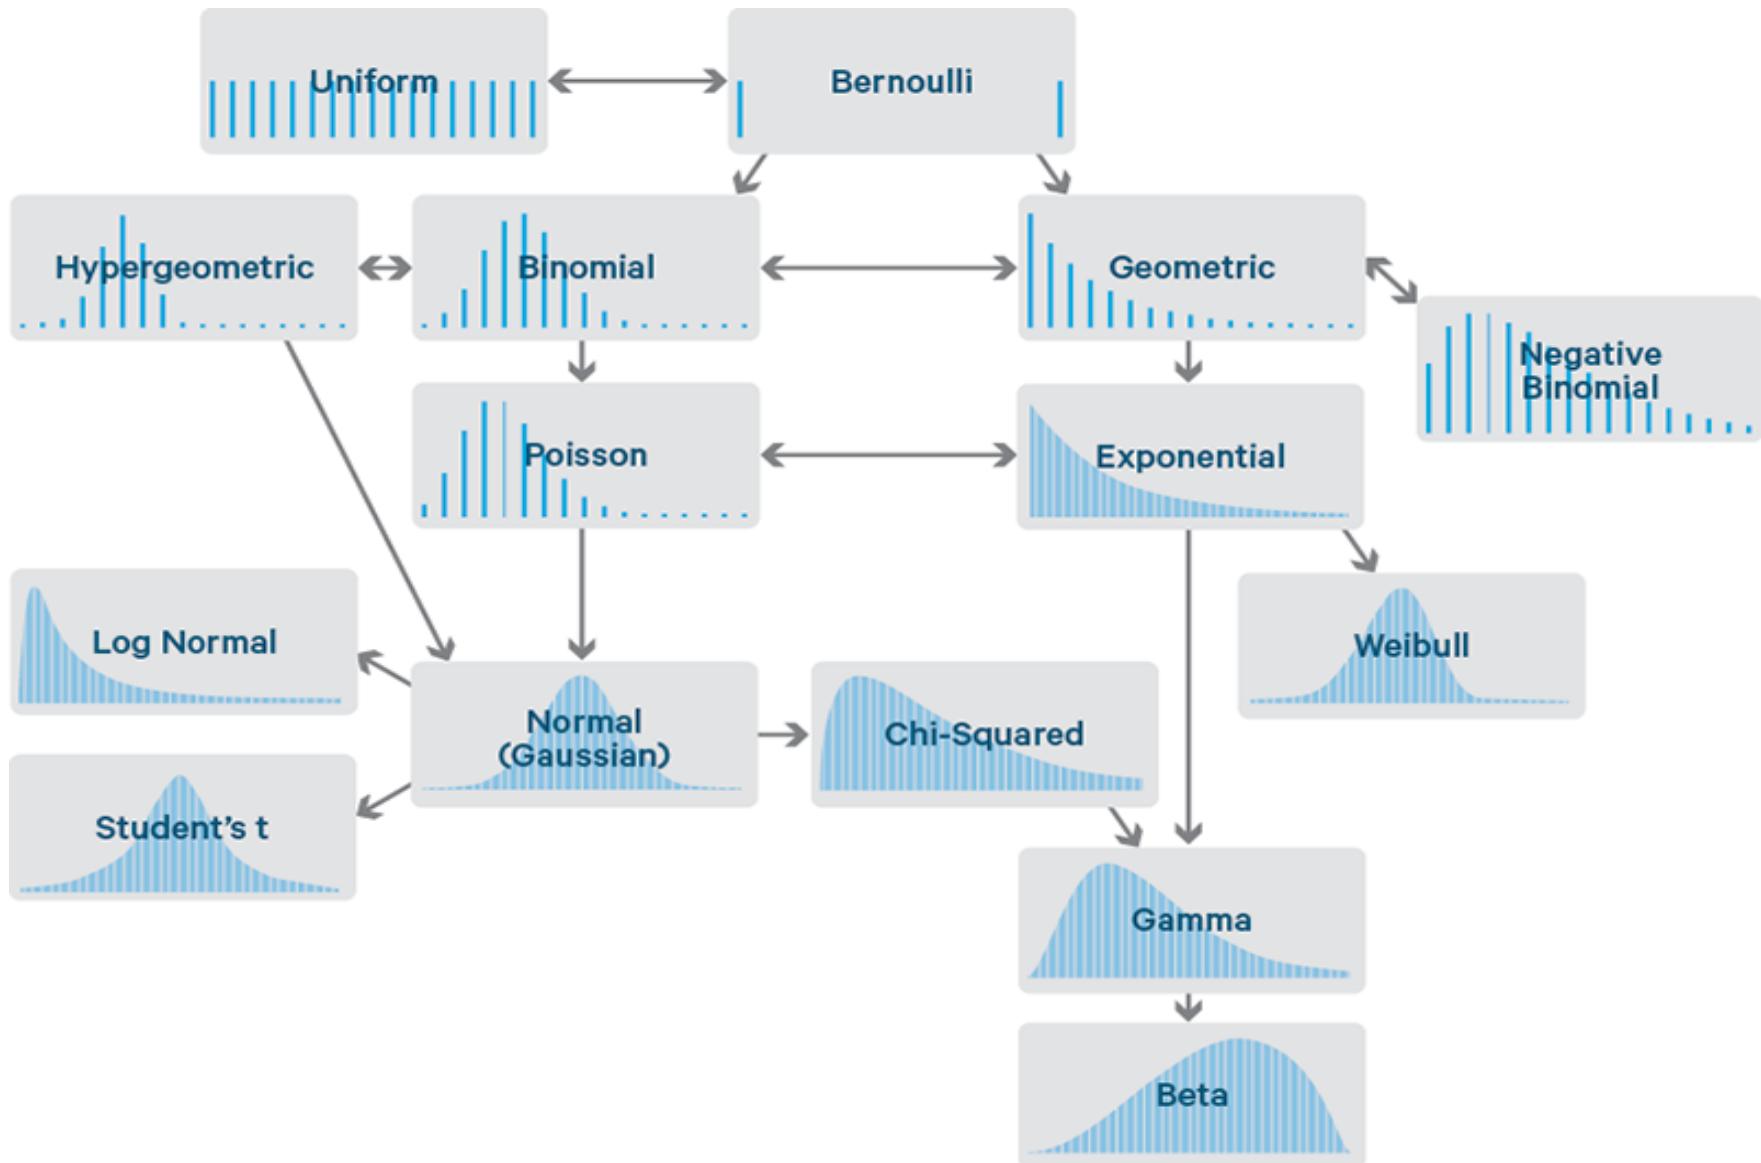
$$f(x) = \alpha e^{-\alpha x},$$

где $\alpha > 0$ – параметр распределения; $x \geq 0$ – непрерывная случайная величина.



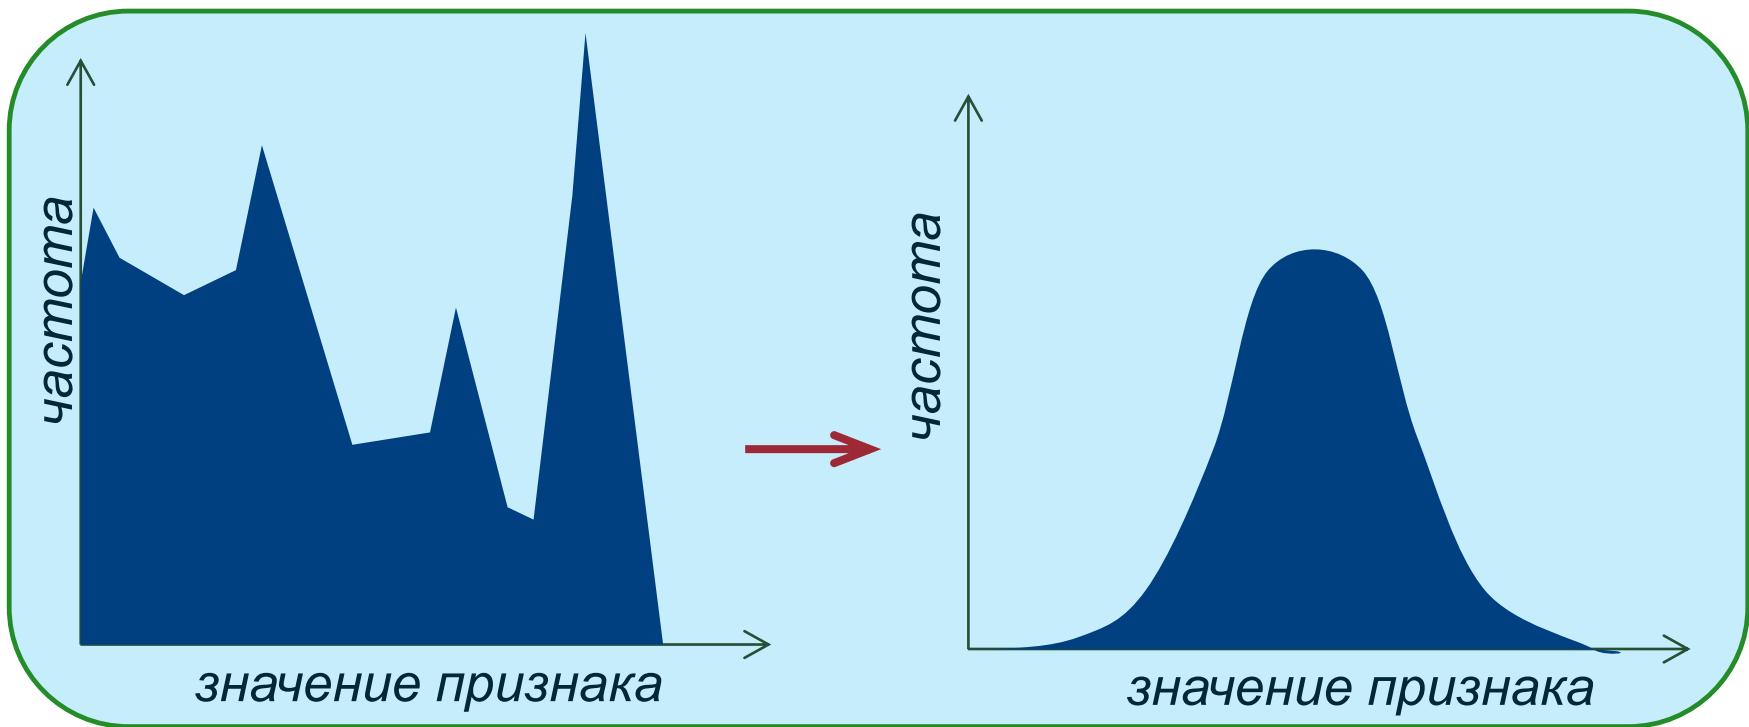
Функция и плотность экспоненциального распределения для трех значений параметра: $\alpha=5,0 ; \alpha=1 ; \alpha=2$

Типы распределений



Трансформация данных

Если распределение отлично от нормального, выборки не гомогенны, факторы мультипликативны, можно
ТРАНСФОРМИРОВАТЬ данные



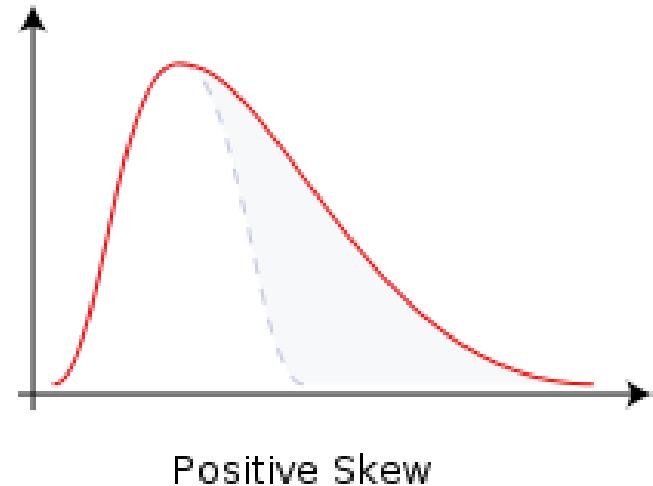
Прекрасное свойство: часто трансформация данных приводит одновременно к нормальному распределению, гомогенности и аддитивности

1. Логарифмическая трансформация (*logarithmic transformation*):

- Делает симметричным скошенное вправо (positively skewed) распределение.
- Используется в случае, когда среднее значение в группе прямо пропорционально стандартному отклонению.

$$X'_i = \lg X_i$$

$$X'_i = \lg(X_i + 1)$$



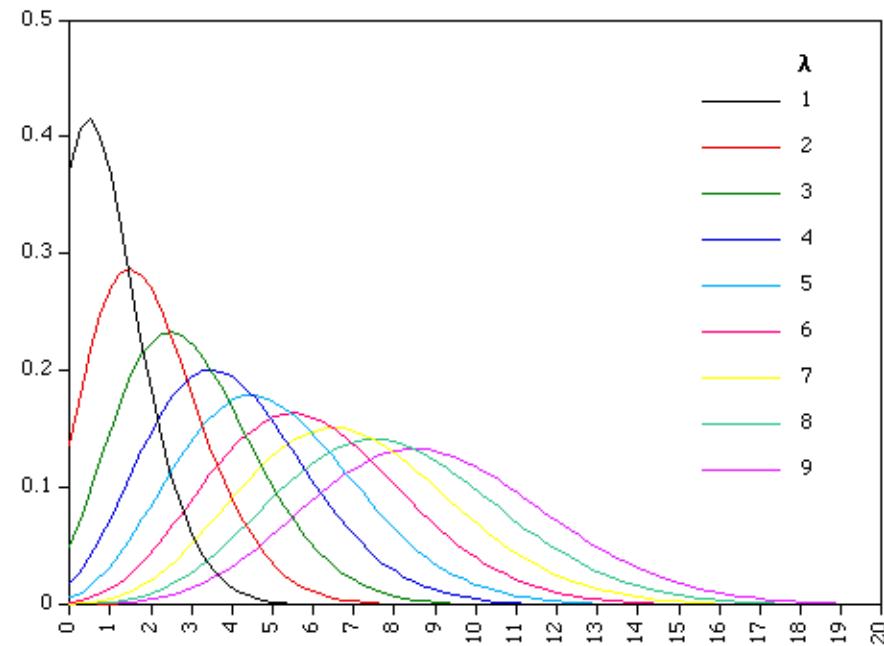
Если в результате логарифмирования получилось нормальное распределение, исходное распределение было **логнормальным**.

2. Извлечение квадратного корня (*square root transformation*)

- Используется, когда среднее значение в группе прямо пропорционально дисперсии.
- обычно такое явление свойственно выборкам из **распределения Пуассона** (т.е., данные представляют собой количества случайных событий, объектов...)

$$X'_i = \sqrt{X_i}$$

$$X'_i = \sqrt{X_i + 0,5}$$

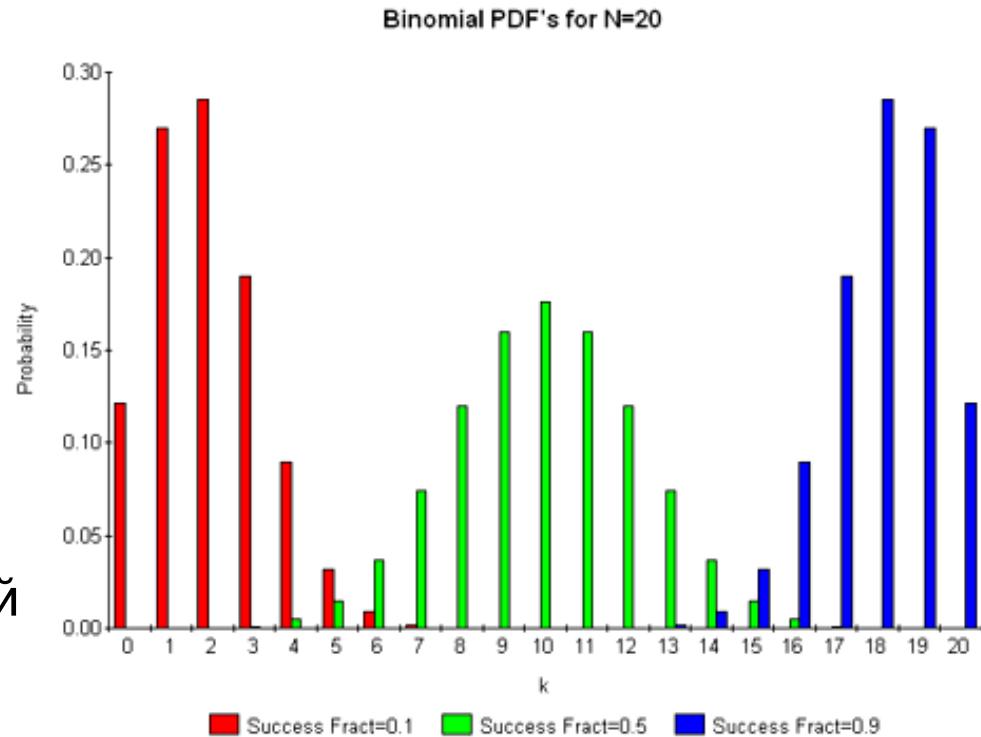


3. Арксинусная трансформация (*arcsine transformation*)

применяется для процентов и долей ($X_i \leq 1$), которые обычно формируют биномиальное распределение.

$$X'_i = \arcsin \sqrt{X_i}$$

Например, мы исследуем долю самцов или долю переживших зиму детёнышей в выводках сурков.



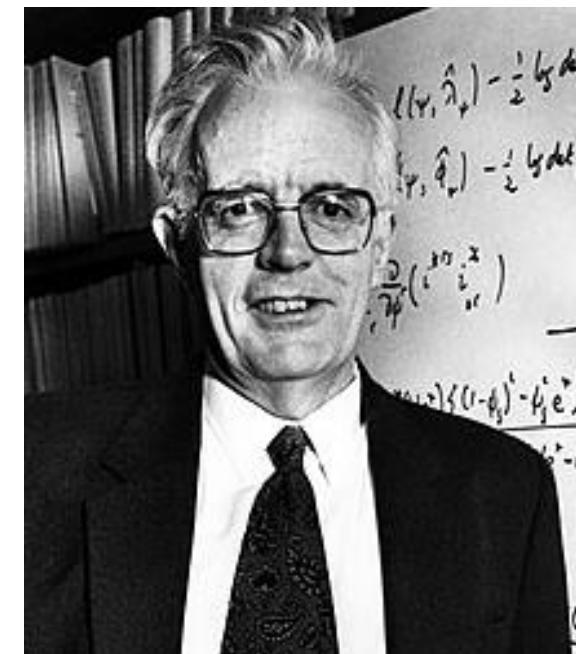
4. Бокс-Кокс преобразование (*Box-Cox transformation*)

Среди множества методов преобразований одним из лучших (при неизвестном типе распределения) считается Бокс-Кокс преобразование.



Сущность метода
впервые была
изложена в **1964 году**,
в Журнале
Королевского
статистического
общества, известными
статистиками –
Джорджем Боксом и
сэром Дэвидом Коксом

Джордж Бокс
(George E. P. Box 1919-2013)



Дэвид Кокс
(David Roxbee Cox 1927)

Универсальная трансформация данных, в которой программа методом проб подбирает наилучшие параметры и способ трансформации для конкретных данных (ищется особый параметр λ)



В зависимости от значения лямбда, преобразование Бокса-Кокса включает в себя следующие частные случаи:

$\lambda = -1.0,$	$x_i(\lambda) = \frac{1}{x_i}$
$\lambda = -0.5,$	$x_i(\lambda) = \frac{1}{\sqrt{x_i}}$
$\lambda = 0.0,$	$x_i(\lambda) = \ln(x_i)$
$\lambda = 0.5,$	$x_i(\lambda) = \sqrt{x_i}$
$\lambda = 2.0,$	$x_i(\lambda) = x_i^2$

При использовании Бокс-Кокс преобразования необходимо, чтобы все значения входной последовательности были положительными и отличными от нуля.

Box-Cox transformation

Трансформация Box-Cox.dat

File Edit Transform Plot Univariate Multivariate Model Diversity Timeseries Geometry Stratigraphic

Show Log
 Row at Subtract mean
 Column Remove trend

Type Convert to ranks
Row percentage
Row normalize length

Name **Box-Cox** Bands Binary

Исходные данные	Трансформированные
-	-
151	5,11761602183518
145	5,07544422330792
99	4,67918786483493
123	4,90443520177034
134	4,99342555438293
147	5,08969082103865
135	5,00115283513417
139	5,03150431271104
140	5,03895676730543
143	5,06100131726685
79	4,72222244261772

Box-Cox transformation

Lambda: 0,0433171

Log likelihood: -385

Если распределение не удовлетворяет условиям параметрических тестов и трансформация не помогает или невозможна, спользуем

Непараметрические методы (nonparametric methods)

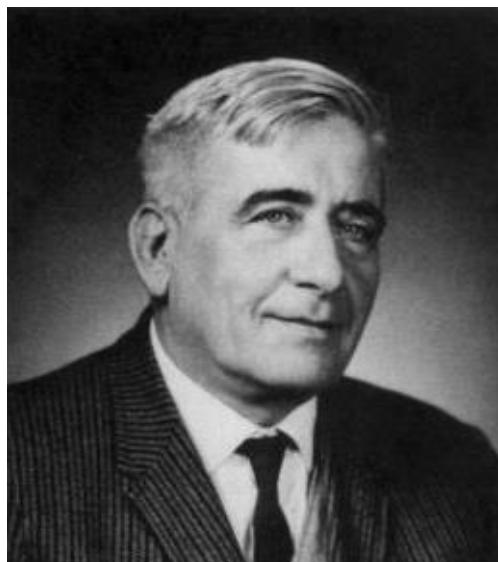
= “distribution-free” tests

- ✓ Свойства распределения неизвестны, и **параметры распределения** (среднее, дисперсию и т. п.) мы использовать не можем
- ✓ Основной подход – ранжирование (*ranking*) наблюдений (выстраиваем их по порядку от самого маленького значения к наибольшему).
- ✓ подразумевается, что сравниваемые распределения имеют одинаковую форму и дисперсию.

Сравнение 2-х независимых групп

Манн-Уитни тест (*Mann-Whitney U-test*)

В 1947 году двумя американскими математиками – **Манном** и **Уитни** для сравнения 2-х независимых выборок был предложен **непараметрический тест**.



Непараметрический аналог теста Стьюдента.

Является развитием идей Франка Уикоксона изложенных в 1945 году. Поэтому в ряде случаев называется – тест **Уикоксона-Манна-Уитни**



Генри Манн
(Henry Berthold Mann
1900-2000)

Дональд Рэнсом Уитни
(Donald Ransom Whitney
1915—2001)

Пример. Мы исследуем две линии лабораторных мышей. Хотим сравнить размеры выводков у этих зверей.

Фактор – линия: 1. белые (BaLB/C); 2. черные (C57BL/6)

Зависимая переменная – размер выводка



белые



черные

H_0 : размер выводка у белые мышей такой же, как и у черных.

H_1 : размер выводка не одинаков у этих линий.

Мы ничего не говорим про параметры распределений!

Тест Манна-Уитни можно использовать и для ранговых, и для непрерывных переменных.

белые		черные	
размер	ранг	размер	ранг
8	15.5	4	5
7	13	7	13
4	5	5	8.5
7	13	8	15.5
9	17.5	3	2
3	2	3	2
5	8.5	5	8.5
6	11	4	5
9	17.5		
5	8.5		
111.5		59.5	

Ранжируем данные от меньшего к большему (**игнорируя** деление на группы).

Число 3 встретилось трижды (это называется **связанные ранги**, *tied ranks*): ранги у них будут одинаковы $(1+2+3)/3=2$

Статистика критерия:

$$U_1 = n_1 n_2 + \frac{n_1(n_1 + 1)}{2} - R_1$$

$$U_2 = n_1 n_2 + \frac{n_2(n_2 + 1)}{2} - R_2$$

n_1 и n_2 – размер выборок,
 R_1 и R_2 – суммы рангов в выборках.

Статистикой критерия U_{obs} будет **меньшее** из этих двух значений. Причём H_0 мы отвергнем в случае, если оно будет **МЕНЬШЕ** критического значения U_{cv} . (т.е., это исключение среди прочих критериев).

Подставим наши данные в формулы:

$$U_1 = 10 \times 8 + \frac{10(8+1)}{2} - 115,5 = 135 - 115,5 = 23,5$$

$$U_2 = 10 \times 8 + \frac{8(8+1)}{2} - 59,5 = 116 - 59,5 = 56,5$$

$$U_{cv} = 20, \text{ при } p=0,05$$

$$U_{obs} = 23,5$$

$$U_{obs} > U_{cv}$$



n_1	2	3	4	5	6	7	8	9	10	11	12
n_2	$p=0,05$										
3	-	0									
4	-	0	1								
5	0	1	2	4							
6	0	2	3	5	7						
7	0	2	4	6	8	11					
8	1	3	5	8	10	13	15				
9	1	4	6	9	12	15	18	21			
10	1	4	7	11	14	17	20	24	27		
11	1	5	8	12	16	19	23	27	31	34	
12	2	6	10	13	17	21	26	30	34	38	

Следовательно статистически значимых различий в величине выводка у разных линий мышей не наблюдается ($U=23,5, p<0,05$)

Тест Колмогорова-Смирнова

(Kolmogorov-Smirnov two-sample test).



Колмогоров
Андрей Николаевич
(1903-1987)

Отличается от М-У теста тем, что М-У более чувствителен к различиям средних значений, медианы и т.п., а К-С тест более чувствителен к различиям распределений по форме.



Смирнов
Николай Васильевич
(1900-1966)

Манн-Уитни тест более мощный, чем этот тест.

Mann-Whitney U-test Kolmogorov-Smirnov two-sample test



В пакете PAST

Плодовитость лабораторных мышей.dat

File Edit Transform Plot **Univariate** Multivariate Model Diversity Timeseries Geometry Stratigraphy Script Help

Show

Row attributes Column attributes

	Белые мыши
1	• 8
2	• 7
3	• 4
4	• 7
5	• 9
6	• 3
7	• 5
8	• 6
9	• 9
10	• 5
11	•
12	•

Summary statistics

One-sample tests (t, Wilcoxon, single-case)

Two-sample tests

ANOVA etc. (several samples)

Correlation

Intraclass correlation

Normality tests

Contingency table (chi² etc.)

Mantel-Cochran-Haenszel test

Risk/odds

Single proportion test

Multiple proportion CIs

Ratios of counts CI

Survival analysis

Combine errors

View

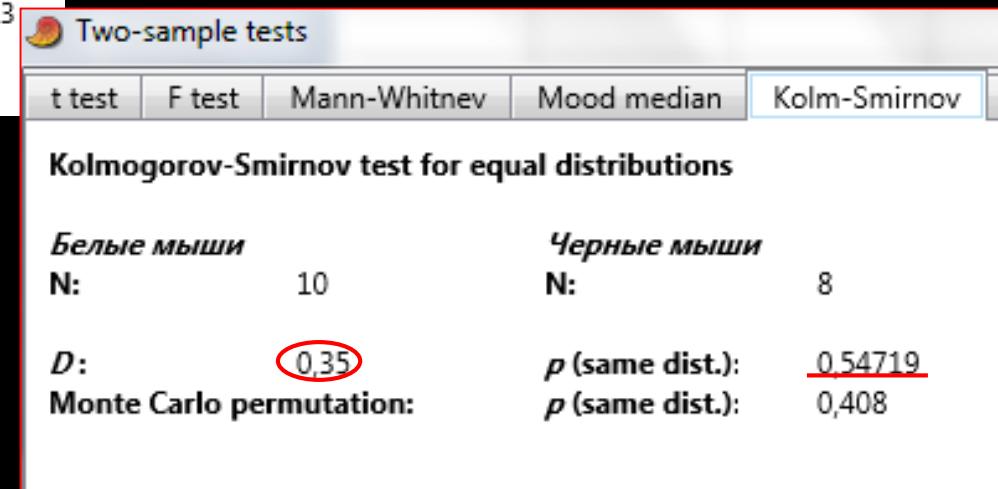
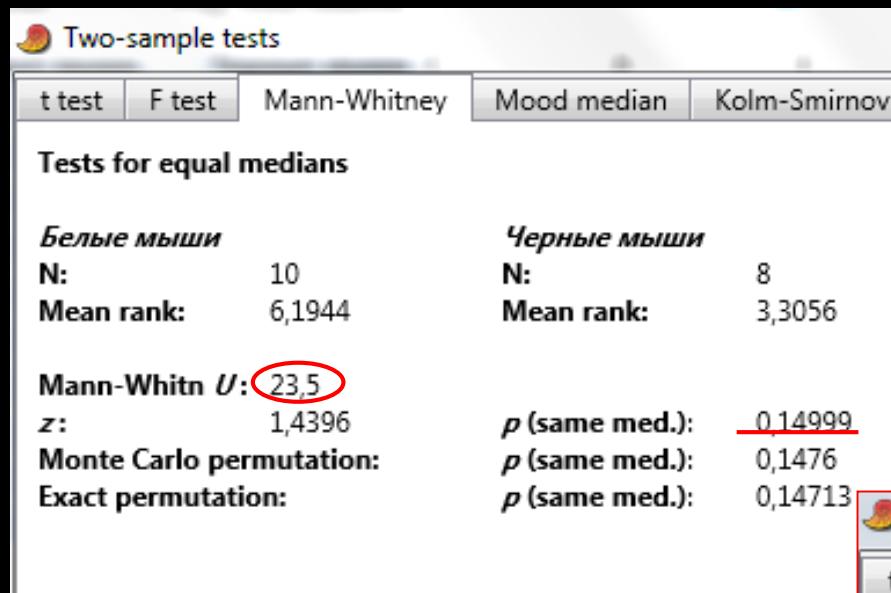
Bands Recover windows

Two-sample tests (F, t, Mann-Wh, Kolm-Sm etc.)

Two-sample paired tests

F and t tests from parameters

Не отвергаем H_0 : М-У тест показал, что размеры выводков у разных линий **одинаковые**



Сравнение 2-х связанных групп

Критерий Уилкоксона (*Wilcoxon matched pairs test*)

W критерий Уилкоксона - это непараметрический аналог парного критерия Стьюдента (t-критерия).



Фрэнк Уилкоксон
(*Frank Wilcoxon*
1892-1965)

Предложен **в 1945 году** американским химиком и статистиком **Френком Уилкоксоном** (создатель первого университетского курса по непараметрической статистике и первой научной школы непараметрической статистики).

Мощность – около 95% мощности t-теста. При числе пар >100 Т аппроксимируется нормальным распределением.

Пример. Сравниваем 2 метода определения тестостерона в пробах, и хотим знать – различается ли его содержание в зависимости от метода определения

H_0 : количество тестостерона при определении первым методом, **такое же**, как и вторым.

H_1 : количество тестостерона не одинаково.

Фактор – метод определения. (Метод 1; Метод 2)
Зависимая переменная – содержание тестостерона в пробе.



№ пробы	Метод 1	Метод 2	$D_i = X_{i1} - X_{i2}$	Ранг
1	0,49	0,40	0,09	5
2	0,71	0,61	0,10	6
3	0,96	0,84	0,12	8
4	0,41	0,35	0,06	3,5
5	0,48	0,51	-0,03	-2
6	0,71	0,60	0,11	7
7	0,41	0,42	-0,01	-1
8	0,52	0,52	0,00	
9	0,63	0,57	0,06	3,5

$$T_{\text{эмп}} = 1+2=3$$

По таблице критических значений критерия Вилкоксона определяем, что при $n=9$

$$T_{\text{кр}}=8, \text{ для } p \leq 0,05$$

$$T_{\text{эмп}} < T_{\text{кр}(0,05)}$$

Различия статистически значимы ($p < 0,05$)

1. Считывают разности между значениями в парах;

2. исключают нулевые разности;

3. присуждают абсолютным значениям (по модулю) разностей ранги;

4. суммируют отдельно ранги положительных и отрицательных разностей;

5. Наименьшая из этих сумм - статистика $T_{\text{эмп}}$.

6. Отвергаем H_0 , если $T_{\text{эмп}}$ меньше $T_{\text{кр}}$.

Wilcoxon matched pair test

Тестостерон два метода.dat

File Edit Transform Plot **Univariate** Multivariate Model Diversity Timeseries Geometry Stratigraphy Script Help

Show
Row attributes
Column attributes

Summary statistics
One-sample tests (t, Wilcoxon, single-case)
Two-sample tests
ANOVA etc. (several samples)
Correlation
Intraclass correlation

View
Bands Recover windows

Two-sample tests (F, t, Mann-Wh, Kolm-Sm etc.)
Two-sample paired tests
F and t tests from parameters

Two-sample paired tests

	Метод 1 Тестостерон (мг)	Метод 2 Тестостерон (мг)
N:	9	
Mean:	0,59111	0,53556
Median:	0,52	0,52

t test

Mean difference: 0,055556 95% conf.: (0,012567 0,098544)
t: 2,9801 p (same mean): 0,017598
Exact: p (same mean): 0,027344

Sign test

r: 6 p (same median): 0,28906

Wilcoxon test:

W: 33 p (same median): 0,035692
Normal appr. z: 2,1004 p (same median): 0,03852
Monte Carlo (n=99999): p (same median): 0,039063
Exact: p (same median): 0,039063

Содержание тестостерона при определении разными методами неодинаково (p=0,04)

Сравнение ≥ 3 -х независимых групп

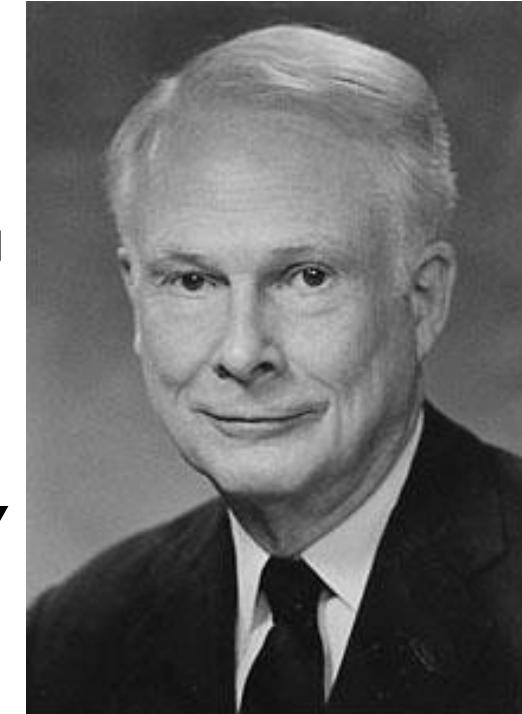
Тест Крускала-Уоллиса (*Kruskal-Wallis test*)



Уильям Крускал
(*William Kruskal*
1919-2005)

Непараметрический аналог
однофакторного
дисперсионного анализа и
предназначен для проверки
равенства медиан
нескольких выборок.

Предложенный в **1952 году**
американскими учеными –
математиком **Уильямом**
Крускалом и экономистом
Алленом Уоллесом



Уилсон Аллен Уоллис
(*Wilson Allen Wallis*
1912-1998)

- ✓ Непараметрический аналог One-way ANOVA
- ✓ на 95% настолько же мощный, как и ANOVA;
- ✓ для 2-х групп идентичен Манн-Уитни тесту;
- ✓ подразумевает сходство форм распределений и равенство дисперсий в группах (хотя бы на глаз)

Пример. Нас интересует, различается ли масса тела студентов, из разных групп разбитых по росту.

Фактор – рост. Группы: 1. 161-165 см.; 2. 166-170 см; 3. 171-175 см.; 4. 176-180 см.

Зависимая переменная – масса тела, кг.



H_0 : распределение в разных группах, из которых мы получили выборки, **одинаковое**.

H_1 : распределения не одинаковые.

1. все значения ранжируются от меньшего к большему (игнорируя деление на группы);
2. Считается сумма рангов в каждой группе;

Рост 161-165 см		Рост 166-170 см		Рост 171-175 см		Рост 176-180 см	
масса, кг	ранг						
59	4,5	63	9	67	11	73	17
53	1	61	7	68	12,5	79	20
60	6	68	12,5	74	18	71	15
54	2	62	8	72	16	75	19
57	3	64	10	69	14		
59	4,5						
Σ	21		46,5		71,5		71

3. считается статистика $H(df, N)$.

сумма рангов в
каждой группе

$$H = \frac{12}{N(N+1)} \sum \frac{R_j^2}{n_j} - 3(N+1)$$

общий размер
выборки

размер группы

$$H = \frac{12}{20 \times (20+1)} \left[\frac{21^2}{6} + \frac{46,5^2}{5} + \frac{71,5^2}{5} + \frac{71^2}{4} \right] - 3(20+1) = 16,676$$

При уровне значимости $\alpha = 0,01$ и числе степеней свободы

$df = k-1 = 4-1 = 3$, где k – число групп; $\chi^2_{\text{кр}} = 11,34$

$H > \chi^2_{\text{кр}}$

Следовательно **масса тела не одинакова** в разных группах.

Рост и масса тела студентов.dat

File Edit Transform Plot Univariate Multivariate Model Diversity Timeseries Geo

Show Click mode Edit

Row attributes Select Cut Paste

Column attributes Drag rows/columns Copy Select all

	Рост 161-165 см	Рост 166-170 см	Рост 171-175 см	Рост 176-180 см
1	• 59	63	67	73
2	• 53	61	68	79
3	• 60	68	74	71
4	• 54	62	72	75

Kruskal-Wallis test

File Edit Transform Plot **Univariate** Multivariate Model Diversity Timeseries Geometry Stratigraphy Script Help

Show Click mode Edit

Row attributes Select Cut Paste

Column attributes Drag rows/columns Copy Select all

Summary statistics

One-sample tests (t, Wilcoxon, single-case)

Two-sample tests

ANOVA etc. (several samples)

Correlation

Intraclass correlation

Normality tests

Contingency table (chi² etc.)

Mantel-Cochran-Haenszel test

Risk/odds

Single proportion test

Multiple proportion CIs

Ratios of counts CI

Survival analysis

Combine errors

View

Bands Binary Decimals: -

Recover windows

Several-sample tests (ANOVA, Kruskal-Wallis)

Several-sample repeated measures tests

Two-way ANOVA

Two-way ANOVA without replication

Two-way repeated measures ANOVA

One-way ANCOVA

1	• 59
2	• 53
3	• 60
4	• 54
5	• 57
6	• 59
7	•
8	•
9	•
10	•
11	•
12	•

Several-sample tests

One-way ANOVA Residuals Tukey's pairwise Kruskal-Wallis M

Kruskal-Wallis test for equal medians

$H(\chi^2)$: 16,68
 H_c (tie corrected): 16,7
 p (same): 0,0008143

There is a significant difference between sample medians

H_c (tie corrected) - H -критерия с поправкой на связанные значения (одинаковые значения в разных группах)

Масса тела студентов статистически значимо отличается в разных по росту группах ($H_{(2)} = 6,70; P < 0,001$).

Множественные апостериорные парные сравнения (*post-hoc comparisons*)

Как и в ANOVA, после сравнения нескольких групп имеет смысл провести **множественные апостериорные сравнения** (*post-hoc comparisons*), по аналогии с тестом Тьюки, чтобы выяснить какие же группы различаются.

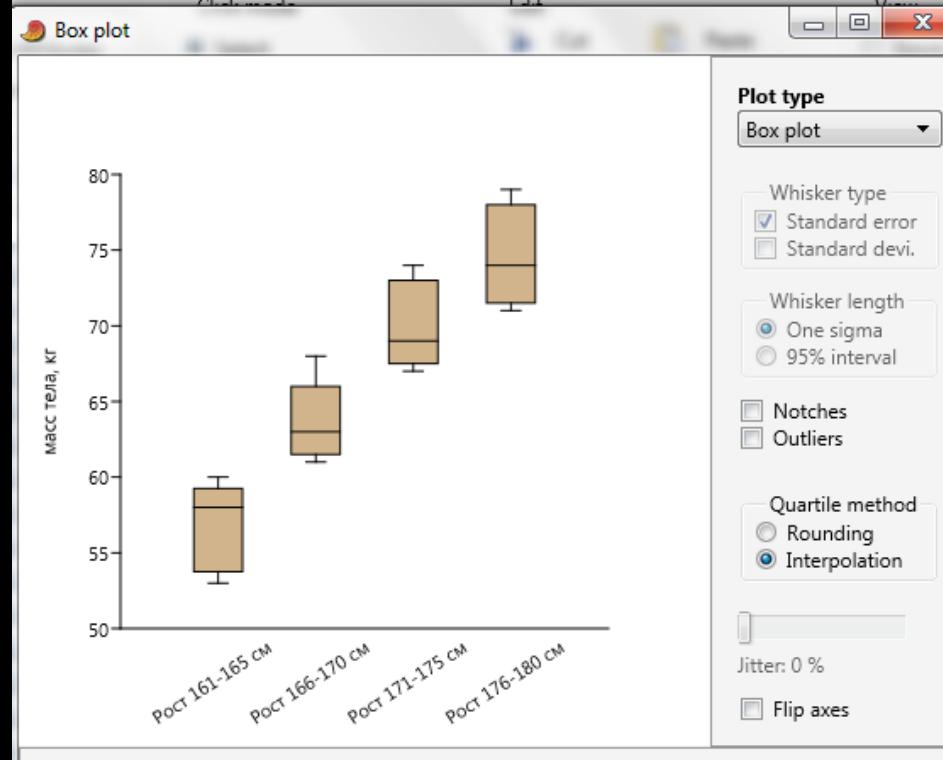
Такие тесты существуют – **Данна** (*Dunn's test*), **Манн-Уитни** (*Mann-Whitney pairwise*), **Неменьи** (*Nemenyi test*).

В ходе решения нашего примера далее для парного сравнения используем непараметрический **критерий Данна** (*Bonferroni–Dunn post hoc test*, *Dunn's multiple comparison post – test*).

Критерий применим для независимых групп как равной, так и различной численности.

Several-sample tests

	One-way ANOVA	Residuals	Tukey's pairwise	Kruskal-Wallis	Mann-Whitney pairwise	Dunn's post hoc
	Raw p values, uncorrected significance					
	Рост 161-165 см	Рост 166-170 см	Рост 171-175 см	Рост 176-180 см		
Рост 161-165 см		0,1052	0,002553	0,0001882		
Рост 166-170 см	0,1052		0,1811	0,03311		
Рост 171-175 см	0,002553	0,1811		0,3843		
Рост 176-180 см	0,0001882	0,03311	0,3843			



Пост-хок тест для непараметрической ANOVA

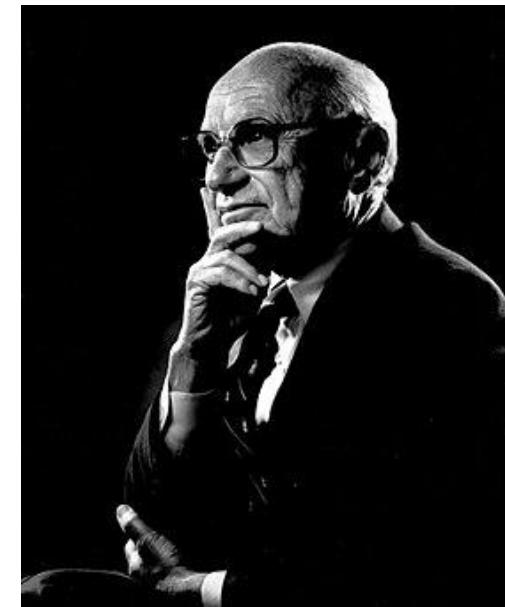
Сравнение ≥ 3 связанных групп

Критерий Фридмана (*Friedman ANOVA*)

Непараметрический статистический тест, аналог дисперсионного анализа с повторными измерениями ANOVA.

Разработанный американским экономистом, нобелевским лауреатом по экономике Милтоном Фридманом.

Является обобщением критерия Уилкоксона на большее, чем 2, количество условий измерения.



Милтон Фридман
(*Milton Friedman 1912-2006*)

По сравнению с аналогичными параметрическими тестами, для 2-х групп имеет всего 64% мощности, для 3-х – 72%, для 100 стремится к 95%.

Пример. Группа из шести человек, желающих отказаться от курения. Проводилось измерение жизненной емкости легких (ЖЕЛ) в динамике:

1. На момент включения в группу;
2. Через 1 месяц после отказа от курения;
3. Через 2 месяца после отказа от курения



1. Значения ранжируются меньшего к большему внутри каждой **строки**.

2. Суммируют ранги для каждого столбца и считают статистику χ^2_r , которая имеет распределение χ^2 .

Группа наблюдения	На момент обследования		Через 1 месяц		Через 2 месяц	
	ЖЕЛ	ранг	ЖЕЛ	ранг	ЖЕЛ	ранг
1	2	1,5	2	1,5	3	3
2	2,1	1	3,1	2	4	3
3	2,4	2	2,1	1	3,5	3
4	2,5	1	3,5	2	4	3
5	2,3	1	3	2,5	3	2,5
6	2,6	1,5	2,6	1,5	4	3
<i>Сумма рангов</i>		8		10,5		17,5

$$\chi^2 = \frac{12}{nk(k+1)} \sum_{j=1}^k T_j^2 - 3n(k+1),$$

где n – число наблюдений; k – количество повторных измерений; T_j – сумма рангов для повторных измерений j

$$\begin{aligned}\chi^2 &= \left[\frac{12}{6 \times 3 \times (3+1)} \times (8^2 + 10,5^2 + 17,5^2) \right] - 3 \times 6 \times (3+1) \\ &= 80,8 - 72 = 8,08\end{aligned}$$

3. Полученное значение сравнивается с критическим. При уровне значимости $\alpha = 0,05$ и числе степеней свободы $df = k-1 = 3-1 = 2$, где k – число групп; $\chi^2_{\text{кр}} = 5,991$
Наша статистика больше, поэтому нулевая гипотеза отвергается.

H_0 и H_1 - по аналогии с предыдущими тестами, о сходстве выборок.

Friedman ANOVA

ЖЕЛ и отказ от курения.dat

File Edit Transform Plot **Univariate** Multivariate Model Diversity

Show Click mode

Row attributes Select

Column attributes Drag rows/columns

Edit Cut Copy

	В момент обследования	через 1 месяц	через 2 месяца
1	• 2	2	3
2	• 2,1	3,1	4

File Edit Transform Plot **Univariate** Multivariate Model Diversity Timeseries Geometry Stratigraphy Script Help

Show

Row attributes Column attributes

View

Bands Binary Decimals: -

Recover windows

	В момент обследования
1	• 2
2	• 2,1
3	• 2,4
4	• 2,5
5	• 2,3
6	• 2,6
7	•
8	•
9	•
10	•
11	•
12	•
13	•

Summary statistics

One-sample tests (t, Wilcoxon, single-case)

Two-sample tests

ANOVA etc. (several samples)

Correlation

Intraclass correlation

Normality tests

Contingency table (chi² etc.)

Mantel-Cochran-Haenszel test

Risk/odds

Single proportion test

Multiple proportion CIs

Ratios of counts CI

Survival analysis

Combine errors

Several-sample tests (ANOVA, Kruskal-Wallis)

Several-sample repeated measures tests

Two-way ANOVA

Two-way ANOVA without replication

Two-way repeated measures ANOVA

One-way ANCOVA

Several-sample repeated measures tests

Repeated-measures ANOVA Tukey's pairwise Friedman test Wilcoxon pairwise

Test for equal medians

chi²: 8.0833
chi², tie corrected: 9.2381
chi², continuity corrected: 8.8031
p (same), asymptotic: 0.012258
p (same), exact: 0.0062241

Degrees of freedom: 2

Отвергаем H_0 –
ЖЭЛ изменилась

$$\chi^2_{(2)} = 9,24; P << 0,012$$

Several-sample repeated measures tests

Repeated-measures ANOVA Tukey's pairwise Friedman test Wilcoxon pairwise

Raw p values, uncorrected significance

	В момент обследования	через 1 месяц	через 2 месяца
В момент обследования		0.2941	0.04615
через 1 месяц	0.2941		0.09091
через 2 месяца	0.04615	0.09091	

Далее попарные сравнения групп методом Вилкоксона

В итоге, при выборе теста важно, что:

1. Параметрические тесты более мощные, чем непараметрические;
2. Непараметрические безопаснее в плане ошибки 1-го рода;
3. Чем больше размер выборки, тем менее критичны требования к распределению (по Центральной предельной теореме); для выборок $N \geq 100$ используют параметрические тесты даже при больших отклонениях от нормального распределения (кроме регрессий).
4. АНОВА не очень чувствительна к отклонениям от нормального распределения (для одинаковых по размеру групп).

Алгоритм выбора статистического критерия для сравнения *количественных данных*

Подчиняются ли данные закону нормального распределения?

Да

Нет

Являются ли группы независимыми, связанными или проводится сравнение с заданным значением?

Независимые

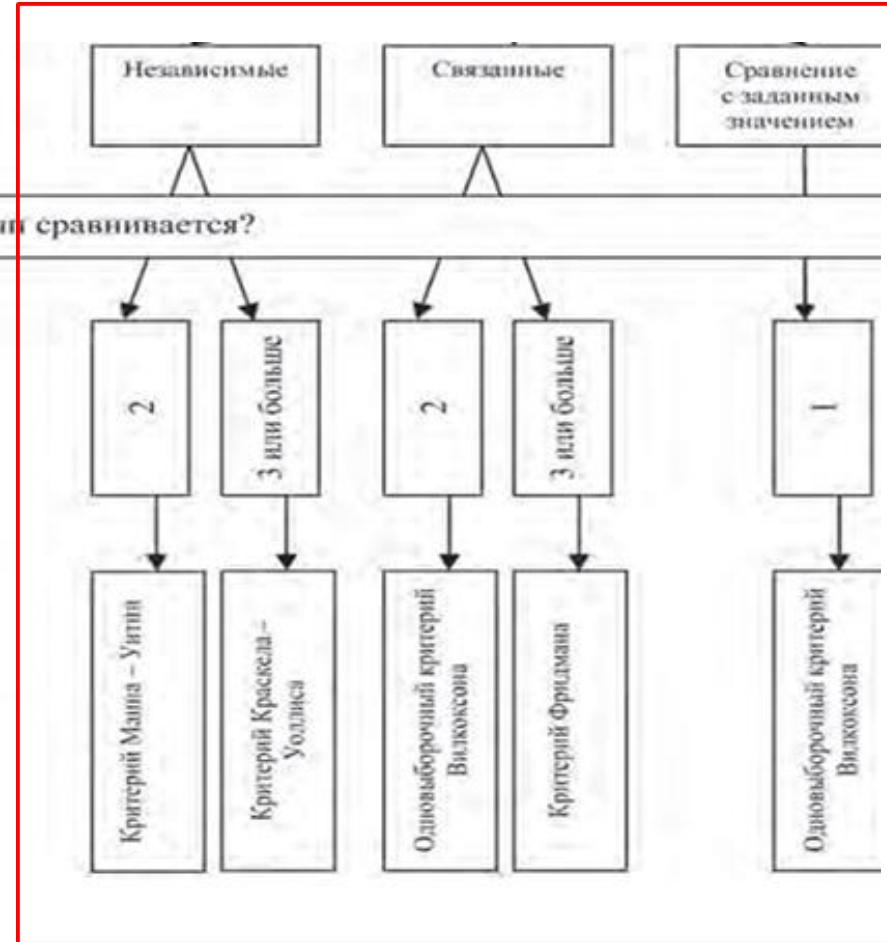
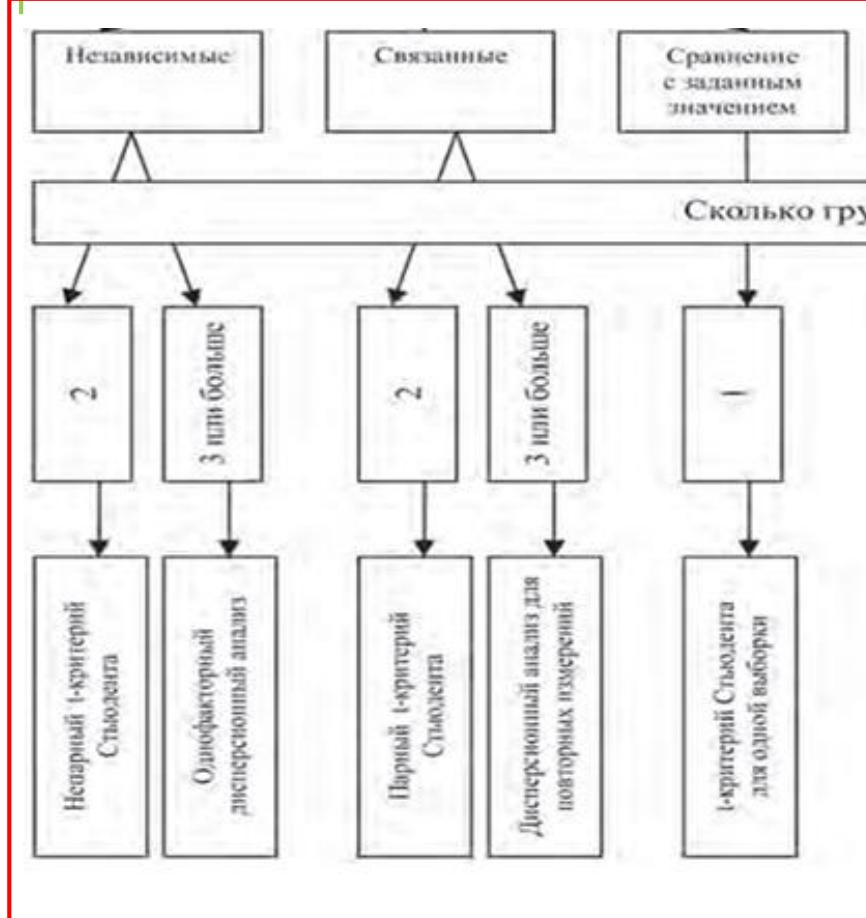
Связанные

Сравнение
с заданным
значением

Независимые

Связанные

Сравнение
с заданным
значением



Точечная и интервальная оценка

Термины точечная оценка (point estimation) и интервальная оценка (interval estimation) впервые использовал в **1943** году американский математик **Генри Шеффе** в статье «*Statistical Inference in the NonParametric Case*»

Точечная оценка определяется одним числом (среднее значение, стандартное отклонение и т.д.)

Интервальная оценка определяется двумя числами – концами интервала (доверительный интервал)



Генри Шеффе
(Henry Scheffé 1907-1977)

Доверительным интервалом (ДИ) называется интервал, в который попадают измеренные в эксперименте значения, соответствующие **доверительной вероятности**

Метод доверительных интервалов разработал американский статистик **Ежи Нейман** (термин доверительный введен им в **1934** году), исходя из идей Рональда Фишера



Ежи Нейман
(*Jerzy Neyman 1894-1981*)

ДИ, используемый статистике при **интервальной оценке** статистических параметров, более предпочтительной при небольшом объеме выборки, чем **точечная оценка**

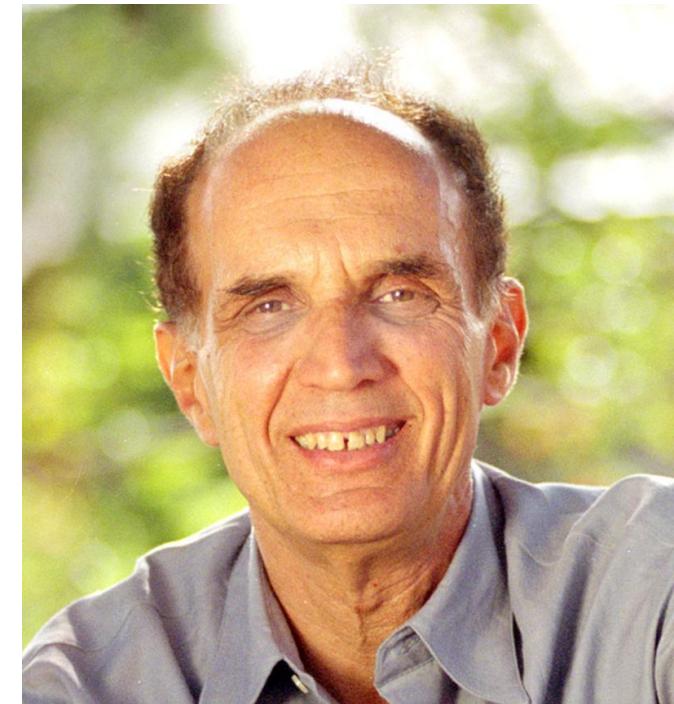
Бутстреп (bootstrap, bootstrapping)

Доверительный интервал можно построить с использованием *ресэмплинг-техник (resampling)*: методом складного ножа или более современным методом *бутстрепа*.

Бутстреп — это современная ресэмплинг-техника, то есть техника, основанная на взятии повторных (re...) выборок (...sample).

Понятие введено в **1977** году **Брэдли Эфроном** (первая публикация относится к 1979 году).

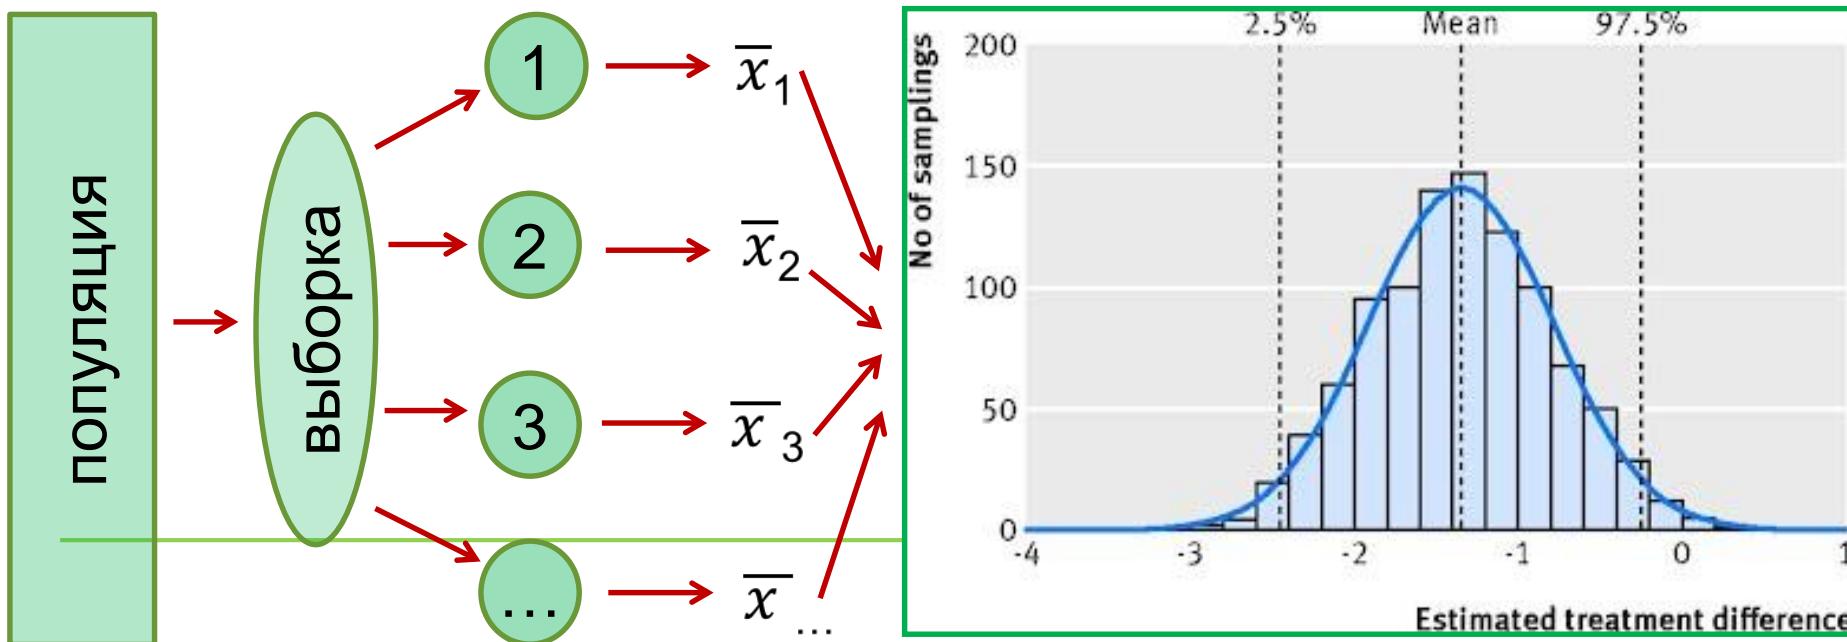
Данный метод является методом **непараметрической статистики**.



Брэдли Эфрон
(*Bradley Efron p.1938*)

Например - выборка 25 студентов, измерили рост. Выписываем значения на карточки, перемешиваем и случайным образом вытягиваем одну. Записываем результат и возвращаем карточку обратно. Повторяем процедуру ещё 24 раза. Получаем *сгенерированную выборку*.

Рассчитываем интересующую нас статистику. В нашем случае – среднее значение. Повторяем множество раз (1тыс. и более). Получаем **множество средних значений**. Строим распределение средних и с концов отрезаем по 2,5% площади. Остаётся 95% ДИ для среднего, вычисленный с помощью процедуры бутстрепа **процентильным методом**.



Один из лучших бутстрепа — **метод ВСа (Bias Corrected accelerated** — *ускоренный бутстреп с поправкой на смещение*).

Наиболее известные алгоритмы ресэмплинг-техник :

- *Перестановочный тест (permutation)*
- *Бутстреп (bootstrap)*
- *Метод «складного ножа» (jackknife)*
- *Кросс-проверка (cross-validation)*

Слово происходит от выражения: «To pull oneself over a fence by one's bootstraps.» (дословно — «перебраться через ограду, потянув за ремешки на ботинках»)



Название «складной нож», потому что его действие напоминает складной нож — простой инструмент, которым можно решить множество различных проблем

КОРРЕЛЯЦИИ (correlation)

До сих пор нас в выборках интересовала только **одна зависимая переменная**.

Мы изучали, отличается ли распределение этой переменной в одних условиях от распределения той же переменной в других условиях.

Обратимся к ситуации, когда зависимых переменных будет **ДВЕ** и более.

Нас интересует вопрос, в какой степени эти переменные связаны между собой, совместно изменяются.

Это могут быть измерения одной особи или связанных пар.

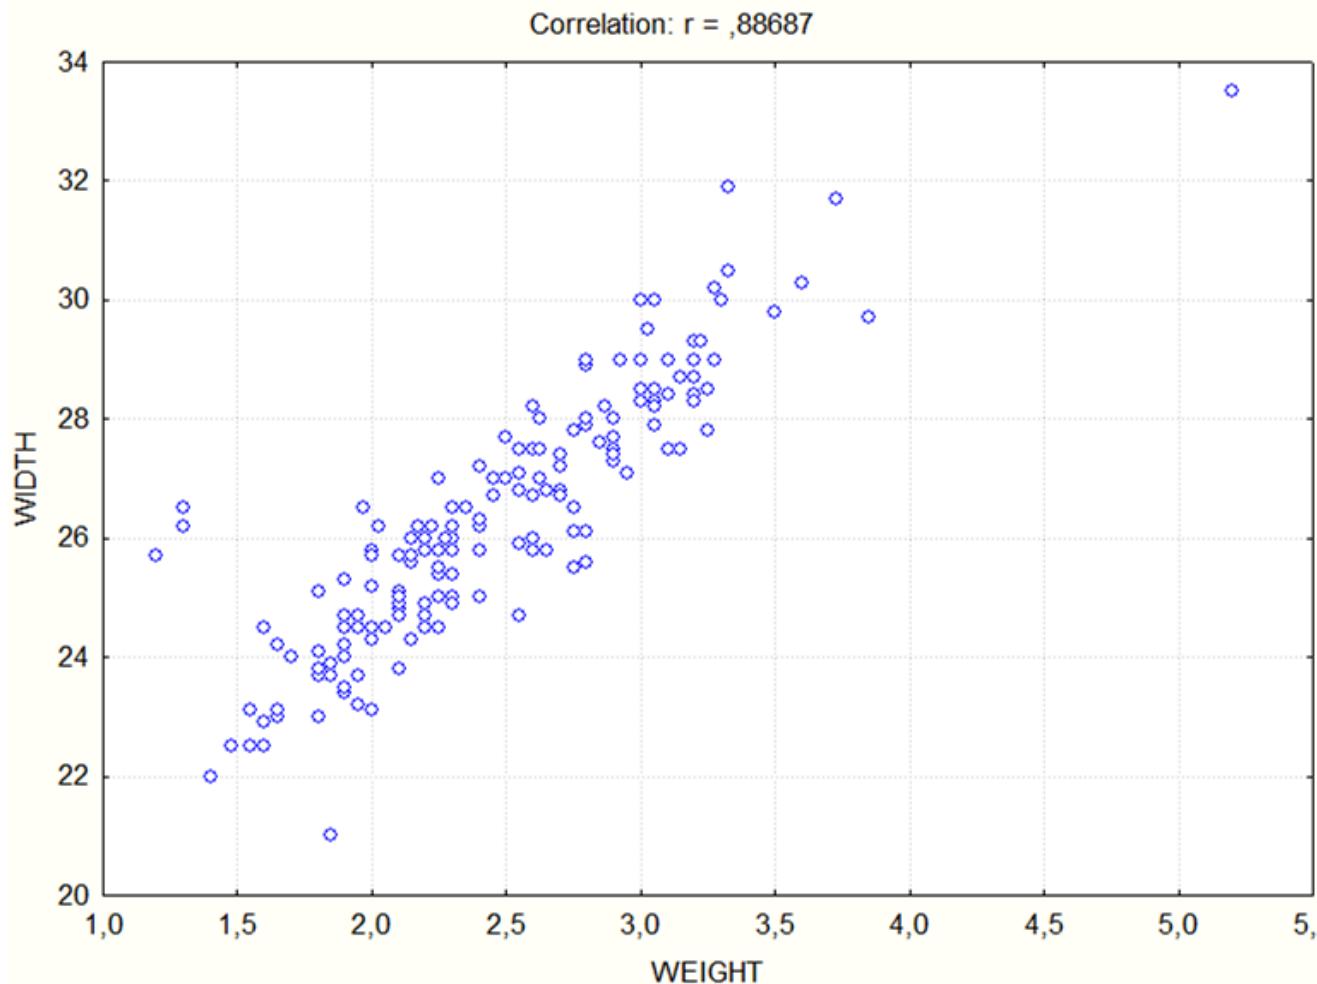
Коэффициент корреляции

Для оценки тесноты (силы) связи служит коэффициент **корреляции**.

1. Может принимать значения от -1 до +1
2. Знак коэффициента показывает *направление связи* (прямая или обратная)
3. Абсолютная величина показывает *силу связи*
4. всегда основан на парах чисел (измерений 2-х переменных от одной особи или 2-х переменных от разных, но связанных особей)

Скаттерплот

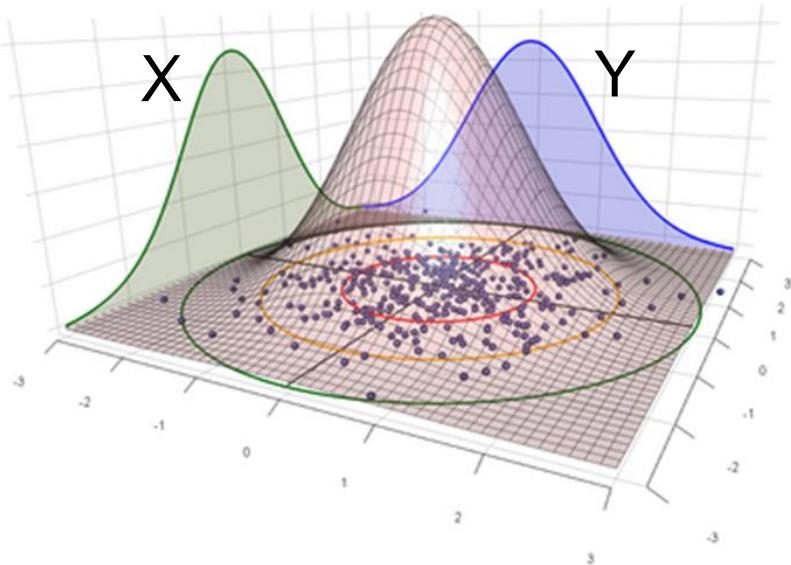
(= диаграмма рассеяния; scatterplot, scatter diagram)



Две характеристики: – наклон (направление связи) и ширина (сила связи) воображаемого эллипса

Оценкой *линейной зависимости (связи)* между 2-мя непрерывными переменными, служит *коэффициент корреляции Пирсона* (Подробнее о параметрических методах оценки связи см. лекцию – «Корреляционный и регрессионный анализ»).

Однако существуют **ограничения** для его **применения**.



Значения Y и X должны быть распределены нормально - *двумерное нормальное распределение* (bivariate normal distribution)

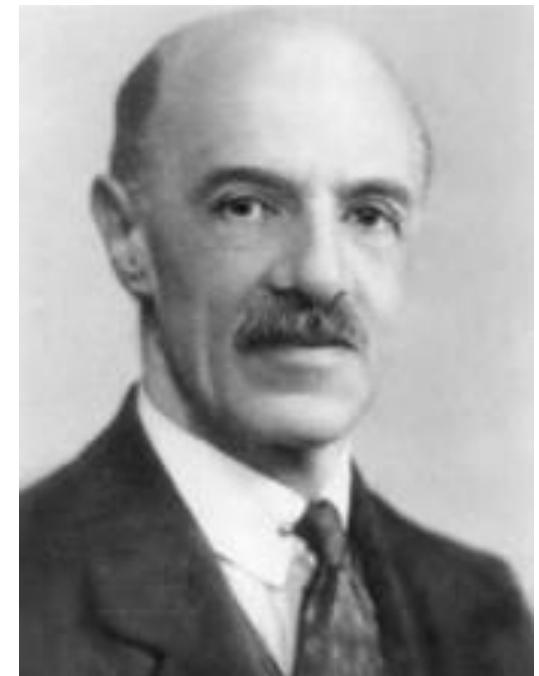
Если хотя бы одна переменная имеет не нормальное распределение или она порядковая, то для оценки зависимости используют *непараметрические коэффициенты корреляции*.

Коэффициент корреляции Спирмана (*Spearman rank order correlation*)

Коэффициент ранговой корреляции Спирмена - непараметрический аналог коэффициента корреляции Пирсона.

Определяется не по величинам переменных признаков, а по рангам - номерам в порядке возрастания величин признаков.

Критерий **разработан и предложен** для проведения корреляционного анализа в **1904 году** Чарльзом Эдвардом Спирменом, английским психологом, профессором Лондонского и Честерфилдского университетов.



Чарльз Эдвард Спирмен
(*Charles Edward Spearman*
1863-1945)

Необходимо узнать существует ли зависимость роста сына от роста отца?

Переменные:

1. рост сына (Y);
2. рост отца (X)



1. Ранжируем данные для каждой переменной от меньшего к большему;
2. Если встретились одинаковые значения (*tied ranks*), присваиваем им средние ранги;
3. Считаем разности рангов в каждой паре данных;

Рост отца		Рост сына		d_i	d_j^2
Значение, см	ранг	Значение, см	ранг		
167	1	169	2	-1	1
169	2	171	3	-1	1
170	1,5	166	1	2,5	6,25
170	1,5	172	4	-0,5	0,25
172	5	180	7	-2	4
173	6	176	5	1	1
174	7	177	6	1	1
175	8	182	8,5	-0,5	0,25
179	9	182	8,5	0,5	0,25
180	10	186	10	0	0
					$\sum d_j^2 = 15$

4. Считаем коэффициент r_s

$$r_s = 1 - \frac{6 \sum d_i^2}{n(n^2 - 1)}$$

разности рангов

число строк
(размер выборки)

$$r_s = 1 - \frac{6 \times 15}{10^3 - 10} \approx 0,9091 \quad \text{При } \alpha=0,001 \text{ значение } r_{\text{кр}}=0,903$$

$r_s > r_{\text{кр}}$, таким образом нулевая гипотеза должна быть отвергнута и наблюдается зависимость роста взрослого сына от роста его отца

$$H_0: \rho_s = 0$$

$$H_1: \rho_s \neq 0$$



Статистика критерия – сам коэффициент корреляции Спирмана (имеет t-распределение)

Коэффициент **Спирмана** – аналог коэффициента корреляции **Пирсона**, стремится к нему в больших выборках. Мощность – около 91% коэффициента Пирсона.

Минимальный объем выборки: Для расчета требуется не менее 5 наблюдений по каждой переменной, лучше ≥ 10 .

Spearman Rank Order Correlations

Зависимость роста сына от роста отца.dat

File Edit Transform Plot Univariate Multivariate Model Diversity Timeseries

Show
 Row attributes Column attributes

	рост отца	рост сына
1	● 167	169
2	● 169	171
3	● 170	166
4	● 170	172
5	● 172	180
6	● 173	176
7	● 174	177
8	● 175	182
9	● 179	182
10	● 180	186
11	●	
12	●	
13	●	

Summary statistics
One-sample tests (t, Wilcoxon, single-case)
Two-sample tests
ANOVA etc. (several samples)
Correlation

Intraclass correlation
Normality tests
Contingency table (chi² etc.)
Mantel-Cochran-Haenszel test
Risk/odds
Single proportion test
Multiple proportion CIs
Ratios of counts CI
Survival analysis
Combine errors

Зависимость роста сына от роста отца.

File Edit Transform Plot Univariate

Show
 Row attributes Select
 Column attributes Drag rows/c

	рост отца	рост сына
1	● 167	169
2	● 169	171
3	● 170	166
4	● 170	172
5	● 172	180
6	● 173	176
7	● 174	177
8	● 175	182
9	● 179	182
10	● 180	186
11		
12		
13		

Spearman Rank Order Correlations

Correlation

Table Plot

	рост отца	рост сына
рост отца		0,00027383
рост сына	0,90854	

Correlation statistic

- Linear r (Pearson)
- Spearman's D
- Spearman's rs
- Kendall's tau
- Polyserial rho
- Partial linear

Table format

- Statistic \ p(uncorr)
- Statistic
- p(uncorr)
- Permutation p

Bonferroni correction



Отвергаем H_0 :

Оказалось, что рост сына положительно связан с ростом его отца.

Коэффициент корреляции Кендалла (Kendall's coefficient of rank correlation, Kendall- τ)

В 1937 году вышла статья *Мориса Кендалла* где описан новый коэффициент ранговой корреляции - τ («тау»).

Оценивает разность между вероятностью того, что порядок данных в обеих переменных одинаков, и вероятностью того, что порядки разные.

Только для **ранговых** переменных! Для количественных лучше коэффициент Спирмана, особенно для больших выборок.



Морис Кендалл
(Sir Maurice George Kendall
1907-1983)

Пример.

Обследовано 20 больных серповидноклеточной анемией.

Оценены:

тяжесть (в баллах) и коэффициент адгезии эритроцитов.

Необходимо ответить

на вопрос:

Связана ли адгезивность
эритроцитов и тяжестью
серповидноклеточной
анемии?



Kendall's coefficient of rank correlation, Kendall- τ

Correlation

Table Plot

	Тяжесть забол	Коэффициен
Тяжесть забол		6,0131E-06
Коэффициен	0,7342	

серповидноклеточная анемия.dat

File Edit Transform Plot Univariate Multivariate Model Diversity Tir

Show

Row attributes Column attributes

	Тяжесть забол
1	• 0
2	• 0
3	• 1
4	• 1
5	• 1
6	• 1
7	• 1
8	• 1
9	• 2
10	• 2
11	• 3
12	• 3
13	• 3

Correlation statistic

- Linear r (Pearson)
- Spearman's D
- Spearman's rs
- Kendall's tau (selected)
- Polyserial rho
- Partial linear

Table format

- Statistic \ p(uncorr) (selected)
- Statistic
- p(uncorr)
- Permutation p

Summary statistics

One-sample tests (t, Wilcoxon, single-case)

Two-sample tests

ANOVA etc. (several samples)

Correlation

Intraclass correlation

Normality tests

Contingency table (chi² etc.)

Mantel-Cochran-Haenszel test

Risk/odds

Single proportion test

Multiple proportion CIs

Ratios of counts CI

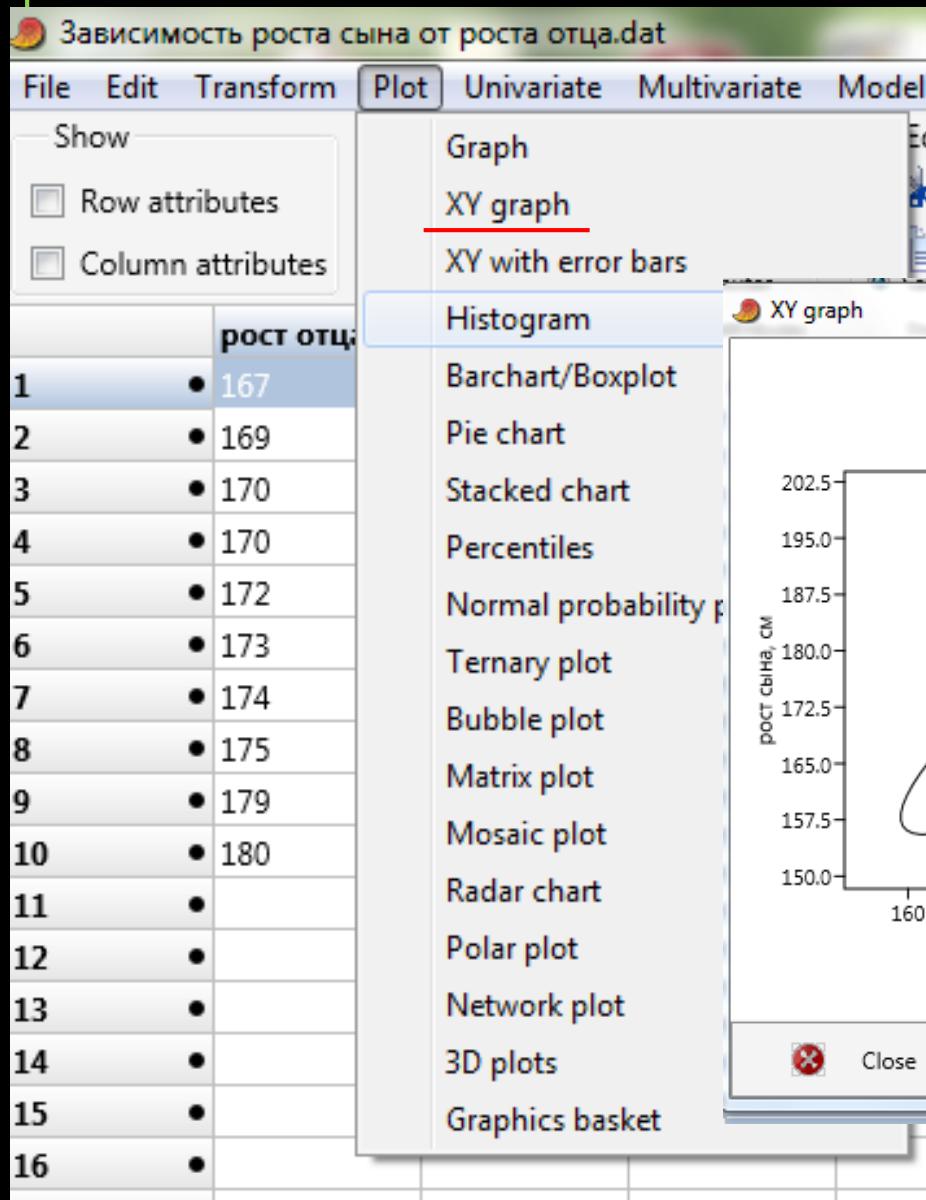
Survival analysis

Combine errors

6.3

Отвергаем H_0 :
адгезивность эритроцитов
положительно связана
тяжестью
серповидноклеточной
анемией

Kendall's coefficient of rank correlation, Kendall- τ



графика — диаграммы
рассеяния (scattergram)

Корреляционный анализ: (линейные) соотношения между двумя непрерывными переменными

- ✓ **Коэффициент корреляции Пирсона r** , который используется для выявления взаимосвязи между двумя приблизительно нормально распределенными непрерывными переменными. В действительности переменные должны удовлетворять совместно «двумерному нормальному распределению».
- ✓ **Коэффициент ранговой корреляции Спирмена, $ρ$ (ρ)**, применяемый для выявления взаимосвязи между двумя непрерывными переменными, по крайней мере одна из которых распределена не по нормальному закону.
- ✓ **Коэффициент ранговой корреляции Кендалла, $τ$ (τ)**, применяемый для выявления взаимосвязи между двумя порядковыми переменными или между одной порядковой и одной непрерывной.

Спасибо за внимание!

