

Проблема множественных сравнений

Чем больше статистических гипотез проверяется на одних и тех же данных, тем вероятнее ошибка первого рода – заключение о наличии различий между группами, тогда как на самом деле верна нулевая гипотеза об отсутствии различий

Пример. Исследуют влияние препаратов А и Б на уровень глюкозы плазмы. Исследования проводят на трех группах: получавших препарат А, получавших препарат Б и получавших плацебо В. С помощью критерия Стьюдента проводят три парных сравнения А и В, Б и В, А и Б.

Получив достаточно высокое значение t **хотя бы в одном из сравнений**, делают вывод о статистической значимости различий ($\alpha < 0,05$).

Но ошибка в 5% возможна **в каждом из трех сравнений**, т.е. вероятность ошибки в целом будет превышать 5%.

Вероятность ошибиться хотя бы в одном из сравнений:

- $p=1-(1-0,05)^k,$

где k – число парных сравнений

- $\sim p=0,05 \cdot k$

- $k=3; p=0,05 \cdot 3=0,15$

7. Lee K. L. et al. *Clinical judgment and statistics. Lessons from a simulated randomized trial in coronary artery disease* / K. K. Lee, J. F. McNeer, C. F. Starmer et al. // *Circulation*. – 1980. – Vol. 61. – N 3. – P. 508–515.

- Симуляция изучения эффективности двух различных методов лечения ишемической болезни сердца.
- Две равные группы, **одно и то же лечение!**
- Данные были обработаны так, как будто бы одной группе назначалось лечение А, а другой – лечение Б.
- При сравнении эффективности «двух видов лечения» различий обнаружено не было.
- Разбили каждую из групп пациентов еще на 6 по количеству пораженных коронарных артерий (1, 2 или 3 сосуда) и сократительной способности миокарда левого желудочка (выше или ниже определенного критического уровня).
- Результаты лечения не различались в пяти подгруппах, а в подгруппе пациентов с наиболее тяжелой формой заболевания лечение А было более эффективно ($p = 0,025$).
- Но в действительности обе группы получали **одно и то же лечение!**

Поправка Бонферрони

Если мы хотим обеспечить вероятность ошибки первого рода α , то в каждом из сравнений мы должны принять уровень значимости α/k , где k – число попарных сравнений

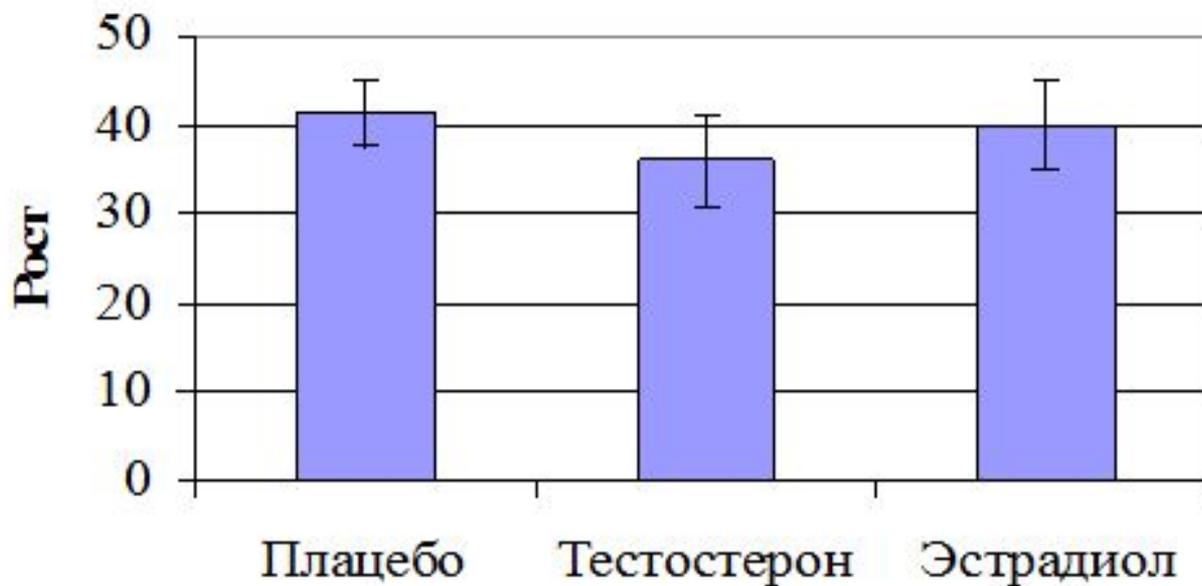
При сравнении нескольких групп с одной контрольной $k=m-1$, где m – количество групп.

Множественные парные сравнения групп и подгрупп обоснованы, если они запланированы в начале исследования, до начала сбора данных!

Три случайные выборки из одной СОВОКУПНОСТИ:

- $N=200$, $\mu=40$, $\sigma=5$

Рост	Частота	Рост	Частота	Рост	Частота
31	1	34	1	34	2
32	1	37	1	36	1
33	1	40	2	38	1
34	1	42	2	39	3
35	2	43	1	44	2
38	1	44	1	50	1
41	1	46	2		
42	1				
46	1				
$\bar{X}_1 = 36$ $s_1 = 5$		$\bar{X}_2 = 41,5$ $s_2 = 3,8$		$\bar{X}_3 = 40$ $s_3 = 5$	



- ✓ плацебо-тестостерон $t=2,39$;
- ✓ плацебо - эстрадиол $t=0,93$;
- ✓ тестостерон - эстрадиол $t=1,34$.

$$v = 10 + 10 - 2 = 18, \quad t_{0,05;18} = 2,101.$$

$$k = 3, \quad \alpha = 0,05 / 3 = 0,017$$

$$t_{0,02;18} = 2,552 > 2,39 \quad \longrightarrow \quad \text{нет значимых различий!}$$

В. Савельев «СТАТИСТИКА И КОТИКИ»

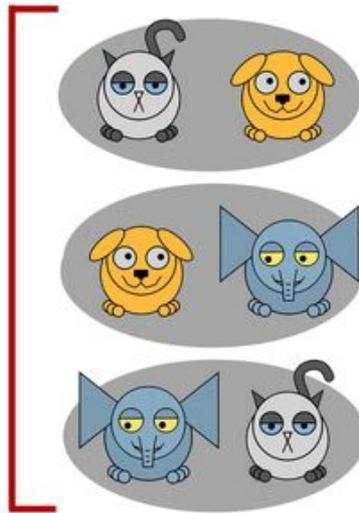
<http://www.statcats.ru>

<https://lib.rus.ec/b/624980>

$$\frac{0,05}{k}$$

Критическое значение с поправкой Бонферрони

$$k = 3$$



$$D = D = D$$

Поправка Бонферрони

Критерий Шеффе

Критерий Тьюки

$$D \neq D \neq D$$

Критерий Тамхейна

С-критерий Даннета

Критерий Геймса-Хоуэлла

Критерий Стьюдента для сравнения средних в двух взаимосвязанных выборках

*(Парный критерий Стьюдента,
критерий Стьюдента для повторных
измерений)*

Выборки называются **независимыми (несвязанными)**, если процедура эксперимента и полученные результаты измерения некоторого признака у испытуемых одной выборки не оказывают влияния на особенности протекания этого же эксперимента и результаты измерения этого же признака у испытуемых другой выборки.

И, напротив, выборки называется **зависимыми (связанными)** если процедура эксперимента и полученные результаты измерения некоторого свойства, проведенные на одной выборке, оказывают влияние на другую.

В зависимых выборках одному случаю из первой выборки соответствует один случай из второй выборки и наоборот.

Примеры зависимых выборок:

- пары близнецов;
- два измерения какого-либо признака до и после экспериментального воздействия,
- мужа и жёны
- родители и дети и т.д.

Зависимые выборки всегда имеют одинаковый объём, а объём независимых может отличаться

Пример. Некий исследователь выдвинул «гипотезу» о том, что люди выше, когда они в обуви, чем когда они босиком.

Схема эксперимента: в случайной выборке из 15 взрослых людей измерили рост каждого в обуви и без нее.

A	164	179	176	151	156	177	175	164	162	157	176	160	192	176	150
B	161	175	172	147	152	174	170	160	157	151	174	155	188	172	148
A-B	3	4	4	4	4	3	5	4	5	6	2	5	4	4	2

$$\bar{X}_A = 167,7; s_A = 12,03; \bar{X}_B = 163,7; s_B = 12,7$$

$$t = \frac{\bar{X}_1 - \bar{X}_2}{\sqrt{\frac{s^2}{n_1} + \frac{s^2}{n_2}}}$$

- $t = 0,89$. Для уровня значимости $\alpha=0,05$ и числа степеней свободы $v=28$ критическое значение t равно $2,05$. Рассчитанное значение меньше критического. Различия НЕ ЯВЛЯЮТСЯ статистически значимыми???

Причина: разность средних (равна 4) очень мала по сравнению с разбросом значений в каждой из выборок (стандартное отклонение 12,03 и 12,17)

На самом деле нас интересует только разница между двумя группами. Здесь есть только одна выборка D : разность между двумя измерениями.

- H_0 – среднее значение в выборке не отличается от 0
- H_1 – среднее значение в выборке отличается от 0

$$t = \frac{\overline{X_D} - 0}{s_{\overline{X_D}}} = \frac{\overline{X_D}}{s_D / \sqrt{n}}$$

Число степеней свободы $\nu = n - 1$

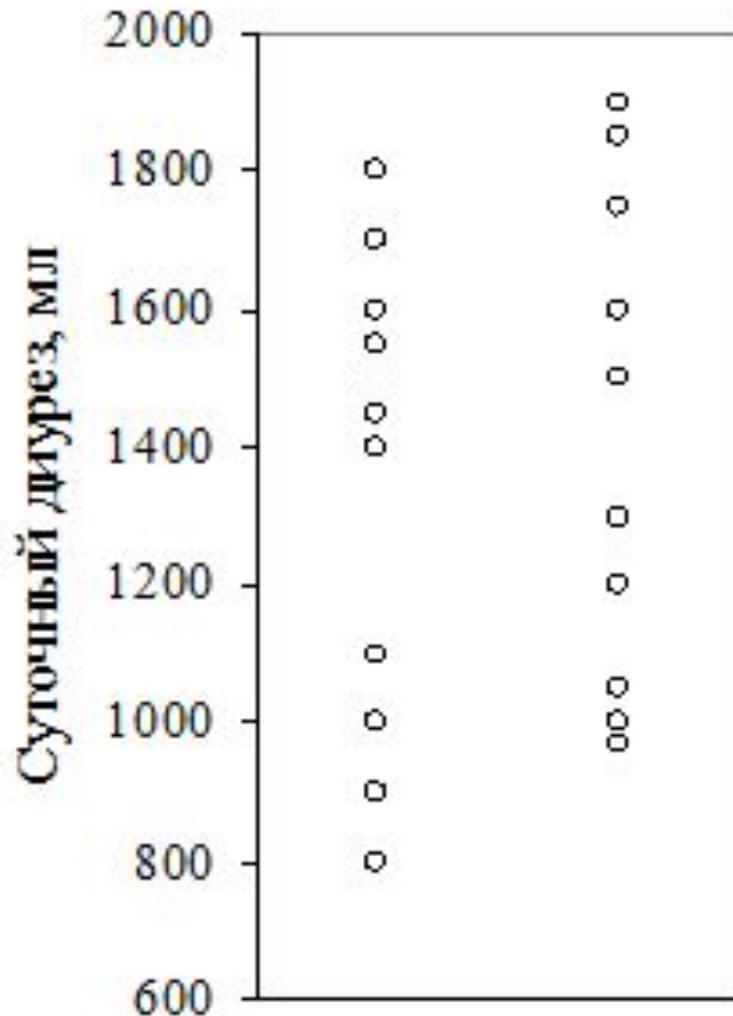
$$\overline{X_D} = 3,93 \quad s_D = 1,1$$

$$s_{\overline{X_D}} = 1,1 / \sqrt{15} = 0,28$$

$$t = 13,85; \nu = 14; t_{0,05} = 2,145; t_{0,001} = 4,14$$

Часто значительная часть внутригрупповой изменчивости (вариации) в обеих группах может быть объяснена индивидуальными различиями субъектов. В случае независимых выборок нельзя определить (или «удалить») часть вариации, связанную с индивидуальными различиями субъектов. Если та же самая выборка тестируется дважды, то можно легко исключить эту часть вариации.

Пример. Проводилось изучение суточного диуреза у 10 человек после приема препарата и у 10 после приема плацебо.



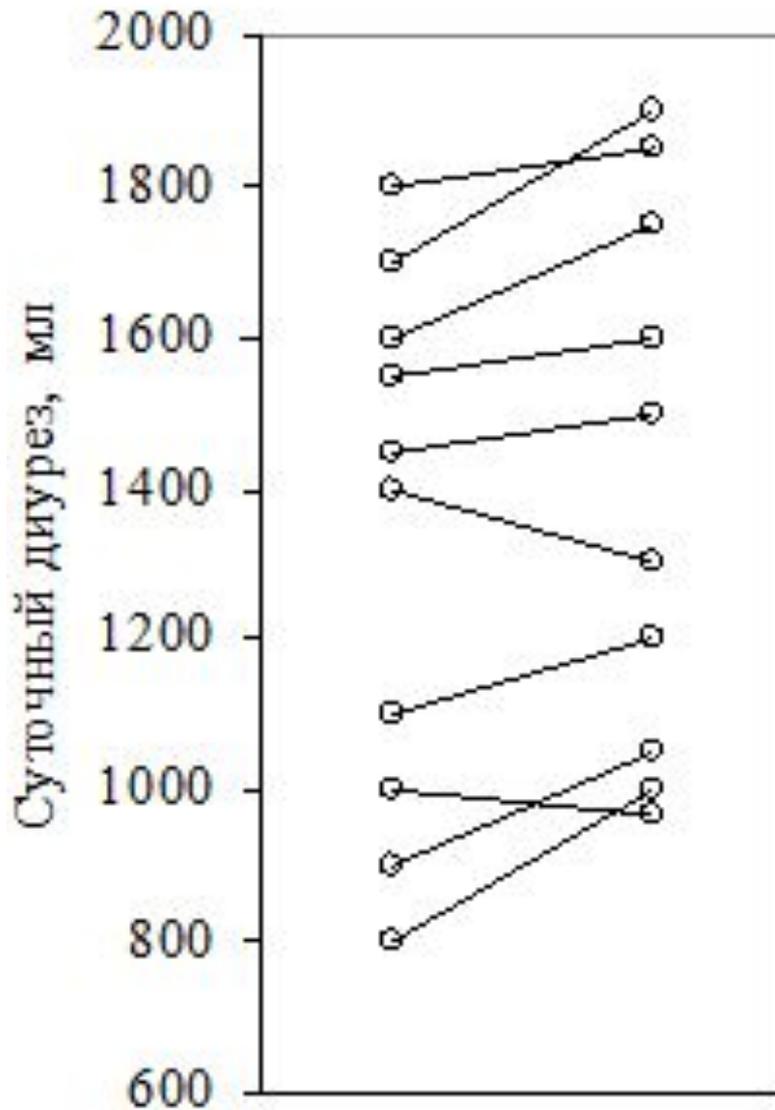
$$\bar{X}_K = 1330 \text{ мл}$$

$$s_K = 353,7 \text{ мл}$$

$$\bar{X}_\Theta = 1412 \text{ мл}$$

$$s_\Theta = 356,1 \text{ мл}$$

$t=0,52$ – нет значимых различий



$$\overline{X_D} = 82,$$

$$s_D = 97,84$$

$$t = 2,65$$

Различия
статистически
значимы

Условие применения:

нормальное
распределение
разности между
парами значений

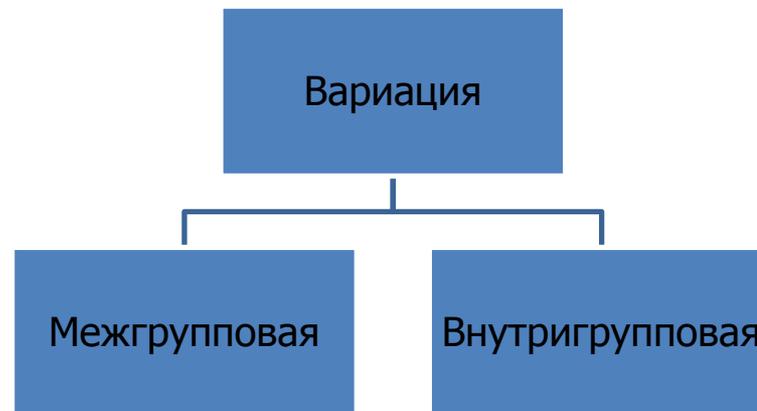
Если схема эксперимента предполагает не две, а три и более групп?



Попарные сравнения групп–
проблема множественных сравнений!!!

Дисперсионный анализ (ANOVA – analysis of variance)

- Разработан в 20-х годах прошлого века английским математиком и генетиком Р.Фишером
- Выявляет статистически значимые различия между несколькими группами

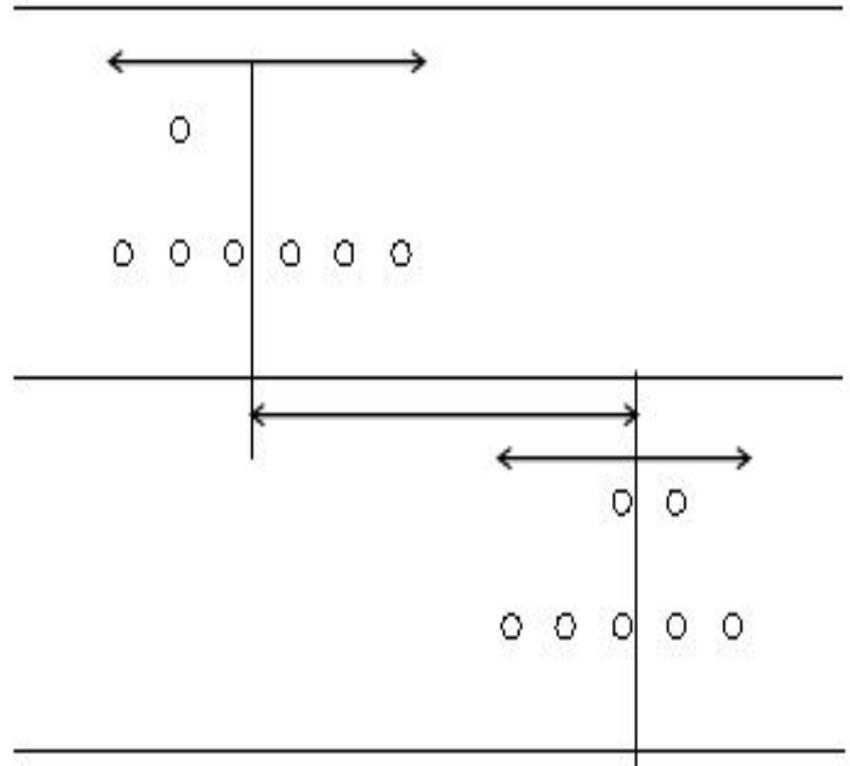
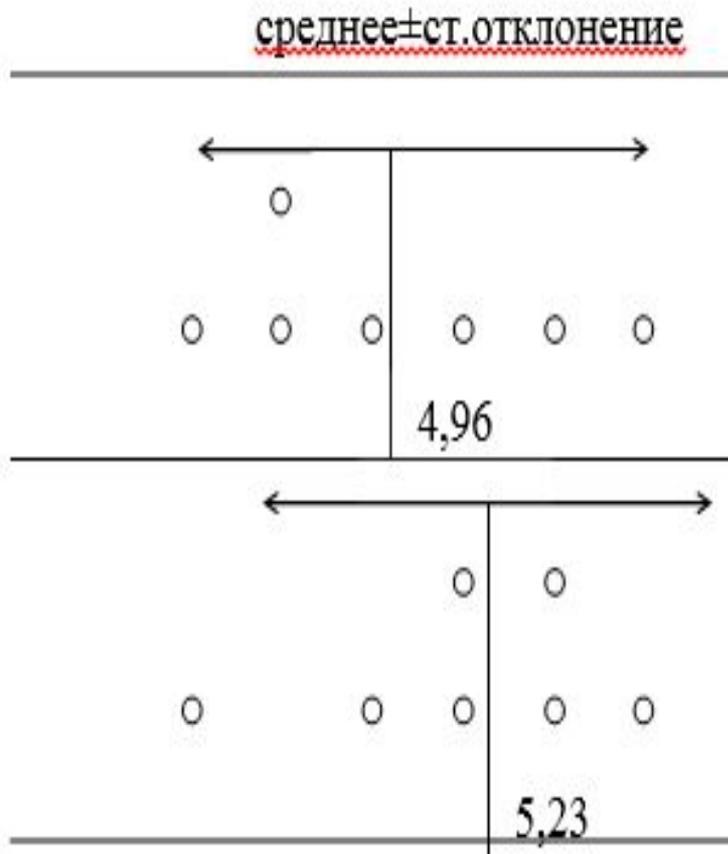


- Значение критерия - отношение межгрупповой вариации к внутригрупповой

Пример. Ученые исследовали влияние диеты на сердечный выброс. Случайным образом отобрали 28 человек и разделили их на 4 группы по 7 человек в каждой. Члены первой (контрольной) группы продолжали питаться как обычно, второй – ели преимущественно макароны, третьей – мясо, четвертой – фрукты. Через месяц у всех участников эксперимента измерили сердечный выброс.

	1	2	3	4
Среднее	4,96	5,23	4,93	4,8
Дисперсия	0,1	0,12	0,22	0,2
Стандартное отклонение	0,315	0,33	0,46	0,44

Нулевая гипотеза: ни одна из диет не влияет на сердечный выброс. Как убедиться в этом?



Оценка дисперсии

СОВОКУПНОСТИ:

1) на основании дисперсий в каждой группе. Такая оценка не зависит от различий групповых средних.

2) по разбросу выборочных средних. Такая оценка зависит от различий выборочных средних.

Если экспериментальные группы являются случайными выборками из одной и той же нормально распределенной совокупности, то обе оценки дисперсии дают примерно одинаковые результаты

Оценка по выборочным дисперсиям:

$$s_{\text{внутр}}^2 = \frac{\sum s_i^2}{k}$$

k – количество групп,

s_i^2 - выборочные оценки дисперсии в группах.

Оценка по выборочным средним

$$s_{\text{меж}}^2 = n s_{\frac{X}{2}}^2,$$

где n – объем выборок,

$s_{\frac{X}{2}}^2$ - дисперсия выборки, составленной из выборочных средних.

$$F = \frac{S_{\text{меж}}^2}{S_{\text{внутр}}^2}$$

$v_{\text{меж}} = k - 1$, где k - число групп.

$v_{\text{внутр}} = k(n - 1)$, где n - численность каждой группы.

Если рассчитанное значение F будет больше, чем табличное для соответствующего числа степеней свободы и уровня значимости, то нулевая гипотеза о равенстве выборочных средних отвергается – различия будут статистически значимыми.

Этапы дисперсионного анализа

1. Проверка нормальности в каждой из групп
2. Проверка гипотезы о равенстве дисперсий (тест Левена)

Если условия 1-2 не выполняются, следует применить непараметрический аналог дисперсионного анализа!

3. Собственно анализ вариаций
4. Апостериорное сравнение групп с помощью специальных процедур

Примеры

1. Женщины с остеопорозом были распределены случайным образом по трем группам:

- лечение по стандартной методике,
- лечение по новой методике
- плацебо (контрольная группа).

Исследуемой переменной является изменение минеральной плотности

костной ткани, по которому различаются группы. Результаты можно проанализировать с помощью однофакторного дисперсионного анализа.

2. В условиях предыдущего примера добавляем в качестве второй группирующей переменной возраст. Возраст классифицируется как одна

из четырех порядковых категорий: от 30 до 40 лет, от 41 до 50, от 51 до 60, от 61 года и старше. Данные можно проанализировать с помощью двухфакторного дисперсионного анализа

3. В условиях предыдущего примера добавление новых категориальных

переменных, таких как диета (вегетарианская или невегетарианская) и употребление алкоголя (менее 60 мл алкоголя в день, от 60 до 150 мл в день, более 150 мл в день), может превратить двухфакторный анализ в четырехфакторный или многофакторный дисперсионный

$$s_{\text{внутр}}^2 = \frac{0,1 + 0,12 + 0,22 + 0,2}{4} = 0,16$$

$$\bar{X} = \frac{4,96 + 5,23 + 4,93 + 4,8}{4} = 4,98;$$

$$s_{\bar{X}}^2 = \frac{(4,98 - 4,96)^2 + (4,98 - 5,23)^2 + (4,98 - 4,93)^2 + (4,98 - 4,8)^2}{4 - 1} = 0,0326$$

$$s_{\text{меж}}^2 = 7 \cdot 0,0326 = 0,23; \quad F = 0,23 / 0,16 = 1,44$$

$$v_{\text{меж}} = 4 - 1 = 3; \quad v_{\text{внутр}} = 4(7 - 1) = 24;$$

$$F_{0,05;3;24} = 3,01.$$

Диета из рассмотренного примера не влияет на сердечный выброс

Обобщение метода на случай неравной численности групп

- Имеется k групп, n_i – численность i -ой группы
- \bar{X}_i - среднее в i -ой группе
- s_i^2 – дисперсия в i -ой группе
- $N = \sum n_i$ - общий объем исследования

$$F = \frac{S_{\text{меж}} / \nu_{\text{меж}}}{S_{\text{внутр}} / \nu_{\text{внутр}}}$$

$$S_{\text{внутр}} = \sum_{i=1}^k (n_i - 1) s_i^2, \quad \nu_{\text{внутр}} = N - k;$$

$$S_{\text{меж}} = \sum_{i=1}^k n_i \bar{X}_i^2 - \frac{(\sum_{i=1}^k n_i \bar{X}_i)^2}{N}, \quad \nu_{\text{меж}} = k - 1.$$

Курение считают основным фактором, предрасполагающим к хроническим обструктивным заболеваниям легких. Является ли таким фактором пассивное курение?

Для проверки данного предположения изучалась проходимость дыхательных путей у некурящих, активных и пассивных курильщиков. Измерялась максимальная объемная скорость середины вдоха (л/с) у некурящих, активных и пассивных курильщиков. Ее уменьшение свидетельствует о нарушении проходимости дыхательных путей.

Можно ли считать этот показатель одинаковым во всех группах? (Выборки считать извлеченными из нормально распределенной

Данные по максимальной объемной скорости середины вдоха (л/с)

Группа	Численность	Среднее значение	Стандартное отклонение
1) <u>Некурящие</u> , работающие в помещении, где не курят;	200	3,17	0,74
2) <u>Некурящие</u> , работающие в накуренном помещении;	201	2,72	0,71
3) <u>Курящие</u> небольшое количество сигарет;	199	2,63	0,73
4) <u>Курящие</u> среднее количество сигарет;	202	2,29	0,7
5) <u>Курящие</u> большое количество сигарет	198	2,12	0,72

Количество групп k=5, общая численность исследования N=1000 человек.

$$S_{\text{меж}} = \sum_{i=1}^k n_i \overline{X}_i^2 - \frac{(\sum_{i=1}^k n_i \overline{X}_i)^2}{N} = (200 \cdot 3,17^2 + 201 \cdot 2,72^2 + 199 \cdot 2,63^2 + 202 \cdot 2,29^2 + 200 \cdot 2,12^2) - \frac{(200 \cdot 3,17 + 201 \cdot 2,72 + 199 \cdot 2,63 + 202 \cdot 2,29 + 200 \cdot 2,12)^2}{1000} = 132,9$$

$$\nu_{\text{меж}} = k - 1 = 4.$$

$$S_{\text{внутр}} = \sum_{i=1}^k (n_i - 1) s_i^2 = (200 - 1) \cdot 0,74^2 + (201 - 1) \cdot 0,71^2 + (199 - 1) \cdot 0,73^2 + (202 - 1) \cdot 0,7^2 + (198 - 1) \cdot 0,72^2 = 515,9$$

$$\nu_{\text{внутр}} = N - k = 995$$

$$F = \frac{S_{\text{меж}} / \nu_{\text{меж}}}{S_{\text{внутр}} / \nu_{\text{внутр}}} = \frac{132,9 / 4}{515,9 / 995} = 64,1$$

Таблица 2

Критические значения F для $\alpha=0,05$ (верхняя строка) и $\alpha=0,01$ (нижняя строка)

		Число степеней свободы для числителя ($\nu_{\text{меж}}$)													
		1	2	3	4	5	6	7	8	9	10	11	12	13	14
знаменателя ($\nu_{\text{внутр}}$)	1	161	199	216	225	230	234	237	239	241	242	243	244	245	245
		4052	4999	5404	5624	5764	5859	5928	5981	6022	6056	6083	6107	6126	6143
	2	18.51	19.00	19.16	19.25	19.30	19.33	19.35	19.37	19.38	19.40	19.40	19.41	19.42	19.42
		98.5	99.0	99.16	99.25	99.30	99.33	99.36	99.38	99.39	99.40	99.41	99.42	99.42	99.43
	3	10.13	9.55	9.28	9.12	9.01	8.94	8.89	8.85	8.81	8.79	8.76	8.74	8.73	8.71
		34.12	30.82	29.46	28.71	28.24	27.91	27.67	27.49	27.34	27.23	27.13	27.05	26.98	26.92
	4	7.71	6.94	6.59	6.39	6.26	6.16	6.09	6.04	6.00	5.96	5.94	5.91	5.89	5.87
		21.20	18.00	16.69	15.98	15.52	15.21	14.98	14.80	14.66	14.55	14.45	14.37	14.31	14.25
	5	6.61	5.79	5.41	5.19	5.05	4.95	4.88	4.82	4.77	4.74	4.70	4.68	4.66	4.64
		16.26	13.27	12.06	11.39	10.97	10.67	10.46	10.29	10.16	10.05	9.96	9.89	9.82	9.77
6	5.99	5.14	4.76	4.53	4.39	4.28	4.21	4.15	4.10	4.06	4.03	4.00	3.98	3.96	
	13.75	10.92	9.78	9.15	8.75	8.47	8.26	8.10	7.98	7.87	7.79	7.72	7.66	7.60	
7	5.59	4.74	4.35	4.12	3.97	3.87	3.79	3.73	3.68	3.64	3.60	3.57	3.55	3.53	
Число степеней свободы с	110	5.95	5.08	4.69	4.45	4.30	4.18	4.09	4.02	3.97	3.92	3.88	3.84	3.81	3.78
		6.87	4.80	3.96	3.49	3.19	2.97	2.81	2.68	2.57	2.49	2.41	2.35	2.30	2.25
	120	3.92	3.07	2.68	2.45	2.29	2.18	2.09	2.02	1.96	1.91	1.87	1.83	1.80	1.78
		6.85	4.79	3.95	3.48	3.17	2.96	2.79	2.66	2.56	2.47	2.40	2.34	2.28	2.23
	130	3.91	3.07	2.67	2.44	2.28	2.17	2.08	2.01	1.95	1.90	1.86	1.83	1.80	1.77
		6.83	4.77	3.94	3.47	3.16	2.94	2.78	2.65	2.55	2.46	2.39	2.32	2.27	2.22
	140	3.91	3.06	2.67	2.44	2.28	2.16	2.08	2.01	1.95	1.90	1.86	1.82	1.79	1.76
		6.82	4.76	3.92	3.46	3.15	2.93	2.77	2.64	2.54	2.45	2.38	2.31	2.26	2.21
	160	3.90	3.05	2.66	2.43	2.27	2.16	2.07	2.00	1.94	1.89	1.85	1.81	1.78	1.75
		6.80	4.74	3.91	3.44	3.13	2.92	2.75	2.62	2.52	2.43	2.36	2.30	2.24	2.20
180	3.89	3.05	2.65	2.42	2.26	2.15	2.06	1.99	1.93	1.88	1.84	1.81	1.77	1.75	
	6.78	4.73	3.89	3.43	3.12	2.90	2.74	2.61	2.51	2.42	2.35	2.28	2.23	2.18	
200	3.89	3.04	2.65	2.42	2.26	2.14	2.06	1.98	1.93	1.88	1.84	1.80	1.77	1.74	
	6.76	4.71	3.88	3.41	3.11	2.89	2.73	2.60	2.50	2.41	2.34	2.27	2.22	2.17	

Рассчитанное значение (64,1) больше табличного (3,41 для уровня 0,01).

Можем опровергнуть нулевую гипотезу с уровнем значимости 0,01 и утверждать, что максимальная объемная скорость середины вдоха в группах статистически значимо различается (вероятность ошибки менее 1%)

Критерий Стьюдента с точки зрения

дисперсионного анализа

Критерий Стьюдента является вариантом дисперсионного анализа в случае сравнения двух групп, при этом выполняется равенство $F=t^2$.

Межгрупповое число степеней свободы будет равно $\nu_{\text{меж}} = k - 1 = 2 - 1 = 1$;

внутригрупповое $\nu_{\text{внутр}} = k(n - 1) = 2(n - 1)$

Средняя продолжительность госпитализации 36 больных пиелонефритом, получавших правильное (соответствующее официальным рекомендациям) лечение, составила 4,51 суток, а у 36 больных, получавших неправильное лечение – 6,28 суток. Стандартные отклонения для этих групп составили соответственно 1,98 суток и 2,54 суток. Можно ли считать эти различия случайными?

$$s^2 = \frac{s_1^2 + s_2^2}{2} = \frac{1,98^2 + 2,54^2}{2} = 5,18$$
$$t = \frac{4,51 - 6,28}{\sqrt{\frac{5,18}{36} + \frac{5,18}{36}}} = -3,3$$

Число степеней свободы $v = 2(n-1) = 2(36 - 1) = 70$. Для $\alpha = 0,01$ и $v=70$ $t_{\text{крит}} = 2,648$. Следовательно, различия в сроках госпитализации статистически значимы. Вероятность ошибки данного заключения составляет менее 1%.

$$s_{\text{внутр}}^2 = \frac{(s_1^2 + s_2^2)}{2} = \frac{1,98^2 + 2,54^2}{2} = 5,19$$

$$\bar{X} = \frac{\bar{X}_1 + \bar{X}_2}{2} = \frac{4,51 + 6,28}{2} = 5,4$$

Дисперсия для среднего по выборочным средним равна:

$$s_{\bar{X}}^2 = \frac{(\bar{X}_1 - \bar{X})^2 + (\bar{X}_2 - \bar{X})^2}{k-1} = \frac{(4,51 - 5,4)^2 + (6,28 - 5,4)^2}{1} = 1,56$$

$$s_{\text{меж}}^2 = ns_{\bar{X}}^2 = 36 \cdot 1,56 = 56,26$$

$$F = \frac{s_{\text{меж}}^2}{s_{\text{внутр}}^2} = \frac{56,26}{5,19} = 10,84$$

$$v_{\text{меж}} = k - 1 = 1; \quad v_{\text{внутр}} = k(n - 1) = 2(36 - 1) = 70; \quad F_{0,01;1;70} = 7,01$$

$$t^2 = (-3,3)^2 = 10,89 \approx F.$$

Дисперсионный анализ повторных измерений

В дисперсионном анализе повторных измерений одна и та же группа последовательно подвергается действию изучаемого фактора или просто наблюдается в несколько последовательных моментов времени.

