

1 фактор  
oooooooooooooooooooo

2 фактора  
ooooo

3 фактора  
o

## Прикладная статистика 5. Дисперсионный анализ.

Рябенко Евгений  
[riabenko.e@gmail.com](mailto:riabenko.e@gmail.com)

17 марта 2014 г.

## Однофакторный дисперсионный анализ (one-way ANOVA)

Пусть имеется  $K$  выборок:

$$X^N = X_1^{n_1} \bigcup X_2^{n_2} \bigcup \dots \bigcup X_K^{n_K}, \quad N = \sum_{i=1}^K n_i.$$

Эквивалентная запись:

фактор  $f: X \rightarrow \{1, \dots, K\}$

| $f$   | 1          | $\dots$ | $k$        | $\dots$ | $K$        |
|-------|------------|---------|------------|---------|------------|
| $X^N$ | $X_{11}$   |         | $X_{k1}$   |         | $X_{K1}$   |
|       | $\vdots$   | $\dots$ | $\vdots$   | $\dots$ | $\vdots$   |
|       | $X_{1n_1}$ |         | $X_{kn_k}$ |         | $X_{Kn_K}$ |

Задача: проверить гипотезу об отсутствии влияния фактора  $f$  на среднее значение признака  $X$ , то есть, о равенстве средних значений  $K$  выборок.

1 фактор  
●○○○○○○○○○○○○○○○○

2 фактора  
○○○○○

3 фактора  
○

## Однофакторный дисперсионный анализ (one-way ANOVA)

Идея: рассмотрим две компоненты разброса значений  $X_{ki}$  относительно глобального среднего  $\bar{X}$ :

$$X_{ki} - \bar{X} = (X_{ki} - \bar{X}_k) + (\bar{X}_k - \bar{X}),$$

где  $\bar{X}_k$  — среднее в  $k$ -й выборке.

Возведём в квадрат и просуммируем:

$$\sum_{k=1}^K \sum_{i=1}^{n_k} (X_{ki} - \bar{X})^2 = \sum_{k=1}^K \sum_{i=1}^{n_k} (X_{ki} - \bar{X}_k)^2 + \sum_{k=1}^K n_k (\bar{X}_k - \bar{X})^2,$$

$$SS_{total} = SS_{wg} + SS_{bg}.$$

Если средние в группах значительно отличаются, преобладает вторая компонента, если же они одинаковы — первая.

# Разновидности однофакторного дисперсионного анализа

- По типу выборок: независимые (between-subjects) 1 2 3, связанные (within-subjects, repeated measurements) 4 5 6.
- По используемым предположениям: нормальный 1 4, непараметрический 2 3 5 6.
- По типу альтернативы: общая 1 2 4 5, тренда 3 6.
- По объёму выборок: одинаковый (balanced), различный (unbalanced).
- По типу эффектов: случайные (random-effects) 7, фиксированные (fixed-effects) 8.

1 фактор  
○○●○○○○○○○○○○○○○○○○

2 фактора  
○○○○○

3 фактора  
○

## Однофакторный дисперсионный анализ для независимых выборок

Линейная модель:

$$X_{ki} = \mu + \alpha_k + \varepsilon_{ki},$$

$$i = 1, \dots, n_k, \quad k = 1, \dots, K.$$

$\mu$  — глобальное среднее значение признака  $X$ ,

$\alpha_k$  — отклонение от  $\mu$ , вызванное влиянием  $k$ -го уровня фактора  $f$ ,

$\varepsilon_{ki}$  — случайные независимые одинаково распределённые ошибки.

Средние значения  $X$  во всех  $K$  выборках одинаковы  $\Leftrightarrow \alpha_1 = \dots = \alpha_K$ .

# 1 Критерий Фишера

выборки:  $X^N = X_1^{n_1} \cup \dots \cup X_K^{n_K}$ ,  $X_{ki} \sim N(\mu_k, \sigma^2)$ ;

нулевая гипотеза:  $H_0: \mu_1 = \mu_2 = \dots = \mu_K$ ;

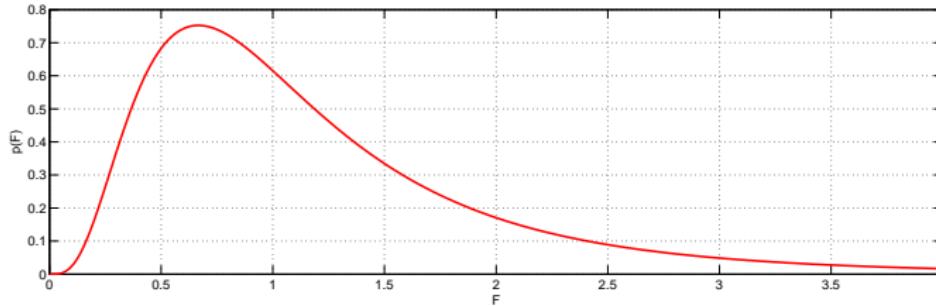
альтернатива:  $H_1: H_0$  неверна;

статистика:  $F(X^N) = \frac{SS_{bg}/(K-1)}{SS_{wg}/(N-K)}$ ,

$$SS_{bg} = \sum_{k=1}^K n_k (\bar{X}_k - \bar{X})^2,$$

$$SS_{wg} = \sum_{k=1}^K \sum_{i=1}^{n_k} (X_{ki} - \bar{X}_k)^2,$$

$F(X^N) \sim F(K-1, N-K)$  при  $H_0$ ;



достигаемый уровень значимости:

$$p(f) = 1 - fcdf(f, K-1, N-K).$$

## 1 Критерий Фишера

Предположения метода:

- ① значения признака во всех группах нормально распределены;
- ② дисперсия значений признака во всех группах одинакова;
- ③ наблюдения независимы.

При  $n_1 = \dots = n_K$  метод устойчив к нарушению первых двух предположений.

Если объёмы выборок различаются, нарушение предположения о равенстве дисперсий может привести к росту вероятности ошибки первого рода.

1 фактор  
○○○●○○○○○○○○○○○○

2 фактора  
○○○○○

3 фактора  
○

## 1 Критерий Фишера

**Пример:** топливная компания тестирует влияние трёх видов присадок на потребление бензина. Выборка получена на 12 одинаковых автомобилях, на каждом из которых использовалась одна из трёх присадок.

$H_0$ : все три вида присадок одинаково влияют на среднее потребление бензина.

$H_1$ : между средними уровнями потребления бензина с разными присадками есть различия  $\Rightarrow p = 2.1717 \times 10^{-5}$ .

## 2 Критерий Краскела-Уоллиса

выборки:  $X^N = X_1^{n_1} \cup \dots \cup X_K^{n_K}, \quad X_{ki} \sim F(x + \Delta_k);$

нулевая гипотеза:  $H_0: \Delta_1 = \Delta_2 = \dots = \Delta_K;$

альтернатива:  $H_1: H_0$  неверна;

статистика:  $K(X^N) = (N - 1) \frac{\sum\limits_{k=1}^K n_k (\bar{r}_k - \bar{r})^2}{\sum\limits_{k=1}^K \sum\limits_{i=1}^{n_k} (r_{ki} - \bar{r})^2},$

$K(X^N)$  имеет табличное распределение при  $H_0$ .

Если нет связок, то:

$$\bar{r} = \frac{N - 1}{2},$$

$$\sum_{k=1}^K \sum_{i=1}^{n_k} (r_{ki} - \bar{r})^2 = \frac{(N - 1) N (N + 1)}{12},$$

$$K(X^N) = \frac{12}{N(N + 1)} \sum_{k=1}^K n_k \bar{r}_k^2 - 3(N + 1).$$

Аппроксимация для  $n_k > 5$ :

$$K(X^N) \sim \chi_{K-1}^2.$$

1 фактор  
○○○○●○○○○○○○○○○○○○○○○

2 фактора  
○○○○○

3 фактора  
○

## 2 Критерий Краскела-Уоллиса

**Пример:** дегустаторы оценивают торты по совокупности факторов — вкус, внешний вид, запах и фактура. Итоговая оценка выставляется в баллах от 0 до 100. Сравниваются оценки трёх видов торты, представленных каждой отдельной команде дегустаторов.

$H_0$ : оценки трёх видов торты в среднем одинаковы.

$H_1$ : между оценками разных видов торты есть различия  $\Rightarrow p = 0.6587$ .

### 3 Критерий Джонкхиера

выборки:  $X^N = X_1^{n_1} \cup \dots \cup X_K^{n_K}$ ,  $X_{ki} \sim F(x + \Delta_k)$ ;

нулевая гипотеза:  $H_0: \Delta_1 = \Delta_2 = \dots = \Delta_K$

$\Rightarrow \text{med } X_1 = \dots = \text{med } X_K$ ;

альтернатива:  $H_1: \text{med } X_1 \leq \dots \leq \text{med } X_K$ ;

статистика:  $S(X^N) = \sum_{k=1}^K \sum_{i=1}^{n_k} a_{ki}$ ,

$a_{ki}$  — число наблюдений из первых  $k - 1$  выборок, меньших, чем  $X_{ki}$ ;

$S(X^N)$  имеет табличное распределение при  $H_0$ .

Аппроксимация для  $n_k > 10$ :

$$S(X^N) \sim N(\mu, \sigma^2),$$

$$\mu = \frac{1}{4} \left( N^2 - \sum_{k=1}^K n_k^2 \right),$$

$$\sigma = \frac{1}{72} \left( N^2 (2N + 3) - \sum_{k=1}^K n_k^2 (2n_k + 3) \right).$$

### 3 Критерий Джонкхиера

**Пример:** исследуется влияние информированности (знания цели работы) на выполнение монотонных производственных операций. 18 рабочих были случайным образом разделены на 3 группы. Попавшие в группу 1 не имели информации о требуемой производительности, в группу 2 — получили общее представление о том, что нужно делать, в группу 3 — точную информацию о задании и график выполнения работ.

$H_0$ : информированность не влияет на производительность.

$H_1$ : информированность влияет на производительность  $\Rightarrow p = 0.113$ .

$H_1$ : информированность повышает производительность  $\Rightarrow p = 0.022$ .

## Однофакторный дисперсионный анализ для связанных выборок

| Объект \ f | 1        | ... | k        | ... | K        |
|------------|----------|-----|----------|-----|----------|
| 1          | $X_{11}$ |     | $X_{k1}$ |     | $X_{K1}$ |
| ⋮          | ⋮        | ... | ⋮        | ... | ⋮        |
| n          | $X_{1n}$ |     | $X_{kn}$ |     | $X_{Kn}$ |

Линейная модель:

$$X_{ki} = \mu + \alpha_k + \beta_i + \varepsilon_{ki},$$

$$i = 1, \dots, n, \quad k = 1, \dots, K.$$

$\mu$  — глобальное среднее значение признака  $X$ ,

$\alpha_k$  — отклонение от  $\mu + \beta_i$ , вызванное влиянием  $k$ -го уровня фактора  $f$ ,

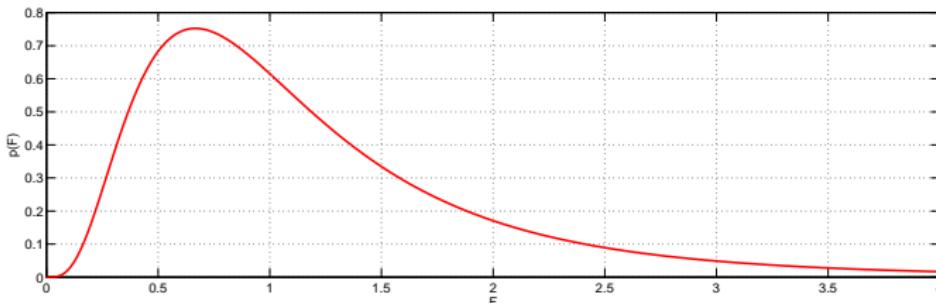
$\beta_i$  — отклонение от  $\mu$ , вызванное влиянием особенностей  $i$ -го объекта,

$\varepsilon_{ki}$  — случайные независимые одинаково распределённые ошибки.

Средние значения  $X$  во всех  $K$  выборках одинаковы  $\Leftrightarrow \alpha_1 = \dots = \alpha_K$ .

## 4 Критерий Фишера

выборки:  $X^N = X_1^{n_1} \cup \dots \cup X_K^{n_K}, \quad X_{ki} \sim N(\mu_k, \sigma^2);$   
 нулевая гипотеза:  $H_0: \mu_1 = \mu_2 = \dots = \mu_K;$   
 альтернатива:  $H_1: H_0$  неверна;  
 статистика:  $F(X^N) = \frac{SS_{bg}/(K-1)}{(SS_{wg}-SS_s)/(n-1)(K-1)},$   
 $SS_{bg} = n \sum_{k=1}^K (\bar{X}_k - \bar{X})^2,$   
 $SS_{wg} = \sum_{k=1}^K \sum_{i=1}^n (X_{ki} - \bar{X}_k)^2,$   
 $SS_s = K \sum_{i=1}^n (\bar{X}_i - \bar{X})^2;$   
 $F(X^N) \sim F(K-1, (n-1)(K-1))$  при  $H_0;$



достигаемый уровень значимости:

$$p(f) = 1 - fcdf(f, K-1, (n-1)(K-1)).$$

## 4 Критерий Фишера

Предположения метода:

- ❶ значения признака во всех группах нормально распределены;
- ❷ для фактора с более чем двумя уровнями: попарные разности признака имеют одинаковую дисперсию для любых уровней фактора (сферичность);
- ❸ объекты независимы.

Предположение сферичности на практике нарушается наиболее часто, причём это может привести к росту вероятности ошибки первого рода. Проверить гипотезу сферичности можно с помощью критерия Маухли, если она отвергается, используются модификации числа степеней свободы критерия Фишера.

1 фактор  
○○○○○○●○○○○○○○○○○○○

2 фактора  
○○○○○

3 фактора  
○

## 4 Критерий Фишера

**Пример:** (Pearson et al, 2003, Treatment effects of methylphenidate on behavioral adjustment in children with mental retardation and ADHD) исследовалось влияние метилфенидата на способность к отсрочке удовольствия умственно отсталыми детьми с синдромом дефицита внимания и гиперактивности. Каждый испытуемый принимал либо препарат в одной из трёх дозировок, либо плацебо, после чего проходил тест.

$H_0$ : препарат не влияет на среднюю способность к отсрочке удовольствия.

$H_1$ : препарат влияет на среднюю способность к отсрочке удовольствия  
 $\Rightarrow p = 0.004$ .

## 5 Критерий Фридмана

выборки:  $X_{ki} = \mu + \alpha_k + \beta_i + \varepsilon_{ki}, \quad i = 1, \dots, n, \quad k = 1, \dots, K;$

нулевая гипотеза:  $H_0: \alpha_1 = \dots = \alpha_K;$

альтернатива:  $H_1: H_0$  неверна;

статистика:  $S(X) = \frac{12}{nK(K+1)} \sum_{k=1}^K R_k^2 - 3n(K-1),$

$$R_k = \sum_{i=1}^n r_{ki},$$

$r_{ki}$  — ранг  $k$ -го элемента в  $i$ -й строке;

$S(X)$  имеет табличное распределение при  $H_0$ .

Распространённая аппроксимация для  $n > 15, K > 10$ :

$$S(X) \sim \chi_{K-1}^2.$$

Более точная аппроксимация:

$$\frac{(n-1)S(X)}{n(K-1)-S(X)} \sim F(n-1, (n-1)(K-1)).$$

1 фактор  
oooooooo●oooooooooooo

2 фактора  
oooooo

3 фактора  
○

## 5 Критерий Фридмана

**Пример:** исследуется 5 технологий вытачивания детали. Каждый из 15 рабочих в течение нескольких смен использовал каждую из технологий.  $X_{ki}$  — производительность  $i$ -го рабочего при использовании  $k$ -й технологии.

$H_0$ : выбор технологии не меняет производительности рабочих.

$H_1$ : выбор технологии влияет на производительность рабочих

$$\Rightarrow p = 0.356.$$

## 6 Критерий Пейджа

выборки:  $X_{ki} = \mu + \alpha_k + \beta_i + \varepsilon_{ki}, \quad i = 1, \dots, n, \quad k = 1, \dots, K;$

нулевая гипотеза:  $H_0: \alpha_1 = \dots = \alpha_K;$

альтернатива:  $H_1: \alpha_1 \leq \dots \leq \alpha_K;$

статистика:  $L(X) = \sum_{k=1}^K kR_k,$

$$R_k = \sum_{i=1}^n r_{ki},$$

$r_{ki}$  — ранг  $k$ -го элемента в  $i$ -й строке;

$L(X)$  имеет табличное распределение при  $H_0$ .

Аппроксимация для  $n > 15, K > 10$ :

$$L(X) \sim N\left(\frac{nK(K+1)^2}{4}, \frac{n(K^3 - K)^2}{144(K-1)}\right).$$

## 6 Критерий Пейджа

**Пример:** на 20 полях тестируется 5 доз калийных удобрений. Каждое поле поделено на 5 участков, по одному на каждую дозу. Измерена прочность выращенного на каждом участке хлопка.

$H_0$ : дозировка удобрений не влияет на прочность хлопка.

$H_1$ : дозировка удобрений влияет на прочность хлопка  $\Rightarrow p = 0.126$ .

$H_1$ : с ростом дозировки удобрений прочность хлопка увеличивается  
 $\Rightarrow p = 0.046$ .

## 7 Модель со случайным эффектом (random-effects model ANOVA)

- Характеристика, определяющая разбиение на группы, не представляет непосредственного интереса.
- Группы случайно выбраны из множества возможных групп.
- Если между группами есть неоднородность, ожидается, что она сохранится при повторе эксперимента, но соотношения между средними могут измениться.

### Примеры.

- Размеры горбаток в разных семьях, выращенных на одном и том же растении; цель — определить значимость фактора семьи для дальнейших исследований.
- Уровень гликогена в различных образцах икроножной мышцы крысы; если вариация между образцами даёт маленький вклад в общую вариацию, то можно считать, что для измерения уровня достаточно одного образца.
- Вкусовые качества персиков с 10 различных деревьев; планируется сравнить различия во вкусовых качествах персиков с разных деревьев с различиями у персиков с одного дерева. Если последние больше, то бессмысленно выбрать для размножения дерево с лучшей средней оценкой.

1 фактор  
oooooooooooo●oooooooo

2 фактора  
oooooo

3 фактора  
o

## 7 Модель со случайным эффектом (random-effects model ANOVA)

Если используется **модель со случайным эффектом**, следующий шаг — разделение дисперсий на внутригрупповые и межгрупповые.

Результат — доля межгрупповой дисперсии в общей дисперсии  $X^N$ .

## 8 Модель с фиксированным эффектом (fixed-effects model ANOVA)

- Разбиение на группы определено до получения данных.
- При повторе эксперимента ожидается, что соотношения между средними групп сохраняются.
- Если между средними есть различия, на следующем этапе анализируется, какие именно группы различаются.

### Примеры.

- Продолжительность жизни разногорих раков в морской воде и растворах глюкозы и маннозы.
- Экспрессия определённого гена в тканях мозга, печени, лёгких и мышц; необходимо понять, в какой ткани экспрессия выше.
- Вкусовые качества персиков с 10 различных деревьев; планируется выбрать лучшее дерево для дальнейшего разведения.

## 8 Модель с фиксированным эффектом (fixed-effects model ANOVA)

Если используется **модель с фиксированным эффектом**, то, в случае отвержения гипотезы однородности средних, проводится дополнительное сравнение с целью уточнения характера различий.

Сравнение может быть:

- запланированным, когда группы для дальнейшего сравнения отобраны до сбора данных.
- незапланированным, когда группы для сравнения выбираются по результатам первичного анализа данных.

Для запланированного попарного сравнения групп можно просто использовать подходящий двухвыборочный критерий.

Для незапланированного сравнения всё сложнее.

## Fisher's LSD (Least Significant Difference)

Если  $\mu_i = \mu_j$ , то

$$\frac{\bar{X}_i - \bar{X}_j}{S \sqrt{\frac{1}{n_i} + \frac{1}{n_j}}} \sim St(n_i + n_j - 2),$$

где  $S^2 = \frac{(n_i-1)S_i^2 + (n_j-1)S_j^2}{n_i+n_j-2}$ .

Рассмотрим величину

$$LSD_{ij} = \frac{t_\alpha S}{\sqrt{\frac{1}{n_i} + \frac{1}{n_j}}},$$

где  $t_\alpha$  —  $\alpha$ -квантиль распределения Стьюдента с  $n_i + n_j - 2$  степенями свободы.

Если  $|\bar{X}_i - \bar{X}_j| > LSD_{ij}$ , то частная нулевая гипотеза  $H_0: \mu_i = \mu_j$  отклоняется против двусторонней альтернативы.

Метод LSD можно использовать только в случае отвержения общей гипотезы однородности.

## Tukey's HSD (Honest Significant Difference)

$$n = \frac{K}{\sum_{k=1}^K \frac{1}{n_k}},$$

$$S^2 = \frac{1}{N - K} \sum_{k=1}^K (n_k - 1) S_k^2,$$

где  $S_k^2$  — дисперсия выборки  $X_k^{n_k}$ ,

$$HSD = \frac{q_\alpha (N - K) S}{\sqrt{n}},$$

где  $q_\alpha (N - K)$  — критическое значение распределения стьюдентизированного размаха с  $N - K$  степенями свободы.

Если  $|\bar{X}_i - \bar{X}_j| > HSD$ , то частная нулевая гипотеза  $H_0: \mu_i = \mu_j$  отклоняется против двусторонней альтернативы.

Метод HSD можно использовать независимо от справедливости общей гипотезы однородности.

## Критерий Неменъи

Непараметрический аналог процедуры HSD.

$$CD = q'_\alpha \sqrt{\frac{K(K+1)}{6N}},$$

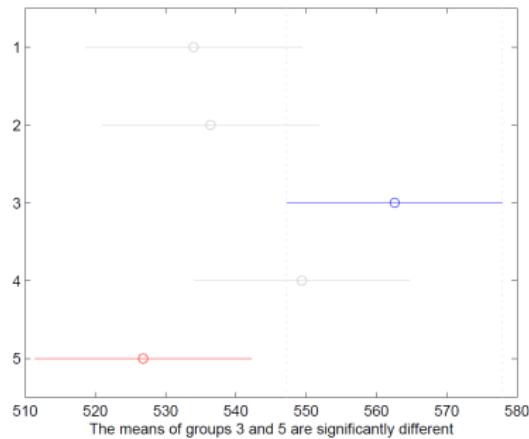
где  $q'_\alpha$  — критическое значение статистики критерия, основанное на распределении стьюдентизированного размаха.

Если  $|\bar{r}_i - \bar{r}_j| > CD$ , то частная нулевая гипотеза  $H_0: \Delta_i = \Delta_j$  отклоняется против двусторонней альтернативы.

## Пример

Овсяная мука пяти видов помола расфасовывается при помощи одного диспенсера. Стандартный объём упаковки — 500 г, но диспенсер обычно насыпает больше. Производитель подозревает, что объём упаковки может зависеть от помола муки.

Метод LSD: вес в группах 3 и 5 значимо отличается.



Метод HSD: значимых различий между средними не обнаружено.

## Критерий Бартлетта

выборки:  $X^N = X_1^{n_1} \cup \dots \cup X_K^{n_K}, \quad X_{ki} \sim N(\mu_k, \sigma_k^2);$

нулевая гипотеза:  $H_0: \sigma_1 = \sigma_2 = \dots = \sigma_K;$

альтернатива:  $H_1: H_0$  неверна;

статистика:  $B(X^N) = \frac{\ln 10}{C} \left( (N - K) \ln S^2 - \sum_{k=1}^K (n_k - 1) \ln S_k^2 \right),$

$$S^2 = \frac{1}{N-K} \sum_{k=1}^K (n_k - 1) S_k^2,$$

$$C = 1 + \frac{1}{3K+1} \left( \sum_{k=1}^K \frac{1}{n_k - 1} - \frac{1}{N} \right);$$

$B(X^N)$  имеет табличное распределение при  $H_0$ .

Аппроксимация для  $n_k > 6$ :

$$B(X^N) \sim \chi_{K-1}^2.$$

1 фактор  
○○○○○○○○○○○○○○●○○

2 фактора  
○○○○○

3 фактора  
○

## Критерий Бартлетта

**Пример:** четыре шпиндельные головки сравниваются по вариабельности размеров деталей, которые выточены с их помощью. Контролёром качества собраны выборки из 31, 15, 20 и 42 деталей.

$H_0$ : дисперсия размеров деталей, выточенных с помощью различных головок, одинакова.

$H_1$ : дисперсия размеров деталей, выточенных с помощью различных головок, неодинакова  $\Rightarrow p = 0.0626$ .

## Критерий квадратов рангов

выборки:  $X^N = X_1^{n_1} \cup \dots \cup X_K^{n_K}, \quad X_{ki} \sim F(\mu_k + \sigma_k x);$

нулевая гипотеза:  $H_0: \sigma_1 = \sigma_2 = \dots = \sigma_K;$

альтернатива:  $H_1: H_0$  неверна;

статистика:  $T_2(X^N) = \frac{1}{D^2} \left( \sum_{k=1}^K \frac{S_k^2}{n_k} - N\bar{S}^2 \right),$

$$S_k = \sum_{i=1}^{n_k} r(|X_{ki} - \bar{X}_k|)^2,$$

$$\bar{S} = \frac{1}{N} \sum_{k=1}^K S_k,$$

$$D^2 = \frac{1}{N-1} \left( \sum_{i=1}^N r_i^4 - N\bar{S}^2 \right);$$

$T_2(X^N)$  имеет табличное распределение при  $H_0$ .

Если нет связок, то:

$$\bar{S} = \frac{1}{6} (N+1)(2N+1),$$

$$D^2 = \frac{1}{180} N(N+1)(2N+1)(8N+11).$$

Аппроксимация для  $n_k > 10$ :

$$T_2(X^N) \sim \chi_{K-1}^2.$$

1 фактор  
○○○○○○○○○○○○○○●○

2 фактора  
○○○○○

3 фактора  
○

## Критерий квадратов рангов

**Пример:** четыре шпиндельные головки сравниваются по вариабельности размеров деталей, которые выточены с их помощью. Контролёром качества собраны выборки из 31, 15, 20 и 42 деталей.

$H_0$ : дисперсия размеров деталей, выточенных с помощью различных головок, одинакова.

$H_1$ : дисперсия размеров деталей, выточенных с помощью различных головок, неодинакова  $\Rightarrow p = 0.0856$ .

## Рост певцов хора

В 1979 году 130 участников Нью-Йоркской ассоциации хорового пения сообщили данные своего роста; для каждого известен также регистр голоса. Есть ли связь между ростом и регистром?

### Vocal Ranges



1 фактор

○○○○○○○○○○○○○●

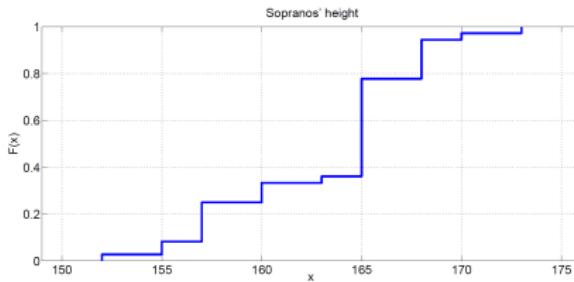
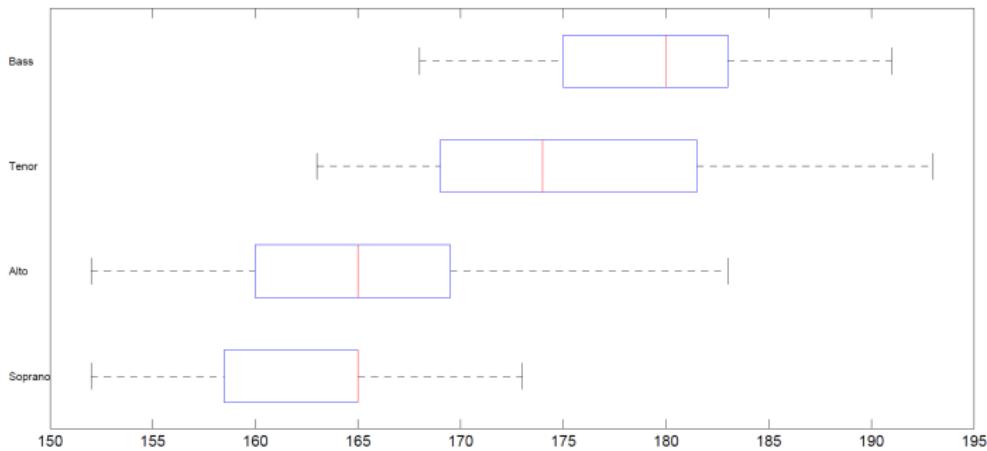
2 фактора

○○○○○

3 фактора

○

## Рост певцов хора



## Рост певцов хора

$H_0$ : рост и регистр голоса не связаны.

$H_1$ : для каких-то видов регистра голоса средний рост отличается.

| Source | SS      | df  | MS      | F     | Prob>F         |
|--------|---------|-----|---------|-------|----------------|
| Groups | 6901.4  | 3   | 2300.47 | 55.73 | 5.34718e - 023 |
| Error  | 5201.1  | 126 | 41.28   |       |                |
| Total  | 12102.5 | 129 |         |       |                |

SS — сумма квадратов отклонений, df — число степеней свободы, MS — дисперсия, F — статистика критерия;

строка Groups — оценки по выборочным средним, строка Error — оценки по выборочным дисперсиям.

## Рост певцов хора

Критерий Стьюдента для проверки гипотезы равенства роста певцов с альтом и сопрано:  $p = 0.2460$  — против двусторонней альтернативы,  $p = 0.1230$  — против односторонней альтернативы.

Критерий Стьюдента для проверки гипотезы равенства роста певцов с тенором и басом:  $p = 0.0597$  — против двусторонней альтернативы,  $p = 0.0298$  — против односторонней альтернативы.

Критерий Джонкхиера для проверки наличия тренда (увеличение роста с понижением регистра голоса):  $p < 0.00001$ .

1 фактор

oooooooooooooooooooo●

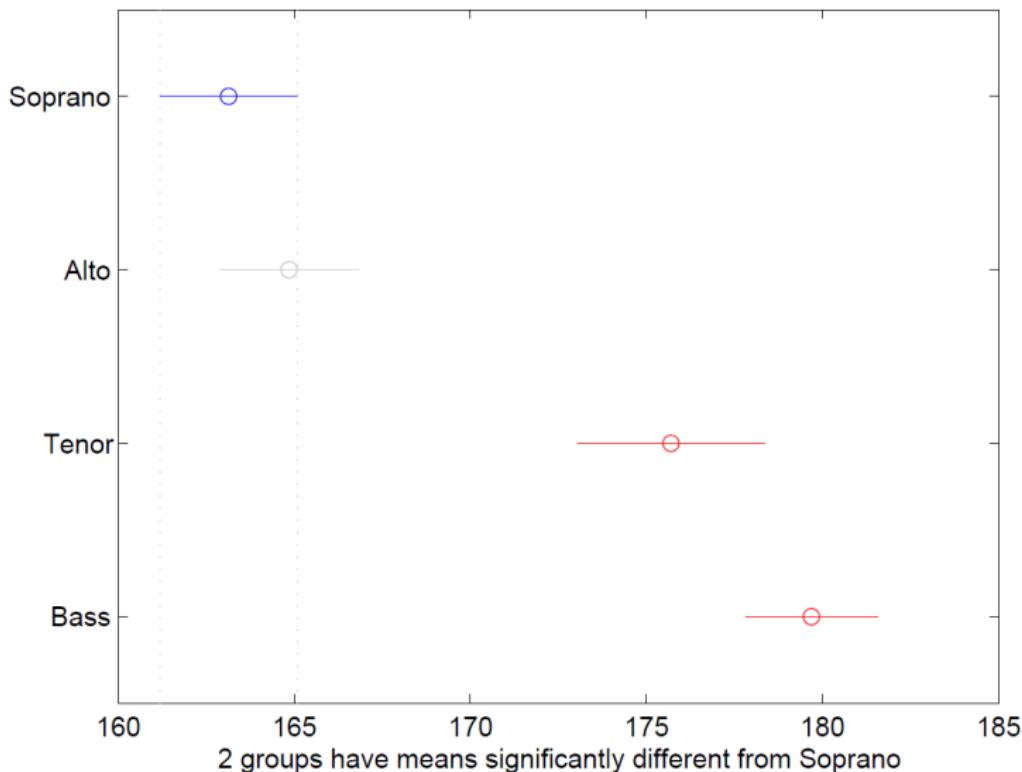
2 фактора

ooooo

3 фактора

○

## Рост певцов хора



1 фактор

oooooooooooooooooooo●

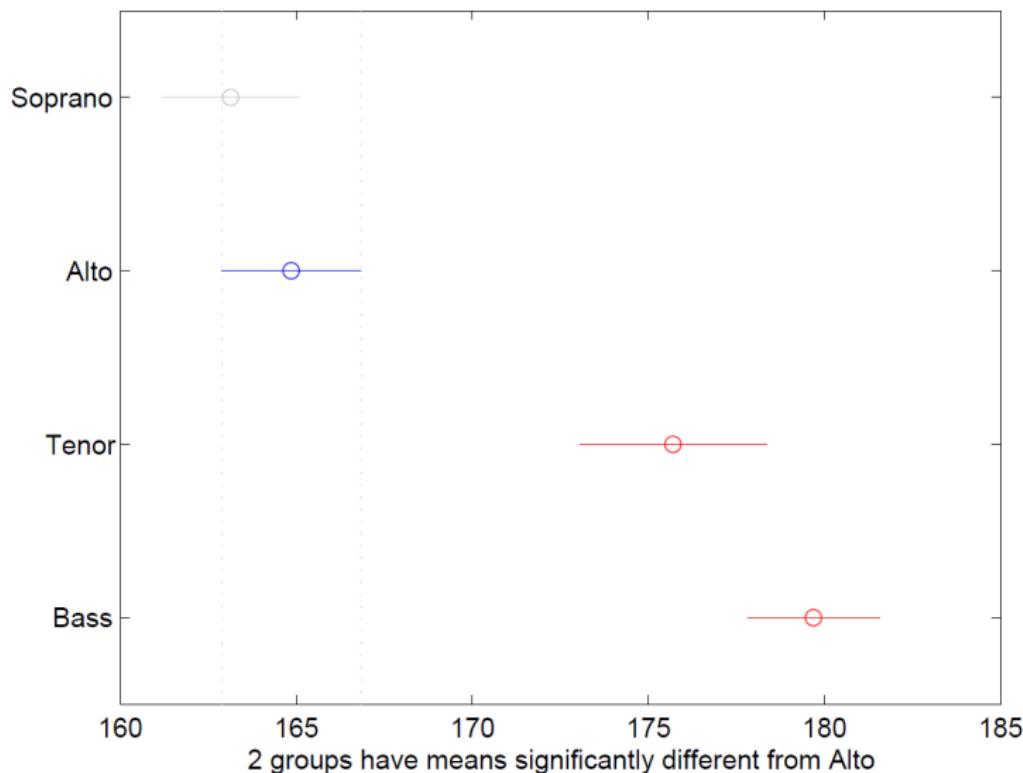
2 фактора

ooooo

3 фактора

○

## Рост певцов хора



1 фактор

oooooooooooooooooooo●

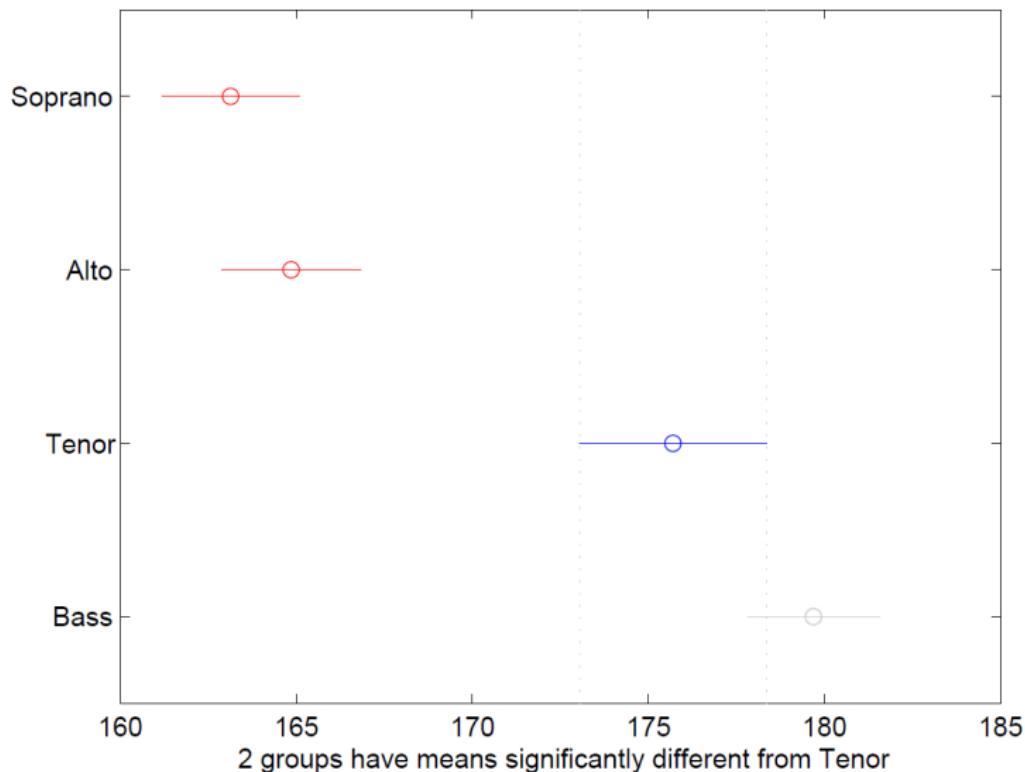
2 фактора

ooooo

3 фактора

○

## Рост певцов хора



1 фактор

oooooooooooooooooooo●

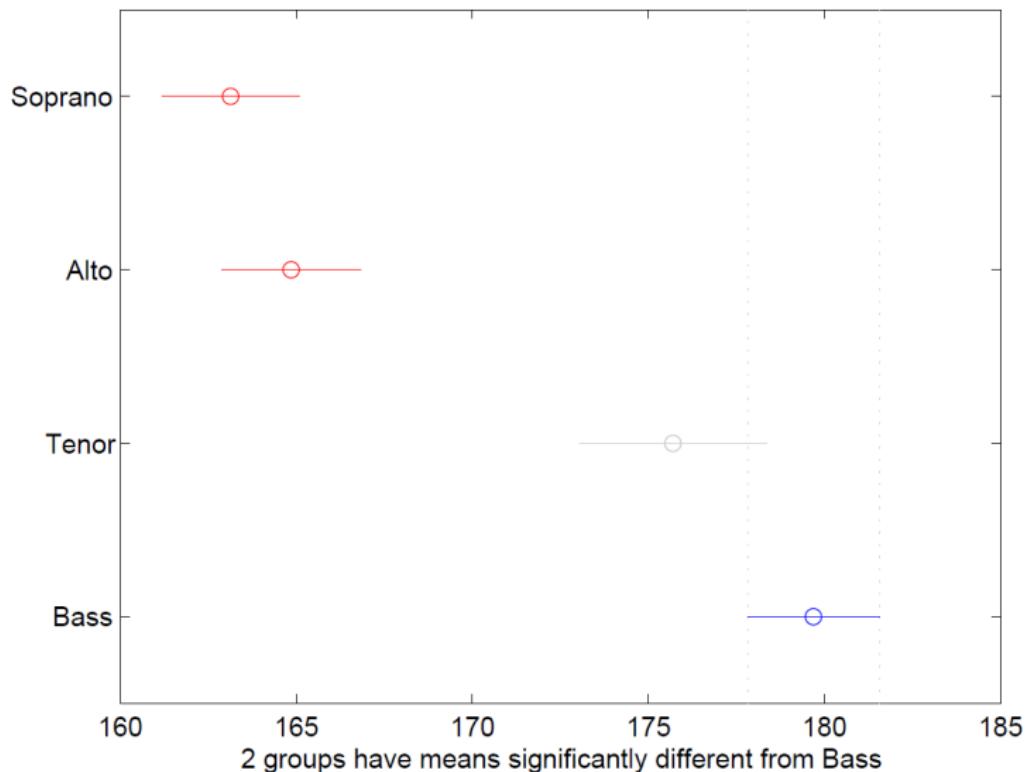
2 фактора

ooooo

3 фактора

○

## Рост певцов хора



## Двухфакторный дисперсионный анализ (two-way ANOVA)

$$f_1: X \rightarrow \{1, \dots, K_1\}, \quad f_2: X \rightarrow \{1, \dots, K_2\}$$

| $f_1 \backslash f_2$ | 1 | $\dots$ | $j$         | $\dots$  | $K_2$ |
|----------------------|---|---------|-------------|----------|-------|
| 1                    |   |         |             |          |       |
| $\vdots$             |   |         |             |          |       |
| $i$                  |   |         | $X_{ij1}$   | $\vdots$ |       |
|                      |   |         | $X_{ijn_i}$ |          |       |
| $\vdots$             |   |         |             |          |       |
| $K_1$                |   |         |             |          |       |

Задача: проверить гипотезу об отсутствии влияния факторов  $f_1$  и  $f_2$  на среднее значение признака  $X$ .

1 фактор  
oooooooooooooooooooo

2 фактора  
●○○○○

3 фактора  
○

## Двухфакторный дисперсионный анализ (two-way ANOVA)

Линейная модель:

$$X_{ijk} = \mu + \alpha_i + \beta_j + \gamma_{ij} + \varepsilon_{ijk},$$

$$i = 1, \dots, K_1, \quad j = 1, \dots, K_2, \quad k = 1, \dots, n.$$

$\mu$  — общее среднее значение признака,

$\alpha_i$  — воздействие уровня  $i$  фактора  $f_1$ ,

$\beta_j$  — воздействие уровня  $j$  фактора  $f_2$ ,

$\gamma_{ij}$  — дополнительное воздействие комбинации уровней  $i$  и  $j$  факторов

$f_1$  и  $f_2$ ,

$\varepsilon_{ijk}$  — случайные независимые одинаково распределённые ошибки.

## Двухфакторный дисперсионный анализ (two-way ANOVA)

$H_0^1$ : фактор  $f_1$  не влияет на значение признака  $X \Leftrightarrow \alpha_i = 0 \quad \forall i,$

$H_1^1$ :  $f_1$  влияет на значение  $X;$

$H_0^2$ : фактор  $f_2$  не влияет на значение признака  $X \Leftrightarrow \beta_j = 0 \quad \forall j,$

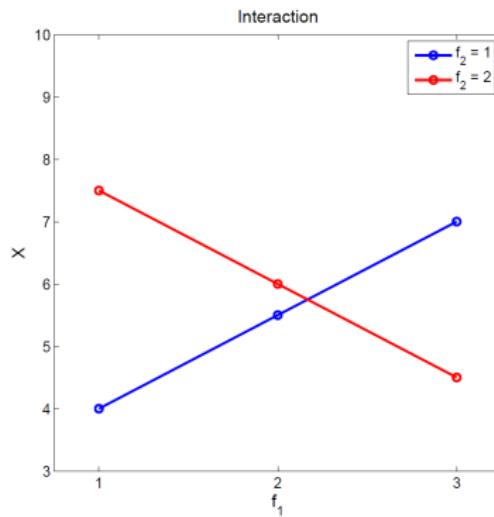
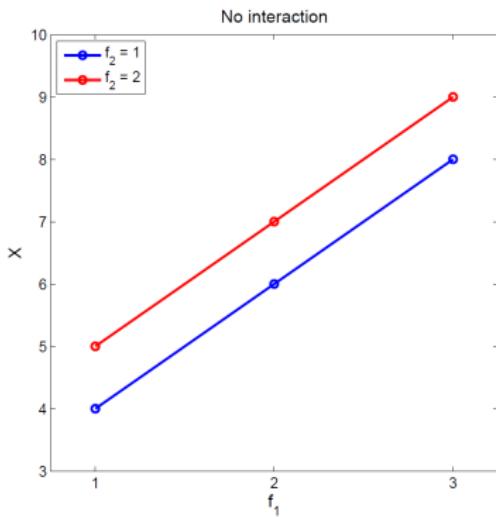
$H_1^2$ :  $f_2$  влияет на значение  $X;$

$H_0^{12}$ : между факторами  $f_1, f_2$  нет взаимодействия  $\Leftrightarrow \gamma_{ij} = 0 \quad \forall i, j,$

$H_1^{12}$ : между факторами  $f_1, f_2$  есть взаимодействие.

## Двухфакторный дисперсионный анализ (two-way ANOVA)

Пример:  $X$  — успешность решения задачи (в баллах от 0 до 10),  
 $f_1$  — размер команды (1 — маленькая, 2 — средняя, 3 — большая),  
 $f_2$  — наличие назначенного лидера (1 — нет, 2 — есть).



1 фактор  
oooooooooooooooooooo

2 фактора  
o●○○○○

3 фактора  
○

## Дополнительные разновидности двухфакторного дисперсионного анализа

- По типу факторов: независимые, вложенные (nested), латинский квадрат (latin square).

Случай выборок разного размера (unbalanced ANOVA) для двух факторов значительно сложнее, поэтому будем считать, что  $n_{11} = \dots = n_{K_1 K_2} = n$ .

## Нормальный двухфакторный дисперсионный анализ

Предположим, что  $X_{ijk} \sim N(\mu_{ij}, \sigma^2) \Leftrightarrow \varepsilon_{ijk} \sim N(0, \sigma^2)$ .

$\bar{X}_{ij}$  — среднее в ячейке,

$\bar{X}_{i\bullet}$  — среднее по строке  $i$ ,

$\bar{X}_{\bullet j}$  — среднее по столбцу  $j$ ,

$\bar{X}$  — среднее по всей таблице.

Внутрифакторные дисперсии:

$$S_1^2 = \frac{nK_2}{K_1 - 1} \sum_{i=1}^{K_1} (\bar{X}_{i\bullet} - \bar{X})^2,$$

$$S_2^2 = \frac{nK_1}{K_2 - 1} \sum_{i=1}^{K_2} (\bar{X}_{\bullet j} - \bar{X})^2,$$

$$S_{12}^2 = \frac{n}{(K_1 - 1)(K_2 - 1)} \sum_{i,j} (\bar{X}_{ij} - \bar{X}_{i\bullet} - \bar{X}_{\bullet j} + \bar{X})^2,$$

$$S_{res}^2 = \frac{1}{K_1 K_2 (n - 1)} \sum_{k=1}^n \sum_{i,j} (X_{ijk} - \bar{X}_{ij})^2.$$

# Нормальный двухфакторный дисперсионный анализ

Проверка значимости факторов и их взаимодействия:

- $n > 1$ :

$$F_1 = \frac{S_1^2}{S_{res}^2} \sim F(K_1 - 1, K_1 K_2 (n - 1)) \text{ при } H_0^1,$$

$$F_2 = \frac{S_2^2}{S_{res}^2} \sim F(K_2 - 1, K_1 K_2 (n - 1)) \text{ при } H_0^2,$$

$$F_{12} = \frac{S_{12}^2}{S_{res}^2} \sim F((K_1 - 1)(K_2 - 1), K_1 K_2 (n - 1)) \text{ при } H_0^{12};$$

- $n = 1$ :

$$F_1 = \frac{S_1^2}{S_{12}^2} \sim F(K_1 - 1, (K_1 - 1)(K_2 - 1)) \text{ при } H_0^1,$$

$$F_2 = \frac{S_2^2}{S_{12}^2} \sim F(K_2 - 1, (K_1 - 1)(K_2 - 1)) \text{ при } H_0^2.$$

При этом подразумевается, что  $H_0^{12}$  верна.

## Марихуана и скорость реакции

Изучалось воздействие марихуаны на скорость реакции. В качестве испытуемых были выбраны по 12 человек из каждой категории:

- никогда не пробовали марихуану;
- иногда употребляют марихуану;
- регулярно употребляют марихуану.

Испытуемые были разделены на две равные группы; половине из них дали выкурить две сигареты с марихуаной, вторая половина выкурила две обычные сигареты с запахом и вкусом марихуаны. Сразу после этого все испытуемые прошли тест на скорость реакции.

Требуется оценить влияние марихуаны на скорость реакции, учитывая фактор предыдущего опыта употребления.

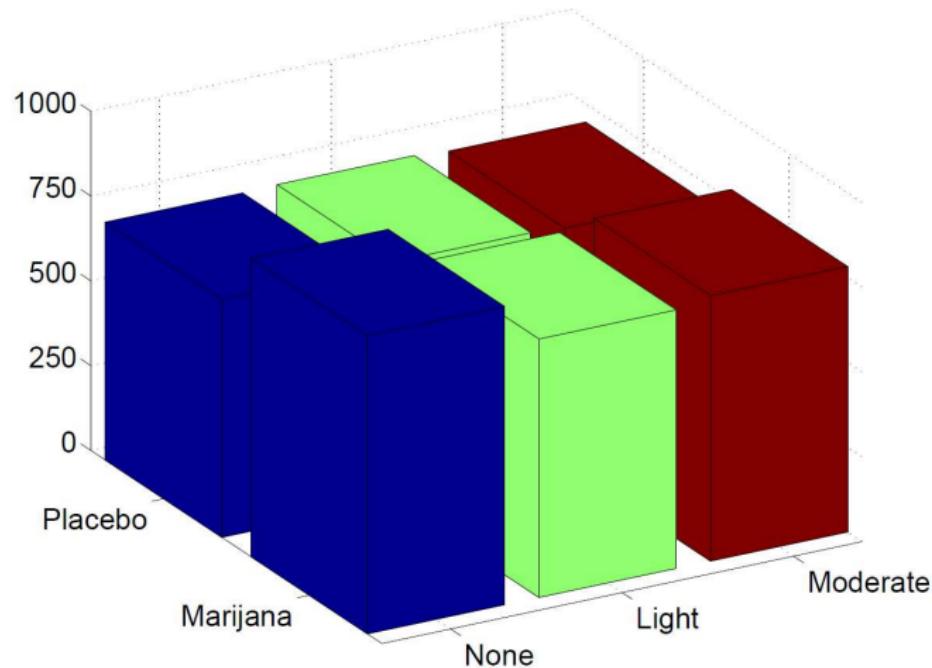
1 фактор  
○○○○○○○○○○○○○○○○

2 фактора  
○○○●○○

3 фактора  
○

## Марихуана и скорость реакции

Плохой график:



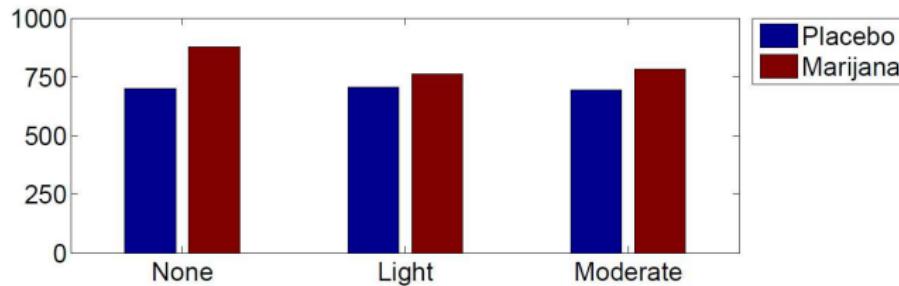
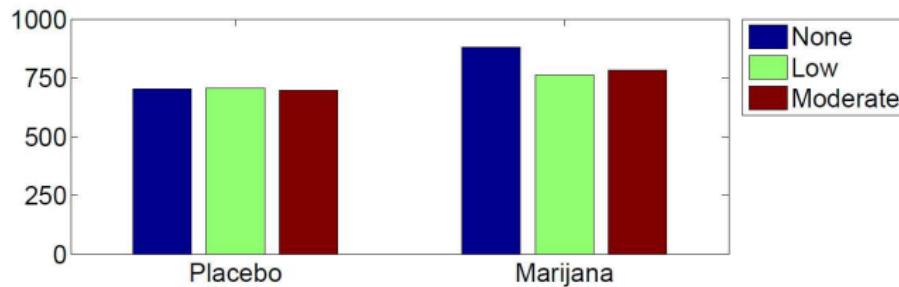
1 фактор  
○○○○○○○○○○○○○○○○

2 фактора  
○○○●○○

3 фактора  
○

## Марихуана и скорость реакции

Хорошие графики:



## Марихуана и скорость реакции

$H_0^1$ : средняя скорость реакции одинакова при употреблении и марихуаны, и сигарет.

$H_0^2$ : средняя скорость реакции не зависит от предыдущего опыта употребления марихуаны.

$H_0^{12}$ : отсутствует межфакторное взаимодействие между употребляемым веществом и предыдущим опытом употребления марихуаны.

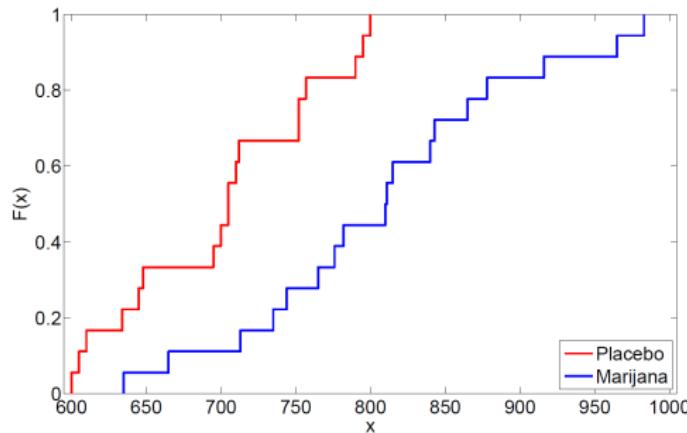
| Source      | SS       | df | MS      | F     | Prob>F |
|-------------|----------|----|---------|-------|--------|
| Group       | 103041   | 1  | 103041  | 17.58 | 0.0002 |
| Past use    | 23634.5  | 2  | 11817.2 | 2.02  | 0.1508 |
| Interaction | 23642.2  | 2  | 11821.1 | 2.02  | 0.1507 |
| Error       | 175796.3 | 30 | 5859.9  |       |        |
| Total       | 326114   | 35 |         |       |        |

## Марихуана и скорость реакции

Вывод: гипотеза о том, что предыдущий опыт употребления не влияет на скорость реакции, не отклоняется  $\Rightarrow$  данные по группам можно объединить.

Для объединённых данных:

- однофакторный дисперсионный анализ:  $p = 0.00036$ ;
- критерий Уилкоксона, двусторонняя альтернатива:  $p = 0.000596$ ;
- критерий Стьюдента, односторонняя альтернатива:  
 $p = 0.00018$ ,  $ci = (61.3, \infty)$ ;



1 фактор  
oooooooooooooooooooo

2 фактора  
oooo●○

3 фактора  
○

## Иерархический дизайн

Стандартная постановка двухфакторного дисперсионного анализа предполагает, что уровни факторов в выборке распределены независимо.

Пример, когда это не так: признак — уровень гликогена в икроножной мышце крысы, фактор 1 — уровень стресса крыс, фактор 2 — различия между клетками. Крысы со стрессом живут в клетках 1 и 2, без стресса — 3 и 4.

Решение — иерархический дисперсионный анализ (nested ANOVA).

1 фактор  
oooooooooooooooooooo

2 фактора  
oooo●

3 фактора  
○

## CBI чернобрюхой дрозофилы

Codon bias index (CBI) — мера случайности использования синонимичных кодонов в геноме — была определена для нескольких регионов двух хромосом чернобрюхой дрозофилы. Требуется определить, есть ли систематические различия по величине CBI между разными хромосомами и регионами.



1 фактор  
oooooooooooooooooooo

2 фактора  
ooooo●

3 фактора  
○

## CBI чернобрюхой дрозофилы

| Source             | SS      | df | MS      | F    | Prob>F |
|--------------------|---------|----|---------|------|--------|
| Chromosome         | 0.00496 | 2  | 0.00248 | 0.32 | 0.7319 |
| Region(Chromosome) | 0.16295 | 3  | 0.05432 | 6.92 | 0.0011 |
| Error              | 0.23564 | 30 | 0.00785 |      |        |
| Total              | 0.40891 | 35 |         |      |        |

Есть различия между регионами, нет различий между хромосомами.

1 фактор  
oooooooooooooooooooo

2 фактора  
ooooo●

3 фактора  
○

## CBI чернобрюхой дрозофилы

Для уточнения различий применим метод HSD:

| Группа 1 | Группа 2 | $CI_L$  | mean    | $CI_U$ |
|----------|----------|---------|---------|--------|
| 7D       | 93C      | -0.1485 | 0.0093  | 0.1672 |
| 7D       | 49E      | -0.0847 | 0.0732  | 0.2310 |
| 7D       | 41F      | -0.0161 | 0.1417  | 0.2996 |
| 7D       | 1A       | 0.0181  | 0.1886  | 0.3591 |
| 7D       | 66D      | -0.0207 | 0.1498  | 0.3203 |
| 93C      | 49E      | -0.0802 | 0.0639  | 0.2079 |
| 93C      | 41F      | -0.0117 | 0.1324  | 0.2765 |
| 93C      | 1A       | 0.0214  | 0.1793  | 0.3371 |
| 93C      | 66D      | -0.0174 | 0.1405  | 0.2983 |
| 49E      | 41F      | -0.0755 | 0.0686  | 0.2127 |
| 49E      | 1A       | -0.0424 | 0.1154  | 0.2733 |
| 49E      | 66D      | -0.0812 | 0.0766  | 0.2345 |
| 41F      | 1A       | -0.1110 | 0.0469  | 0.2047 |
| 41F      | 66D      | -0.1498 | 0.0081  | 0.1659 |
| 1A       | 66D      | -0.2093 | -0.0388 | 0.1317 |

1 фактор

oooooooooooooooooooo

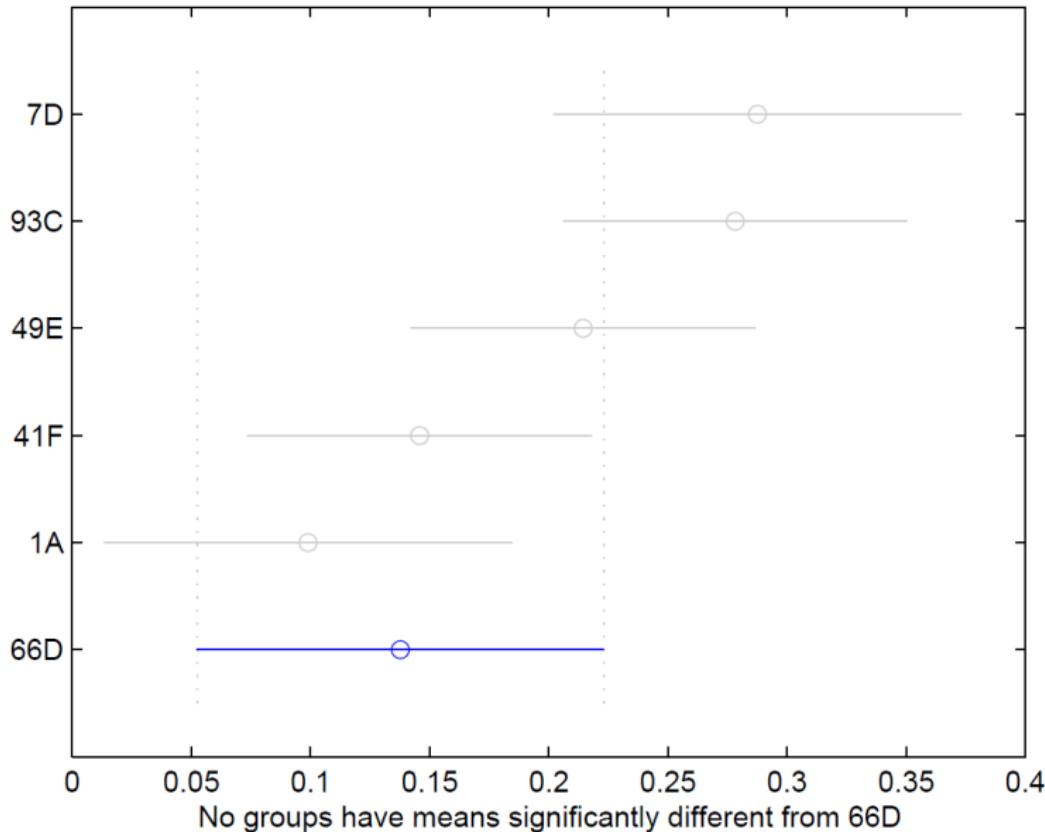
2 фактора

ooooo●

3 фактора

○

## CBI чернобрюхой дрозофилы



1 фактор

oooooooooooooooooooo

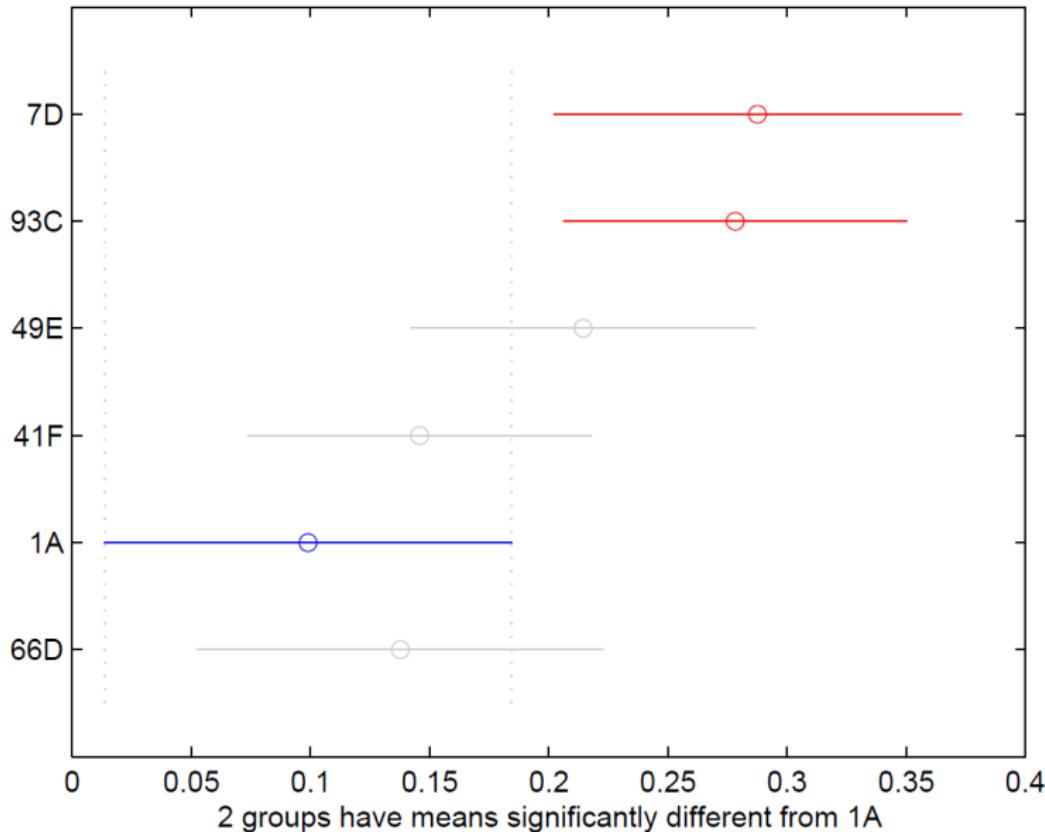
2 фактора

ooooo●

3 фактора

○

## CBI чернобрюхой дрозофилы



1 фактор

oooooooooooooooooooo

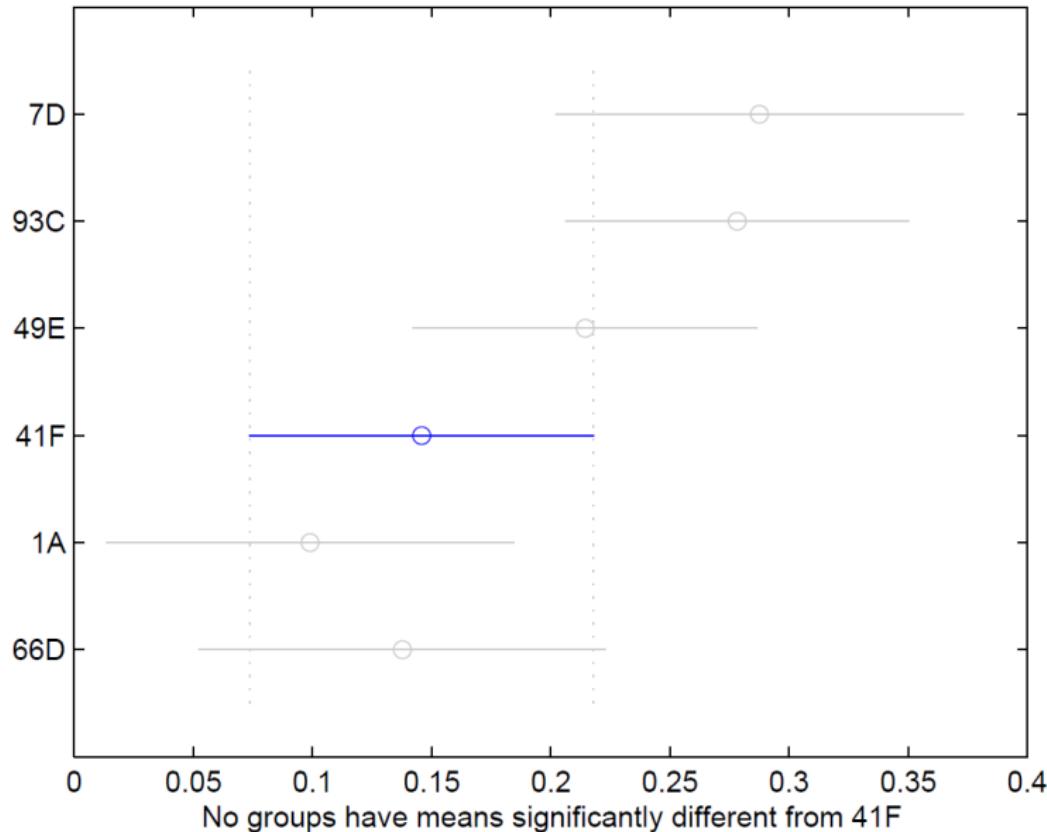
2 фактора

ooooo●

3 фактора

○

## CBI чернобрюхой дрозофилы



1 фактор

oooooooooooooooooooo

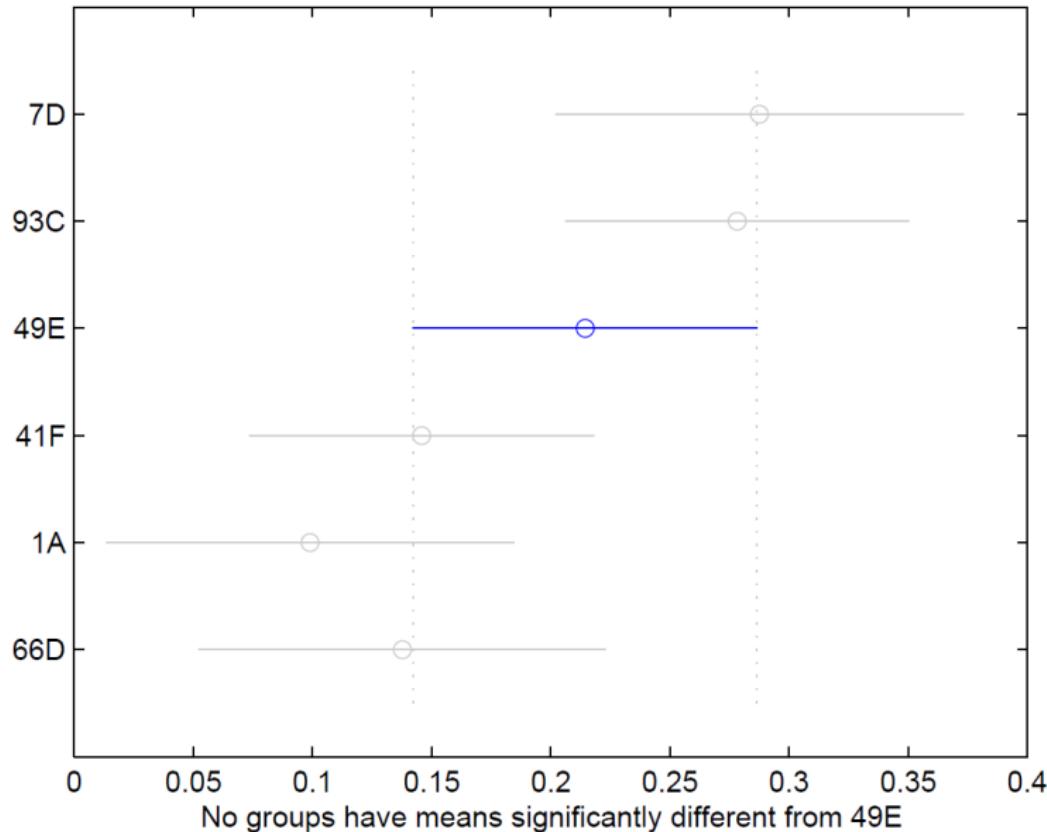
2 фактора

ooooo●

3 фактора

○

## CBI чернобрюхой дрозофилы

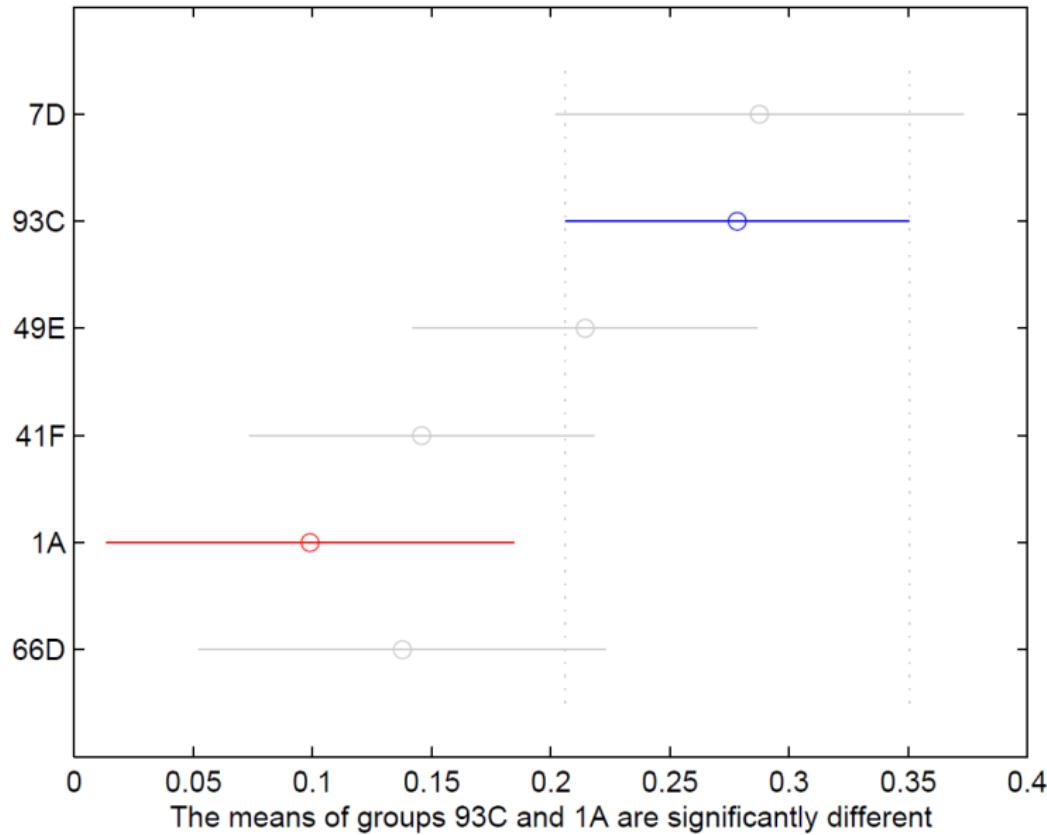


1 фактор  
○○○○○○○○○○○○○○○○

2 фактора  
○○○○●

3 фактора  
○

## CBI чернобрюхой дрозофилы



1 фактор

○○○○○○○○○○○○○○○○○○○○

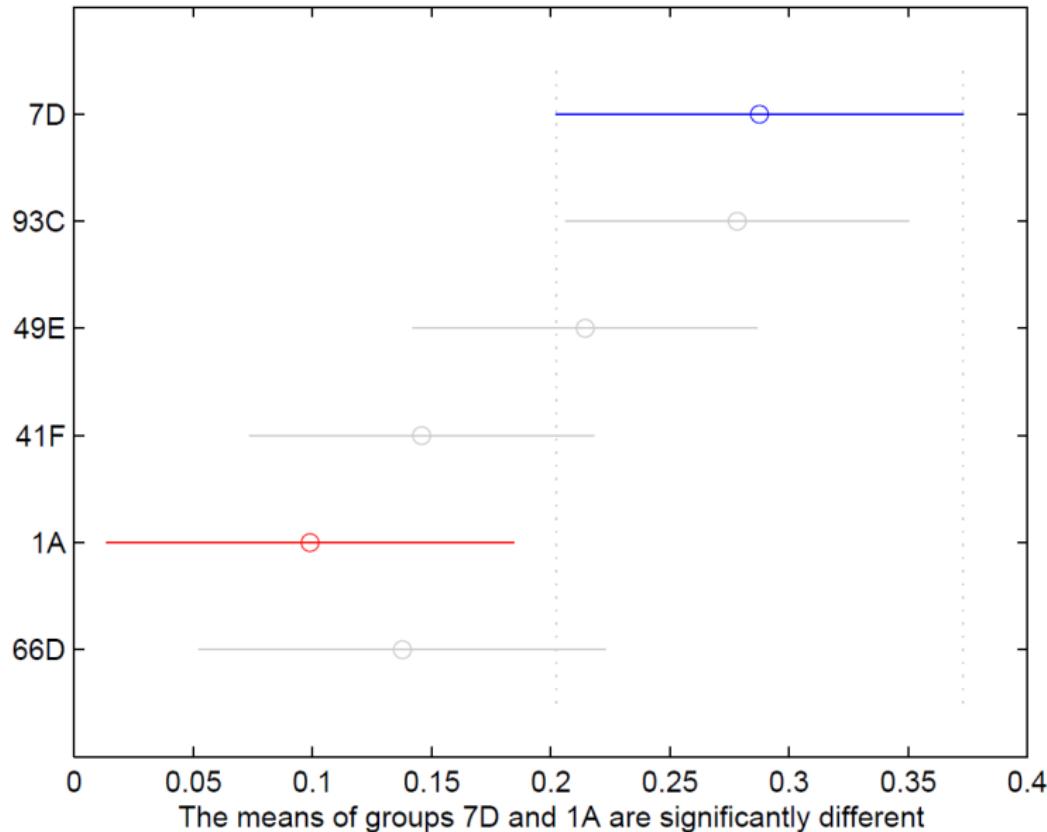
2 фактора

○○○○●

3 фактора

○

## CBI чернобрюхой дрозофилы



## Лечение гипертонии

72 пациента проходили лечение от гипертонии. Для лечения использовались три вида лекарств, при этом их эффект изучался как при использовании специальной диеты, так и в её отсутствии; кроме того, в ряде случаев применялась психотерапия. Данные — артериальное давление пациента по окончании лечения.

Требуется сравнить эффективность методов для лечения гипертонии.

Дизайн  $[3 \times 2 \times 2]$ .

## Лечение гипертонии

Трёхфакторный дисперсионный анализ, все взаимодействия:

| Source            | SS    | df | MS     | F     | Prob>F |
|-------------------|-------|----|--------|-------|--------|
| Therapy           | 2048  | 1  | 2048   | 13.07 | 0.0006 |
| Diet              | 5202  | 1  | 5202   | 33.2  | 0      |
| Drug              | 3675  | 2  | 1837.5 | 11.73 | 0.0001 |
| Therapy*Diet      | 32    | 1  | 32     | 0.2   | 0.6529 |
| Therapy*Drug      | 259   | 2  | 129.5  | 0.83  | 0.4425 |
| Diet*Drug         | 903   | 2  | 451.5  | 2.88  | 0.0638 |
| Therapy*Diet*Drug | 1075  | 2  | 537.5  | 3.43  | 0.0388 |
| Error             | 9400  | 60 | 156.67 |       |        |
| Total             | 22594 | 71 |        |       |        |

## Лечение гипертонии

Значимость многофакторных взаимодействий:

- Diet\*Drug: воздействие диеты различно при различных применяемых препаратах (или наоборот, действие препаратов зависит от диеты);
- Therapy\*Diet\*Drug: воздействие одного из факторов различно при различных комбинациях двух других. Хотя эффект Therapy\*Drug незначим в целом, значимость Therapy\*Diet\*Drug говорит о том, что влияние Therapy\*Drug необходимо оценивать отдельно для пациентов, использующих и не использующих диету.

## Литература

- разновидности ANOVA — Tabachnick, 3.2;
- применение в R — Chang,  
[http://www.cookbook-r.com/Statistical\\_analysis/ANOVA/](http://www.cookbook-r.com/Statistical_analysis/ANOVA/);
- критерий Маухли (Mauchly's sphericity test), поправки при отсутствии сферичности (Huynh-Feldt, Greenhouse-Geisser, lower-bound) —  
[http://en.wikipedia.org/wiki/Mauchly%27s\\_sphericity\\_test](http://en.wikipedia.org/wiki/Mauchly%27s_sphericity_test);
- unbalanced two-way ANOVA — Tabachnik, 6;
- критерии Краскела-Уоллиса (Kruskal-Wallis) и Джонкхиера (Jonckheere) — Кобзарь, 4.2.1.2.1, 4.2.1.2.9;
- критерии Фридмана (Friedman) и Пейджа (Page) — Лагутин, гл. 17;
- непараметрический двухфакторных дисперсионный анализ — Wilcox, 7.9.

Tabachnick B.G., Fidell L.S. *Using Multivariate Statistics*. — Boston: Pearson Education, 2012.

Chang W. *Cookbook for R*. — <http://www.cookbook-r.com/>.

Лагутин М.Б. *Наглядная математическая статистика*. — Москва: Бином, 2007.

Кобзарь А.И. *Прикладная математическая статистика*. — М.: Физматлит, 2006.

Wilcox R.R. *Introduction to Robust Estimation and Hypothesis Testing*. — Academic Press, 2012.