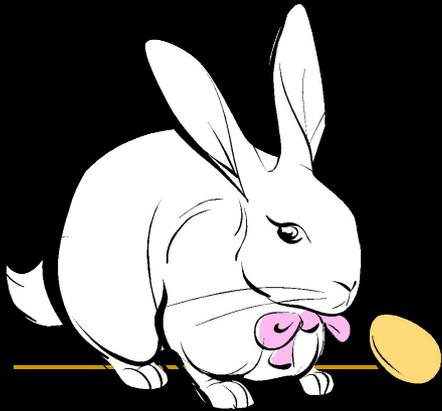


Занятие 6

Корреляции.

Регрессионный анализ



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 (скажем, сравнивали разные группы в ANOVA).

Настало время обратиться к ситуации, когда зависимых переменных будет **ДВЕ** и более.

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

Это могут быть измерения одной особи или связанных пар.

* кроме MANOVA

Корреляции

Мы исследуем сусликов. И хотим узнать, связаны ли между собой у них масса и длина хвоста?

Переменные – 1. масса; 2. длина хвоста.



Корреляции

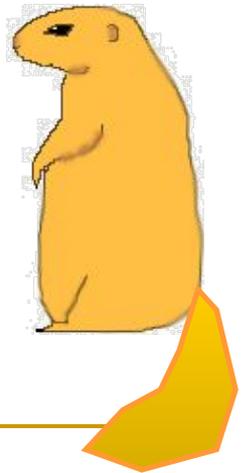
Вопрос: в какой степени две переменные СОВМЕСТНО ИЗМЕНЯЮТСЯ? (т.е., можно ли предполагать, что если у особи одна переменная принимает большое значение, то и значение второй переменной будет большим, или, наоборот, маленьким)

КОЭФФИЦИЕНТ КОРРЕЛЯЦИИ характеризует силу связи между переменными.

ЭТО ПРОСТО ПАРАМЕТР ОПИСАТЕЛЬНОЙ СТАТИСТИКИ



Большой коэффициент корреляции между массой тела и длиной хвоста позволяет нам предсказывать, что у большого суслика, скорее всего, и хвост будет длинным



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)

r – в случае, если мы характеризуем **ВЫБОРКУ**

ρ - если мы характеризуем **ПОПУЛЯЦИЮ**

Корреляции

Рост братьев: коэффициент корреляции r -?



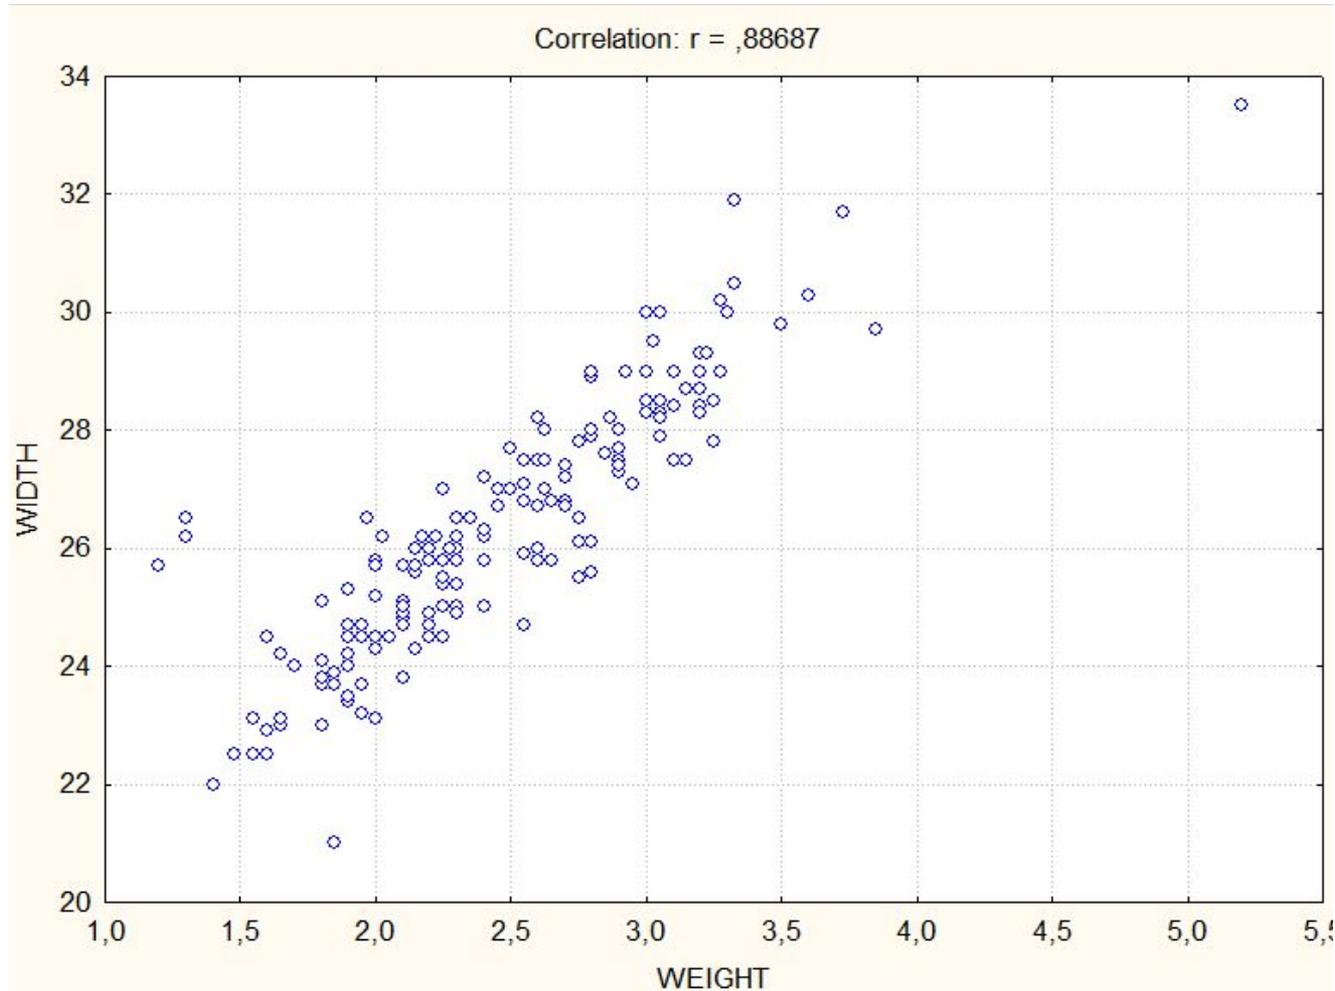
Петя



Гриша

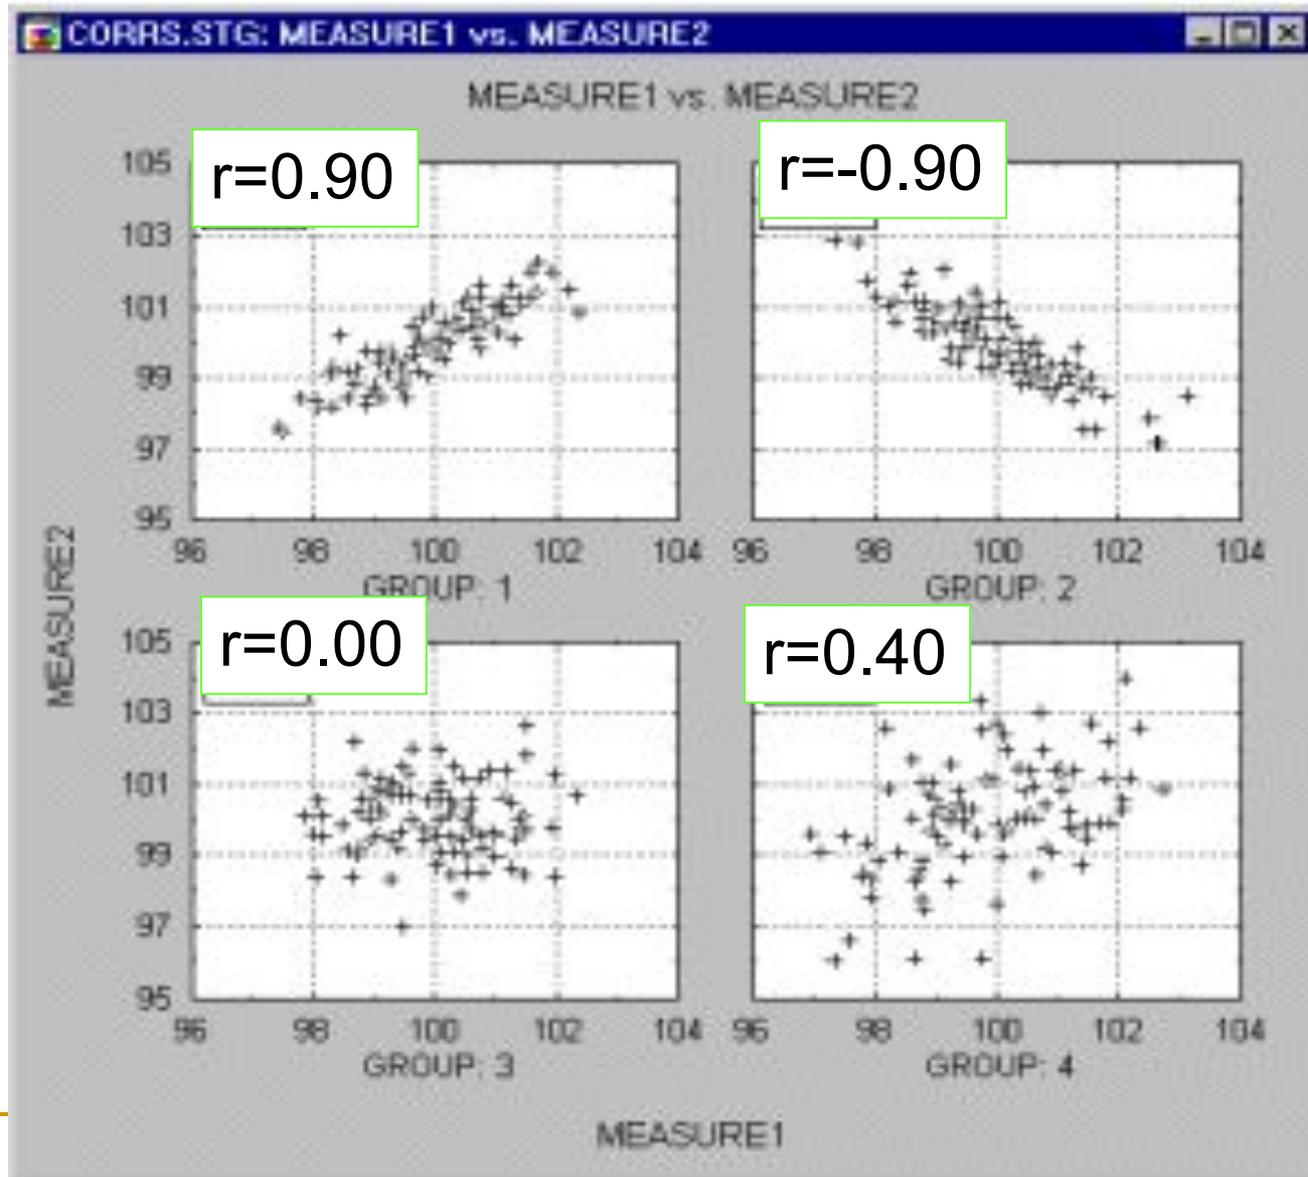
1. $r=1.0$: если Петя высокого роста, значит, Гриша тоже высокий, это не предположение, а **факт**.
2. $r=0.7$: если Петя высокий, то, **скорее всего**, Гриша тоже высокий.
3. $r=0.0$: если Петя высокий, то мы... не можем сказать росте Гриши **НИЧЕГО**.

(= диаграмма рассеяния; scatterplot, scatter diagram)



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

Корреляции



Корреляции

Коэффициент корреляции Пирсона
(Pearson product-moment correlation coefficient r)



Karl Pearson (1857 –1936)

Корреляции

Коэффициент корреляции Пирсона

| суслик | вес | хвост |
|--------|------|-------|
| Дима | 72 | 160 |
| Гриша | 66 | 144 |
| Миша | 68 | 154 |
| Коля | 74 | 210 |
| Федя | 68 | 182 |
| Рома | 64 | 159 |
| | 68,7 | 168,2 |

$$r = \frac{\sum z_{X_i} z_{Y_i}}{n - 1}$$

z – оценки
(см. занятие 1)

число строк
(сусликов)

$$z_{X_i} = \frac{X_i - \bar{X}}{s_X}$$

$$z_{Y_i} = \frac{Y_i - \bar{Y}}{s_Y}$$

стандартное
отклонение для веса

стандартное
отклонение для хвоста

для каждого X и Y (для каждого суслика)

Это одна из нескольких эквивалентных формул для коэффициента корреляции Пирсона

Корреляции

$$r = \frac{\sum z_X z_Y}{n-1}$$

параметр
ВЫБОРКИ



$$\rho = \frac{\sum z_X z_Y}{N}$$

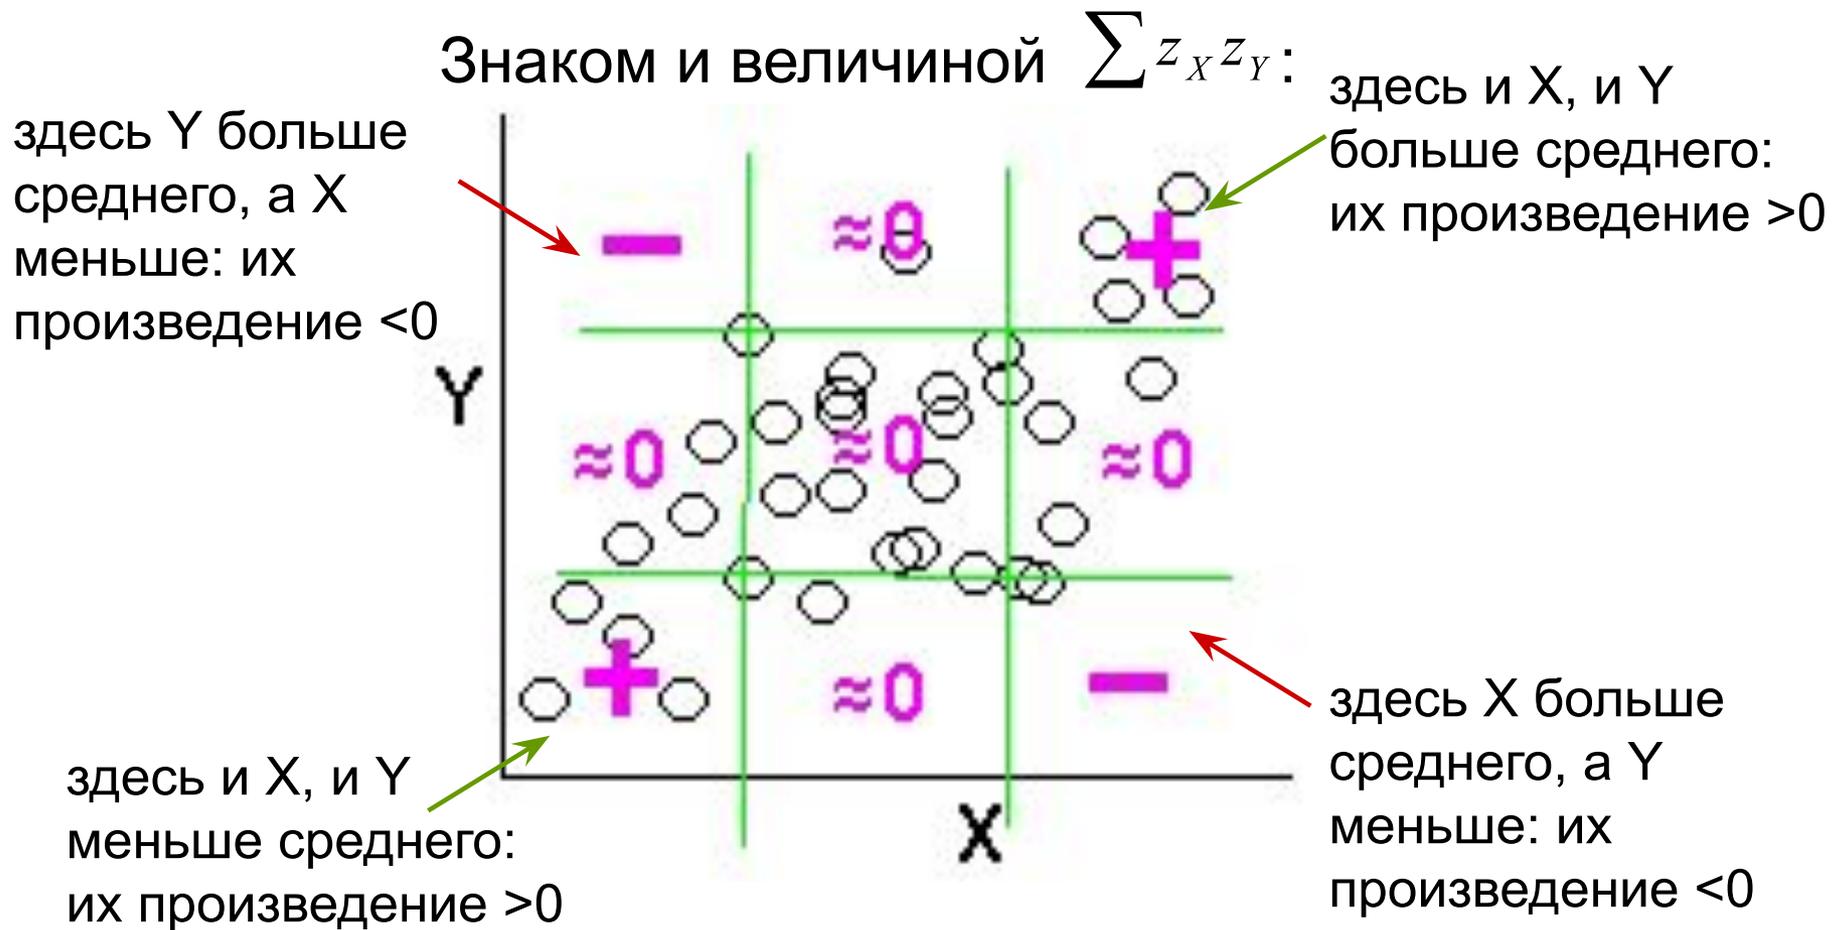
параметр
ПОПУЛЯЦИИ

Всё как для других параметров описательной статистики: среднего, дисперсии, и т.д.!

Что определяет $\sum z_X z_Y$?

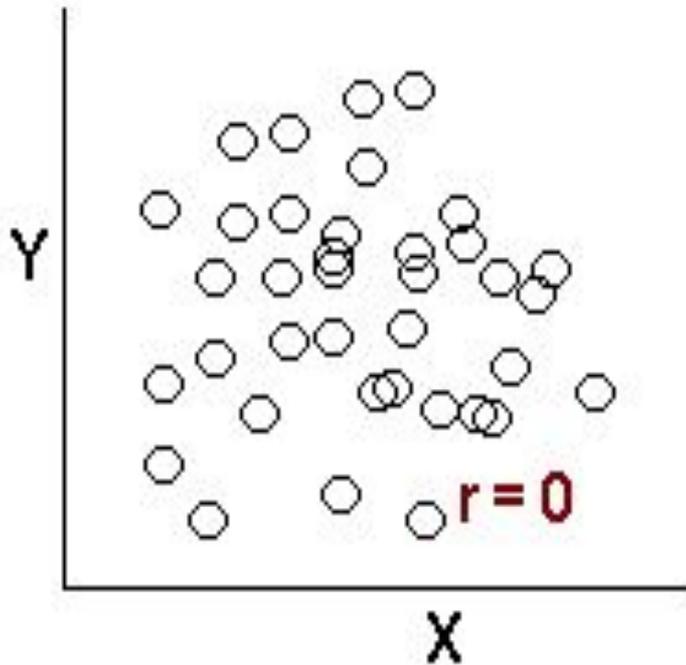
Корреляции

Чем определяются **знак и величина** коэффициента корреляции?



Корреляции

Создаётся впечатление, что близкий к нулю коэффициент корреляции говорит о том, что связи между переменными нет или почти нет.



Здесь и впрямь её нет

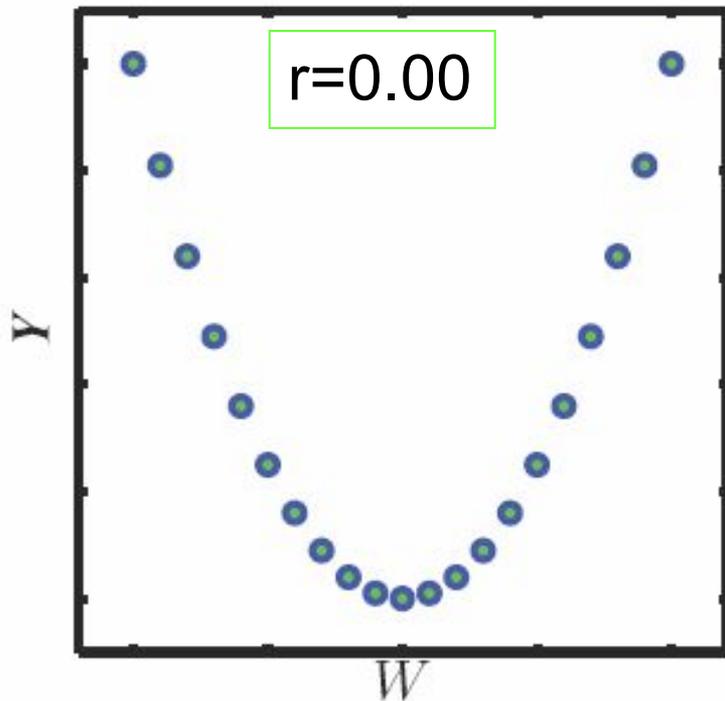
НО это не всегда так, есть исключения.

Корреляции

Факторы, влияющие на коэффициент корреляции

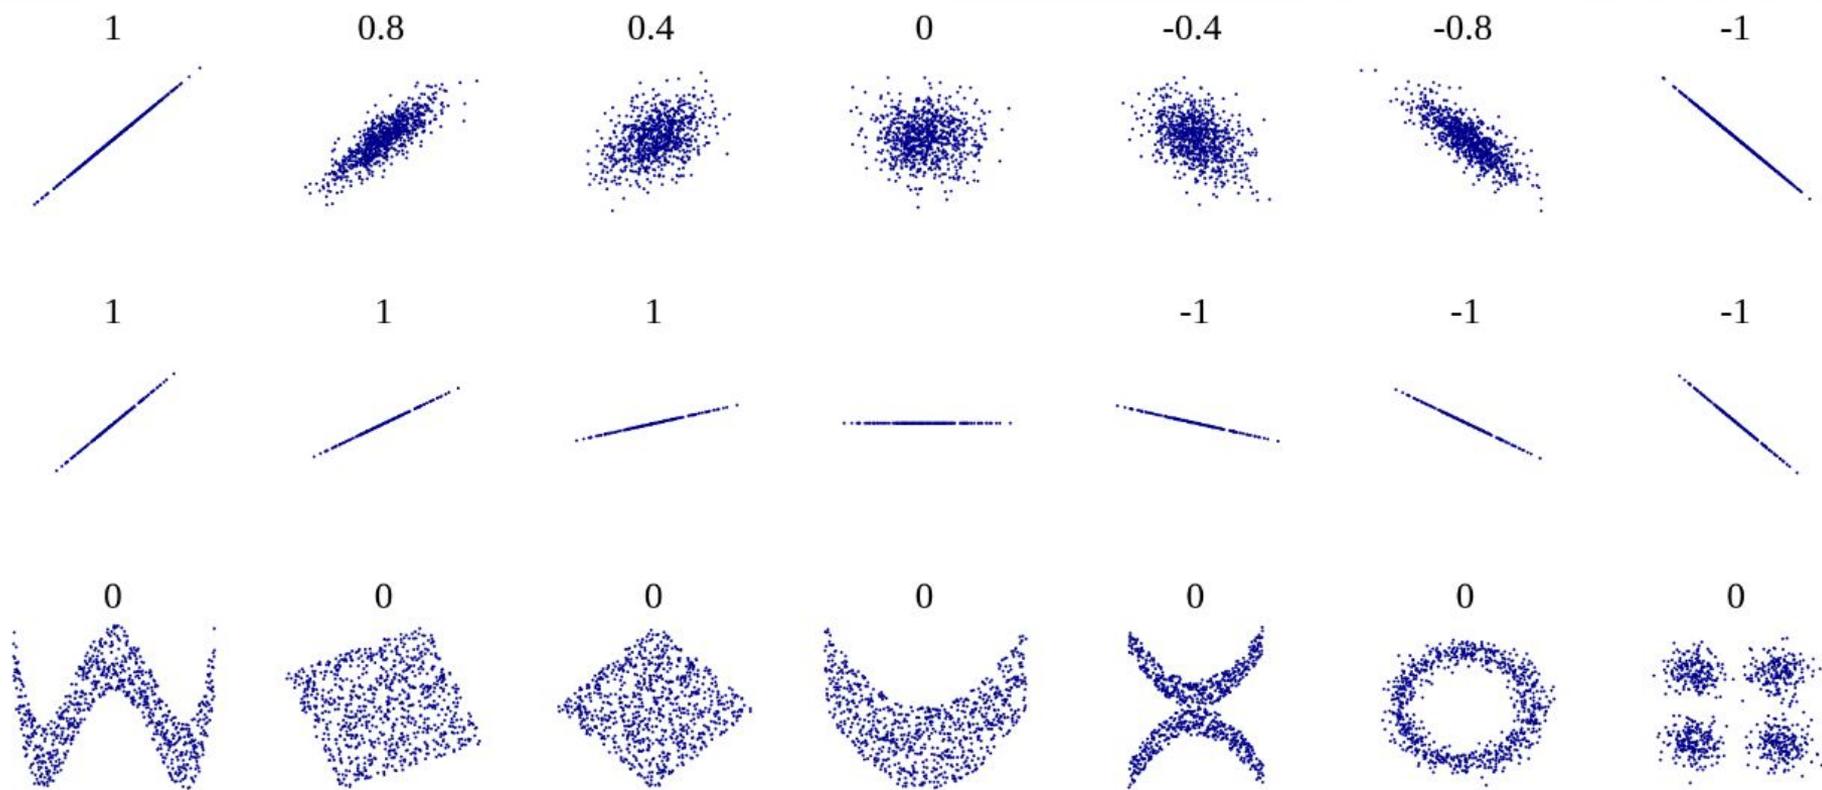
1. Коэффициент корреляции Пирсона оценивает только линейную связь переменных!

И он не покажет нам **наличие нелинейной связи**



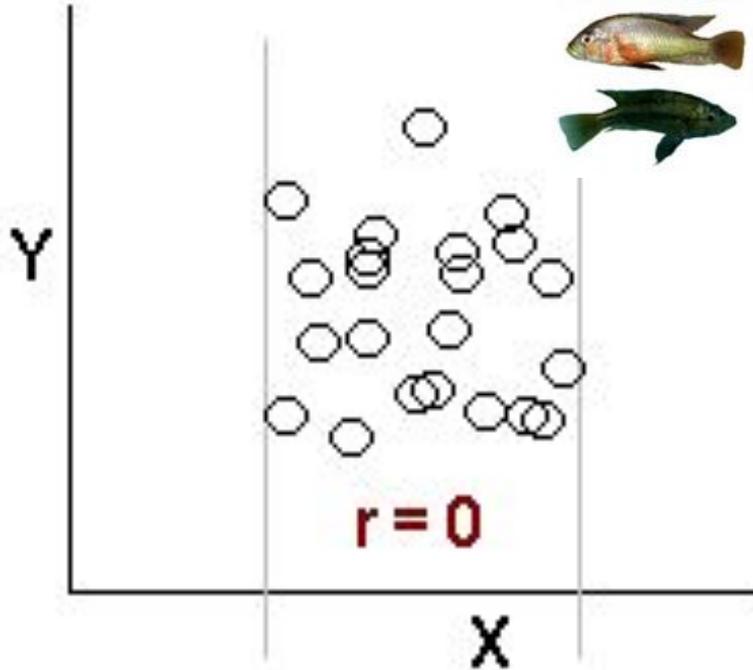
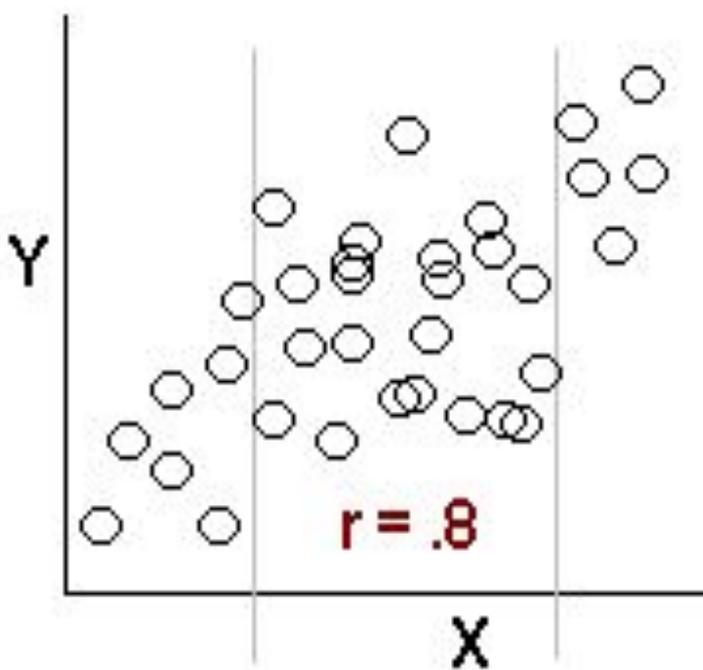
Здесь связь переменных есть, и она очень сильная, но $r=0.00$

Корреляции



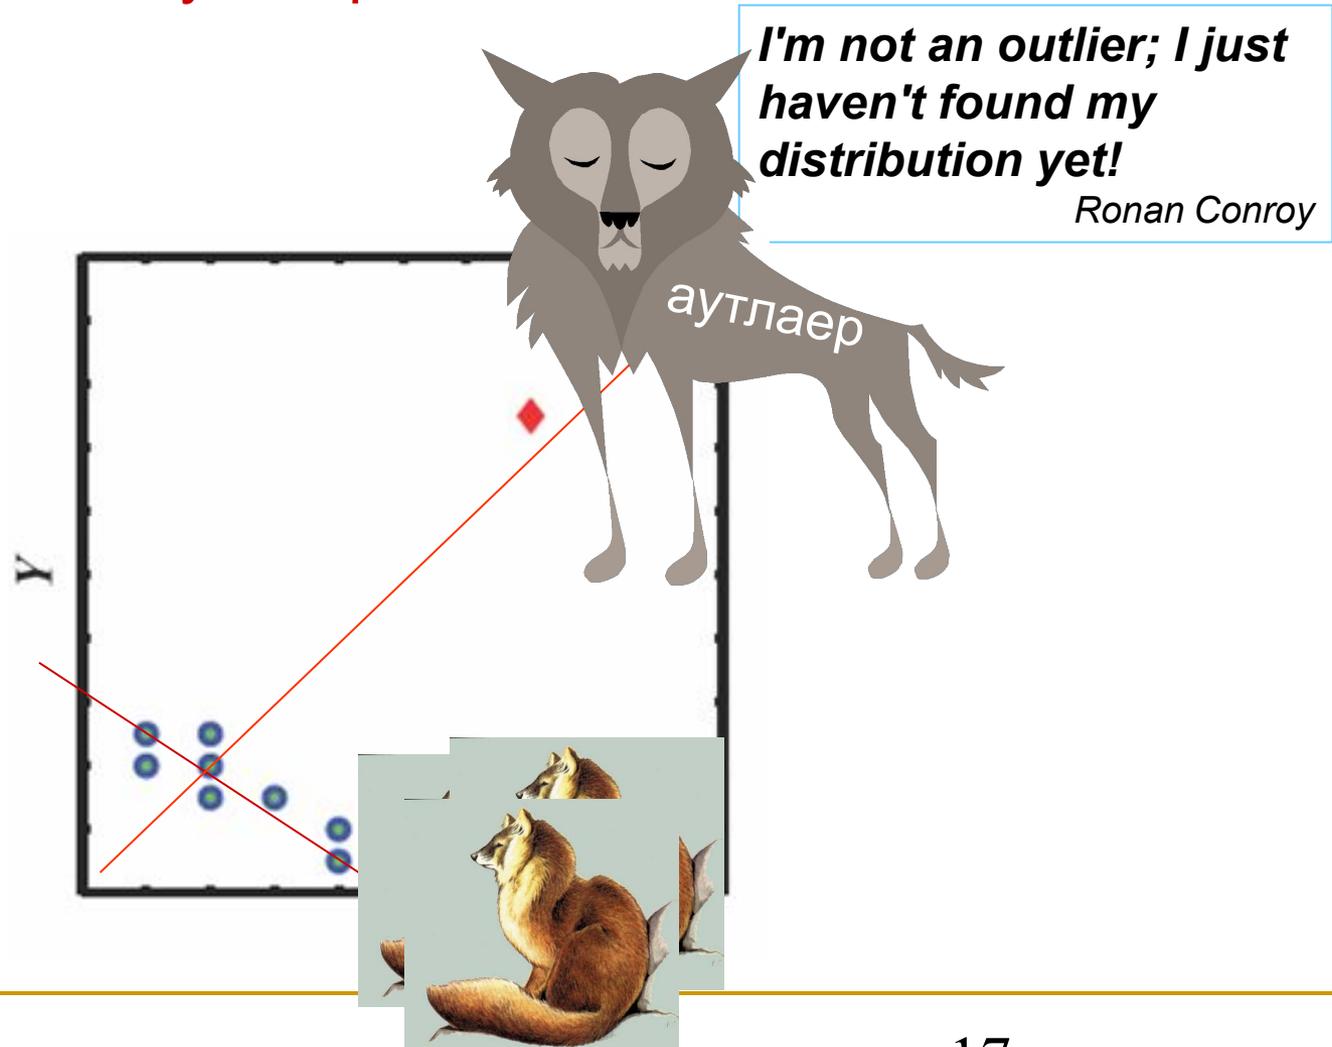
Корреляции

2. Необходимо, чтобы у переменных была значительная **изменчивость**! Если сформировать выборку изначально однотипных особей, нечего надеяться выявить там корреляции.



Корреляции

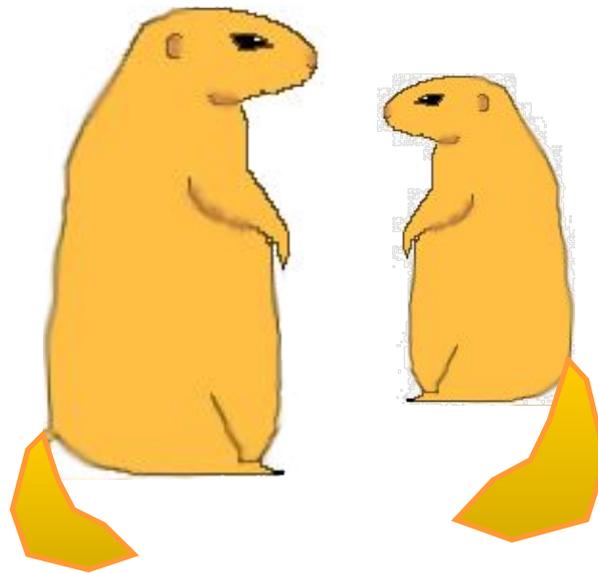
3. Коэффициент корреляции Пирсона очень чувствителен к **аутлаерам**.



Важное замечание:

Корреляция совершенно **не подразумевает** наличие **причинно-следственной связи!**

Она **ВООБЩЕ НИЧЕГО** о ней **НЕ ГОВОРИТ** (даже очень большой r)

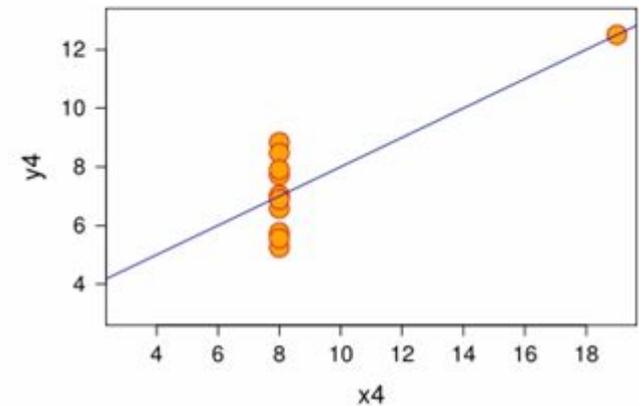
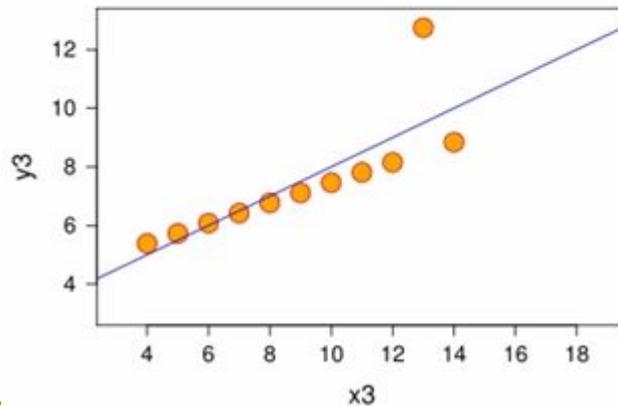
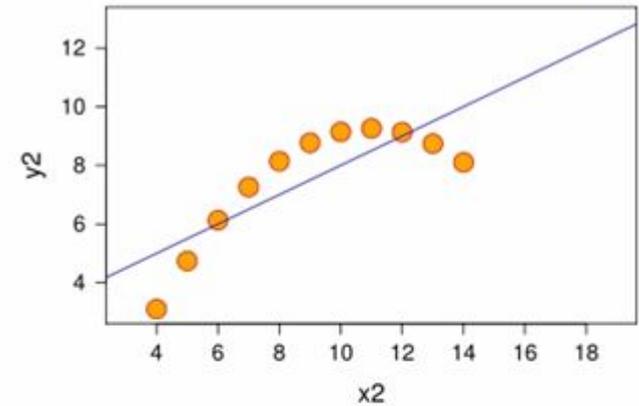
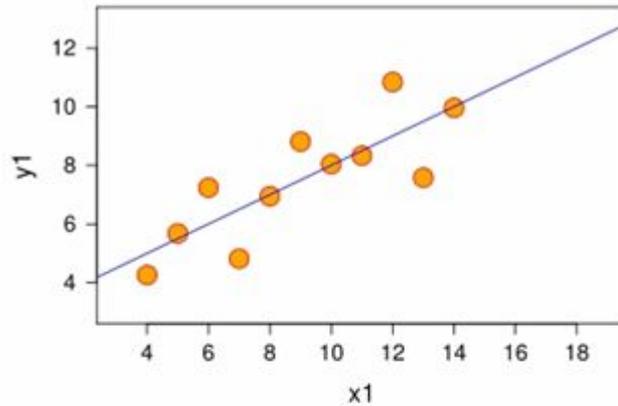


Корреляции

Коэффициент корреляции Пирсона – параметр **выборки**.
Можем ли мы на основе него судить о **популяции**?
Просто глядя на коэффициент – **НЕТ**.



Correlation
between each x and
 $y = 0.816$



Корреляции

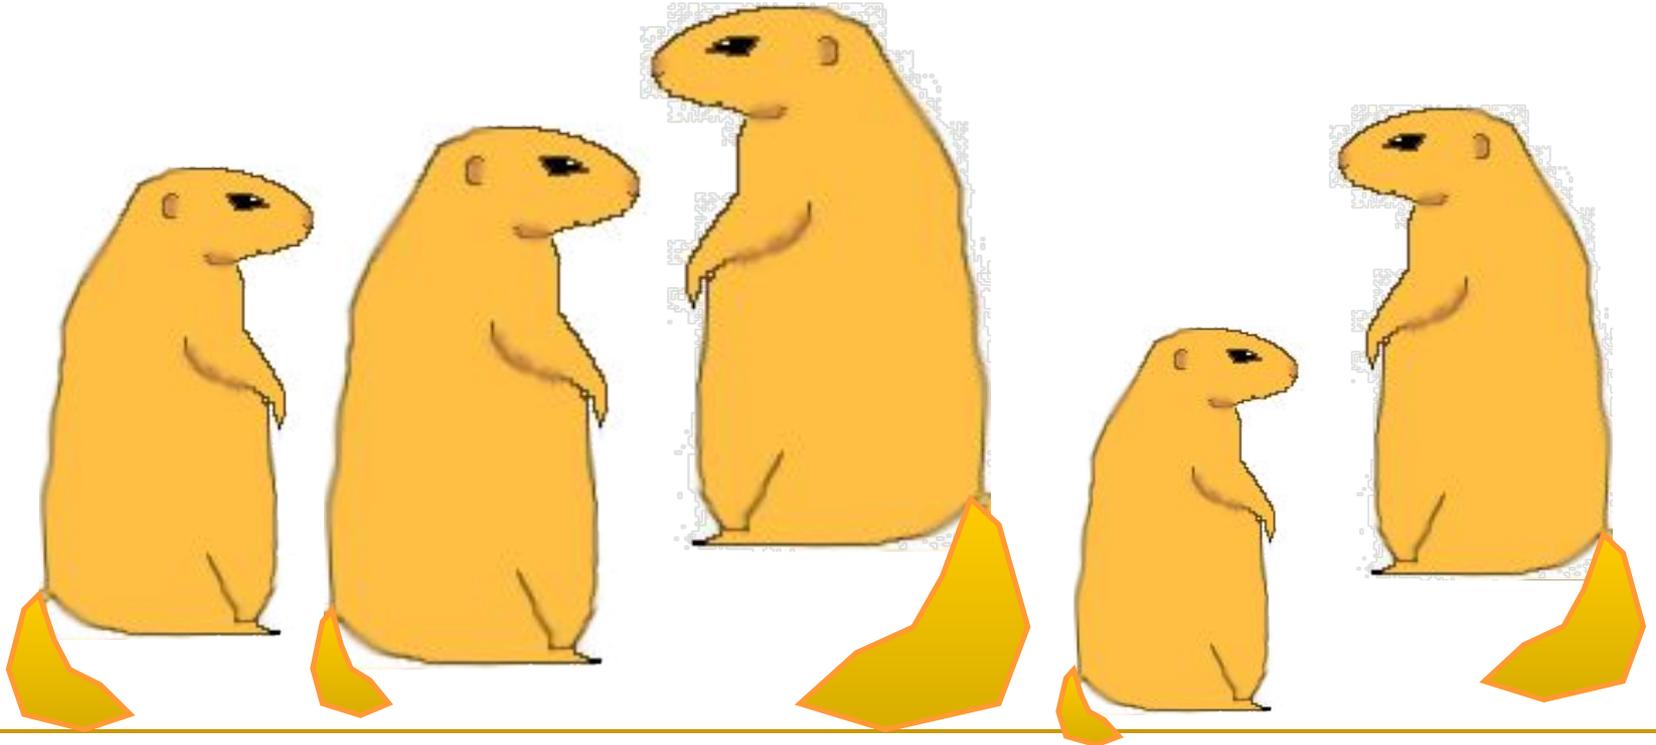
Мы хотим оценить коэффициент корреляции в популяции.

$$H_0 : \rho = 0$$

$$H_1 : \rho \neq 0$$

(альтернативная гипотеза может быть односторонней)

Связаны ли у сусликов масса тела и длина хвоста?



Корреляции

Статистика = $\frac{\text{параметр выборки} - \text{параметр популяции}}{\text{стандартная ошибка параметра выборки}}$

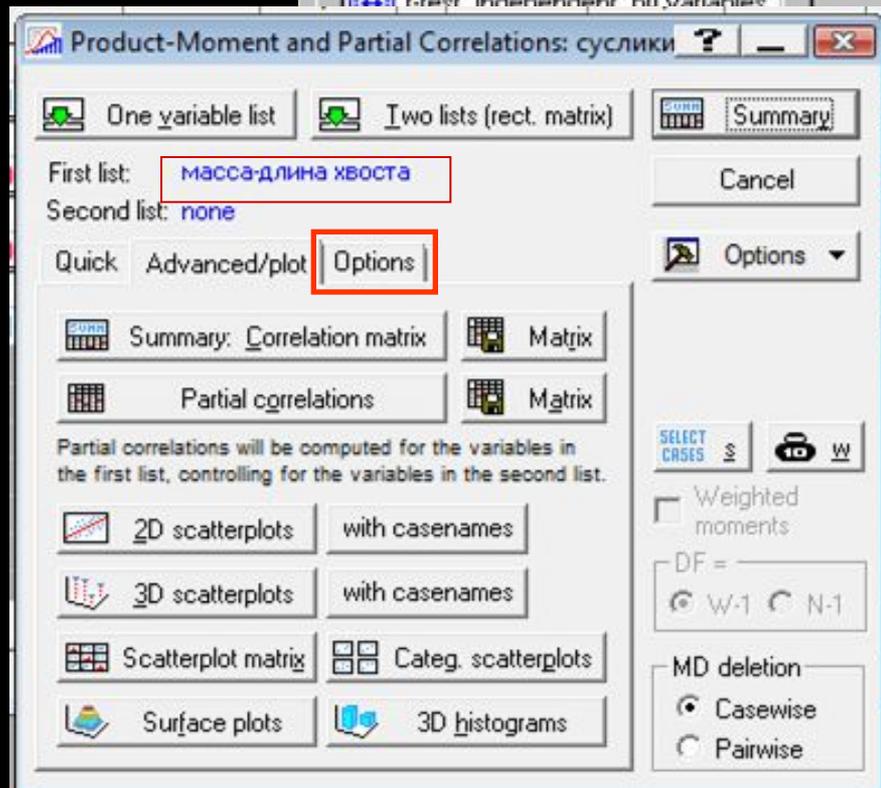
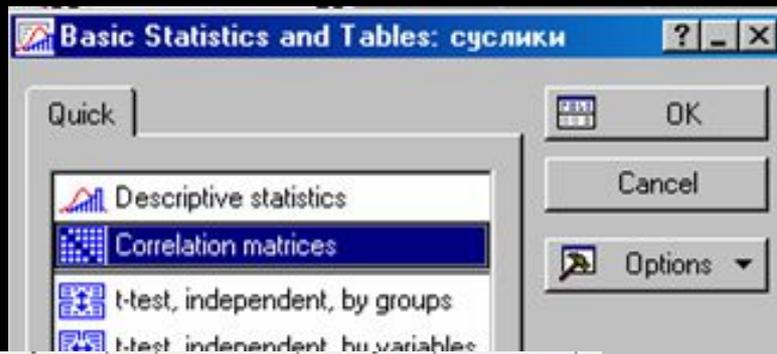
$$t = \frac{r - \rho}{s_r} \longrightarrow t = \frac{r}{s_r}$$

стандартная ошибка
коэффициента корреляции



$$s_r = \sqrt{\frac{1 - r^2}{n - 2}}$$

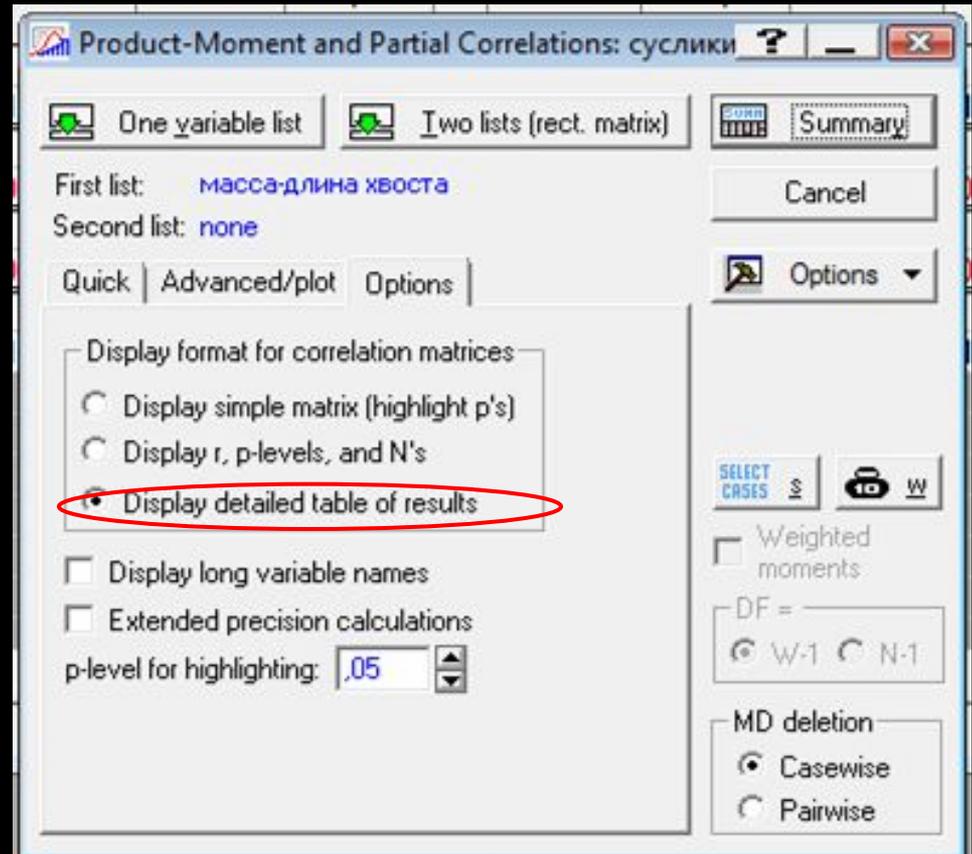
Pearson product-moment correlation coefficient r



Data: суслики* (11v by 20c)

| | 1 | 2 | 3 |
|----|--------|-------|--------------|
| | зверёк | масса | длина хвоста |
| 1 | 1 | 21,5 | 21,11 |
| 2 | 2 | 13,8 | 13,64 |
| 3 | 3 | 16,8 | 18,00 |
| 4 | 4 | 13,5 | 20,00 |
| 5 | 5 | 14,0 | 17,27 |
| 6 | 6 | 20,2 | 31,25 |
| 7 | 7 | 14,1 | 15,83 |
| 8 | 8 | 13,0 | 20,00 |
| 9 | 9 | 11,3 | 17,50 |
| 10 | 10 | 12,2 | 16,15 |
| 11 | 11 | 12,2 | 16,15 |
| 12 | 12 | 10,8 | 15,71 |
| 13 | 13 | 12,1 | 15,71 |
| 14 | 14 | 14,4 | 15,33 |
| 15 | 15 | 12,2 | 14,67 |
| 16 | 16 | 12,2 | 14,67 |
| 17 | 17 | 13,2 | 24,17 |
| 18 | 18 | 15,6 | 28,18 |
| 19 | 19 | 10,6 | 16,00 |
| 20 | 20 | 12,7 | 19,29 |

Отвергаем H_0 :
 Оказалось, что масса
 тела у сусликов
 положительно связана
 с длиной хвоста.



Correlations (суслики)
 Marked correlations are significant at $p < .05000$
 (Casewise deletion of missing data)

| Var. X & Var. Y | Mean | Std.Dv. | r(X,Y) | r? | t | p | N | Constant dep: Y | Slope dep: Y | Constant dep: X | Slope dep: X |
|--------------------|----------|----------|----------|----------|----------|----------|----|--------------------|-----------------|--------------------|-----------------|
| масса | 13,82845 | 2,838194 | | | | | | | | | |
| длина хвоста | 18,53203 | 4,622850 | 0,611508 | 0,373942 | 3,278920 | 0,004171 | 20 | 4,758573 | 0,996024 | 6,870880 | 0,375435 |

Коэффициенты а и b

Бывают задачи, когда нам необходимо получить **МАТРИЦУ КОРРЕЛЯЦИЙ** (для многомерных методов анализа)

Product-Moment and Partial Correlations: age

One variable list | Two lists (rect. matrix) | Summary

First list: 6-7 22-23
Second list: none

Quick | Advanced/plot | Options

Display format for correlation matrices

- Display simple matrix (highlight p's)
- Display r, p-levels, and N's
- Display detailed table of results

Display long variable names
 Extended precision calculations
p-level for highlighting: .05

Product-Moment and Partial Correlations: age

One variable list | Two lists (rect. matrix) | Summary

First list: 6-7 22-23
Second list: none

Quick | Advanced/plot | Options

Summary: Correlation matrix | Matrix

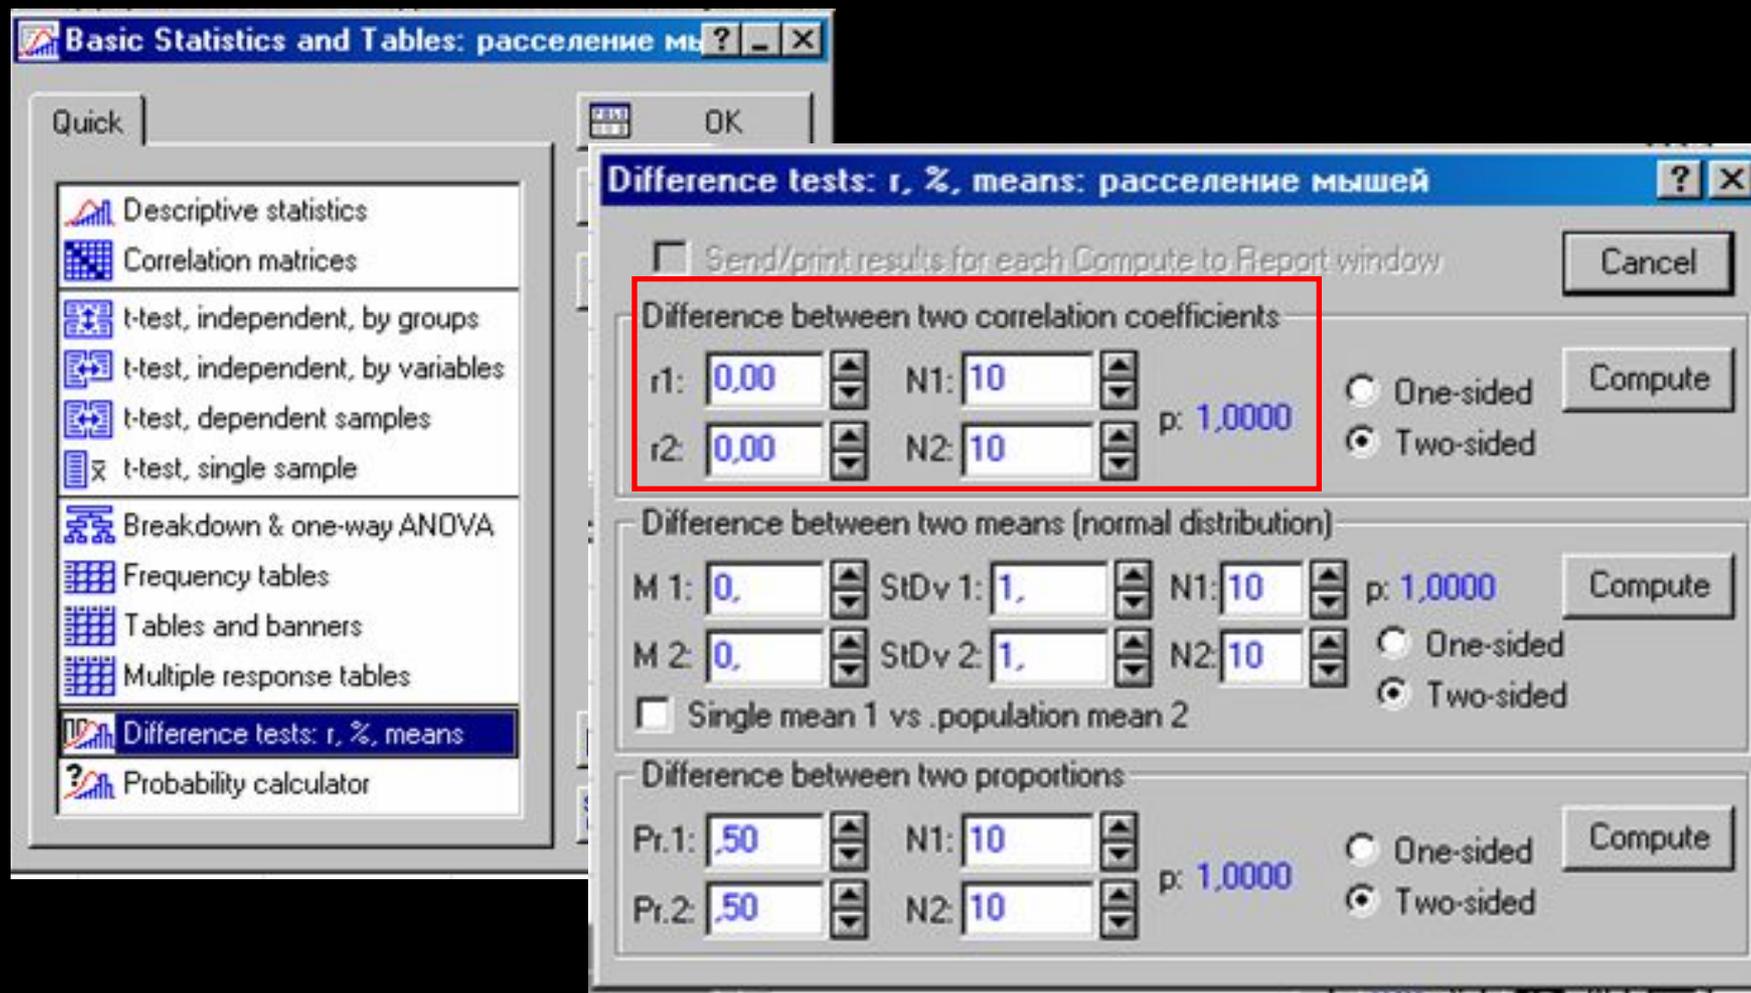
Partial correlations will be computed for the variables in the first list, controlling for the variables in the second list.

Matrix

Correlations (age 6.12)
Marked correlations are significant at $p < ,05000$
N=14 (Casewise deletion of missing data)

| Variable | масса | упитанность | масса детёныша | масса выводка |
|----------------|-------|-------------|----------------|---------------|
| масса | 1,00 | 0,98 | -0,03 | -0,35 |
| упитанность | 0,98 | 1,00 | -0,02 | -0,27 |
| масса детёныша | -0,03 | -0,02 | 1,00 | 0,40 |
| масса выводка | -0,35 | -0,27 | 0,40 | 1,00 |

Можно сравнить два коэффициента корреляции от двух выборок



Для двумерного нормального распределения

Корреляции

В статьях обычно приводят сам коэффициент корреляции Пирсона (значение t не столь обязательно).

Он сам и является показателем практической значимости (**effect size**) корреляции.

Cohen, 1988:

$\rho = 0.1$ - слабая корреляция;

$\rho = 0.3$ – корреляция средней силы;

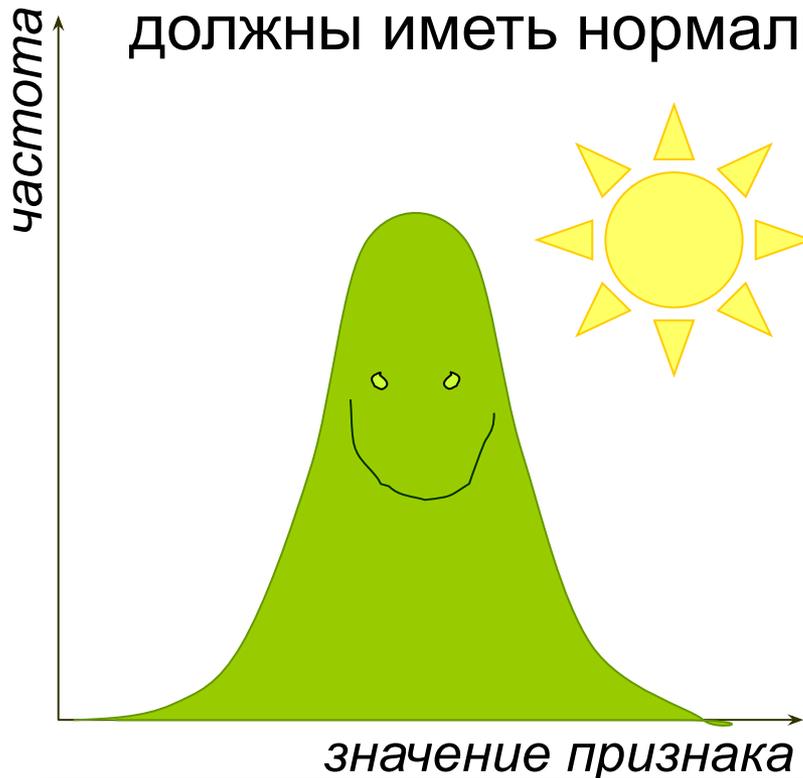
$\rho = 0.5$ - сильная корреляция.



Корреляции

Требование к выборке для тестирования гипотезы о коэффициенте корреляции Пирсона:

1. Для каждого X значения Y должны быть распределены нормально, и для каждого Y все X должны иметь нормальное распределение -



двумерное нормальное распределение (bivariate normal distribution)

2. Должно соблюдаться требование гомогенности дисперсии X для каждого Y и наоборот.

РЕГРЕССИОННЫЙ АНАЛИЗ

Рост братьев.



Петя



Гриша

$r=0.7$: если Петя высокий, то, **скорее всего**, Гриша тоже высокий. Но можем ли мы предсказать, **насколько высокий**? Сам коэффициент корреляции этого нам не скажет. Ответ нам даст РЕГРЕССИОННЫЙ АНАЛИЗ.

Регрессии

Регрессионный анализ – инструмент для количественного **предсказания** значения одной переменной на основании другой.

Для этого в линейной регрессии строится прямая – **линия регрессии**.

Простая линейная регрессия:

Даёт нам правила, определяющие линию регрессии, которая ЛУЧШЕ ДРУГИХ предсказывает одну переменную на основании другой (переменных всего две).

По оси Y располагают переменную, которую мы хотим предсказать (зависимую, dependent), а по оси X – переменную, на основе которой будем предсказывать (независимую, independent).

Предсказанное значение Y обычно обозначают как 

Регрессии

То есть,

РЕГРЕССИЯ (*regression*) – предсказание одной переменной на основании другой. Одна переменная – независимая (*independent*), а другая – зависимая (*dependent*).

Пример: чем больше еды съедает каждый день детёныш бегемота, тем больше у него будет прибавка в весе за месяц

КОРРЕЛЯЦИЯ (*correlation*) – показывает, в какой степени две переменные **СОВМЕСТНО ИЗМЕНЯЮТСЯ**. Нет зависимой и независимой переменных, они эквивалентны.

Пример: длина хвоста у суслика коррелирует положительно с его массой тела

ЭТО НЕ ОДНО И ТО ЖЕ!

Регрессии

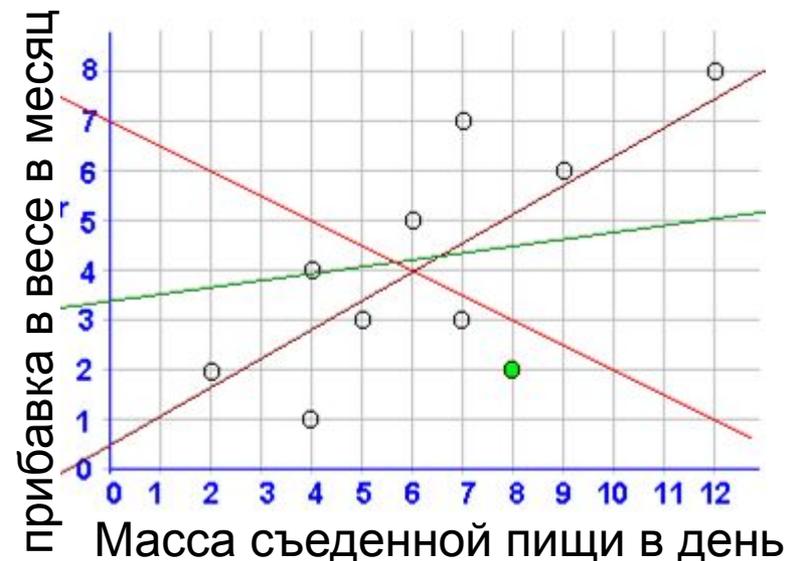
Мы изучаем поведение молодых бегемотов в Африке. Мы хотим узнать, как зависит прибавка в весе за месяц от количества пищи, съедаемой в день, у этих зверей?

У нас **две переменные** – 1. кол-во съедаемой в день пищи, кг (independent); 2. прибавка в весе за месяц, кг (dependent)



Регрессии

Мы ищем прямую, которая наилучшим образом будет предсказывать значения Y на основании значений X .



Регрессии

Простая линейная регрессия (*linear regression*)

Y – **зависимая** переменная

X – **независимая** переменная

a и b - коэффициенты регрессии

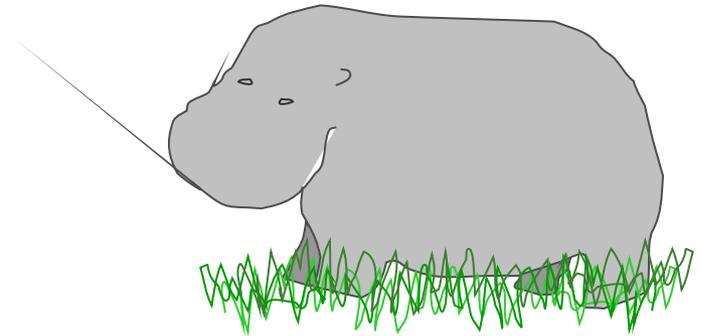
$$\hat{Y}_i = a + bX_i$$

b – характеризует **НАКЛОН** прямой (slope); это самый важный коэффициент;

a – определяет точку пересечения прямой с осью OY; не столь существенный (intercept).

Это уравнение регрессии для **ВЫБОРКИ**.

$$Y_i = \alpha + \beta X_i \quad \text{уравнение для популяции}$$



Регрессии

Задача сводится к поиску коэффициентов a и b .

$$b = r \frac{s_X}{s_Y}$$

коэффициент корреляции Пирсона

стандартные отклонения для X и Y

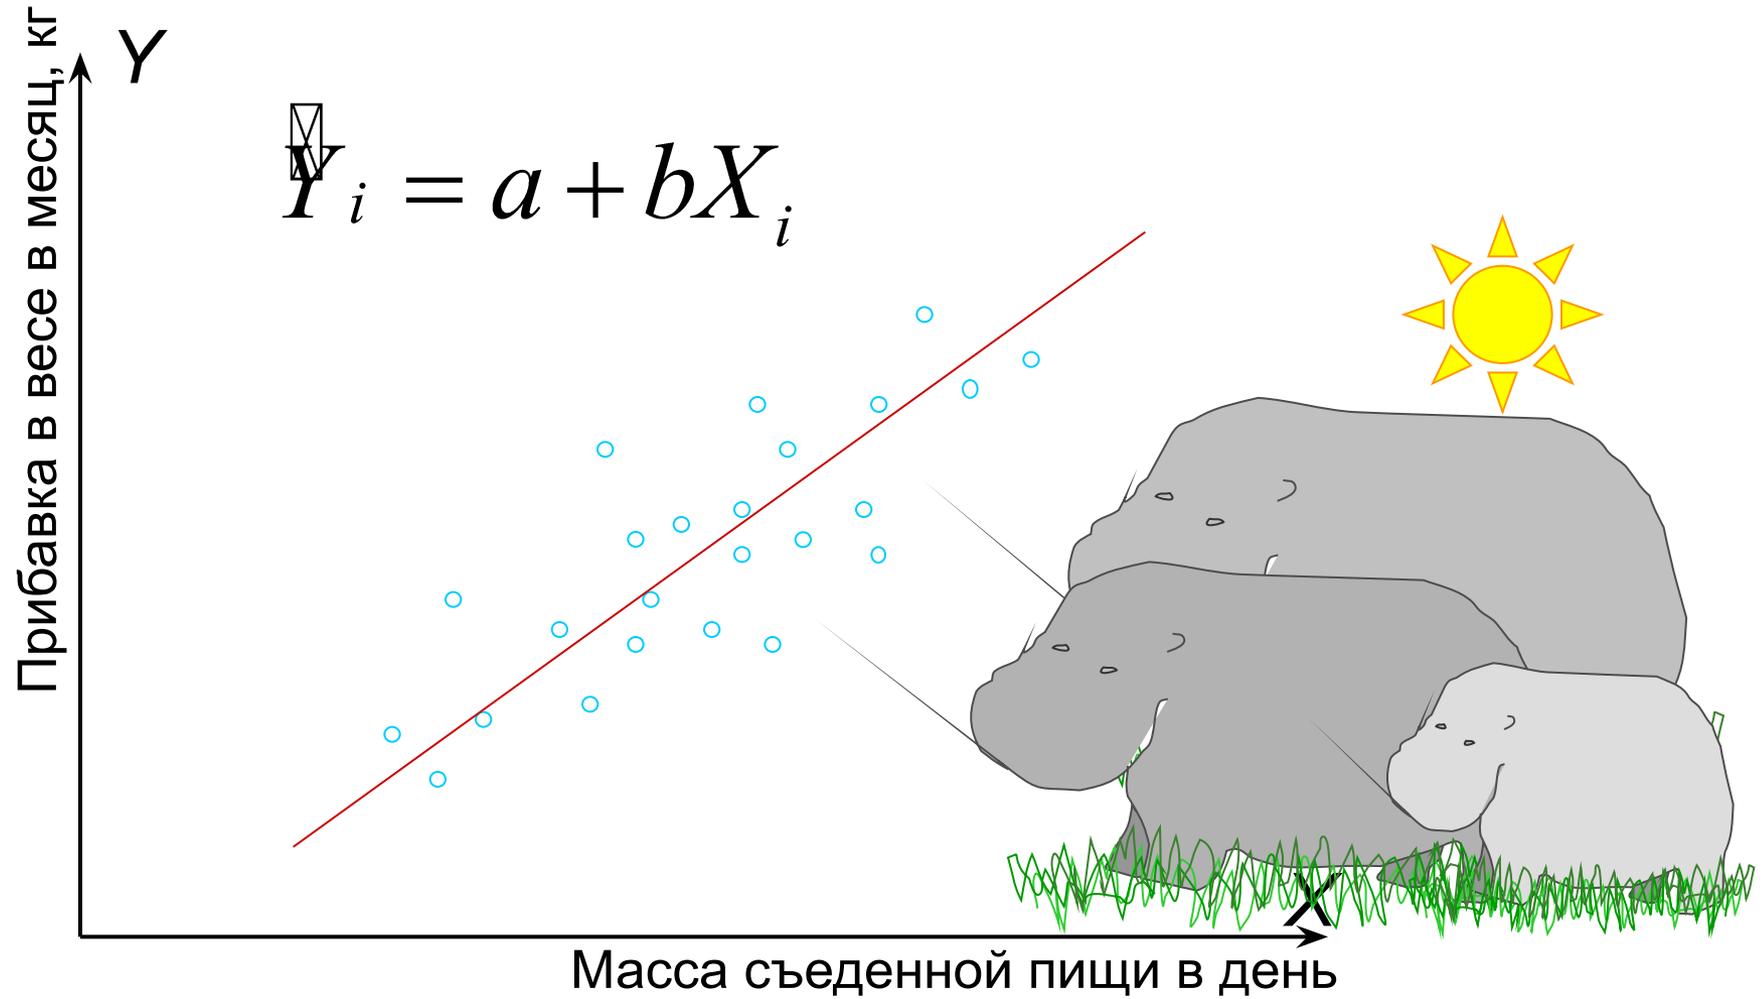
$$\bar{Y} = a + b\bar{X} \longrightarrow a = \bar{Y} - b\bar{X}$$

Линия регрессии всегда проходит через точку (\bar{X}, \bar{Y}) , то есть через середину графика.

b – определяет, насколько изменится Y на единицу X ; имеет тот же знак, что и r .

Пример с кол-вом удобрения на каждый кг помидоров

Регрессии



Регрессии

Если $r=0.0$, линия регрессии всегда горизонтальна. Чем ближе r к нулю, тем труднее на глаз провести линию регрессии. А **чем больше r** , тем **лучше предсказание**.

Важная особенность нашего предсказания: предсказанное значение Y всегда ближе к среднему значению, чем то значение X , на основе которого оно было предсказано – **регрессия к среднему**.

Пример про Dr. Nostat, который отобрал 100 самых глупых учеников, подверг их специальной программе и потом протестировал повторно, и их IQ оказался в среднем выше.
Пример про очень умную 5-летнюю девочку



Регрессии

Линия регрессии в стандартной форме

$$a = \bar{Y} - b\bar{X}$$

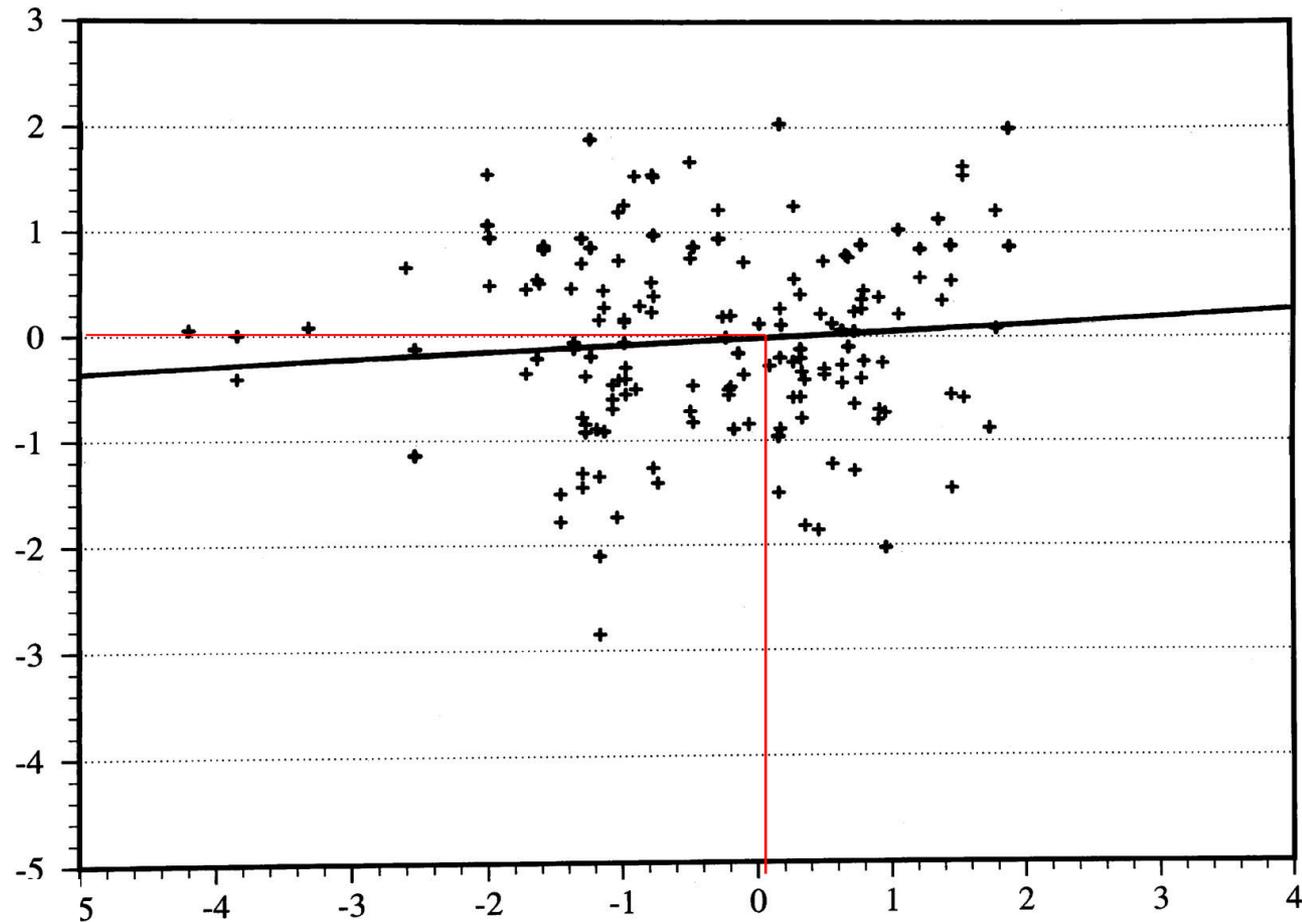
$$b = r \frac{s_X}{s_Y}$$



$$a = 0, b = r$$

$$Y_z = r X_z$$

Child's FEV1 (z-score)



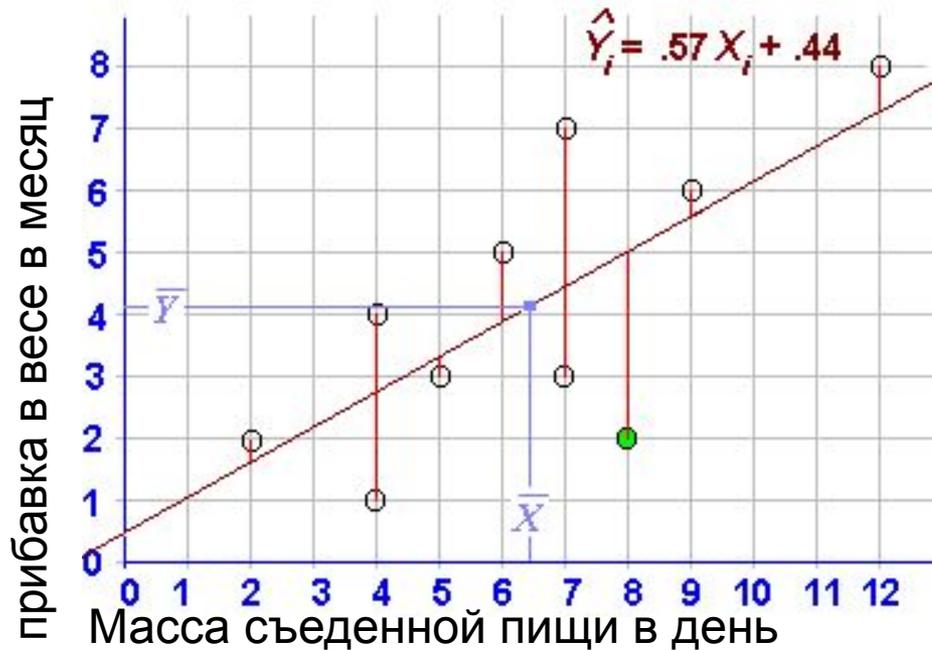
Father's FEV1 (z-score)

(математическое
объяснение регрессии к
среднему)

Регрессии

Ошибка предсказания и поиск «лучшей» линии

Очевидно, что точки не лежат на самой линии регрессии.



$$e_i = Y_i - \hat{Y}_i$$

Ошибка предсказания
(residual) = «остатки»

е положительно для точек
над прямой и
отрицательно для точек
под прямой.

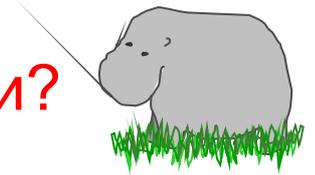
$$Y_i = \alpha + \beta X_i + \varepsilon_i \quad \text{Для популяции}$$

$$Y_i = a + bX_i + e_i \quad \text{Для выборки}$$

важно: нельзя пытаться предсказывать Y на основе значений X , лежащих за пределами размаха X в выборке.

Регрессии

Как определить «лучшую» линию регрессии?

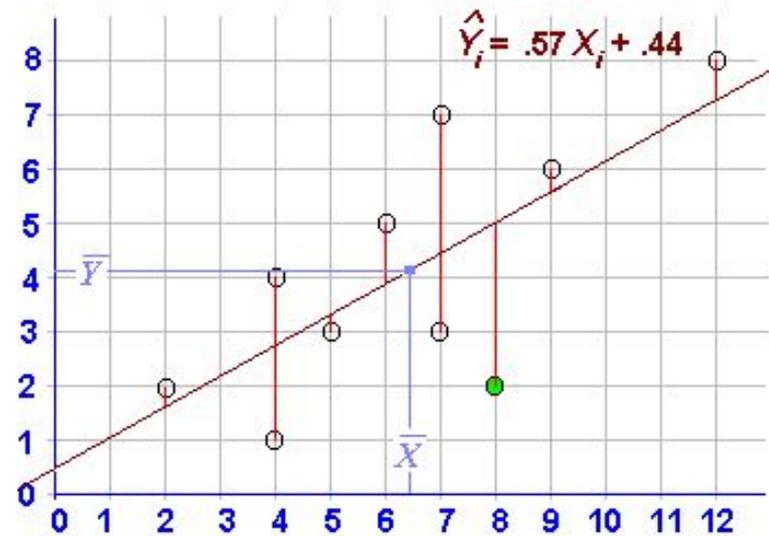
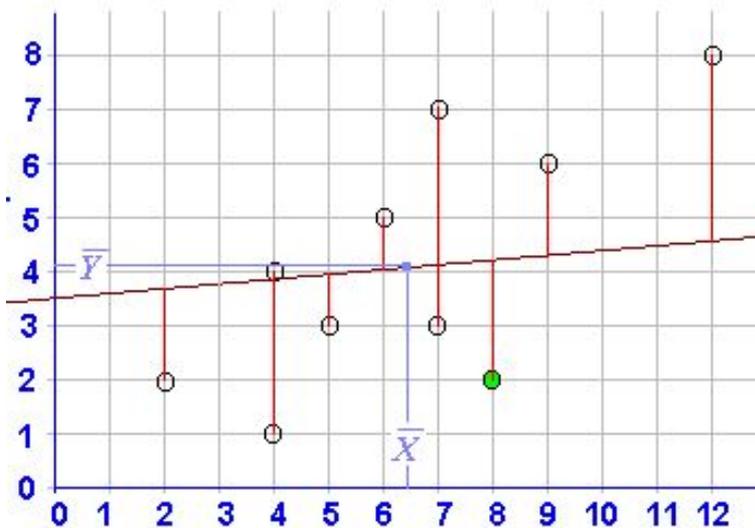


Метод наименьших квадратов:

линию регрессии подбирают такую, чтобы общая сумма квадратов ошибок (residuals) была наименьшей.

$$\sum e_i = 0$$

$$\sum e_i^2 \text{ - минимальна}$$



$\sum e_i^2$ - residual sum of squares = residual SS

Регрессии

В регрессионном анализе, как и в ANOVA, используют разные **суммы квадратов отклонений (SS)** для разных источников изменчивости, и на их основе **тестируют гипотезы**.

$$SS_{total} = \sum (Y_i - \bar{Y})^2$$

$$SS_{total} = SS_{regression} + SS_{residual}$$

$$SS_{regression} = \sum (Y_i - \bar{Y})^2$$

Для каждого SS считают соответствующий $MS = SS/DF$ (df=1 и df=n-2)

$$SS_{residual} = \sum (Y_i - \hat{Y}_i)^2$$

$$\begin{array}{l} H_0: \beta = 0 \\ H_1: \beta \neq 0 \end{array}$$

$$F = \frac{MS_{regression}}{MS_{residual}}$$

Можно тестировать гипотезу и о том, что intercept () = 0

Регрессии

Эту же гипотезу можно протестировать с помощью t -статистики:

$$t = \frac{b - \beta_0}{s_b} = \frac{b}{s_b}$$

Причём $t^2 = F$



На самом деле,

если r достоверно отличается от нуля, то и $\beta \neq 0$!

То есть, если мы отвергаем H_0 о том, что $r=0$, то нулевая гипотеза о коэффициенте β отвергается автоматически.

Коэффициент детерминации

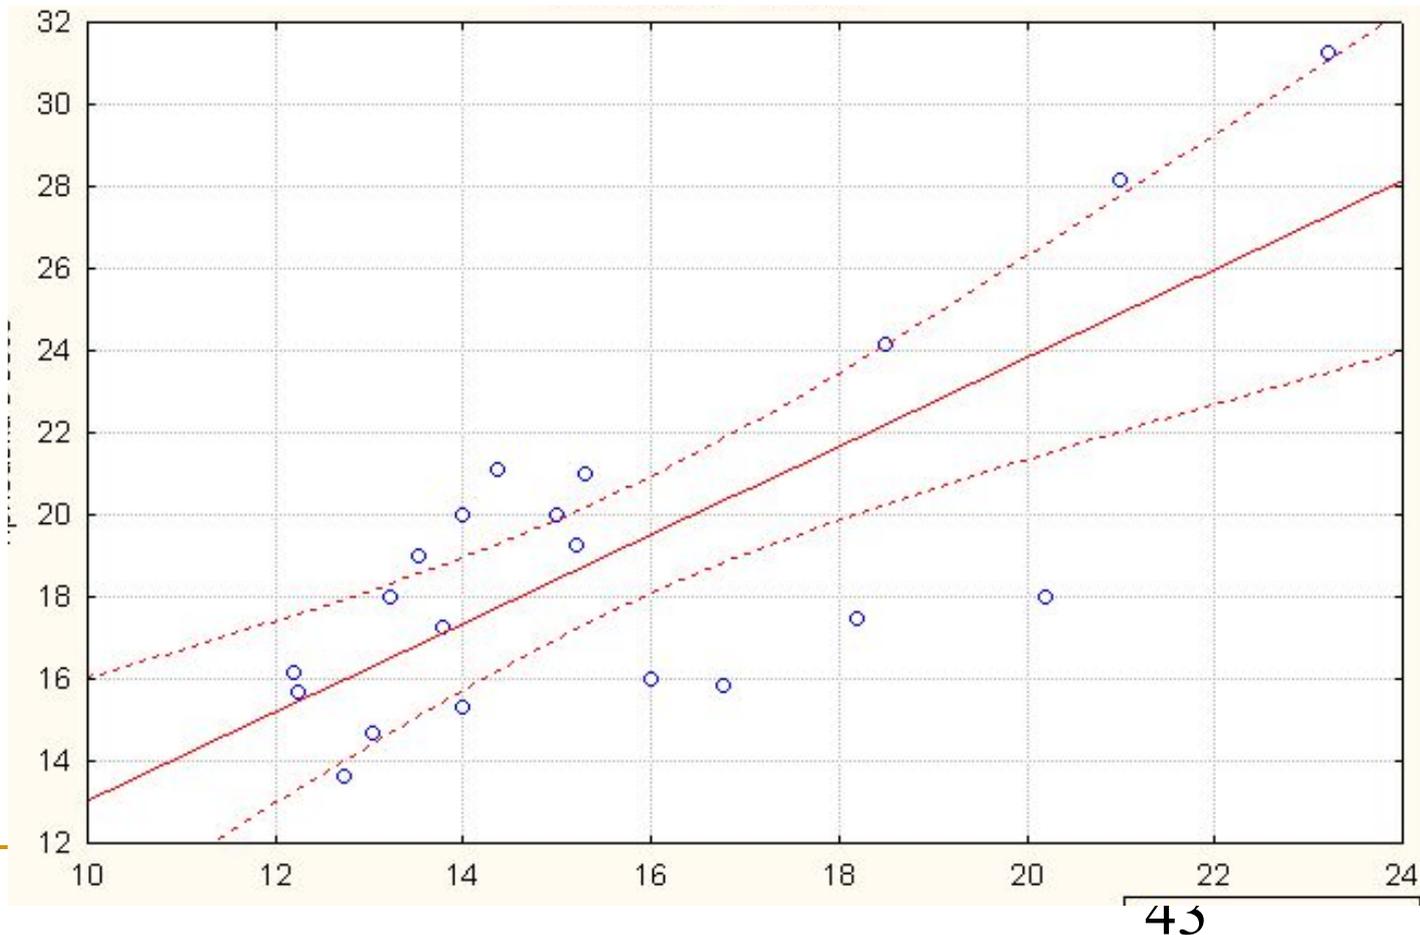
$$R^2 = \frac{SS_{regression}}{SS_{total}} = \frac{\sum_i (\hat{Y}_i - \bar{Y})^2}{\sum_i (Y_i - \bar{Y})^2}$$

Показывает, какую долю изменчивости (буквально, её даже можно выразить в процентах) зависимой переменной (Y) объясняет независимая переменная (регрессионная модель)

r – коэффициент корреляции, $r^2 = R^2$

Регрессии

Доверительный интервал для значений зависимой переменной: строится для каждого значения X , причём наименьшая ошибка получается для среднего Y .



Регрессии


Сравнение двух (и более) уравнений линейной регрессии

1. Сравнение коэффициентов наклона b_1 b_2
2. Сравнение коэффициентов сдвига a_1 и a_2

На основе критерия Стьюдента

3. Сравнение двух линий регрессии в целом
(предполагается, что если линии для 2-х выборок у нас сильно различаются, и мы объединим выборки, то общая линия по этим двум выборкам будет хуже описывать изменчивость, остаточная дисперсия будет больше)

на основе F-критерия



линии регрессии

Множественная линейная регрессия и корреляция (multiple regression)

Простая линейная регрессия: одна зависимая переменная и одна независимая.

Множественная регрессия: исследуется влияние **НЕСКОЛЬКИХ** независимых переменных на **ОДНУ** зависимую.

Множественная корреляция: исследуется взаимосвязь нескольких переменных, среди которых невозможно выделить зависимую.

Регрессии

Например, мы хотим узнать, как на прибавку в весе у бегемотов (1 **зависимая** переменная) влияют: средняя масса пищи, съедаемой в день; продолжительность сна в сутки; подвижность бегемота (км/день) (3 **независимых** непрерывных переменных).



Регрессии

Уравнение регрессии:

для популяции

$$Y_i = \alpha + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_m X_{mi} + \varepsilon_i$$

для выборки

$$\hat{Y}_i = a + b_1 X_{1i} + b_2 X_{2i} + \dots + b_m X_{mi}$$

Это уже не прямая, это уже либо плоскость (для 3-х переменных), либо пространство.

Регрессии

Тестирование гипотез для множественной регрессии:

Если для простой регрессии можно было проверить только гипотезу относительно коэффициента корреляции, в множественной регрессии без SS, MS и F не обойтись – этот анализ тоже называется ANOVA

$$H_o : \beta_1 = \beta_2 = \dots = \beta_m = 0$$

$$F = \frac{MS_{regression}}{MS_{residual}}$$

| Source of variation | Sum of squares (SS) | DF* | Mean square (MS) |
|---------------------|---------------------------------|-------------|---|
| Total | $\sum(Y_j - \bar{Y})^2$ | $n - 1$ | |
| Regression | $\sum(\hat{Y}_j - \bar{Y}_j)^2$ | m | $\frac{\text{regression SS}}{\text{regression DF}}$ |
| Residual | $\sum(Y_j - \hat{Y}_j)^2$ | $n - m - 1$ | $\frac{\text{residual SS}}{\text{residual DF}}$ |

* n = total number of data points (i.e., total number of Y values); m = number of independent variables in the regression model.

Регрессии

Коэффициент детерминации (coefficient of determination)

$$R^2 = \frac{SS_{regression}}{SS_{total}}$$

Считается потому же принципу, что и для простой регрессии, и тоже показывает, какую долю общей изменчивости зависимой переменной объясняет модель, т.е., совместное влияние всех независимых переменных.

Multiple **correlation coefficient**:

аналогичен коэффициенту корреляции Пирсона

$$R = \sqrt{R^2}$$

Adjusted coefficient of determination:

лучше, чем просто R^2 , так как не увеличивается с ростом кол-ва переменных в модели

$$R_a^2 = 1 - \frac{MS_{residual}}{MS_{total}}$$

Добавление переменных в модель:

- $SS_{\text{regression}}$ увеличивается, поэтому R^2 растёт.
- При этом F может уменьшаться.

Для каждой переменной по отдельности можно протестировать гипотезу $\beta = 0$ -

Partial regression coefficients.

У нас много переменных, поэтому расчёт коэффициентов и статистик сопряжён с операциями над матрицами.

Если какие-то независимые переменные сильно коррелируют между собой, возникает принципиальная проблема в расчётах (матрицы оказываются вырожденными) — коэффициенты регрессии не могут быть рассчитаны.

Признаки:

- ✓ При удалении (добавлении) какой-либо переменной принципиально меняются коэффициенты при других переменных;
- ✓ общее F для всей модели достоверно, а отдельные t-тесты для каждой переменной — нет;
- ✓ при пошаговом анализе выбирая разные способы анализа мы получаем разные результаты.

Что делать? Искать коррелирующие переменные и исключать одну из них из модели.

Выбор «лучших» независимых переменных

Как выбрать лучшую модель, чтобы наименьшим числом независимых переменных описать наибольшую долю изменчивости Y ?

Используют пошаговые модели:

- ✓ Backward elimination – постепенное удаление переменных из модели.
- ✓ Forward selection – постепенное добавление переменных в модель
- ✓ Смешанный пошаговый метод анализа.

Simple linear regression

а: бегемоты (12v by 20c)

| | 1 № бегемота | 2 масса пищи, съеденной за день | 3 прибавка в весе за месяц | 4 продолжите льность сна, ч | 5 расстояние, пройденное за день, км | место |
|----|--------------------|---------------------------------------|----------------------------------|--------------------------------------|---|-------|
| 1 | 1 | 14,4 | 21,11 | 10 | | 3 |
| 2 | 2 | 12,7 | 13,64 | 5,8 | | 4 |
| 3 | 3 | 20,2 | 18,00 | 7 | | 4,5 |
| 4 | 4 | 14,0 | 20,00 | 8 | | 2,5 |
| 5 | 5 | 13,8 | 17,27 | 8,2 | | 3,7 |
| 6 | 6 | 23,2 | | | | |
| 7 | 7 | 16,8 | | | | |
| 8 | 8 | 15,0 | | | | |
| 9 | 9 | 18,2 | | | | |
| 10 | 10 | 13,5 | | | | |
| 11 | 11 | 12,2 | | | | |
| 12 | 12 | 12,2 | | | | |
| 13 | 13 | 13,2 | | | | |
| 14 | 14 | 14,0 | | | | |
| 15 | 15 | 15,3 | | | | |
| 16 | 16 | 13,0 | | | | |
| 17 | 17 | 18,5 | | | | |
| 18 | 18 | 21,0 | | | | |
| 19 | 19 | 16,0 | | | | |
| 20 | 20 | 15,2 | | | | |

Multiple Linear Regression: бегемоты

Quick | Advanced

Variables

Dependent: 3
Independent: 2 4 5

OK
Cancel
Options
Open Data
SELECT CASES
Weighted moments
DF =
W/1 N/1
MD deletion
Casewise
Pairwise
Mean substitution

See also the General Regression Models (GRM) module.

linear regression

У бегемотов прибавка в весе зависела от этих переменных

Multiple Regression Results: бегемоты

Multiple Regression Results

Dependent: прибавка в вес

| | | | |
|---------------------------|-----------|------|----------|
| Multiple R = | ,94911309 | F = | 48,43860 |
| R ² = | ,90081566 | df = | 3,16 |
| adjusted R ² = | ,88221860 | p = | ,000000 |

No. of cases: 20

Standard error of estimate: 1,529805216

Intercept: 20,076334485 Std. Error: 4,146420 t(16) = 4,8418 p = ,0002

масса пищи, с beta=,366 продолжительн beta=,088 расстояние, п beta=-,63

(significant betas are highlighted)

Alpha for highlighting effects: .05

Quick | Advanced | Residuals/assumptions/prediction

- Summary: Regression results
- Partial correlations
- ANOVA (Overall goodness of fit)
- Redyndancy
- Coyariance of coefficients
- Stepwise regression summary
- Current sweep matrix
- ANOVA adjusted for mean

OK
Cancel
Options
By Group

Residual Analysis: бегемоты

Dependent: прибавка в Multiple R : ,94911309 F = 48,43860
 R?: ,90081566 df = 3,16
 No. of cases: 20 adjusted R?: ,88221860 p = ,000000
 Standard error of estimate: 1,529805216
 Intercept: 20,076334485 Std. Error: 4,146420 t(16) = 4,8418 p < ,0002

& Residual Values (бегемоты)

| Predicted & Residual Values (бегемоты) | | | | | |
|--|----------------|-----------------|----------|-------------------|----------|
| Dependent variable: прибавка в весе за мес | | | | | |
| Case No. | Observed Value | Predicted Value | Residual | Standard Pred. v. | |
| 1 | 21,11111 | 20,08197 | 1,02914 | 0,23085 | |
| 2 | 13,63636 | 15,24849 | -1,61213 | -0,91162 | |
| 3 | 18,00000 | 17,82153 | 0,17847 | -0,30344 | |
| 4 | 20,00000 | 21,08455 | -1,08455 | 0,46783 | |
| 5 | 17,27273 | 17,20708 | 0,06565 | -0,44867 | |
| 6 | 31,25000 | 29,86369 | 1,38631 | 2,54291 | |
| 7 | 15,83333 | 19,55820 | -3,72486 | 0,10705 | |
| 8 | 20,00000 | 19,90662 | 0,09338 | 0,18941 | |
| 9 | 17,50000 | 19,76637 | -2,26637 | 0,15626 | -1,48148 |
| 10 | 19,00000 | 18,15647 | 0,84353 | -0,22427 | 0,55140 |
| 11 | 16,15385 | 15,72465 | 0,42919 | -0,79907 | 0,28055 |
| 12 | 15,71429 | 14,96591 | 0,74838 | -0,97841 | 0,48920 |
| 13 | 18,00000 | 18,28773 | -0,28773 | -0,19324 | -0,18808 |
| 14 | 15,33333 | 14,57290 | 0,76043 | -1,07130 | 0,49708 |
| 15 | 21,00000 | 21,82652 | -0,82652 | 0,64321 | -0,54028 |
| 16 | 14,66667 | 12,15947 | 2,50720 | -1,64176 | 1,63890 |
| 17 | 24,16667 | 23,20703 | 0,95963 | 0,96951 | 0,62729 |
| 18 | 28,18182 | 27,40240 | 0,77942 | 1,96115 | 0,50949 |
| 19 | 16,00000 | 16,70276 | -0,70276 | -0,56788 | -0,45938 |
| 20 | 19,28572 | 18,56154 | 0,72418 | -0,12852 | 0,47338 |
| Minimum | 13,63636 | 12,15947 | -3,72486 | -1,64176 | -2,43486 |
| Maximum | 31,25000 | 29,86369 | 2,50720 | 2,54291 | 1,63890 |
| Mean | 19,10529 | 19,10529 | 0,00000 | -0,00000 | 0,00000 |
| Median | 18,00000 | 18,42463 | 0,30383 | -0,16088 | 0,19861 |

Quick Advanced Residuals Predicted Scatterplots Probability plots Outliers **Save** Summary

Summary: Residuals & predicted

Descriptive statistics

Regression summary

Durbin-Watson statistic

Maximum number of rows (cases) in a single results Spreadsheet or Graph: 100000

Cancel

Options

By Group

Predicted & Residual Values (бегемоты)

Residual Analysis: бегемоты

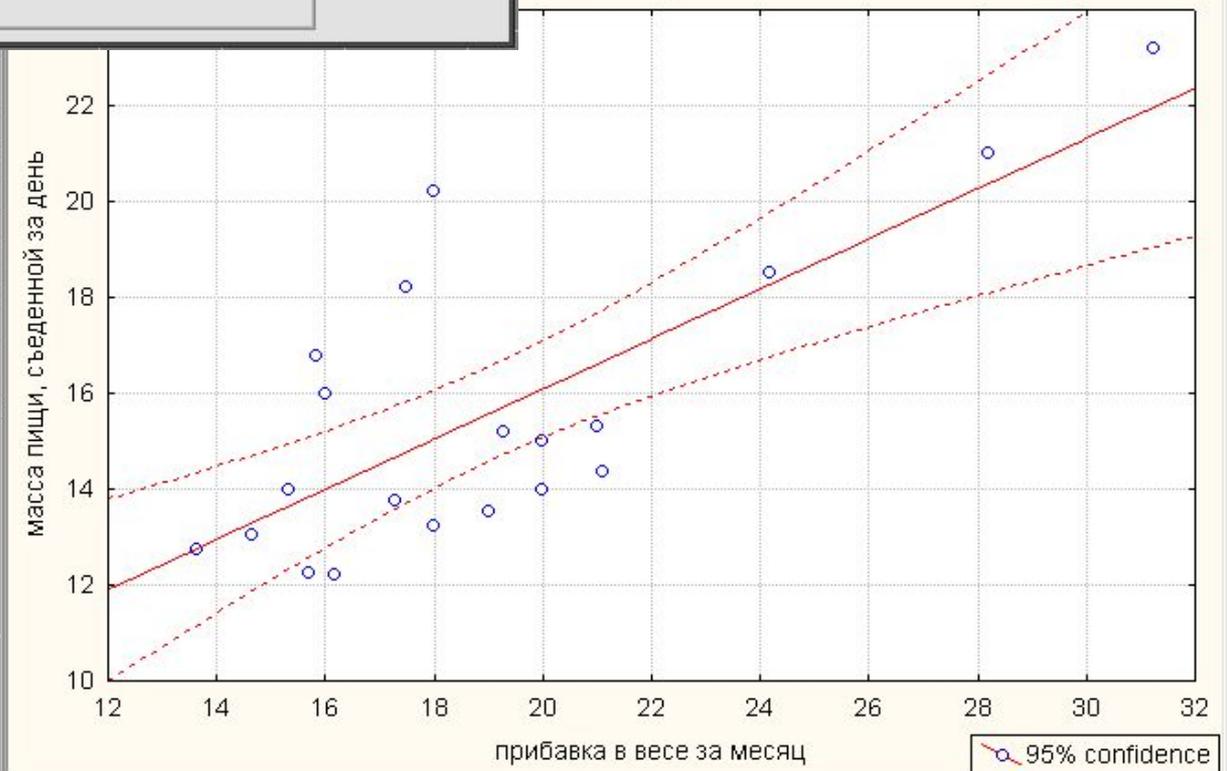
Dependent: прибавка в весе Multiple R: ,94911309 F = 48,43860
 R?: ,90081566 df = 3,16
 No. of cases: 20 adjusted R?: ,88221860 p = ,000000
 Standard error of estimate: 1,529805216
 Intercept: 20,076334485 Std. Error: 4,146420 t(16) = 4,8418 p < ,0002

Quick | Advanced | Residuals | Predicted | Scatterplots | Probability plots | Outliers | Save | Summary

Predicted vs. residuals Observed vs. squared residuals
 Predicted vs. squared residuals Residuals vs. deleted residuals
 Predicted vs. observed Bivariate correlation
 Observed vs. residuals Partial residual plot

Buttons: Cancel, Options, By Group

прибавка в весе за день vs. прибавка в весе за месяц
 уравнение: $y = 5,6335 + ,52281 * \text{прибавка в весе за месяц}$
 correlation: $r = ,75110$



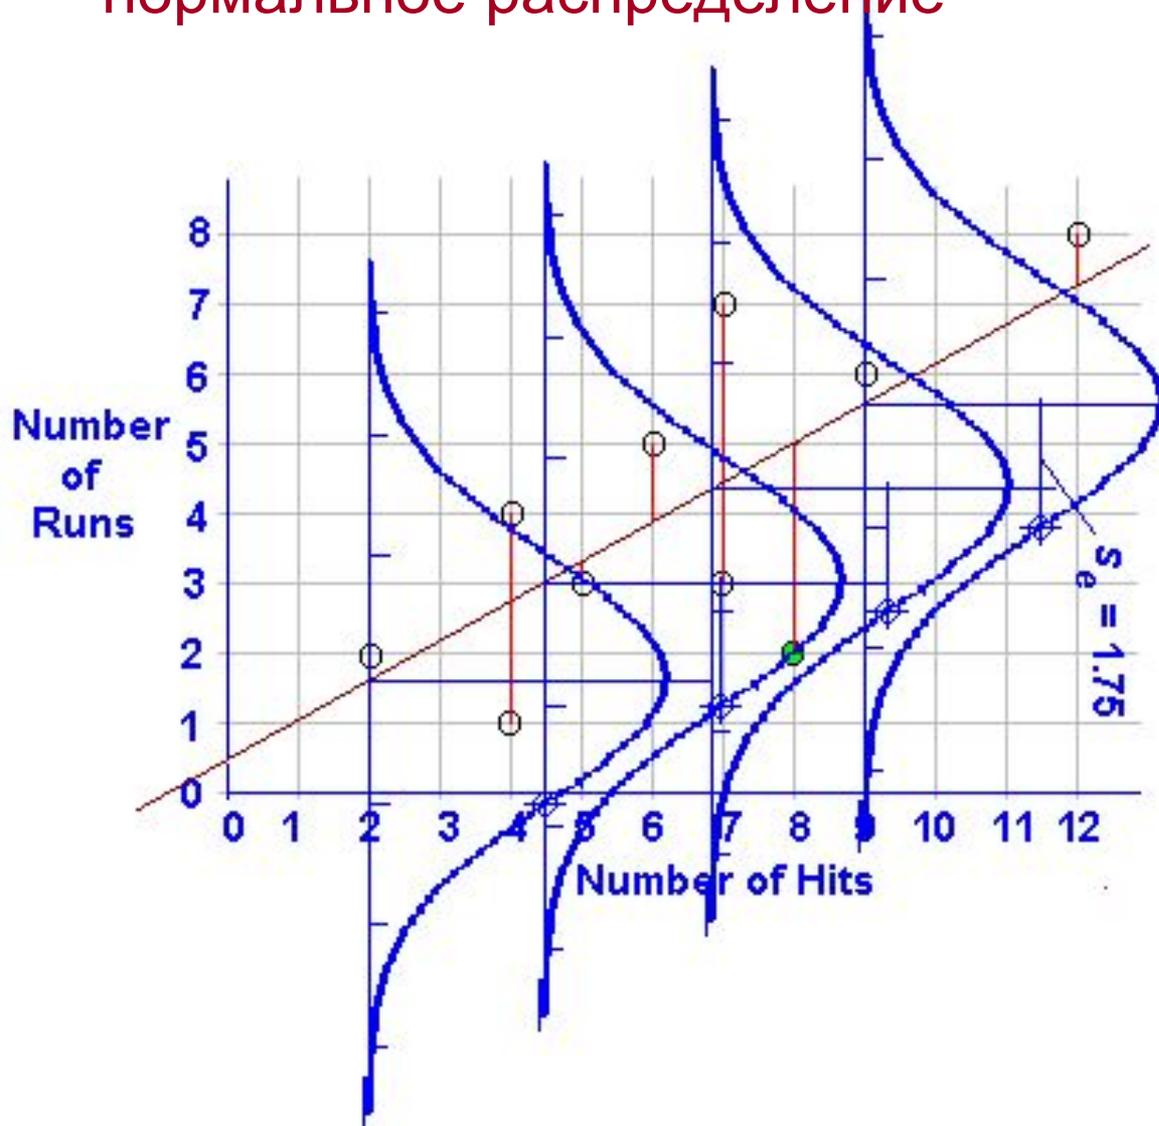
Регрессии

Требования к выборке для проведения регрессионного анализа

1. Ожидаемая зависимость переменной Y от X должна быть **линейной**.
2. Для любого значения X_i , Y должна иметь **нормальное распределение**, и residuals тоже должны быть распределены нормально.
3. Для любого значения X_i выборки для Y должны иметь **одинаковую дисперсию** (homogeneity).
4. Для любого значения X_i выборки для Y должны быть **независимы** друг от друга.
5. Размер выборки должен быть не меньше, чем в 10 раз превосходить число переменных в анализе (лучше – в 20 раз).
6. Следует исключить аутлаеры

Регрессии

Для любого значения X_i Y должна иметь нормальное распределение



Например, прибавка в весе для всех бегемотов, съедавших по 20 кг в день имеет нормальное распределение



Иногда связь между зависимой и независимой переменной нелинейная. Например:

$$Y_i = \alpha \beta^{X_i} + \epsilon_i \quad \text{экспоненциальный рост}$$

$$Y_i = \alpha - \beta(e^{-\gamma X_i}) + \epsilon_i \quad \text{асимптотическая регрессия}$$

$$Y_i = \frac{\alpha}{1 + \beta \delta^{X_i}} + \epsilon_i \quad \text{логистический рост}$$

$$Y_i = \alpha X_i^\beta \epsilon_i$$

Отдельный случай – **полиномиальная регрессия**.

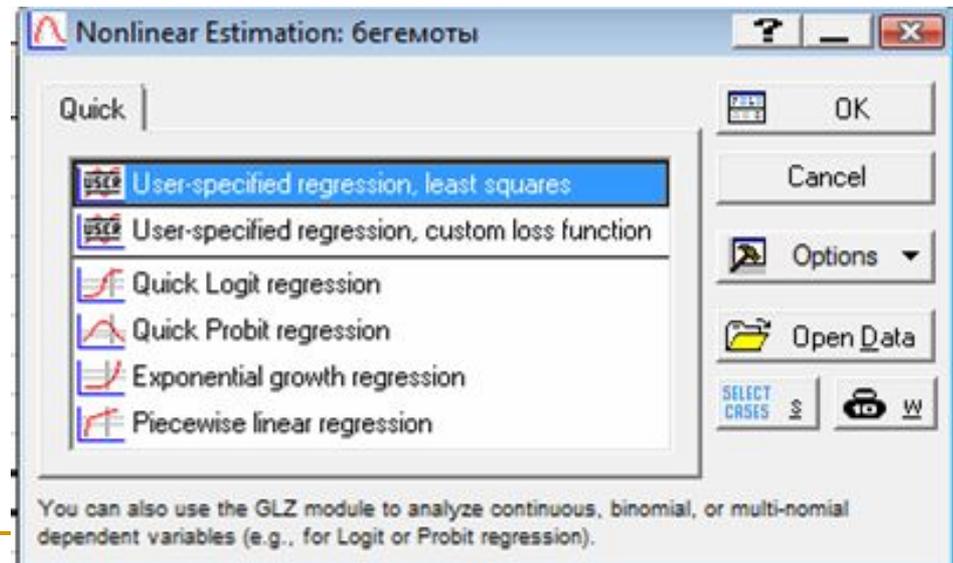
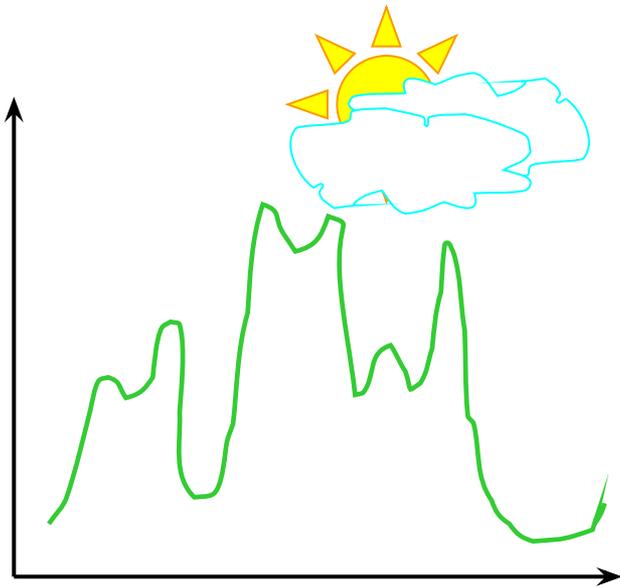
$$Y_i = \alpha + \beta_1 X_i + \beta_2 X_i^2 + \beta_3 X_i^3 + \dots + \beta_m X_i^m + \epsilon_i$$

В статистике каждый X^m обозначают как новую переменную и дальше анализируют почти как линейную модель.

Регрессии

В случае, если наши переменные связаны друг с другом принципиально не линейной зависимостью:

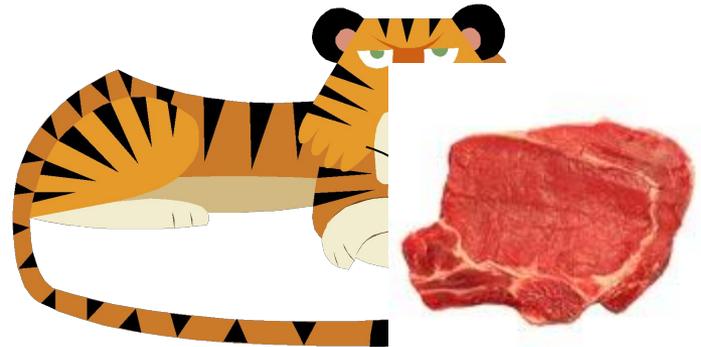

1. можно трансформировать данные и привести зависимость к линейной (логарифмирование, извлечение квадратного корня и пр.);
2. Можно предположить (или угадать) функцию, которая их связь отражает и потом сравнить данные с ней



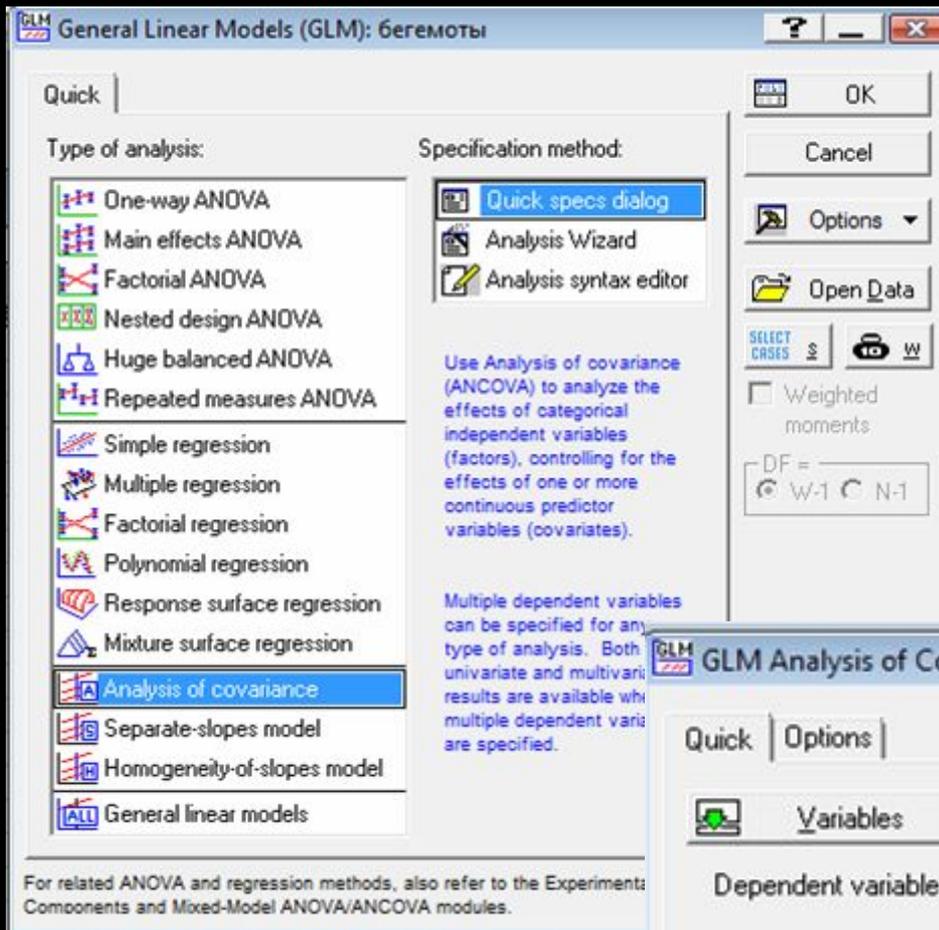
ANCOVA

Модель, когда исследуется действие **и** группирующей, и непрерывной независимых переменных на непрерывную зависимую переменную

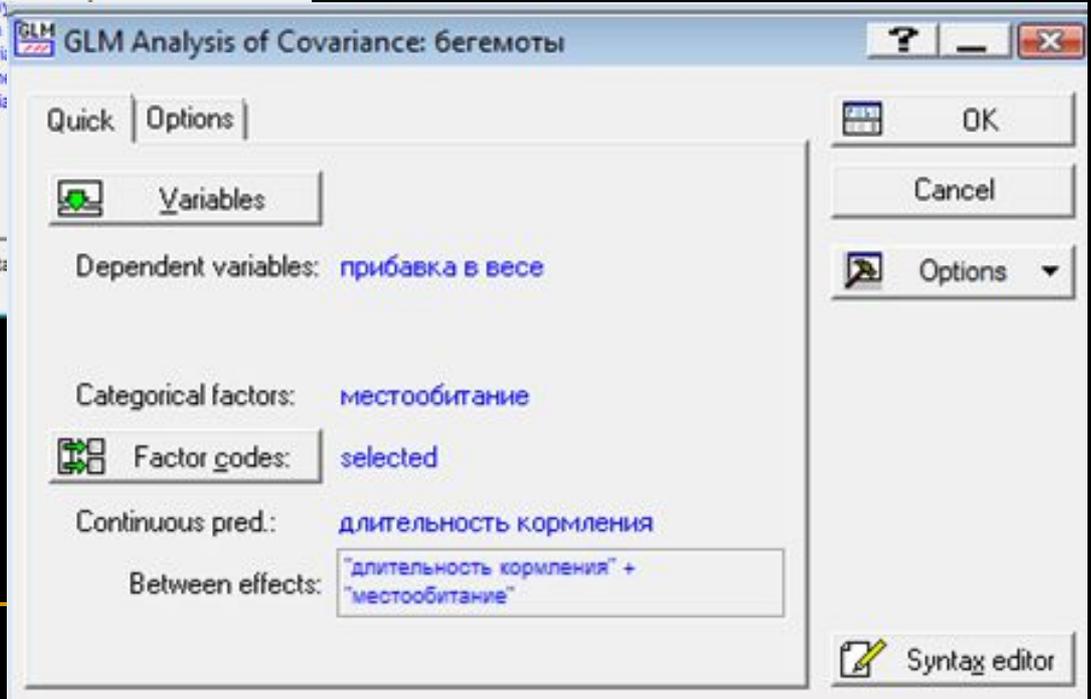
Пример: мы анализируем влияние типа пищи (группирующая независимая) и уровня кортикостероидов в крови (непрерывная независимая) на массу тигров (непрерывная зависимая).



Комбинированный тип анализа – ANOVA + регрессионный анализ = ANCOVA (analysis of covariance)



ANCOVA: прибавка в весе у бегемотов в разных типах местообитания



Тип местообитания не влиял на прибавку в весе, она зависела только от длительности кормления.

Univariate Tests of Significance for прибавка в весе (бегемоты)

| Effect | Univariate Tests of Significance for прибавка в весе (бегемоты) Sigma-restricted parameterization Effective hypothesis decomposition | | | | |
|------------------------|--|------------------|----------|----------|----------|
| | SS | Degr. of Freedom | MS | F | p |
| Intercept | 4,9196 | 1 | 4,9196 | 0,48372 | 0,496721 |
| длительность кормления | 185,0210 | 1 | 185,0210 | 18,19214 | 0,000592 |
| местообитание | 1,8211 | 2 | 0,9106 | 0,08953 | 0,914815 |
| Error | 162,7262 | 16 | 10,1704 | | |

Univariate Tests of Significance for прибавка в весе (бегемоты) Univariate Tests of Significance for пр

Выбор модели в GLM

| Независимые переменные | Зависимые переменные | Модель |
|--|----------------------|---|
| Одна группирующая | Одна непрерывная | One-way ANOVA |
| Много группирующих | Одна непрерывная | Factorial ANOVA (two-, multiway). Main effect ANOVA |
| Одна или много группирующих | Много непрерывных | MANOVA (multivariate ANOVA) |
| Одна непрерывная | Одна непрерывная | Simple regression |
| Много непрерывных | Одна непрерывная | Multiple regression |
| Одна группирующая (или много) + одна непрерывная (или много) | Одна непрерывная | ANCOVA |

1. исследователь решил узнать, как зависит размер дома у семьи от дохода семьи (в год). Собрал данные от 50 семей. H_0 ?
Статистический критерий? Как изменится результат теста, если доходы семей увеличатся каждая на 5000\$ в год?

2. педиатры изучают прибавку в весе у младенцев (её оценивают как разницу в массе ребёнка в 2 мес и при рождении). При этом, в их выборке есть дети, которые вскармливаются искусственно, а есть те, которые находятся на грудном вскармливании. Кроме того, некоторые матери кормят младенцев по требованию, другие же – строго по расписанию. Влияют ли тип пищи и распорядок вскармливания на прибавку в весе? H_0 ?
Статистический критерий?

3. владелец бассейна думает, что количество хлора, которое ежедневно затрачивается на то, чтобы содержать бассейн в чистоте, зависит от температуры воздуха и дня недели. Он стал отмечать, сколько каждый раз у него уходит хлора на очистку, и взял из газет данные о дневных температурах. Так он делал в течение полугода. Зависит ли количество хлора от температуры и дня недели? H_0 ?
Статистический критерий?

Регрессии

Насколько хорошо «лучшая» линия регрессии предсказывает Y?

Чем меньше **стандартное отклонение ошибок e_i** (standard error of estimate), тем точнее предсказание (потому, что оно напрямую зависит от размера самих ошибок).

$$s_e = \sqrt{\frac{\sum (e_i - \bar{e})^2}{n-2}} = \sqrt{\frac{\sum e_i^2}{n-2}}$$

$$s_e = s_Y \sqrt{1 - r^2} \sqrt{\frac{n-1}{n-2}} \approx 1$$

зависит от квадрата коэффициента корреляции

