

Прикладной статистический анализ данных.  
1. Введение: распределения, статистики, оценки, гипотезы.

Константин Воронцов  
psad.homework@gmail.com

1, 2017

## Зачем нужен этот курс

- специфические статистические методы для конкретных постановок задач
- границы применимости методов
- статистическое мышление

## Зачем нужен этот курс

- специфические статистические методы для конкретных постановок задач
- границы применимости методов  
(Marriott, 1974): If the results disagree with informed opinion, do not admit a simple logical interpretation, and do not show up clearly in a graphical presentation, they are probably wrong. There is no magic about numerical methods, and many ways in which they can break down. They are a valuable aid to the interpretation of data, not sausage machines automatically transforming bodies of numbers into packets of scientific fact.
- СТАТИСТИЧЕСКОЕ МЫШЛЕНИЕ

## Зачем нужен этот курс

- специфические статистические методы для конкретных постановок задач
- границы применимости методов
- статистическое мышление  
(Begg et al., 1992): понимание механизмов работы статистики позволяет находить менее стереотипные и более осознанные решения повседневных задач.



# Случайность




# Случайность




# Случайность




# Случайность




# Случайность



# Изучение случайности




# Изучение случайности



**Вероятность события** — доля испытаний, завершившихся наступлением события, в бесконечном эксперименте.

# Изучение случайности

теория вероятностей



# Изучение случайности



# Изучение случайности



**Закон больших чисел:** на больших выборках частота события хорошо приближает его вероятность.

## Описание случайных величин

Дискретная случайная величина  $X$  принимает счётное множество значений  $A = \{a_1, a_2, \dots\}$  с вероятностями  $p_1, p_2, \dots, \sum_i p_i = 1$ .

$f_X(a_i) = \mathbf{P}(X = a_i) = p_i$  — **функция вероятности**.

Непрерывная случайная величина задаётся с помощью **функции распределения**:

$$F_X(x) = \mathbf{P}(X \leq x)$$

или **плотности распределения**:

$$f_X(x) : \int_a^b f_X(x) dx = \mathbf{P}(a \leq X \leq b)$$

## Характеристики распределений

- **матожидание** — среднее значение  $X$ :

$$\mathbb{E}X = \int x dF(x)$$

- **дисперсия** — мера разброса  $X$ :

$$\mathbb{D}X = \mathbb{E}((X - \mathbb{E}X)^2)$$

- **квантиль** порядка  $\alpha \in (0, 1)$ :

$$X_\alpha: \mathbf{P}(X \leq X_\alpha) \geq \alpha, \quad \mathbf{P}(X \geq X_\alpha) \geq 1 - \alpha$$

эквивалентное определение:

$$X_\alpha = F^{-1}(\alpha) = \inf\{x: F(x) \geq \alpha\}$$

- **медиана** — квантиль порядка 0.5, центральное значение распределения:

$$\text{med } X: \mathbf{P}(X \leq \text{med } X) \geq 0.5, \quad \mathbf{P}(X \geq \text{med } X) \geq 0.5$$

- **интерквартильный размах**:

$$IQR = X_{0.75} - X_{0.25}$$


- **мода** — точка максимума функции вероятности или плотности:

$$\text{mode } X = \underset{x}{\operatorname{argmax}} f(x)$$

# Характеристики распределений


- коэффициент асимметрии (skewness):

$$\gamma_1 = \mathbb{E} \left( \frac{X - \mathbb{E}X}{\sqrt{\mathbb{D}X}} \right)^3$$



# Характеристики распределений


$\gamma_1 = 0$  — необходимое, но не достаточное условие симметричности:



# Характеристики распределений


- коэффициент эксцесса (excess, без вычитания тройки — kurtosis):

$$\gamma_2 = \frac{\mathbb{E}(X - \mathbb{E}X)^4}{(\mathbb{D}X)^2} - 3$$




# Нормальное распределение

$$X \in \mathbb{R} \sim N(\mu, \sigma^2), \sigma^2 > 0$$



$$F(x) = \Phi\left(\frac{x - \mu}{\sigma}\right)$$

$$f(x) = \frac{1}{\sigma} \phi\left(\frac{x - \mu}{\sigma}\right)$$



$$\Phi(x) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{t^2}{2}} dt$$

$$\phi(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{x^2}{2}}$$

# Нормальное распределение

- предельное распределение суммы слабо взаимозависимых сл. в.
- $\mathbb{E}X = \text{med } X = \text{mode } X = \mu$ ,  $\mathbb{D}X = \sigma^2$ , все моменты более высокого порядка нулевые
- пусть  $X_1, \dots, X_n$  независимы,  $X_i \sim N(\mu_i, \sigma_i^2)$ , тогда  $\forall a_1, \dots, a_n$

$$\sum_{i=1}^n a_i X_i \sim N\left(\sum_{i=1}^n a_i \mu_i, \sum_{i=1}^n a_i^2 \sigma_i^2\right)$$



- центральная предельная теорема: пусть  $X_1, \dots, X_n$  i.i.d. с  $\mathbb{E}X$  и  $\mathbb{D}X < \infty$ , тогда

$$\frac{1}{n} \sum_{i=1}^n X_i \sim \approx N\left(\mathbb{E}X, \frac{\mathbb{D}X}{n}\right)$$

- пример: погрешность измерения

# Распределение хи-квадрат

$$X \in \mathbb{R}_+ \sim \chi_k^2, k \in \mathbb{N}$$



$$F(x) = \frac{1}{\Gamma\left(\frac{k}{2}\right)} \gamma\left(\frac{k}{2}, \frac{x}{2}\right)$$

$$f(x) = \frac{1}{2^{\frac{k}{2}} \Gamma\left(\frac{k}{2}\right)} x^{\frac{k}{2}-1} e^{-\frac{x}{2}}$$

$\Gamma(x) = \int_0^\infty t^{x-1} e^{-t} dt$  — гамма-функция

$\gamma(a, x) = \int_0^x e^{-t} t^{a-1} dt$  — нижняя неполная гамма-функция

## Распределение хи-квадрат

- пусть  $X_1, \dots, X_k$  — i.i.d.,  $X_i \sim N(0, 1)$ , тогда



$$\sum_{i=1}^k X_i^2 \sim \chi_k^2$$

- пример: нормированная выборочная дисперсия:

$$(n-1) \frac{S_n^2}{\sigma^2} \sim \chi_{n-1}^2$$

# Распределение Фишера

$$X \in \mathbb{R}_+ \sim F(d_1, d_2), \quad d_1, d_2 > 0$$



$$F(x) = I_{\frac{d_1 x}{d_1 x + d_2}} \left( \frac{d_1}{2}, \frac{d_2}{2} \right)$$

$$f(x) = \sqrt{\frac{(d_1 x)^{d_1} d_2^{d_2}}{(d_1 x + d_2)^{d_1 + d_2}}} / x B \left( \frac{d_1}{2}, \frac{d_2}{2} \right)$$

$B(a, b) = \int_0^1 t^{a-1} (1-t)^{b-1} dt$  — бета-функция

$I_x(a, b) = \frac{B(x; a, b)}{B(a, b)}$  — регуляризованная неполная бета-функция

$B(x; a, b) = \int_0^x t^{a-1} (1-t)^{b-1} dt$  — неполная бета-функция

# Распределение Фишера

- пусть  $X_1 \sim \chi_{d_1}^2$ ,  $X_2 \sim \chi_{d_2}^2$ ,  $X_1$  и  $X_2$  независимы, тогда

$$\frac{X_1/d_1}{X_2/d_2} \sim F(d_1, d_2)$$



- если  $X \sim F(d_1, d_2)$ , то

$$Y = \lim_{d_2 \rightarrow \infty} d_1 X \sim \chi_{d_1}^2$$

- $F(x, d_1, d_2) = F(1/x, d_2, d_1)$
- возникает в дисперсионном и регрессионном анализе

# Распределение Стьюдента

$$X \in \mathbb{R} \sim St(\nu), \nu > 0$$



$$F(x) = \frac{1}{2} + x \Gamma\left(\frac{\nu+1}{2}\right)$$

$$f(x) = \frac{\Gamma\left(\frac{\nu+1}{2}\right)}{\sqrt{\nu\pi}\Gamma\left(\frac{\nu}{2}\right)} \left(1 + \frac{x^2}{\nu}\right)^{-\frac{\nu+1}{2}}$$

# Распределение Стьюдента

- $\mathbb{E}X = 0$  при  $\nu > 1$ ,  $\text{med } X = \text{mode } X = 0$  всегда
- пусть  $Z \sim N(0, 1)$  и  $V \sim \chi_\nu^2$  независимы, тогда

$$T = \frac{Z}{\sqrt{V/\nu}} \sim St(\nu)$$



- если  $X \sim St(\nu)$ , то

$$Y = \lim_{\nu \rightarrow \infty} X \sim N(0, 1)$$

- возникает при оценке среднего значения сл. в. с неизвестной дисперсией

# Распределение Бернулли

$$X \in \{0, 1\} \sim \text{Ber}(p), \quad p \in (0, 1)$$





$$F(x) = \begin{cases} 0, & x < 0, \\ 1 - p, & 0 \leq x < 1, \\ 1, & x \geq 1. \end{cases}$$

$$f(x) = \begin{cases} 1 - p, & x = 0, \\ p, & x = 1. \end{cases}$$

- пример: результат подбрасывания монеты

# Биномиальное распределение

$X \in \{0, \dots, N\} \sim \text{Bin}(N, p), N \in \mathbb{N}, p \in [0, 1]$



$$F(x) = I_{1-p}(N-x, 1+x)$$

$$f(x) = C_N^x p^x (1-p)^{N-x}$$

# Биномиальное распределение

- пусть  $X_1, \dots, X_n$  независимы,  $X_i \sim Ber(p)$ , тогда

$$\sum_{i=1}^n X_i \sim Bin(n, p).$$



- $Bin(1, p) = Ber(p)$
- если  $N > 20$  и  $p$  не слишком близко к нулю или единице, то для  $X \sim Bin(N, p)$  справедлива нормальная аппроксимация:

$$F_X(x) \approx \Phi\left(\frac{x - Np}{\sqrt{Np(1-p)}}\right)$$

- пример: число попаданий из  $N$  бросков в баскетбольное кольцо

# Распределение Пуассона

$X \in \{0, 1, 2, \dots\} \sim Pois(\lambda), \lambda > 0$



$$F(x) = e^{-\lambda} \sum_{i=0}^{\lfloor x \rfloor} \frac{\lambda^i}{i!}$$

$$f(x) = e^{-\lambda} \frac{\lambda^x}{x!}$$

## Распределение Пуассона

- распределение числа независимых событий в фиксированном временном или пространственном интервале
- $\mathbb{E}X = \mathbb{D}X = \lambda$
- пусть  $X_1, \dots, X_n$  независимы,  $X_i \sim Pois(\lambda_i)$ , тогда

$$\sum_{i=1}^n X_i \sim Pois\left(\sum_{i=1}^n \lambda_i\right)$$

- если  $X \sim Pois(\lambda)$ ,  $Y = \sqrt{X}$ , то при больших  $\lambda$

$$F_Y(x) \approx \Phi\left(\frac{x - \sqrt{\lambda}}{\sqrt{\lambda}}\right)$$

- пример: количество изюма в булочке с изюмом

**Генеральная совокупность** — множество объектов, свойства которых подлежат изучению в рассматриваемой задаче.

**Выборка** — конечное множество объектов, отобранных из генеральной совокупности для проведения измерений.

$$X^n = (X_1, \dots, X_n).$$


$n$  — объём выборки.

$X^n$  — **простая выборка**, если  $X_1, \dots, X_n$  — независимые одинаково распределённые случайные величины (i.i.d.).



Основная задача статистики — описание  $F_X(x)$  по реализации выборки.

# Функция распределения

$$F_n(x) = \frac{1}{n} \sum_{i=1}^n [X_i \leq x] \text{ — эмпирическая функция распределения.}$$



# Плотность распределения



## Статистика

**Статистика**  $T(X^n)$  — любая измеримая функция выборки.

- выборочное среднее:

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

- выборочная дисперсия:

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

**вариационный ряд:**

$$X_{(1)} \leq X_{(2)} \leq \dots \leq X_{(n)}$$

**ранг** элемента выборки  $X_i$ :

$$\text{rank}(X_i) = r: X_i = X_{(r)}$$

- $k$ -я порядковая статистика:  $X_{(k)}$
- выборочный  $\alpha$ -квантиль:  $X_{([n\alpha])}$
- выборочная медиана:

$$m = \begin{cases} X_{(k+1)}, & \text{если } n = 2k + 1, \\ \frac{X_{(k)} + X_{(k+1)}}{2}, & \text{если } n = 2k. \end{cases}$$

- выборочный интерквартильный размах:

$$IQR_n = X_{([0.75n])} - X_{([0.25n])}$$

- выборочный коэффициент асимметрии:

$$g_1 = \frac{\sqrt{n} \sum_{i=1}^n (X_i - \bar{X})^3}{\left( \sum_{i=1}^n (X_i - \bar{X})^2 \right)^{3/2}}$$

- выборочный коэффициент эксцесса:


$$g_2 = \frac{n \sum_{i=1}^n (X_i - \bar{X})^4}{\left( \sum_{i=1}^n (X_i - \bar{X})^2 \right)^2} - 3$$

## Оценки центральной тенденции

Выборочное среднее — среднее арифметическое по выборке.

Выборочная медиана — центральный элемент вариационного ряда.

Выборочная мода — самое распространённое значение в выборке.



# Оценки центральной тенденции

(Huff, 1954):



\$45,000



\$15,000



\$10,000



← **ARITHMETICAL AVERAGE**

\$5,700



\$5,000



\$3,700



← **MEDIAN** (the one in the middle)  
(12 above him, 12 below)


\$3,000



\$2,000

← **MODE**  
(occurs most frequently)

# Об ограниченности статистик







Уровень стартовой заработной платы выпускников юридических факультетов, США, 2012, данные NALP.

## Об ограниченности статистик

Квартет Энскомба (Anscombe, 1973):

№	1	2	3	4
$\bar{x}$	9	9	9	9
$S_x$	11	11	11	11
$\bar{y}$	7.5	7.5	7.5	7.5
$S_y$	4.127	4.127	4.128	4.128
$r_{xy}$	0.816	0.816	0.816	0.816

# Об ограниченности статистик



# Точечные оценки

Пусть распределение генеральной совокупности параметрическое:

$$F(x) = F(x, \theta).$$

Статистика  $\hat{\theta}_n = \hat{\theta}(X^n)$  — точечная оценка параметра  $\theta$ .

Какая оценка лучше?

**Состоятельность:**  $\text{plim}_{n \rightarrow \infty} \hat{\theta}_n = \theta$ .

**Несмещённость:**  $\mathbb{E}\hat{\theta}_n = \theta$ .

**Асимптотическая несмещённость:**  $\lim_{n \rightarrow \infty} \mathbb{E}\hat{\theta}_n = \theta$ .

**Оптимальность:**  $\mathbb{D}\hat{\theta}_n = \min_{\hat{\theta}: \mathbb{E}\hat{\theta}=\theta} \mathbb{D}\hat{\theta}$ .

**Робастность:** устойчивость  $\hat{\theta}_n$  относительно

- отклонений истинного распределения  $X$  от модельного семейства
- выбросов, содержащихся в выборке

## Метод максимума правдоподобия

Популярный метод получения точечных оценок:

$$\begin{aligned}X &\sim f(x, \theta), \\X^n &= (X_1, \dots, X_n), \\L(X^n, \theta) &= \prod_{i=1}^n f(X_i, \theta), \\ \hat{\theta}_{MLE} &\equiv \operatorname{argmax}_{\theta} L(X^n, \theta).\end{aligned}$$

Удобно прологарифмировать:

$$\begin{aligned}\log L(X^n, \theta) &= \sum_{i=1}^n f(X_i, \theta), \\ \hat{\theta}_{MLE} &\equiv \operatorname{argmax}_{\theta} \log L(X^n, \theta).\end{aligned}$$

## Производные функции правдоподобия

Score function:

$$S(\theta) \equiv \frac{\partial}{\partial \theta} \log L(\theta)$$

ОМП — решение score equation:

$$S(\theta) = 0$$

Информация Фишера:

$$I(\theta) \equiv -\frac{\partial^2}{\partial \theta^2} \log L(\theta)$$

Дисперсия ОМП:

$$\mathbb{D}\hat{\theta}_{MLE} \approx I^{-1}(\hat{\theta}_{MLE})$$

## Свойства ОМП

- состоятельность:

$$\text{plim}_{n \rightarrow \infty} \hat{\theta}_{MLE} = \theta$$

- асимптотическая нормальность: при  $n \rightarrow \infty$

$$\hat{\theta}_{MLE} \sim N(\theta, I^{-1}(\theta))$$

- эффективность: ОМП имеют наименьшую дисперсию среди всех состоятельных оценок
- инвариантность:  $g(\hat{\theta}_{MLE})$  — ОМП-оценка для  $g(\theta)$

## Интервальные оценки

Доверительный интервал:

$$P(\theta \in [C_L, C_U]) \geq 1 - \alpha,$$

$1 - \alpha$  — уровень доверия,

$C_L, C_U$  — нижний и верхний доверительные пределы.

**Неверная интерпретация:** неизвестный параметр лежит в пределах построенного доверительного интервала с вероятностью  $1 - \alpha$ .

**Верная интерпретация:** при бесконечном повторении процедуры построения доверительного интервала на аналогичных выборках в  $100(1 - \alpha)\%$  случаев он будет содержать истинное значение  $\theta$ .

## Для нормального распределения

$$X \sim N(\mu, \sigma^2), \quad X^n = (X_1, \dots, X_n),$$

$\bar{X}_n$  — оценка  $\mathbb{E}X = \mu$ ,

ЦПТ:  $\bar{X}_n \sim N\left(\mu, \frac{\sigma^2}{n}\right) \Rightarrow$

$$\mathbf{P}\left(\mu - z_{1-\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}} \leq \bar{X}_n \leq \mu + z_{1-\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}}\right) = 1 - \alpha \Rightarrow$$

доверительный интервал для  $\mu$ :

$$\mathbf{P}\left(\bar{X}_n - z_{1-\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X}_n + z_{1-\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}}\right) = 1 - \alpha,$$

$z_{1-\frac{\alpha}{2}}$  — квантиль стандартного нормального распределения.

## Для ненормальных распределений

ЦПТ: если  $X^n$  — выборка из  $F(x)$ ,  $F(x)$  не слишком скошено и  $n > 30$ , то

$$\bar{X}_n \sim\sim N\left(\mathbb{E}X, \frac{\mathbb{D}X}{n}\right) \Rightarrow$$

доверительный интервал для  $\mathbb{E}X$ :

$$\mathbf{P}\left(\bar{X}_n - z_{1-\frac{\alpha}{2}} \sqrt{\frac{\mathbb{D}X}{n}} \leq \mathbb{E}X \leq \bar{X}_n + z_{1-\frac{\alpha}{2}} \sqrt{\frac{\mathbb{D}X}{n}}\right) \approx 1 - \alpha.$$

Если дисперсия неизвестна:

$$\mathbf{P}\left(\bar{X}_n - t_{n-1, 1-\frac{\alpha}{2}} \frac{S_n}{\sqrt{n}} \leq \mathbb{E}X \leq \bar{X}_n + t_{n-1, 1-\frac{\alpha}{2}} \frac{S_n}{\sqrt{n}}\right) \approx 1 - \alpha,$$

$t_{n-1, 1-\frac{\alpha}{2}}$  — квантиль распределения Стьюдента с  $n - 1$  степенью свободы.

## Квантили

Непараметрический доверительный интервал для медианы непрерывного распределения.

$$X^n = (X_1, \dots, X_n), \quad X \sim F(x) \Rightarrow$$

$$\mathbf{P}(\text{med } X \in [X_{(r)}, X_{(n-r+1)}]) = \frac{1}{2^n} \sum_{i=r}^{n-r+1} C_n^i.$$

При  $n > 10$  применима нормальная аппроксимация:

$$\mathbf{P}\left(\text{med } X \in \left[ X\left(\left\lfloor \frac{n - \sqrt{n}z_{1-\frac{\alpha}{2}}}{2} \right\rfloor\right), X\left(\left\lceil \frac{n + \sqrt{n}z_{1-\frac{\alpha}{2}}}{2} \right\rceil\right) \right] \right) \approx 1 - \alpha.$$

Аналогично строится непараметрический доверительный интервал для любого квантиля  $X_\alpha$ ,  $\alpha \in (0, 1)$ :

$$\mathbf{P}(X_\alpha \in [X_{(l)}, X_{(u)}]) = \sum_{i=l}^u C_n^i \alpha^i (1 - \alpha)^{n-i}.$$

# Построение доверительных интервалов


Как можно оценить  $F_{\hat{\theta}_n}(x)$  — выборочное распределение статистики  $\hat{\theta}_n$ ? (Hesterberg, 2005):

- параметрический метод:



НОРМАЛЬНАЯ ПОПУЛЯЦИЯ  
неизвестное среднее  $\mu$

Теория  
→



Выборочное распределение

Сделать предположение, что  $X$  распределена по закону  $F_X(x)$ , при выполнении которого закон распределения  $\hat{\theta}_n$  известен.

# Построение доверительных интервалов


- наивный метод:



ПОПУЛЯЦИЯ

неизвестное среднее  $\mu$

SRS объёма  $n$   $\rightarrow$   $\bar{x}$   
 SRS объёма  $n$   $\rightarrow$   $\bar{x}$   
 SRS объёма  $n$   $\rightarrow$   $\bar{x}$   
 . . .  
 . . .



Выборочное распределение

Извлечь из генеральной совокупности  $N$  выборок объёма  $n$  и оценить выборочное распределение  $\hat{\theta}_n$  эмпирическим.


# Построение доверительных интервалов

- бутстреп:




популяция  
неизвестное среднее  $\mu$

SRS объёма  $n$



"Псевдовыборка" объёма  $n$   $\bar{x}$   
 "Псевдовыборка" объёма  $n$   $\bar{x}$   
 "Псевдовыборка" объёма  $n$   $\bar{x}$   
 ⋮  
 ⋮  
 ⋮




Бутстреп

Сгенерировать  $N$  «псевдовыборок» объёма  $n$  и оценить выборочное распределение  $\hat{\theta}_n$  «псевдоэмпирическим».

## Бутстреп

Извлечение выборок из генеральной совокупности — сэмплирование из неизвестного распределения  $F_X(x)$ .


Лучшая оценка  $F_X(x)$ , которая у нас есть —  $F_{X^n}(x)$ :



Сэмплировать из неё — это то же самое, что делать из  $X^n$  выборки с возвращением объёма  $n$ .

# Бутстреп-распределение

$X^{1*}, \dots, X^{N*}$  — бутстреп-псевдовыборки из  $X^n$  объёма  $n$ ,  
 $\hat{\theta}_n^{1*}, \dots, \hat{\theta}_n^{N*}$  — значения статистики на них,  
 $F_{\hat{\theta}_n}^{boot}(x)$  — бутстреп-распределение  $\hat{\theta}_n$  — эмпирическая функция распределения, построенная по значениям статистики на псевдовыборках.



По  $F_{\hat{\theta}_n}^{boot}(x)$  можно строить доверительные интервалы для  $\theta!$

## Доверительные интервалы

- Посчитаем  $S_n^{boot}$  — выборочное стандартное отклонение  $\hat{\theta}_n$  на псевдовыборках;

$$\mathbf{P}\left(\hat{\theta}_n - t_{n-1, 1-\frac{\alpha}{2}} S_n^{boot} \leq \theta \leq \hat{\theta}_n + t_{n-1, 1-\frac{\alpha}{2}} S_n^{boot}\right) \approx 1 - \alpha.$$

Это стьюдентизированный бутстреп.

- Возьмём выборочные квантили бутстреп-распределения:

$$\mathbf{P}\left(\left(F_{\hat{\theta}_n}^{boot}\right)^{-1}\left(\frac{\alpha}{2}\right) \leq \theta \leq \left(F_{\hat{\theta}_n}^{boot}\right)^{-1}\left(1 - \frac{\alpha}{2}\right)\right) \approx 1 - \alpha.$$

Это базовый бутстреп.

## Доверительные интервалы

- Слегка изменим наивный бутстреп:

$$\mathbf{P}\left(\left(F_{\hat{\theta}_n}^{boot}\right)^{-1}(\alpha_1) \leq \theta \leq \left(F_{\hat{\theta}_n}^{boot}\right)^{-1}(\alpha_2)\right) \approx 1 - \alpha,$$

$$\alpha_1 = \Phi\left(\hat{z}_0 + \frac{\hat{z}_0 + z_{\frac{\alpha}{2}}}{1 - \hat{a}\left(\hat{z}_0 + z_{\frac{\alpha}{2}}\right)}\right),$$

$$\alpha_2 = \Phi\left(\hat{z}_0 + \frac{\hat{z}_0 + z_{1-\frac{\alpha}{2}}}{1 - \hat{a}\left(\hat{z}_0 + z_{1-\frac{\alpha}{2}}\right)}\right),$$

$$\hat{z}_0 = \Phi^{-1}\left(\frac{1}{N} \sum_{i=1}^N [\hat{\theta}_n^{i*} < \hat{\theta}_n]\right),$$

$\hat{a}$  не поместится на этом слайде.


Это несмещённый ускоренный бутстреп.

## Свойства бутстрепа


- асимптотическая состоятельность
- простота использования даже для самых сложных статистик
- плохо работает для статистик, значение которых зависит от небольшого числа элементов выборки

# Проверка гипотез

выборка:  $X^n = (X_1, \dots, X_n)$ ,  $X \sim \mathbf{P} \in \Omega$   
 нулевая гипотеза:  $H_0: \mathbf{P} \in \omega$ ,  $\omega \in \Omega$   
 альтернатива:  $H_1: \mathbf{P} \notin \omega$   
 статистика:  $T(X^n)$ ,  $T(X^n) \sim F(x)$  при  $\mathbf{P} \in \omega$   
 $T(X^n) \not\sim F(x)$  при  $\mathbf{P} \notin \omega$



реализация выборки:  $x^n = (x_1, \dots, x_n)$   
 реализация статистики:  $t = T(x^n)$   
 достигаемый уровень значимости:  $p(x^n)$  — вероятность при  $H_0$  получить  $T(X^n) = t$  или ещё более экстремальное



$$p(x^n) = \mathbf{P}(T \geq t | H_0)$$

Гипотеза отвергается при  $p(x^n) \leq \alpha$ ,  $\alpha$  — уровень значимости

# Проверка гипотез



## Достижимый уровень значимости

$$p = \mathbf{P}(T \geq t | H_0) \neq \mathbf{P}(H_0)$$

**Пример:** утверждается, что осьминог предсказывает результаты матчей с участием сборной Германии на чемпионате мира по футболу 2010 года, выбирая кормушку с флагом страны-победителя. По результатам 13 испытаний ему удаётся верно угадать результаты 11 матчей. Применяя подходящий статистический критерий, мы получаем  $p \approx 0.0112$ .



0.0112 — не вероятность того, что осьминог выбирает кормушку наугад!  
Эта вероятность равна единице.

## Ошибки I и II рода

	$H_0$ верна	$H_0$ неверна
$H_0$ принимается	$H_0$ верно принята	Ошибка второго рода (False negative)
$H_0$ отвергается	Ошибка первого рода (False positive)	$H_0$ верно отвергнута

**Type I error**  
(false positive)



**Type II error**  
(false negative)



## Ошибки I и II рода

Задача проверки гипотез несимметрична относительно пары  $(H_0, H_1)$ : вероятность ошибки первого рода ограничивается сверху величиной  $\alpha$ , а второго рода — минимизируется путём выбора критерия.

**Корректный** критерий:  $\mathbf{P}(p(T) \leq \alpha | H_0) \leq \alpha \forall \mathbf{P} \in \Omega$ .

**Мощность**:  $\text{pow} = \mathbf{P}(p(T) \leq \alpha | H_1)$ .

**Состоятельный** критерий:  $\text{pow} \rightarrow 1$  для всех альтернатив  $H_1$  при  $n \rightarrow \infty$ .

$T_1$  — **равномерно наиболее мощный** критерий, если  $\forall T_2$

$$\mathbf{P}(p(T_1) \leq \alpha | H_1) \geq \mathbf{P}(p(T_2) \leq \alpha | H_1) \quad \forall H_1 \neq H_0,$$

$$\mathbf{P}(p(T_1) \leq \alpha | H_0) = \mathbf{P}(p(T_2) \leq \alpha | H_0),$$

причём хотя бы для одной  $H_1$  неравенство строгое.

## Интерпретация результата

Если величина  $p$  достаточно мала, то данные свидетельствуют против нулевой гипотезы в пользу альтернативы.

Если величина  $p$  недостаточно мала, то данные не свидетельствуют против нулевой гипотезы в пользу альтернативы.

При помощи инструмента проверки гипотез нельзя доказать справедливость нулевой гипотезы!

Absence of evidence  $\nRightarrow$  evidence of absence.

# Статистическая и практическая значимость

Вероятность отвергнуть нулевую гипотезу зависит не только от того, насколько она отличается от истины, но и от размера выборки.

По мере увеличения  $n$  нулевая гипотеза может сначала приниматься, но потом выявятся более тонкие несоответствия выборки гипотезе  $H_0$ , и она будет отвергнута.

При любой проверке гипотез нужно оценивать **размер эффекта** — степень отличия нулевой гипотезы от истины, и оценивать его практическую значимость.

## Статистическая и практическая значимость

- (Lee et al, 2010): за три года женщины, упражнявшиеся не меньше часа в день, набрали значимо меньше веса, чем женщины, упражнявшиеся меньше 20 минут в день ( $p < 0.001$ ). Разница в набранном весе составила 150 г. Практическая значимость такого эффекта сомнительна. Подробности: <http://youtu.be/oqDZ0-mfN4Q>.
- (Ellis, 2010, гл. 2): в 2002 году клинические испытания гормонального препарата Премарин, облегчающего симптомы менопаузы, были досрочно прерваны. Было обнаружено, что его приём ведёт к значимому увеличению риска развития рака груди на 0.08%, риска инсульта на 0.08% и инфаркта на 0.07%. Формально эффект крайне мал, но с учётом численности населения он превращается в тысячи дополнительных смертей.
- (Kirk, 1996): если при испытании гипотетического лекарства, позволяющего замедлить прогресс ослабления интеллекта больных Альцгеймером, оказывается, что разница в IQ контрольной и тестовой групп составляет 13 пунктов, возможно, изучение лекарства стоит продолжить, даже если эта разница статистически незначима.

## Другие особенности

- Выбранная статистика может отражать не всю информацию, содержащуюся в выборке. Пример:

$$H_0: X \sim N(\mu, \sigma^2), \quad H_1: H_0 \text{ неверна};$$

$$T(X^n) = g_1.$$

Все симметричные распределения будут признаны нормальными!

- Гипотезы вида  $H_0: \theta = \theta_0$  можно проверять при помощи доверительных интервалов для  $\theta$ :
  - если  $\theta_0$  не попадает в  $100(1 - \alpha)\%$  доверительный интервал для  $\theta$ , то  $H_0$  отвергается на уровне значимости  $\alpha$ ;
  - p-value — максимальное  $\alpha$ , при котором  $\theta_0$  попадает в соответствующий доверительный интервал.

# Shaken, not stirred

Джеймс Бонд говорит, что предпочитает мартини взболтанным, но не смешанным. Проведём слепой тест:  $n$  раз предложим ему пару напитков и выясним, какой из двух он предпочитает.

Выборка: бинарный вектор длины  $n$ , 1 — Джеймс Бонд предпочёт взболтанный, 0 — смешанный.


Нулевая гипотеза: Джеймс Бонд не различает два вида мартини, т. е., выбирает наугад.

Статистика  $T$  — число единиц в выборке.

# Нулевое распределение

Если нулевая гипотеза справедлива и Джеймс Бонд не различает два вида мартини, то равновероятны все выборки длины  $n$  из нулей и единиц.

Пусть  $n = 16$ , тогда существует  $2^{16} = 65536$  равновероятных вариантов. Статистика  $T$  принимает значения от 0 до 16:




## Односторонняя альтернатива

$H_1$ : Джеймс Бонд предпочитает взболтанный мартини.

При справедливости такой альтернативы более вероятны большие значения  $T$  (т.е., большие  $T$  свидетельствуют против  $H_0$  в пользу  $H_1$ ).

Вероятность того, что Джеймс Бонд предпочтёт взболтанный мартини в 12 или более случаях из 16 при справедливости  $H_0$ , равна  $\frac{2517}{65536} \approx 0.0384$ .




0.0384 — достигаемый уровень значимости при реализации  $t = 12$ .

## Двусторонняя альтернатива

$H_1$ : Джеймс Бонд предпочитает какой-то определённый вид мартини. При справедливости такой альтернативы и большие, и маленькие значения  $T$  свидетельствуют против  $H_0$  в пользу  $H_1$ ).

Вероятность того, что Джеймс Бонд предпочтёт взболтанный мартини в  $\geq 12$  случаях из 16 при справедливости  $H_0$ , равна  $\frac{5034}{65536} \approx 0.0768$ .



0.0768 — достигаемый уровень значимости при реализации  $t = 12$ .

## Достижимый уровень значимости

Чем ниже достижимый уровень значимости, тем сильнее данные свидетельствуют против нулевой гипотезы в пользу альтернативы.

0.0384 — вероятность реализации  $t \geq 12$  при условии, что нулевая гипотеза справедлива, т. е. Джеймс Бонд выбирает мартини наугад.


Ещё раз: это не вероятность справедливости нулевой гипотезы!

**Пример:** пусть Джеймс Бонд выбирает взболтанный мартини в 51% случаев (ненаблюдаемая вероятность).


Пусть по итогам 100 испытаний взболтанный мартини был выбран 49 раз. Достижимый уровень значимости против односторонней альтернативы —  $p \approx 0.6178$ . Нулевая гипотеза не отвергается, при этом сказать, что она верна, было бы ошибкой — Джеймс Бонд выбирает смешанный и взболтанный мартини не с одинаковыми вероятностями!

# Мощность

Проверяя нулевую гипотезу против двусторонней альтернативы, мы отвергаем  $H_0$  при  $t \geq 13$  или  $t \leq 3$ , что обеспечивает достигаемый уровень значимости  $p = 0.0213 \leq \alpha = 0.05$ .



Пусть Джеймс Бонд выбирает взболтанный мартини в 75% случаев.




$\text{pow} \approx 0.6202$ , т. е., при многократном повторении эксперимента гипотеза будет отклонена только в 62% случаев.

# Мощность

Мощность критерия зависит от следующих факторов:

- размер выборки
- размер отклонения от нулевой гипотезы
- чувствительность статистики критерия
- тип альтернативы

## Мощность



## Размер выборки

Особенности прикладной задачи: 1 порция мартини содержит 55 мл джина и 15 мл вермута — суммарно около 25 мл спирта. Смертельная доза алкоголя при массе тела 80 кг составляет от 320 до 960 мл спирта в зависимости от толерантности (от 13 до 38 мартини).

Обеспечение требуемой мощности: размеры выборки подбирается так, чтобы при размере отклонения от нулевой гипотезы не меньше заданного (например, вероятность выбора взболтанного мартини не меньше 0.75) мощность была не меньше заданной.

# Литература

Справочники по статистике:

- Кобзарь А.И. *Прикладная математическая статистика*, 2006.
- Kanji G.K. *100 statistical tests*, 2006.

Вводные учебники по статистике:

- Good P.I., Hardin J.W. *Common Errors in Statistics (and How to Avoid Them)*, 2003.
- Reinhart A. *Statistics Done Wrong. The woefully complete guide*,  
<http://www.statisticsonewrong.com/>

R:

- видео с Тревором Хастии: [http://youtu.be/jwBgGS\\_4RQA](http://youtu.be/jwBgGS_4RQA)
- краткий справочник функций:  
<http://cran.r-project.org/doc/contrib/Short-refcard.pdf>
- выучить R в R: <http://swirlstats.com>
- курс по R: <https://www.coursera.org/course/rprog>

# Литература

## Правдоподобие:

- Chihara L., Hesterberg T. *Mathematical Statistics with Resampling and R*, 2011, глава 6.
- Pawitan, Y. *In all likelihood: statistical modelling and inference using likelihood*, 2001.

## Бутстреп:

- Hesterberg T., Monaghan S., Moore D.S., Clipson A., Epstein R. *Bootstrap methods and permutation tests*. In Introduction to the Practice of Statistics, 2005. <http://statweb.stanford.edu/~tibs/stat315a/Supplements/bootstrap.pdf>
- Efron B., Tibshirani R. *An Introduction to the Bootstrap*, 1993.

## Проверка гипотез:

- Good P.I., Hardin J.W. *Common Errors in Statistics (and How to Avoid Them)*, 2003, глава 2.

Anscombe F.J. (1973). *Graphs in Statistical Analysis*. American Statistician, 27(1): 17–21.

Begg I.M., Anas A., Farinacci S. (1992). *Dissociation of processes in belief: Source recollection, statement familiarity, and the illusion of truth*. Journal of Experimental Psychology: General, 121(4), 446–458.

Ellis P.D. *The Essential Guide to Effect Sizes: Statistical Power, Meta-Analysis, and the Interpretation of Research Results*, 2010.

Huff D. *How To Lie With Statistics*, 1954.

Kirk R.E. (1996). *Practical Significance: A Concept Whose Time Has Come*. Educational and Psychological Measurement, 56(5), 746–759.

Lee I.-M., Djoussè L., Sesso H.D., Wang L., Buring J.E. (2010). *Physical Activity and Weight Gain Prevention*. JAMA: the Journal of the American Medical Association, 303(12), 1173–1179.

Marriott, F. H. C. *The Interpretation of Multiple Observations*, 1974.