

# Бутстреп

Браженко Дмитрий

December 19, 2017

# План

- 1 **Непараметрический бутстреп**
- 2 **Оценка доверительных интервалов на основе бутстрепа**
  - Нормальный интервал
  - Центральный интервал
  - Метод складного ножа

# Стандартная постановка задачи

## Идея

- Есть некоторая выборка  $\{X_i\}_{i=1}^n \in R$ , порожденная некоторым распределением.
- Имеется некоторая статистика  $T_n = T_n(X_1, X_2, \dots, X_n)$
- Цель – определить дисперсию  $V_F(T_n)$

## Тогда

- $T_n = \overline{X}_n$
- $V_F(T_n) = \frac{\sigma^2}{n}$
- $\sigma^2 = \int (x - \mu)^2 dF(x)$ , а  $\mu = \int x dF(x)$

# Идея бутстрепа

To pull oneself over a fence by one's bootstraps

**Как на самом деле**

$$F \rightarrow X_1, \dots, X_n \rightarrow T_n = g(X_1, X_2, \dots, X_n)$$

**С точки зрения бутстрепа**

$$\hat{F}_n \rightarrow X_1^*, \dots, X_n^* \rightarrow T_n^* = g(X_1^*, X_2^*, \dots, X_n^*)$$

**Как получить  $X_1^*, \dots, X_n^*$**

Из имеющейся выборки выбрать сделать новую выборку такой же длины, при этом каждый раз элемент каждый раз попадает в новую выборку равно вероятно

## Пример про МНК-оценку

- Имеется два наблюдения:  $(x_1, y_1) = (1, 1)$ ,  $(x_2, y_2) = (2, 3)$
- Требуется оценить МНК-модель  $y_i = \theta x_i + \epsilon_i$
- МНК-оценка:  $\hat{\theta} = 1.2$
- 

$$(x_1, y_1), (x_2, y_2) = \begin{cases} (1, 1), (1, 1) & p = 1/4 \\ (1, 1), (2, 3) & p = 1/4 \\ (2, 3), (1, 1) & p = 1/4 \\ (2, 3), (2, 3) & p = 1/4 \end{cases}$$

- Получаются МНК-оценки

$$\hat{\theta}^* = \begin{cases} 1 & p = 1/4 \\ 1.2 & p = 1/2 \\ 1.5 & p = 1/4 \end{cases}$$

# Алгоритм

- 1 Выбираем  $X_1^*, \dots, X_n^* \sim \hat{F}_n$
- 2 Вычисляем  $T_n^* = g(X_1^*, \dots, X_n^*)$
- 3 Повторяем шаги 1-2, пока не получится  $T_{n,1}^*, \dots, T_{n,B}^*$
- 4 Получаем  $v_{boot} \approx \frac{1}{B} \sum_{b=1}^B (T_{n,b}^* - \frac{1}{B} \sum_{r=1}^B T_{n,r}^*)^2$

# Нормальный интервал

Если можно предположить, что данные распределены нормально, то можно воспользоваться нормальным доверительным интервалом.

$$(T_n - z_{\alpha/2}\hat{s}e, T_n + z_{\alpha/2}\hat{s}e)$$

- $z_{\alpha} : F_{N(0,1)}(z_{\alpha})=1-\alpha$
- $\hat{s}e = \sqrt{v_{boot}}$

# Оценка параметра в распределении

- $X_1, \dots, X_n \sim t_3, n = 25$
- $\Theta = T(F) = \frac{q_{0.75} - q_{0.25}}{1.34}$
- Доверительный интервал (0.71, 1.78)
- Реальное значение 1.14



# Исследование влияния реагентов на осадки, 1975

Требуется оценить влияния распыления реагентов на вероятность дождя.

- Имеется 26 облаков, на каждое распылили реагент. Также контрольная выборка из 26 других облаков.
- После распыления измерили "объем выпавшего дождя" (acre-foot)
- Как оценить влияние реагента?
- $\theta$  – разность в средних значения выпадения осадков.
- $\hat{\theta} = 277.9$
- $\theta \in (10.6, 545.2)$
- Величина эффекта не так очевидна.

# Центральный интервал

- $\Theta = T(F)$ ,  $\hat{\Theta}_n = T(\hat{F}_n)$ , а  $R_n = \Theta_n - \Theta$
- $H(r) = P_F\{R_n < r\}$
- $C_n^* = (a, b)$ ,  $a = \hat{\Theta}_n - H^{-1}(1 - \alpha/2)$ ,  $b = \hat{\Theta}_n - H^{-1}(\alpha/2)$
- $P(a < \Theta < b) = P(a - \Theta_n < \Theta - \Theta_n < b - \Theta_n) =$   
 $= P(\Theta_n - b < \Theta_n - \Theta < \Theta_n - a) = P(\Theta_n - b < R_n < \Theta_n - a) =$   
 $= H(H^{-1}(1 - \alpha/2)) - H(H^{-1}(\alpha/2)) = 1 - \alpha$

# Центральный интервал


Требуется оценить функцию распределения

$$\hat{H}(r) = \frac{1}{B} \sum_{b=1}^B I(\hat{\Theta}_{n,b}^* - \hat{\Theta}_n < r)$$

Далее берется нижняя граница и верхняя граница, получается доверительный интервал.

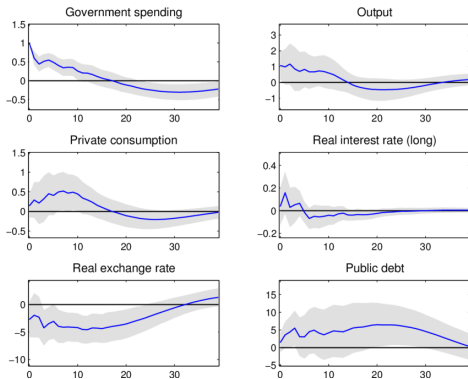
# Пример про землетрясения у острова Фиджи

Требуется оценить функцию распределения магнитуды землетрясений.



# Оценка отклика в VAR-моделях

$$\begin{bmatrix} x_t \\ y_t \end{bmatrix} = \begin{bmatrix} \alpha_0 \\ \beta_0 \end{bmatrix} + \begin{bmatrix} \alpha_{11}^1 & \alpha_{12}^1 \\ \alpha_{21}^1 & \alpha_{22}^1 \end{bmatrix} \begin{bmatrix} x_{t-1} \\ y_{t-1} \end{bmatrix} + \dots + \begin{bmatrix} \alpha_{11}^p & \alpha_{12}^p \\ \alpha_{21}^p & \alpha_{22}^p \end{bmatrix} \begin{bmatrix} x_{t-p} \\ y_{t-p} \end{bmatrix} + \begin{bmatrix} \epsilon_{x,p} \\ \epsilon_{y,p} \end{bmatrix}$$



# Метод складного ножа

- $T_n = (X_1, \dots, X_n)$ . Рассматривается  $n$  подвыборок:
- $T_{-1} = \frac{1}{n-1} \sum_{j \neq i} X_j$
- $\bar{T}_n = \frac{\sum_{i=1}^n T_{-1}}{n}$
- $v_{jack} = \frac{n-1}{n} \sum_{i=1}^n (T_{-i} - \bar{T}_n)^2$
- $se_{jack} = \sqrt{v_{jack}}$
- $\frac{v_{jack}(T)}{v(T)} \xrightarrow{P} 1$