

# Эконометрика 1

## осень 2016

Лекция 2  
14.09.2016

# Пример: данные по результатам тестов в Калифорнии (продолжение)

$$\beta_{ClassSize} = \frac{\text{изменение } TestScore}{\text{изменение } ClassSize} = \frac{\Delta TestScore}{\Delta ClassSize} = \frac{\Delta Y}{\Delta X} \quad (1)$$

ИЛИ

$$\Delta TestScore = \beta_{ClassSize} \Delta ClassSize \quad (2)$$

# Пример: данные по результатам тестов в Калифорнии (продолжение)

Уравнение (1) – определение коэффициента наклона прямой, которая может быть записана

$$TestScore = \beta_0 + \beta_{ClassSize} \times ClassSize \quad (3)$$

$\beta_0$  – константа, свободный член

$\beta_{ClassSize}$  – коэффициент наклона

Но!

$$TestScore = \beta_0 + \beta_{ClassSize} \times ClassSize + \text{другие факторы} \quad (4)$$

# Формальная модель (1)

---

Пусть

$Y_i$  – среднее значение за тест в  $i$ -м школьном округе

$X_i$  – среднее значение размера класса в  $i$ -м школьном округе

$u_i$  – прочие факторы, влияющие на результаты обучения в  $i$ -м школьном округе

$$Y_i = \beta_0 + \beta_1 X_i + u_i \quad (5)$$

# Формальная модель (2)

Уравнение (5) – модель парной линейной регрессии или линейная модель наблюдений или линейная эконометрическая модель или линейная регрессионная модель

$i$  – номер наблюдения ( $i = 1, \dots, n$ )

$Y_i$  – зависимая переменная

$X_i$  – независимая переменная или регрессор

$u_i$  – случайная ошибка регрессии или ошибка  $i$  – го наблюдения

$Y = \beta_0 + \beta_1 X$  – линия (функция) теоретической регрессии (регрессии генеральной совокупности) или линейная модель связи

$\beta_0$  - свободный член (константа) линии теоретической регрессии

$\beta_1$  - коэффициент наклона линии теоретической регрессии

# Пример: гипотетические данные по результатам тестов в Калифорнии




Рисунок 4.1. Диаграмма рассеяния результатов тестов относительно числа учеников в классе (гипотетические данные)

# Оценка коэффициентов в модели парной линейной регрессии

---

Как оценить

$\beta_{classSize}$

или

$\beta_1$

в более общей постановке?

# Что такое оценка?

---

**Оценка (an estimator)** – функция от результатов наблюдения (выборки), выбранных случайным образом из генеральной совокупности.

**Оценка (an estimate)** – численное значение оценки, полученной по данным из конкретной случайной выборки.



# Какие бывают оценки: примеры

Пусть  $\mu_Y$  - математическое ожидание  $Y$  в генеральной совокупности (обозначаем  $E(Y)$ ).

Пусть  $Y_1, Y_2, \dots, Y_n$  - выборка  $n$  независимых одинаково распределенных случайных величин (i.i.d) из рассматриваемой генеральной совокупности. Как мы можем оценить  $\mu_Y$ ?

Оценка 1:  $\hat{\mu}_Y = \bar{Y} = \frac{1}{n} \sum_{i=1}^n Y_i$

Оценка 2:  $\tilde{\mu}_Y = Y_1$

Оценка 3:  $\bar{\bar{\mu}}_Y = \frac{1}{n} \left( \frac{1}{2} Y_1 + \frac{3}{2} Y_2 + \frac{1}{2} Y_3 + \frac{3}{2} Y_4 + \dots + \frac{1}{2} Y_{n-1} + \frac{3}{2} Y_n \right)$ ,

при четном  $n$  (для удобства)

# Свойства оценок

## Смещенность (несмещенность)

$\hat{\mu}_Y$  - несмещенная оценка  $\mu_Y$ , если  $E(\hat{\mu}_Y) = \mu_Y$

Смещением  $\hat{\mu}_Y$  называется величина  $E(\hat{\mu}_Y) - \mu_Y$

## Состоятельность

$\hat{\mu}_Y$  - состоятельная оценка  $\mu_Y$ , если  $\hat{\mu}_Y \xrightarrow{p} \mu_Y$

## Эффективность

$\hat{\mu}_Y$  и  $\tilde{\mu}_Y$  - несмещенные оценки  $\mu_Y$ . Тогда  $\hat{\mu}_Y$   
(более) эффективная чем  $\tilde{\mu}_Y$ , если

$$\text{var}(\hat{\mu}_Y) < \text{var}(\tilde{\mu}_Y)$$

# МНК оценка

---

$$\min_m \sum_{i=1}^n (Y_i - m)^2$$

Пример: выборочное среднее – МНК оценка математического ожидания

# МНК оценка коэффициентов парной линейной регрессии

$$Y_i = \beta_0 + \beta_1 X_i + u_i \quad (5)$$

$$\min_{b_0, b_1} \sum_{i=1}^n (Y_i - b_0 - b_1 X_i)^2 \quad (6)$$
$$\rightarrow \hat{\beta}_0, \hat{\beta}_1$$

$\hat{\beta}_0, \hat{\beta}_1$  - МНК оценки коэффициентов  $\beta_0$  и  $\beta_1$

$Y_i = \hat{\beta}_0 + \hat{\beta}_1 X_i + u_i$  - МНК оценка линии регрессии, (линия выборочной регрессии или функция выборочной регрессии);

$\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 X_i$  - предсказанное значение  $Y_i$ ;

$\hat{u}_i = Y_i - \hat{Y}_i$  - остаток МНК регрессии

# МНК оценка коэффициентов парной линейной регрессии

$$\hat{\beta}_1 = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sum_{i=1}^n (X_i - \bar{X})^2}$$

$$\hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{X}$$

# Предположения МНК


---

*Предположение №1: условное распределение  $u_i$  относительно  $X_i$  имеет нулевое среднее:  $E(u_i|X_i) = 0$*

*Предположение №2:  $(X_i, Y_i)$ ,  $i = 1, \dots, n$ , независимы и одинаково распределены (i.i.d.)*

*Предположение №3: большие выбросы маловероятны:  $X_i$  и  $Y_i$  имеют ненулевые конечные четвертые моменты*

# Предположение №1: $E(u_i | X_i) = 0$



Предположение №2:  $(X_i, Y_i), i = 1, \dots, n$ , - (i.i.d.)

---

Это утверждение о способе формирования выборки –  
простым случайным образом из одной генеральной  
совокупности



# Предположение №3: большие выбросы маловероятны




Рисунок 4.5. Чувствительность МНК к большим выбросам

# Зачем нужны эти предположения?

---

- Математическая роль: при их выполнении МНК оценка имеет некоторые хорошие свойства
- Позволяют понять проблемы, возникающие при оценке МНК регрессии, если они нарушаются

# Свойства МНК оценок

Если выполняются предположения 1-3 метода наименьших квадратов, то в больших выборках

1.  $\hat{\beta}_0$  и  $\hat{\beta}_1$  имеют совместное нормальное распределение;

2.  $\hat{\beta}_1 \sim N(\beta_1, \sigma_{\beta_1}^2)$  (асимптотически), где

$$\sigma_{\beta_1}^2 = \frac{1}{n} \frac{\text{var}[(X_i - \mu_X)u_i]}{[\text{var}(X_i)]^2}$$

3.  $\hat{\beta}_0 \sim N(\beta_0, \sigma_{\beta_0}^2)$  (асимптотически), где

$$\sigma_{\beta_0}^2 = \frac{1}{n} \frac{\text{var}[H_i u_i]}{[E(H_i^2)]^2}, \text{ где } H_i = 1 - \left[ \frac{\mu_X}{E(X_i^2)} \right] X_i$$

# Свойства МНК оценок

- $\hat{\beta}_0$  и  $\hat{\beta}_1$  - несмещенные оценки;
- $\frac{1}{n} \sum_{i=1}^n \hat{u}_i = 0$ ;
- $\frac{1}{n} \sum_{i=1}^n \hat{Y}_i = \bar{Y}$ ;
- $\sum_{i=1}^n \hat{u}_i X_i = 0$