

# **Пропущенные и излишние регressоры**

**лекция 15**

## КОРОТКАЯ ИЛИ ДЛИННАЯ РЕГРЕССИЯ

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + Z\gamma + \boldsymbol{\varepsilon}; \quad \mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}$$

$$R_{UR,adj}^2 = 1 - \frac{RSS_{UR}}{TSS} \frac{n-1}{n-k-1}; \quad R_{R,adj}^2 = 1 - \frac{RSS_R}{TSS} \frac{n-1}{n-k}$$

$$R_{R,adj}^2 - R_{UR,adj}^2 = \frac{RSS_{UR}/(n-k-1) - RSS_R/(n-k)}{TSS/(n-1)}$$

## КОРОТКАЯ ИЛИ ДЛИННАЯ РЕГРЕССИЯ

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + Z\gamma + \boldsymbol{\varepsilon}; \quad \mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}$$

$$R_{R,adj}^2 - R_{UR,adj}^2 = \frac{RSS_{UR}/(n-k-1) - RSS_R/(n-k)}{TSS/(n-1)}$$

$$F = \frac{(RSS_R - RSS_{UR})/1}{RSS_{UR}/(n-k-1)} \sim F(1; n-k-1) = t_{n-k-1}^2 \Rightarrow$$

$$\Rightarrow \frac{1-t_Z^2}{n-k} \frac{RSS_{UR}/(n-k-1)}{TSS/(n-1)} = R_{R,adj}^2 - R_{UR,adj}^2$$

$$R_{R,adj}^2 < R_{UR,adj}^2 \Leftrightarrow |t_Z| > 1$$

$\Rightarrow$  регрессор  $Z$  существенен,

т.к. без него оценки станут "хуже":  $R_{adj}^2$  уменьшится

## F TESTS OF GOODNESS OF FIT

```
. reg S ASVABC SM SF
```

Source	SS	df	MS	Number of obs	=	570
Model	1278.24153	3	426.080508	F( 3, 566)	=	110.83
Residual	2176.00584	566	3.84453329	Prob > F	=	0.0000
Total	3454.24737	569	6.07073351	R-squared	=	0.3700
				Adj R-squared	=	0.3667
				Root MSE	=	1.9607

S	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
ASVABC	.1295006	.0099544	13.009	0.000	.1099486 .1490527
SM	.069403	.0422974	1.641	0.101	-.013676 .152482
SF	.1102684	.0311948	3.535	0.000	.0489967 .1715401
_cons	4.914654	.5063527	9.706	0.000	3.920094 5.909214

Регрессор SM исключать не следует

## Выбор переменных множественной регрессии

### Оценка значимости включаемой переменной

Значимость включаемой переменной измеряется  $t$ -статистикой соответствующего коэффициента

Эквивалентный метод - использование  $F$ -критерия

$$F = \frac{\text{Улучшение качества уравнения}}{\text{Необъясненная сумма квадратов отклонений / оставшееся число степеней свободы}}$$

$$F = \frac{(RSS_k - RSS_{k+1})/1}{RSS_{k+1}/(n - (k + 1) - 1)} = \frac{(RSS_k - RSS_{k+1})/1}{RSS_{k+1}/(n - k - 2)}$$

Эквивалентность предполагает двухстороннюю альтернативу для  $t$ -критерия

## Выбор переменных множественной регрессии

### Четыре критерия для включения переменной

1. Роль переменной в уравнении опирается на прочные теоретические основания
2. Высокие значения  $t$ -статистики
3. Исправленный коэффициент детерминации растет при включении переменной
4. Другие коэффициенты испытывают значительное смещение при включении новой переменной

## Выбор переменных множественной регрессии

### Последствия невключения в уравнение существенной переменной

Для краткости будем называть переменную существенной, если она должна быть включена в уравнение (согласно правильной теории)

Будем говорить также об исключении переменной из правильно специфицированного уравнения регрессии

## Выбор переменных множественной регрессии

### Последствия невключения в уравнение существенной переменной

1. Уменьшается возможность правильной оценки и интерпретации уравнения
2. Коэффициенты при оставшихся переменных могут оказаться смещенными
3. Их стандартные ошибки,  $t$ -статистики и другие показатели качества становятся некорректными и не могут быть использованы для суждения о качестве уравнения

Отсутствие существенной переменной

**Механизм разрушения оценок**

$$Y_i = \alpha + \beta_1 X_{1i} + \beta_2 X_{2i} + u_i$$

Если вторая объясняющая переменная отсутствует, то

$$Y_i = \alpha + \beta_1 X_{1i} + u_i^*$$

где

$$u_i^* = f(\beta_2 X_{2i} + \varepsilon)$$

Если объясняющие переменные коррелированы, то  
нарушается условие некоррелированности случайного  
члена и объясняющих переменных

## ПРОПУСК СУЩЕСТВЕННЫХ ПЕРЕМЕННЫХ

GeneratedDataProcess  $\mathbf{y} = \mathbf{X}\beta + \mathbf{Z}\gamma + \varepsilon; \quad \mathbf{X} = (\mathbf{X}_1, \dots, \mathbf{X}_k); \quad \mathbf{Z} = (\mathbf{Z}_{k+1}, \dots, \mathbf{Z}_{k+l})$

$$\hat{\delta}^* = \begin{bmatrix} \hat{\beta}^* \\ \hat{\gamma}^* \end{bmatrix} = \left[ (\mathbf{X}\mathbf{Z})' (\mathbf{X}\mathbf{Z}) \right]^{-1} (\mathbf{X}\mathbf{Z})' \mathbf{y} = \begin{bmatrix} \mathbf{X}'\mathbf{X} & \mathbf{X}'\mathbf{Z} \\ \mathbf{Z}'\mathbf{X} & \mathbf{Z}'\mathbf{Z} \end{bmatrix}^{-1} \begin{bmatrix} \mathbf{X}' \\ \mathbf{Z}' \end{bmatrix} \mathbf{y}$$

$$\mathbf{y} = \mathbf{X}\beta + \varepsilon; \quad \hat{\beta} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{y}$$

$$\mathbf{E}(\beta + (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{Z}\gamma + (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\varepsilon) = \beta + \mathbf{Z}\gamma.$$

Оценка МНК смещенная (кроме случая  $\gamma = \mathbf{0}$  или  $\mathbf{X}'\mathbf{Z} = \mathbf{0}$ )

$$\mathbf{X}'\mathbf{Z} = \mathbf{0} \Rightarrow \begin{bmatrix} \hat{\beta}^* \\ \hat{\gamma}^* \end{bmatrix} = \begin{bmatrix} \mathbf{X}'\mathbf{X} & \mathbf{0} \\ \mathbf{0} & \mathbf{Z}'\mathbf{Z} \end{bmatrix}^{-1} \begin{bmatrix} \mathbf{X}' \\ \mathbf{Z}' \end{bmatrix} \mathbf{y} = \begin{bmatrix} (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{y} \\ (\mathbf{Z}'\mathbf{Z})^{-1} \mathbf{Z}'\mathbf{y} \end{bmatrix} = \begin{bmatrix} \hat{\beta} \\ \hat{\gamma} \end{bmatrix}$$

## ПРОПУСК СУЩЕСТВЕННЫХ ПЕРЕМЕННЫХ

GeneratedDataProcess  $\mathbf{y} = \mathbf{X}\beta + \mathbf{Z}\gamma + \boldsymbol{\varepsilon}; \quad \mathbf{X} = (\mathbf{X}_1, \dots, \mathbf{X}_k); \quad \mathbf{Z} = (\mathbf{Z}_{k+1}, \dots, \mathbf{Z}_{k+l})$

$$\mathbf{y} = \mathbf{X}\beta + \boldsymbol{\varepsilon}; \quad \hat{\beta} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{y}; \quad \mathbf{M} = \mathbf{I} - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'$$

$$\begin{aligned} RSS &= \mathbf{e}'\mathbf{e} = (\mathbf{My})'(\mathbf{My}) = \mathbf{y}'\mathbf{M}\mathbf{y} = (\mathbf{X}\beta + \mathbf{Z}\gamma + \boldsymbol{\varepsilon})' \mathbf{M}(\mathbf{X}\beta + \mathbf{Z}\gamma + \boldsymbol{\varepsilon}) = \\ &= \boldsymbol{\varepsilon}'\mathbf{M}\boldsymbol{\varepsilon} + 2\gamma'\mathbf{Z}'\mathbf{M}\boldsymbol{\varepsilon} + \gamma'\mathbf{Z}'\mathbf{M}\mathbf{Z}\gamma \end{aligned}$$

$$E\left(\frac{RSS}{n-k}\right) = E\left(\widehat{\sigma^2}\right) = \boxed{\text{[REDACTED]}} ,$$

т.к.  $\mathbf{Z}'\mathbf{M}\mathbf{Z}$  симметрична  $\Rightarrow$  положительно определена

$$(даже в случае \mathbf{X}'\mathbf{Z} = \mathbf{0} \Rightarrow \mathbf{M}\mathbf{Z} = \mathbf{Z} \Rightarrow E(\widehat{\sigma^2}) = \sigma^2 + \frac{1}{n-k} \gamma'\mathbf{Z}'\mathbf{Z}\gamma > \sigma^2)$$

$\widehat{\sigma^2}$  смещена  $\Rightarrow$  многие тесты некорректны

# ПРОПУСК СУЩЕСТВЕННЫХ ПЕРЕМЕННЫХ

GeneratedDataProcess  $\mathbf{y} = \mathbf{X}\beta + \mathbf{Z}\gamma + \boldsymbol{\varepsilon}; \quad \mathbf{X} = (\mathbf{X}_1, \dots, \mathbf{X}_k); \quad \mathbf{Z} = (\mathbf{Z}_{k+1}, \dots, \mathbf{Z}_{k+l})$

$$\hat{\delta}^* = \begin{bmatrix} \hat{\beta}^* \\ \hat{\gamma}^* \end{bmatrix} = \begin{bmatrix} \mathbf{X}'\mathbf{X} & \mathbf{X}'\mathbf{Z} \\ \mathbf{Z}'\mathbf{X} & \mathbf{Z}'\mathbf{Z} \end{bmatrix}^{-1} \begin{bmatrix} \mathbf{X} \\ \mathbf{Z} \end{bmatrix} \mathbf{y};$$

$$\text{Var} \hat{\delta}^* = \sigma^2 \left[ (\mathbf{X}\mathbf{Z})' (\mathbf{X}\mathbf{Z}) \right]^{-1} = \sigma^2 \begin{bmatrix} \mathbf{X}'\mathbf{X} & \mathbf{X}'\mathbf{Z} \\ \mathbf{Z}'\mathbf{X} & \mathbf{Z}'\mathbf{Z} \end{bmatrix}^{-1} = \sigma^2 \begin{bmatrix} \mathbf{Q}_{11} & \mathbf{Q}_{12} \\ \mathbf{Q}_{21} & \mathbf{Q}_{22} \end{bmatrix}$$

$$\text{Var} \hat{\beta}^* = \sigma^2 \mathbf{Q}_{11} = \sigma^2 \left( \mathbf{X}'\mathbf{X} - \mathbf{X}'\mathbf{Z}(\mathbf{Z}'\mathbf{Z})^{-1} \mathbf{Z}'\mathbf{X} \right)^{-1}$$

$$\mathbf{y} = \mathbf{X}\beta + \boldsymbol{\varepsilon}; \quad \hat{\beta} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{y}; \quad \text{Var} \hat{\beta} = \sigma^2 (\mathbf{X}'\mathbf{X})^{-1}$$

$$\text{Var}^{-1} \hat{\beta} - \text{Var}^{-1} \hat{\beta}^* = \frac{1}{\sigma^2} \mathbf{X}'\mathbf{Z}(\mathbf{Z}'\mathbf{Z})^{-1} \mathbf{Z}'\mathbf{X} \geq 0,$$

в смысле положительной определенности  $\Rightarrow \text{Var} \hat{\beta}^* \geq \text{Var} \hat{\beta}$

## ПРОПУСК СУЩЕСТВЕННЫХ ПЕРЕМЕННЫХ

GeneratedDataProcess  $\mathbf{y} = \alpha + \mathbf{x}\beta + \mathbf{z}\gamma + \boldsymbol{\varepsilon};$

$$\hat{\beta}^* = \frac{\text{Cov}(X, Y)\text{Var}(Z) - \text{Cov}(Z, Y)\text{Cov}(X, Z)}{\text{Var}(X)\text{Var}(Z) - [\text{Cov}(X, Z)]^2}$$

$$E(\hat{\beta}^*) = \beta; \quad \text{Var } \hat{\beta}^* = \frac{\sigma^2}{n\text{Var}(X)} \cdot \frac{1}{1 - r_{X,Z}^2}$$

$$\mathbf{y} = \alpha + \mathbf{x}\beta; \quad \hat{\beta} = \frac{\text{Cov}(X, Y)}{\text{Var}(X)};$$

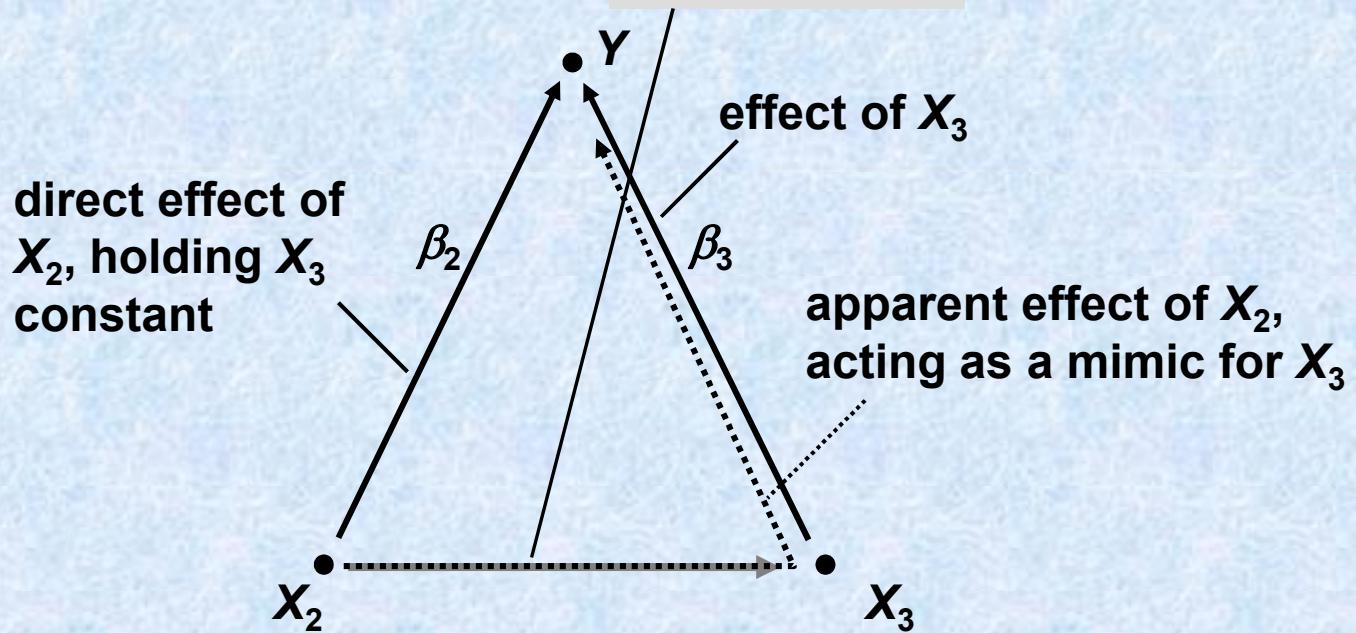
$$E(\hat{\beta}) = \beta + \gamma \frac{\text{Cov}(X, Z)}{\text{Var}(X)}; \quad \text{Var } \hat{\beta} = \frac{\sigma^2}{n\text{Var}(X)}$$

## ПРОПУСК СУЩЕСТВЕННЫХ ПЕРЕМЕННЫХ

$$Y = \beta_1 + \beta_2 X_2 + \beta_3 X_3 + u$$

$$\hat{Y} = b_1 + b_2 X_2$$

$$E(b_2) = \beta_2 + \beta_3 \frac{\text{Cov}(X_2, X_3)}{\text{Var}(X_2)}$$



The ability of  $X_2$  to mimic  $X_3$  is determined by the slope coefficient obtained when  $X_3$  is regressed on  $X_2$ , which of course is  $\text{Cov}(X_2, X_3)/\text{Var}(X_2)$ .

## ПРОПУСК СУЩЕСТВЕННЫХ ПЕРЕМЕННЫХ

$$Y = \beta_1 + \beta_2 X_2 + \beta_3 X_3 + u$$

$$\hat{Y} = b_1 + b_2 X_2$$

$$b_2 = \frac{\text{Cov}(X_2, Y)}{\text{Var}(X_2)} = \frac{\text{Cov}(X_2, [\beta_1 + \beta_2 X_2 + \beta_3 X_3 + u])}{\text{Var}(X_2)}$$

We will now derive the expression for the bias mathematically. Since we are mistakenly fitting a simple regression model, the slope coefficient is calculated as  $\text{Cov}(X_2, Y)/\text{Var}(X_2)$ . The first step is to substitute for  $Y$  from the true model..

## ПРОПУСК СУЩЕСТВЕННЫХ ПЕРЕМЕННЫХ

$$Y = \beta_1 + \beta_2 X_2 + \beta_3 X_3 + u$$

$$\hat{Y} = b_1 + b_2 X_2$$

$$\begin{aligned} b_2 &= \frac{\text{Cov}(X_2, Y)}{\text{Var}(X_2)} = \frac{\text{Cov}(X_2, [\beta_1 + \beta_2 X_2 + \beta_3 X_3 + u])}{\text{Var}(X_2)} \\ &= \frac{\text{Cov}(X_2, \beta_1) + \text{Cov}(X_2, \beta_2 X_2) + \text{Cov}(X_2, \beta_3 X_3) + \text{Cov}(X_2, u)}{\text{Var}(X_2)} \end{aligned}$$

We use Covariance Rule 1 to decompose the numerator.

## ПРОПУСК СУЩЕСТВЕННЫХ ПЕРЕМЕННЫХ

$$Y = \beta_1 + \beta_2 X_2 + \beta_3 X_3 + u$$

$$\hat{Y} = b_1 + b_2 X_2$$

$$\begin{aligned} b_2 &= \frac{\text{Cov}(X_2, Y)}{\text{Var}(X_2)} = \frac{\text{Cov}(X_2, [\beta_1 + \beta_2 X_2 + \beta_3 X_3 + u])}{\text{Var}(X_2)} \\ &= \frac{\text{Cov}(X_2, \beta_1) + \text{Cov}(X_2, \beta_2 X_2) + \text{Cov}(X_2, \beta_3 X_3) + \text{Cov}(X_2, u)}{\text{Var}(X_2)} \\ &= \frac{0 + \beta_2 \text{Cov}(X_2, X_2) + \beta_3 \text{Cov}(X_2, X_3) + \text{Cov}(X_2, u)}{\text{Var}(X_2)} \end{aligned}$$

The first term is 0 because  $\beta_1$  is a constant.  $\beta_2$  and  $\beta_3$  can be taken out of the second and third terms.

## ПРОПУСК СУЩЕСТВЕННЫХ ПЕРЕМЕННЫХ

$$Y = \beta_1 + \beta_2 X_2 + \beta_3 X_3 + u$$

$$\hat{Y} = b_1 + b_2 X_2$$

$$\begin{aligned} b_2 &= \frac{\text{Cov}(X_2, Y)}{\text{Var}(X_2)} = \frac{\text{Cov}(X_2, [\beta_1 + \beta_2 X_2 + \beta_3 X_3 + u])}{\text{Var}(X_2)} \\ &= \frac{\text{Cov}(X_2, \beta_1) + \text{Cov}(X_2, \beta_2 X_2) + \text{Cov}(X_2, \beta_3 X_3) + \text{Cov}(X_2, u)}{\text{Var}(X_2)} \\ &= \frac{0 + \beta_2 \text{Cov}(X_2, X_2) + \beta_3 \text{Cov}(X_2, X_3) + \text{Cov}(X_2, u)}{\text{Var}(X_2)} \\ &= \beta_2 + \beta_3 \frac{\text{Cov}(X_2, X_3)}{\text{Var}(X_2)} + \frac{\text{Cov}(X_2, u)}{\text{Var}(X_2)} \end{aligned}$$

Hence we have demonstrated that  $b_2$  has three components.

## Отсутствие существенной переменной Оценка смещения коэффициента

$$b_1 = \beta_1 + \beta_2 \frac{Cov(x_1, x_2)}{Var(x_1)} + \text{Ошибка выборки}$$

$$\text{Смещение} = \beta_2 \frac{Cov(x_1, x_2)}{Var(x_1)}$$

Направление смещения зависит от знака истинного значения коэффициента при отсутствующей переменной и выборочной ковариации переменных

## ПРОПУСК СУЩЕСТВЕННЫХ ПЕРЕМЕННЫХ

$$Y = \beta_1 + \beta_2 X_2 + \beta_3 X_3 + u$$

$$\hat{Y} = b_1 + b_2 X_2$$

$$b_2 = \frac{\text{Cov}(X_2, Y)}{\text{Var}(X_2)} = \beta_2 + \beta_3 \frac{\text{Cov}(X_2, X_3)}{\text{Var}(X_2)} + \frac{\text{Cov}(X_2, u)}{\text{Var}(X_2)}$$

$$E(b_2) = E\left\{ \beta_2 + \beta_3 \frac{\text{Cov}(X_2, X_3)}{\text{Var}(X_2)} + \frac{\text{Cov}(X_2, u)}{\text{Var}(X_2)} \right\}$$

## ПРОПУСК СУЩЕСТВЕННЫХ ПЕРЕМЕННЫХ

$$Y = \beta_1 + \beta_2 X_2 + \beta_3 X_3 + u$$

$$\hat{Y} = b_1 + b_2 X_2$$

$$b_2 = \frac{\text{Cov}(X_2, Y)}{\text{Var}(X_2)} = \beta_2 + \beta_3 \frac{\text{Cov}(X_2, X_3)}{\text{Var}(X_2)} + \frac{\text{Cov}(X_2, u)}{\text{Var}(X_2)}$$

$$\begin{aligned} E(b_2) &= E\left\{ \beta_2 + \beta_3 \frac{\text{Cov}(X_2, X_3)}{\text{Var}(X_2)} + \frac{\text{Cov}(X_2, u)}{\text{Var}(X_2)} \right\} \\ &= E(\beta_2) + E\left\{ \beta_3 \frac{\text{Cov}(X_2, X_3)}{\text{Var}(X_2)} \right\} + E\left\{ \frac{\text{Cov}(X_2, u)}{\text{Var}(X_2)} \right\} \end{aligned}$$



## ПРОПУСК СУЩЕСТВЕННЫХ ПЕРЕМЕННЫХ

$$Y = \beta_1 + \beta_2 X_2 + \beta_3 X_3 + u$$

$$\epsilon = b_1 + b_2 X_2$$

$$b_2 = \frac{\text{Cov}(X_2, Y)}{\text{Var}(X_2)} = \beta_2 + \beta_3 \frac{\text{Cov}(X_2, X_3)}{\text{Var}(X_2)} + \frac{\text{Cov}(X_2, u)}{\text{Var}(X_2)}$$

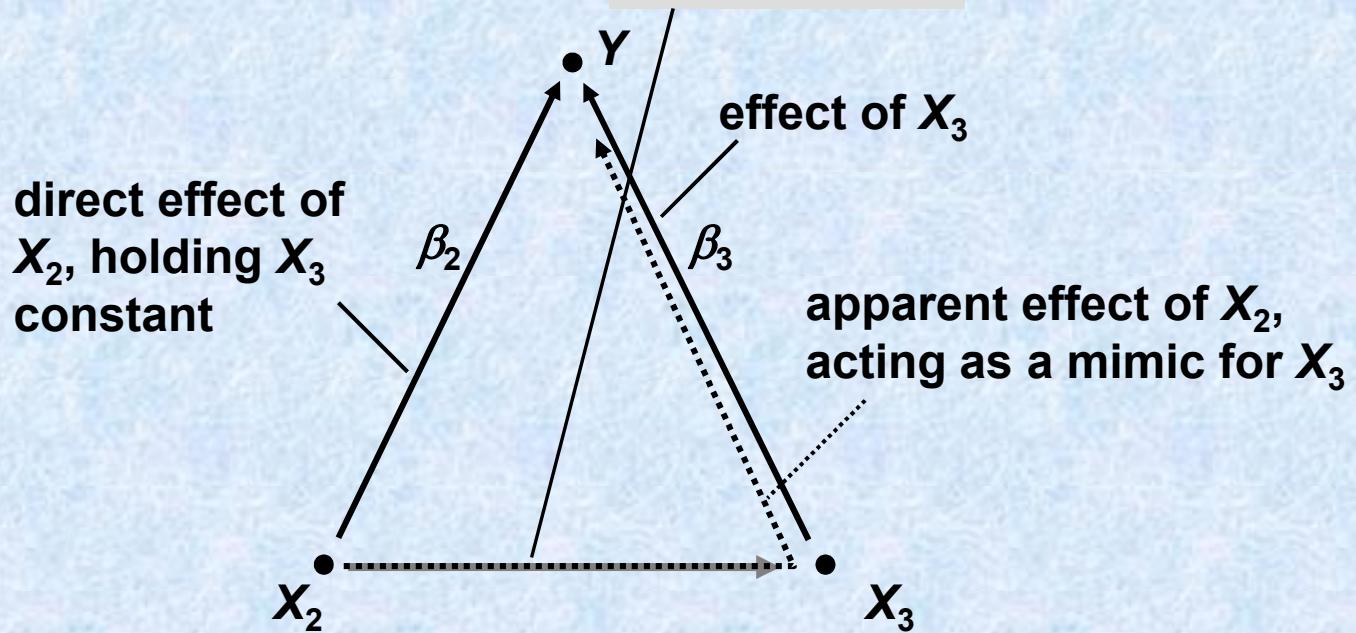
$$\begin{aligned} E(b_2) &= E\left\{ \beta_2 + \beta_3 \frac{\text{Cov}(X_2, X_3)}{\text{Var}(X_2)} + \frac{\text{Cov}(X_2, u)}{\text{Var}(X_2)} \right\} \\ &= E(\beta_2) + E\left\{ \beta_3 \frac{\text{Cov}(X_2, X_3)}{\text{Var}(X_2)} \right\} + E\left\{ \frac{\text{Cov}(X_2, u)}{\text{Var}(X_2)} \right\} \\ &= \beta_2 + \beta_3 \frac{\text{Cov}(X_2, X_3)}{\text{Var}(X_2)} \end{aligned}$$

## ПРОПУСК СУЩЕСТВЕННЫХ ПЕРЕМЕННЫХ

$$Y = \beta_1 + \beta_2 X_2 + \beta_3 X_3 + u$$

$$\hat{Y} = b_1 + b_2 X_2$$

$$E(b_2) = \beta_2 + \beta_3 \frac{\text{Cov}(X_2, X_3)}{\text{Var}(X_2)}$$



The ability of  $X_2$  to mimic  $X_3$  is determined by the slope coefficient obtained when  $X_3$  is regressed on  $X_2$ , which of course is  $\text{Cov}(X_2, X_3)/\text{Var}(X_2)$ .

## Выбор переменных множественной регрессии

### Последствия невключения в уравнение существенной переменной

1. Уменьшается возможность правильной оценки и интерпретации уравнения
2. Коэффициенты при оставшихся переменных могут оказаться смещенными
3. Их стандартные ошибки,  $t$ -статистики и другие показатели качества становятся некорректными и не могут быть использованы для суждения о качестве уравнения

# ПРОПУСК СУЩЕСТВЕННЫХ ПЕРЕМЕННЫХ

```
. reg S ASVABC SM
```

Source	SS	df	MS	Number of obs	=	570
Model	1230.2039	2	615.101949	F( 2, 567)	=	156.81
Residual	2224.04347	567	3.92247526	Prob > F	=	0.0000
Total	3454.24737	569	6.07073351	R-squared	=	0.3561
				Adj R-squared	=	0.3539
				Root MSE	=	1.9805

S	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
ASVABC	.1381062	.0097494	14.166	0.000	.1189567 .1572556
SM	.154783	.0350728	4.413	0.000	.0858946 .2236715
_cons	4.791277	.5102431	9.390	0.000	3.78908 5.793475

## ПРОПУСК СУЩЕСТВЕННЫХ ПЕРЕМЕННЫХ

```
. reg S ASVABC SM
```

Source	SS	df	MS	Number of obs	=	570
Model	1230.2039	2	615.101949	F( 2, 567)	=	156.81
Residual	2224.04347	567	3.92247526	Prob > F	=	0.0000
Total	3454.24737	569	6.07073351	R-squared	=	0.3561
				Adj R-squared	=	0.3539
				Root MSE	=	1.9805

S	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
ASVABC	.1381062	.0097494	14.166	0.000	.1189567 .1572556
SM	.154783	.0350728	4.413	0.000	.0858946 .2236715
_cons	4.791277	.5102431	9.390	0.000	3.78908 5.793475

$$S = \beta_1 + \beta_2 ASVABC + \beta_3 SM + u$$

$$E(b_2) = \beta_2 + \beta_3 \frac{\text{Cov}(ASVABC, SM)}{\text{Var}(ASVABC)}$$

## Отсутствие существенной переменной Направление смещения коэффициента

	$Cov(x_1, x_2)$	
	+	-
$\beta_2 +$	+	-
$\beta_2 -$	-	+

- Ковариация оценивается по выборке
- Знак коэффициента отсутствующей переменной предполагается из теории

## ПРОПУСК СУЩЕСТВЕННЫХ ПЕРЕМЕННЫХ

```
. reg S ASVABC SM
```

Source	SS	df	MS	Number of obs	=	570
Model	1230.2039	2	615.101949	F( 2, 567)	=	156.81
Residual	2224.04347	567	3.92247526	Prob > F	=	0.0000
Total	3454.24737	569	6.07073351	R-squared	=	0.3561
				Adj R-squared	=	0.3539
				Root MSE	=	1.9805

S	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
ASVABC	.1381062	.0097494	14.166	0.000	.1189567 .1572556
SM	.154783	.0350728	4.413	0.000	.0858946 .2236715
_cons	4.791277	.5102431	9.390	0.000	3.78908 5.793475

$$S = \beta_1 + \beta_2 ASVABC + \beta_3 SM + u$$

$$E(b_2) = \beta_2 + \beta_3 \frac{\text{Cov}(ASVABC, SM)}{\text{Var}(ASVABC)}$$

# ПРОПУСК СУЩЕСТВЕННЫХ ПЕРЕМЕННЫХ

```
. reg S ASVABC SM
```

Source	SS	df	MS
<hr/>			
Model	1230.2039	2	615.101949
Residual	2224.04347	567	3.92247526
<hr/>			
Total	3454.24737	569	6.07073351

```
. cor SM ASVABC  
(obs=570)
```

	SM	ASVABC
SM	1.0000	
ASVABC	0.3819	1.0000

S	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
ASVABC	.1381062	.0097494	14.166	0.000	.1189567 .1572556
SM	.154783	.0350728	4.413	0.000	.0858946 .2236715
_cons	4.791277	.5102431	9.390	0.000	3.78908 5.793475

$$S = \beta_1 + \beta_2 ASVABC + \beta_3 SM + u$$

$$E(b_2) = \beta_2 + \beta_3 \frac{\text{Cov}(ASVABC, SM)}{\text{Var}(ASVABC)}$$

## ПРОПУСК СУЩЕСТВЕННЫХ ПЕРЕМЕННЫХ

```
. reg S ASVABC
```

Source	SS	df	MS	Number of obs	=	570
Model	1153.80864	1	1153.80864	F( 1, 568)	=	284.89
Residual	2300.43873	568	4.05006818	Prob > F	=	0.0000
Total	3454.24737	569	6.07073351	R-squared	=	0.3340
				Adj R-squared	=	0.3329
				Root MSE	=	2.0125

S	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
ASVABC	.1545378	.0091559	16.879	0.000	.1365543 .1725213
_cons	5.770845	.4668473	12.361	0.000	4.853888 6.687803

## ПРОПУСК СУЩЕСТВЕННЫХ ПЕРЕМЕННЫХ

```
. reg S ASVABC SM
```

S	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
ASVABC	.1381062	.0097494	14.166	0.000	.1189567	.1572556
SM	.154783	.0350728	4.413	0.000	.0858946	.2236715
_cons	4.791277	.5102431	9.390	0.000	3.78908	5.793475

```
. reg S ASVABC
```

S	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
ASVABC	.1545378	.0091559	16.879	0.000	.1365543	.1725213
_cons	5.770845	.4668473	12.361	0.000	4.853888	6.687803

## ПРОПУСК СУЩЕСТВЕННЫХ ПЕРЕМЕННЫХ

```
. reg S SM
```

Source	SS	df	MS	Number of obs	=	570
Model	443.110436	1	443.110436	F( 1, 568)	=	83.59
Residual	3011.13693	568	5.30129742	Prob > F	=	0.0000
Total	3454.24737	569	6.07073351	R-squared	=	0.1283
				Adj R-squared	=	0.1267
				Root MSE	=	2.3025

S	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
SM	.3445198	.0376833	9.142	0.000	.2705041 .4185354
_cons	9.506491	.4495754	21.145	0.000	8.623458 10.38952

$$S = \beta_1 + \beta_2 ASVABC + \beta_3 SM + u$$

$$E(b_3) = \beta_3 + \beta_2 \frac{\text{Cov}(ASVABC, SM)}{\text{Var}(SM)}$$

## ПРОПУСК СУЩЕСТВЕННЫХ ПЕРЕМЕННЫХ

```
. reg S ASVABC SM
```

S	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
ASVABC	.1381062	.0097494	14.166	0.000	.1189567	.1572556
SM	.154783	.0350728	4.413	0.000	.0858946	.2236715
_cons	4.791277	.5102431	9.390	0.000	3.78908	5.793475

```
. reg S SM
```

S	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
SM	.3445198	.0376833	9.142	0.000	.2705041	.4185354
_cons	9.506491	.4495754	21.145	0.000	8.623458	10.38952

```
. corr ASVABC SM,cov  
(obs=570)
```

	ASVABC	SM
ASVABC	78.654	
SM	7.48179	6.52508

# ПРОПУСК СУЩЕСТВЕННЫХ ПЕРЕМЕННЫХ

```
. reg S ASVABC SM
```

Source	SS	df	MS
-----			
Model	1230.2039	2	615.101949
Residual	2224.04347	567	3.92247526
-----			
Total	3454.24737	569	6.07073351

Number of obs = 570  
F( 2, 567) = 156.81  
Prob > F = 0.0000  
**R-squared = 0.3561**  
Adj R-squared = 0.3539  
Root MSE = 1.9805

```
. reg S ASVABC
```

Source	SS	df	MS
-----			
Model	1153.80864	1	1153.80864
Residual	2300.43873	568	4.05006818
-----			
Total	3454.24737	569	6.07073351

Number of obs = 570  
F( 1, 568) = 284.89  
Prob > F = 0.0000  
**R-squared = 0.3340**  
Adj R-squared = 0.3329  
Root MSE = 2.0125

```
. reg S SM
```

Source	SS	df	MS
-----			
Model	443.110436	1	443.110436
Residual	3011.13693	568	5.30129742
-----			
Total	3454.24737	569	6.07073351

Number of obs = 570  
F( 1, 568) = 83.59  
Prob > F = 0.0000  
**R-squared = 0.1283**  
Adj R-squared = 0.1267  
Root MSE = 2.3025

Does this imply that ASVABC explains 33% of the variance in S and SM 13%? No, because the multiple regression reveals that their joint explanatory power is 0.36, not 0.46.

# ПРОПУСК СУЩЕСТВЕННЫХ ПЕРЕМЕННЫХ

```
. reg S ASVABC SM
```

Source	SS	df	MS
-----			
Model	1230.2039	2	615.101949
Residual	2224.04347	567	3.92247526
-----			
Total	3454.24737	569	6.07073351

Number of obs = 570  
F( 2, 567) = 156.81  
Prob > F = 0.0000  
**R-squared = 0.3561**  
Adj R-squared = 0.3539  
Root MSE = 1.9805

```
. reg S ASVABC
```

Source	SS	df	MS
-----			
Model	1153.80864	1	1153.80864
Residual	2300.43873	568	4.05006818
-----			
Total	3454.24737	569	6.07073351

Number of obs = 570  
F( 1, 568) = 284.89  
Prob > F = 0.0000  
**R-squared = 0.3340**  
Adj R-squared = 0.3329  
Root MSE = 2.0125

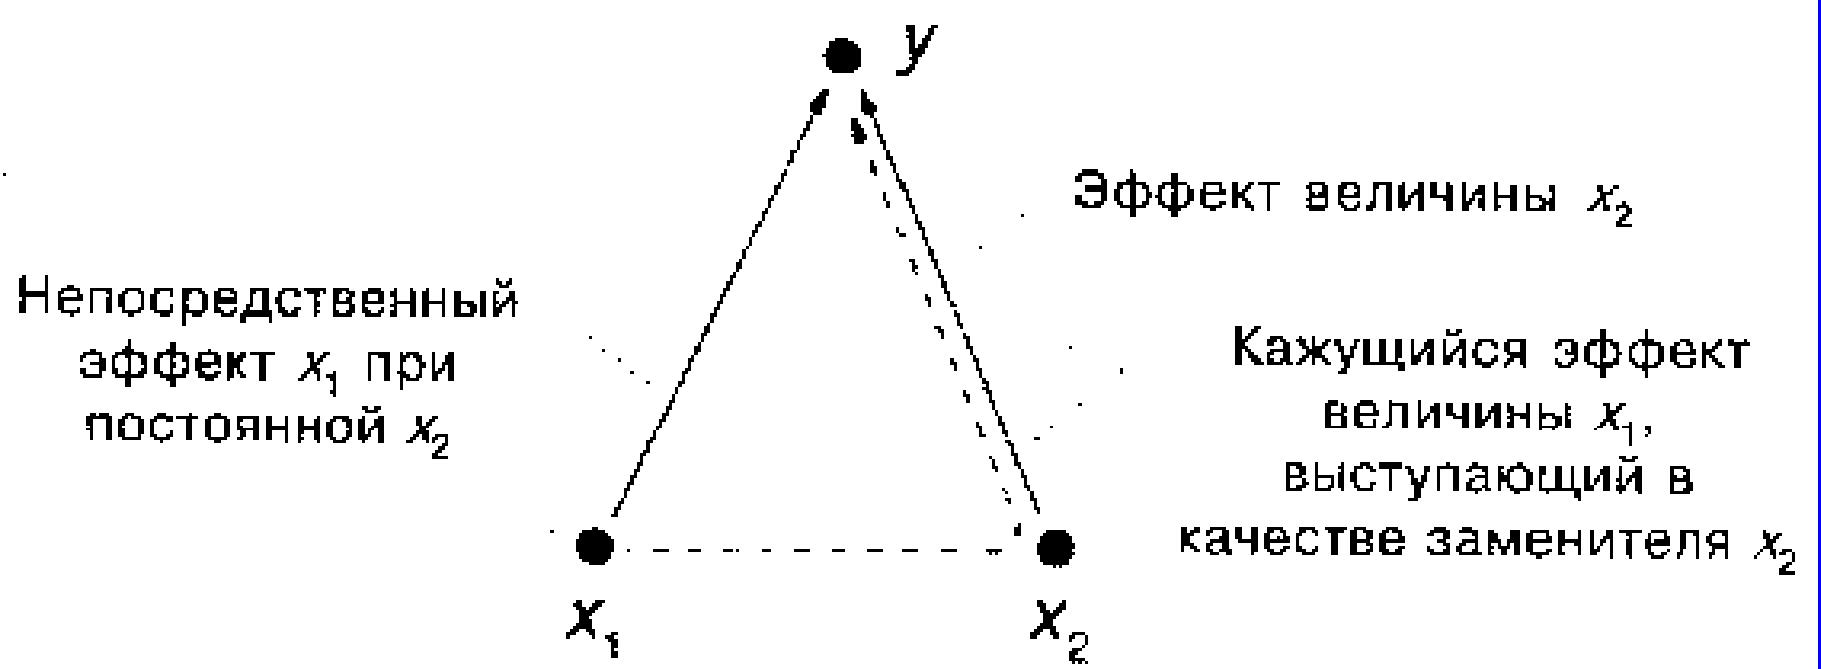
```
. reg S SM
```

Source	SS	df	MS
-----			
Model	443.110436	1	443.110436
Residual	3011.13693	568	5.30129742
-----			
Total	3454.24737	569	6.07073351

Number of obs = 570  
F( 1, 568) = 83.59  
Prob > F = 0.0000  
**R-squared = 0.1283**  
Adj R-squared = 0.1267  
Root MSE = 2.3025

In the second regression, ASVABC is partly acting as a proxy for SM, and this inflates its apparent explanatory power. Similarly, in the third regression, SM is partly acting as a proxy for ASVABC, again inflating its apparent explanatory power.

# Отсутствие существенной переменной Направление смещения коэффициента



Коэффициент детерминации может оставаться большим за счет кажущегося эффекта замещающей переменной

## ПРОПУСК СУЩЕСТВЕННЫХ ПЕРЕМЕННЫХ

```
. reg LGEARN S MALE
```

Source	SS	df	MS
<hr/>			
Model	28.951332	2	14.475666
Residual	124.850561	567	.220194992
<hr/>			
Total	153.801893	569	.270302096

```
. cor S MALE
```

(obs=570)

	S	MALE
S	1.0000	
MALE	-0.0581	1.0000

LGEARN	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
S	.0818944	.0079976	10.240	0.000	.0661858 .097603
MALE	.2285156	.0397695	5.746	0.000	.1504021 .3066291
_cons	1.19254	.1134845	10.508	0.000	.9696386 1.415441

$$LGEARN = \beta_1 + \beta_2 S + \beta_3 MALE + u$$

$$E(b_2) = \beta_2 + \beta_3 \frac{\text{Cov}(S, MALE)}{\text{Var}(S)}$$

If we omit *MALE* from the regression, the coefficient of *S* should be subject to a downward bias.  $\beta_3$  is likely to be positive, and we know that  $\text{Var}(S)$  is positive, but  $\text{Cov}(S, MALE)$  is negative because *S* and *MALE* are negatively correlated.

# ПРОПУСК СУЩЕСТВЕННЫХ ПЕРЕМЕННЫХ

```
. reg LGEARN S MALE
```

Source	SS	df	MS
<hr/>			
Model	28.951332	2	14.475666
Residual	124.850561	567	.220194992
<hr/>			
Total	153.801893	569	.270302096

```
. cor S MALE
```

(obs=570)

	S	MALE
S	1.0000	
MALE	-0.0581	1.0000

LGEARN	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
S	.0818944	.0079976	10.240	0.000	.0661858 .097603
MALE	.2285156	.0397695	5.746	0.000	.1504021 .3066291
_cons	1.19254	.1134845	10.508	0.000	.9696386 1.415441

$$LGEARN = \beta_1 + \beta_2 S + \beta_3 MALE + u$$

$$E(b_3) = \beta_3 + \beta_2 \frac{\text{Cov}(S, MALE)}{\text{Var}(MALE)}$$

# ПРОПУСК СУЩЕСТВЕННЫХ ПЕРЕМЕННЫХ

```
. reg LGEARN S MALE
```

LGEARN	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
S	.0818944	.0079976	10.240	0.000	.0661858 .097603
MALE	.2285156	.0397695	5.746	0.000	.1504021 .3066291
_cons	1.19254	.1134845	10.508	0.000	.9696386 1.415441

```
. reg LGEARN S
```

LGEARN	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
S	.0792256	.0082061	9.655	0.000	.0631077 .0953435
_cons	1.358919	.1127785	12.049	0.000	1.137406 1.580433

```
. reg LGEARN MALE
```

LGEARN	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
MALE	.2048652	.0431797	4.744	0.000	.1200538 .2896767
_cons	2.313324	.032605	70.950	0.000	2.249282 2.377365

# ПРОПУСК СУЩЕСТВЕННЫХ ПЕРЕМЕННЫХ

```
. reg LGEARN S MALE
```

Source	SS	df	MS
<hr/>			
Model	28.951332	2	14.475666
Residual	124.850561	567	.220194992
<hr/>			
Total	153.801893	569	.270302096

Number of obs = 570  
F( 2, 567) = 65.74  
Prob > F = 0.0000  
**R-squared = 0.1882**  
Adj R-squared = 0.1854  
Root MSE = .46925

```
. reg LGEARN S
```

Source	SS	df	MS
<hr/>			
Model	21.681253	1	21.681253
Residual	132.12064	568	.23260676
<hr/>			
Total	153.801893	569	.270302096

Number of obs = 570  
F( 1, 568) = 93.21  
Prob > F = 0.0000  
**R-squared = 0.1410**  
Adj R-squared = 0.1395  
Root MSE = .48229

```
. reg LGEARN MALE
```

Source	SS	df	MS
<hr/>			
Model	5.86288165	1	5.86288165
Residual	147.939011	568	.260456005
<hr/>			
Total	153.801893	569	.270302096

Number of obs = 570  
F( 1, 568) = 22.51  
Prob > F = 0.0000  
**R-squared = 0.0381**  
Adj R-squared = 0.0364  
Root MSE = .51035

A comparison of  $R^2$  for the three regressions shows that the sum of  $R^2$  in the simple regressions is actually less than  $R^2$  in the multiple regression. However, in this case the difference is small because the negative correlation between *S* and *MALE* is small (-0.05)

## Выбор переменных множественной регрессии

### Последствия включения в уравнение несущественной переменной

Для краткости будем называть переменную несущественной, если она не должна быть включена в уравнение (согласно правильной теории)

Будем говорить также о включении лишней переменной в правильное уравнение регрессии

## Выбор переменных множественной регрессии

### Последствия включения в уравнение несущественной переменной

1. Не теряется возможность правильной оценки и интерпретации уравнения
2. Коэффициенты при прочих переменных остаются несмещеными
3. Стандартные ошибки растут,  $t$ -статистики уменьшаются, эффективность оценок падает
4. Несущественная переменная может быть значимой, уравнение с ней - давать лучшую оценку
5. Увеличивается риск мультиколлинеарности

## ВКЛЮЧЕНИЕ НЕСУЩЕСТВЕННЫХ ПЕРМЕННЫХ

GeneratedDataProcess  $\mathbf{y} = \mathbf{X}\beta + \boldsymbol{\varepsilon}; \quad \mathbf{X} = (\mathbf{X}_1, \dots, \mathbf{X}_k);$

$$\hat{\beta}^* = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{y}; \quad \text{Var } \hat{\beta}^* = \sigma^2 (\mathbf{X}'\mathbf{X})^{-1}$$

$\mathbf{y} = \mathbf{X}\beta + \mathbf{Z}\gamma + \boldsymbol{\varepsilon}; \quad \mathbf{Z} = (\mathbf{Z}_{k+1}, \dots, \mathbf{Z}_{k+l});$

$$\begin{bmatrix} \hat{\beta} \\ \hat{\gamma} \end{bmatrix} = \begin{bmatrix} \mathbf{X}'\mathbf{X} & \mathbf{X}'\mathbf{Z} \\ \mathbf{Z}'\mathbf{X} & \mathbf{Z}'\mathbf{Z} \end{bmatrix}^{-1} \begin{bmatrix} \mathbf{X}' \\ \mathbf{Z}' \end{bmatrix} \mathbf{y} = \begin{bmatrix} \mathbf{Q}_{11} & \mathbf{Q}_{12} \\ \mathbf{Q}_{21} & \mathbf{Q}_{22} \end{bmatrix} \begin{bmatrix} \mathbf{X}' \\ \mathbf{Z}' \end{bmatrix} \mathbf{y} \Rightarrow$$
$$\Rightarrow \hat{\beta} = (\mathbf{Q}_{11}\mathbf{X}' + \mathbf{Q}_{12}\mathbf{Z}')\mathbf{y}$$

## ВКЛЮЧЕНИЕ НЕСУЩЕСТВЕННЫХ ПЕРМЕННЫХ

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{Z}\gamma + \boldsymbol{\varepsilon}; \quad \mathbf{Z} = (\mathbf{Z}_{k+1}, \dots, \mathbf{Z}_{k+l}); \quad \mathbf{M}_Z = \mathbf{I} - \mathbf{Z}(\mathbf{Z}'\mathbf{Z})^{-1}\mathbf{Z}'$$

$$\mathbf{M}_Z \mathbf{y} = \mathbf{M}_Z \mathbf{X}\boldsymbol{\beta} + \mathbf{M}_Z \boldsymbol{\varepsilon}; \quad \hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{M}_Z \mathbf{X})^{-1} \mathbf{X}'\mathbf{M}_Z \mathbf{y} = \mathbf{R}\mathbf{y}$$

$$E \hat{\boldsymbol{\beta}} = E \left[ (\mathbf{X}'\mathbf{M}_Z \mathbf{X})^{-1} \mathbf{X}'\mathbf{M}_Z \mathbf{X}\boldsymbol{\beta} + \mathbf{e}_Z \right] = \boldsymbol{\beta}$$

$$Var \hat{\boldsymbol{\beta}} = Var(\mathbf{R}\mathbf{y}) = \mathbf{R}(Var \mathbf{y})\mathbf{R}' = \mathbf{R}(Var \boldsymbol{\varepsilon})\mathbf{R}' = \mathbf{R}(\sigma^2 \mathbf{I})\mathbf{R}' =$$

$$\sigma^2 (\mathbf{X}'\mathbf{M}_Z \mathbf{X})^{-1} \mathbf{X}'\mathbf{M}_Z \mathbf{M}'_Z \mathbf{X} (\mathbf{X}'\mathbf{M}_Z \mathbf{X})^{-1} = \sigma^2 (\mathbf{X}'\mathbf{M}_Z \mathbf{X})^{-1} = \sigma^2 \left[ \mathbf{X}'\mathbf{X} - \mathbf{X}'\mathbf{Z}(\mathbf{Z}'\mathbf{Z})^{-1}\mathbf{Z}'\mathbf{X} \right]^{-1}$$

$$Var \hat{\boldsymbol{\beta}}^* = \sigma^2 (\mathbf{X}'\mathbf{X})^{-1}$$

$$Var^{-1} \hat{\boldsymbol{\beta}}^* - Var^{-1} \hat{\boldsymbol{\beta}} = \frac{1}{\sigma^2} \mathbf{X}'\mathbf{Z}(\mathbf{Z}'\mathbf{Z})^{-1}\mathbf{Z}'\mathbf{X} \geq 0,$$

т.к.  $\mathbf{X}'\mathbf{Z}(\mathbf{Z}'\mathbf{Z})^{-1}\mathbf{Z}'\mathbf{X}$  симметрична  $\Rightarrow$  положительно определена  $\Rightarrow$

$$\Rightarrow Var \hat{\boldsymbol{\beta}} \geq Var \hat{\boldsymbol{\beta}}^*$$

## ВКЛЮЧЕНИЕ НЕСУЩЕСТВЕННЫХ ПЕРМЕННЫХ

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{Z}\boldsymbol{\gamma} + \boldsymbol{\varepsilon}; \quad \mathbf{X} = (\mathbf{X}_1, \dots, \mathbf{X}_k); \quad \mathbf{Z} = (\mathbf{Z}_{k+1}, \dots, \mathbf{Z}_{k+l})$$

$$\mathbf{M} = \mathbf{I} - \mathbf{XZ} \left( (\mathbf{XZ})' \mathbf{X}' \mathbf{Z} \right)^{-1} (\mathbf{XZ})';$$

$$\mathbf{M}[\mathbf{XZ}] = [(\mathbf{MX})(\mathbf{MZ})] = \mathbf{0} \Rightarrow \mathbf{MX} = \mathbf{0}$$

$$RSS = \mathbf{e}'^* \mathbf{e}^* = \mathbf{e}'^* \mathbf{M} \mathbf{e}^* = \left( \mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}}^* - \mathbf{Z}\hat{\boldsymbol{\gamma}}^* + \boldsymbol{\varepsilon} \right)' \mathbf{M} \left( \mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}}^* - \mathbf{Z}\hat{\boldsymbol{\gamma}}^* + \boldsymbol{\varepsilon} \right) =$$

$$= \mathbf{y}' \mathbf{M} \mathbf{y} = (\mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon})' \mathbf{M} (\mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}) = \boldsymbol{\varepsilon}' \mathbf{M} \boldsymbol{\varepsilon}$$

$$E\left(\frac{RSS}{n-k-l}\right) = E(s^2) = E(\widehat{\sigma^2}) = \sigma^2 \text{ несмещена}$$

## Выбор переменных множественной регрессии

### Последствия включения в уравнение несущественной переменной

1. Не теряется возможность правильной оценки и интерпретации уравнения
2. Коэффициенты при прочих переменных остаются несмещеными
3. Стандартные ошибки растут,  $t$ -статистики уменьшаются, эффективность оценок падает
4. Несущественная переменная может быть значимой, уравнение с ней - давать лучшую оценку
5. Увеличивается риск мультиколлинеарности

## ВКЛЮЧЕНИЕ НЕСУЩЕСТВЕННЫХ ПЕРМЕННЫХ

```
. reg LGEARN S ASVABC
```

Source	SS	df	MS	Number of obs	=	570
Model	25.9166749	2	12.9583374	F( 2, 567)	=	57.45
Residual	127.885218	567	.225547121	Prob > F	=	0.0000
Total	153.801893	569	.270302096	R-squared	=	0.1685
				Adj R-squared	=	0.1656
				Root MSE	=	.47492

LGEARN	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
S	.0544266	.0099018	5.497	0.000	.034978 .0738753
ASVABC	.0114733	.0026476	4.333	0.000	.0062729 .0166736
_cons	1.118832	.124107	9.015	0.000	.8750665 1.362598

## ВКЛЮЧЕНИЕ НЕСУЩЕСТВЕННЫХ ПЕРМЕННЫХ

```
. reg LGEARN S ASVABC SM SF
```

Source	SS	df	MS	Number of obs	=	570
Model	26.3617806	4	6.59044515	F( 4, 565)	=	29.22
Residual	127.440112	565	.22555772	Prob > F	=	0.0000
Total	153.801893	569	.270302096	R-squared	=	0.1714
				Adj R-squared	=	0.1655
				Root MSE	=	.47493

LGEARN	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
S	.0511811	.0101812	5.027	0.000	.0311835 .0711788
ASVABC	.010444	.0027481	3.800	0.000	.0050463 .0158417
SM	.0071835	.0102695	0.699	0.485	-.0129876 .0273547
SF	.004794	.0076389	0.628	0.531	-.0102101 .0197981
_cons	1.073972	.1324621	8.108	0.000	.8137933 1.33415

## ВКЛЮЧЕНИЕ НЕСУЩЕСТВЕННЫХ ПЕРМЕННЫХ

```
. reg LGEARN S ASVABC
```

LGEARN	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
S	.0544266	.0099018	5.497	0.000	.034978	.0738753
ASVABC	.0114733	.0026476	4.333	0.000	.0062729	.0166736
_cons	1.118832	.124107	9.015	0.000	.8750665	1.362598

```
. reg LGEARN S ASVABC SM SF
```

LGEARN	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
S	.0511811	.0101812	5.027	0.000	.0311835	.0711788
ASVABC	.010444	.0027481	3.800	0.000	.0050463	.0158417
SM	.0071835	.0102695	0.699	0.485	-.0129876	.0273547
SF	.004794	.0076389	0.628	0.531	-.0102101	.0197981
_cons	1.073972	.1324621	8.108	0.000	.8137933	1.33415

# ВКЛЮЧЕНИЕ НЕСУЩЕСТВЕННЫХ ПЕРМЕННЫХ

```
. reg LGEARN S ASVABC
```

LGEARN	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
S   .0544266	.0099018	5.497	0.000	.034978	.0738753
ASVABC   .0114733	.0026476	4.333	0.000	.0062729	.0166736
_cons   1.118832	.124107	9.015	0.000	.8750665	1.362598

```
. reg LGEARN S ASVABC SM SF
```

LGEARN	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
S   .0511811	.0101812	5.027	0.000	.0311835	.0711788
ASVABC   .010444	.0027481	3.800	0.000	.0050463	.0158417
SM   .0071835	.0102695	0.699	0.485	-.0129876	.0273547
SF   .004794	.0076389	0.628	0.531	-.0102101	.0197981
_cons   1.073972	.1324621	8.108	0.000	.8137933	1.33415

The standard errors are larger in the misspecified model, reflecting the loss of efficiency.

# ВКЛЮЧЕНИЕ НЕСУЩЕСТВЕННЫХ ПЕРМЕННЫХ

```
. reg LGEARN S ASVABC
```

LGEARN		Coef.	Std. Err.
S		.0544266	.0099018
ASVABC		.0114733	.0026476
_cons		1.118832	.124107

```
. cor S ASVABC SM SF  
(obs=570)
```

		S	ASVABC	SM	SF
S		1.0000			
ASVABC		0.5779	1.0000		
SM		0.3582	0.3819	1.0000	
SF		0.4066	0.4179	0.6391	1.0000

```
. reg LGEARN S ASVABC SM SF
```

LGEARN		Coef.	Std. Err.
S		.0511811	.0101812
ASVABC		.010444	.0027481
SM		.0071835	.0102695
SF		.004794	.0076389
_cons		1.073972	.1324621

```
. pcorr SM S ASVABC SF  
(obs=570)
```

Partial correlation of SM with

Variable	Corr.	Sig.
S	0.1277	0.002
ASVABC	0.0805	0.055
SF	0.4926	0.000

```
. pcorr SF S ASVABC SM  
(obs=570)
```

Partial correlation of SF with

Variable	Corr.	Sig.
S	0.1454	0.001
ASVABC	0.1423	0.001
SM	0.4926	0.000

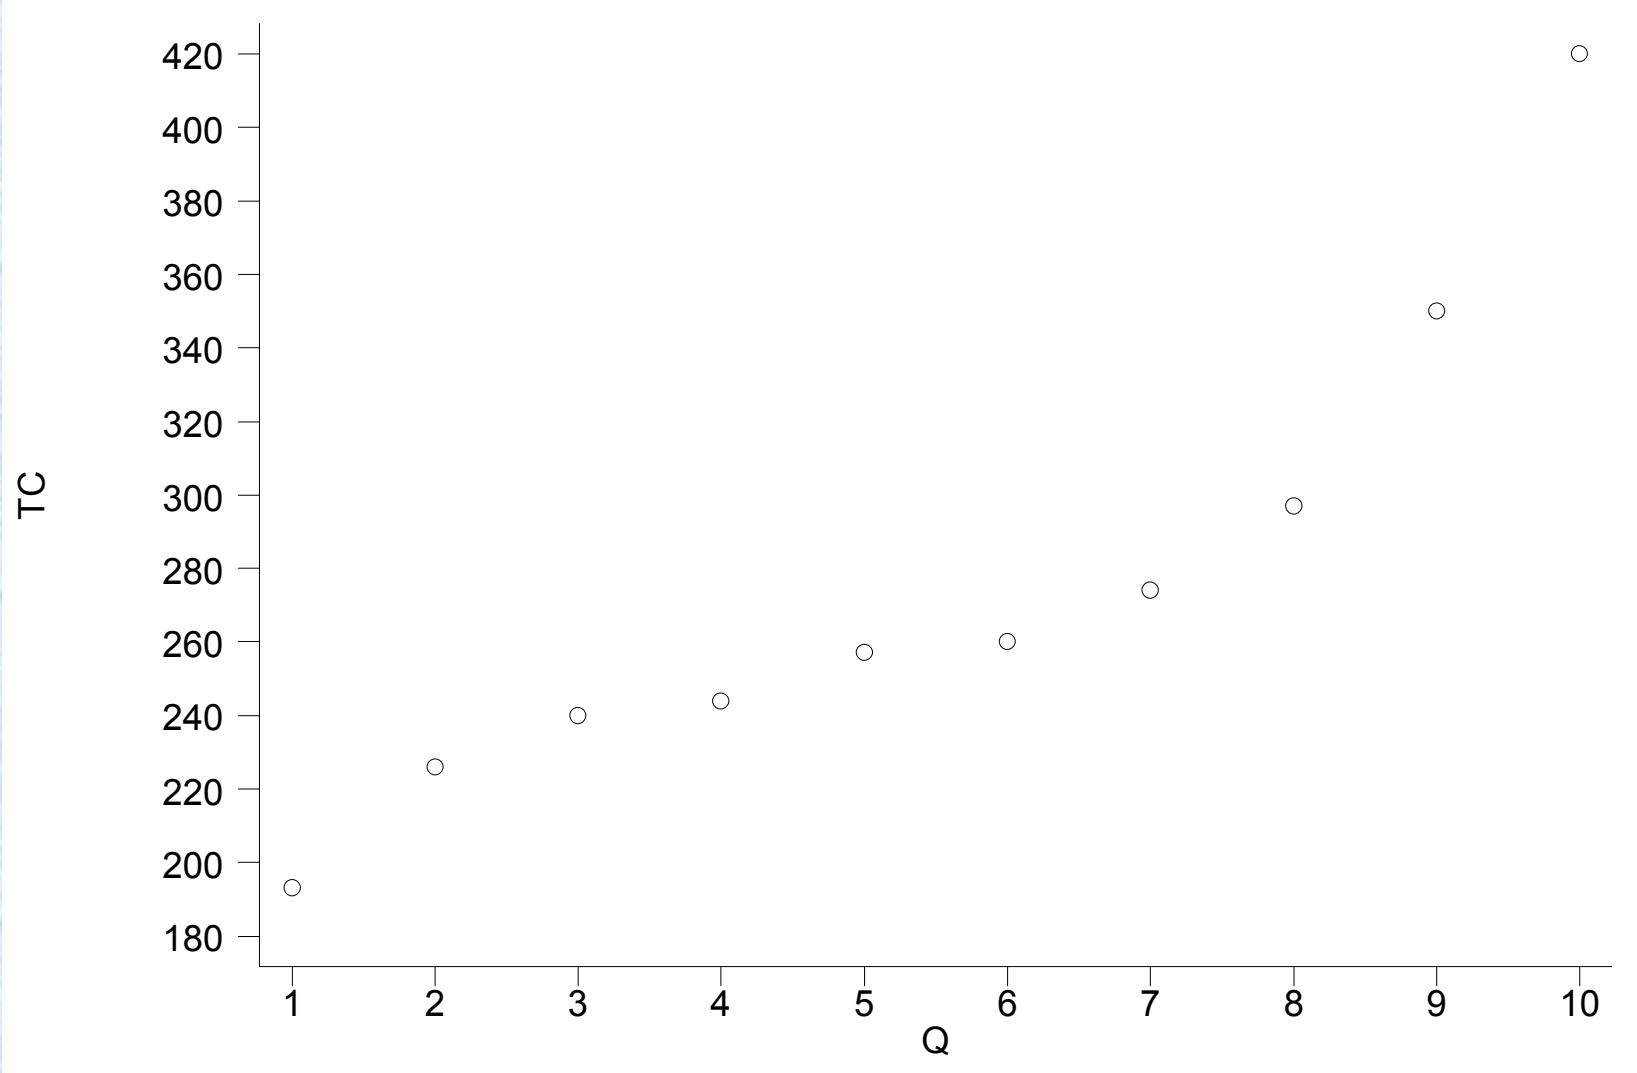
However, the loss of efficiency is not very great. The parental education variables are correlated with both S and ASVABC but, with a sample as large as the present one, the correlation has to be greater for the loss of efficiency to become a serious problem.

# ОШИБОЧНАЯ СПЕЦИФИКАЦИЯ МОДЕЛИ

## Consequences of Variable Misspecification

		<i>True Model</i>	
		$Y = \beta_1 + \beta_2 X_2 + u$	$Y = \beta_1 + \beta_2 X_2 + \beta_3 X_3 + u$
<i>Fitted Model</i>	$\hat{Y} = b_1 + b_2 X_2$	<b>Correct specification, no problems</b>	<b>Coefficients are biased (in general). Standard errors are invalid.</b>
	$\hat{Y} = b_1 + b_2 X_2 + b_3 X_3$	<b>Coefficients are unbiased (in general), but inefficient. Standard errors are valid (in general)</b>	<b>Correct specification, no problems</b>

# ОГРАНИЧЕНИЯ В ОБОБЩЕННОЙ МОДЕЛИ



# ОГРАНИЧЕНИЯ В ОБОБЩЕННОЙ МОДЕЛИ

. reg TC Q

Source	SS	df	MS	Number of obs	=	10
Model	32780.3667	1	32780.3667	F(	1,	42.28
Residual	6202.53333	8	775.316667	Prob > F	=	0.0002
Total	38982.90	9	4331.43333	R-squared	=	0.8409

Adj R-squared = 0.8210  
Root MSE = 27.845

TC	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
Q	19.93333	3.06558	6.50	0.000	12.86409 27.00257
_cons	166.4667	19.02142	8.75	0.000	122.6032 210.3301

. ovtest

Ramsey RESET test using powers of the fitted values of TC

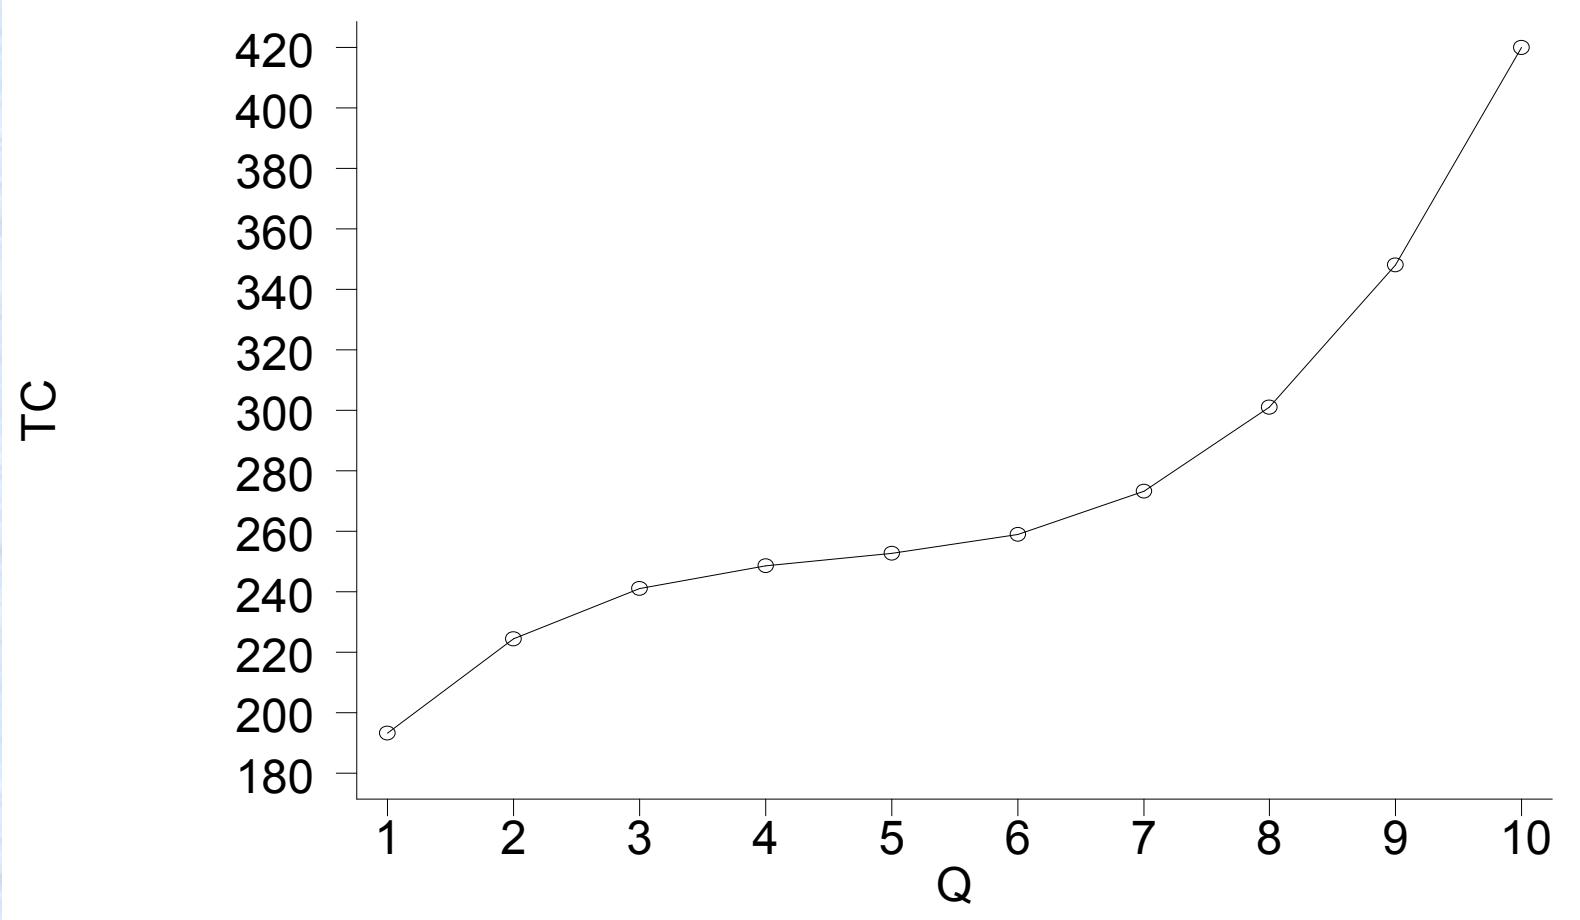
Ho: model has no omitted variables

F(3, 5) = 165.83

Prob > F = 0.0000

## ОГРАНИЧЕНИЯ В ОБОБЩЕННОЙ МОДЕЛИ

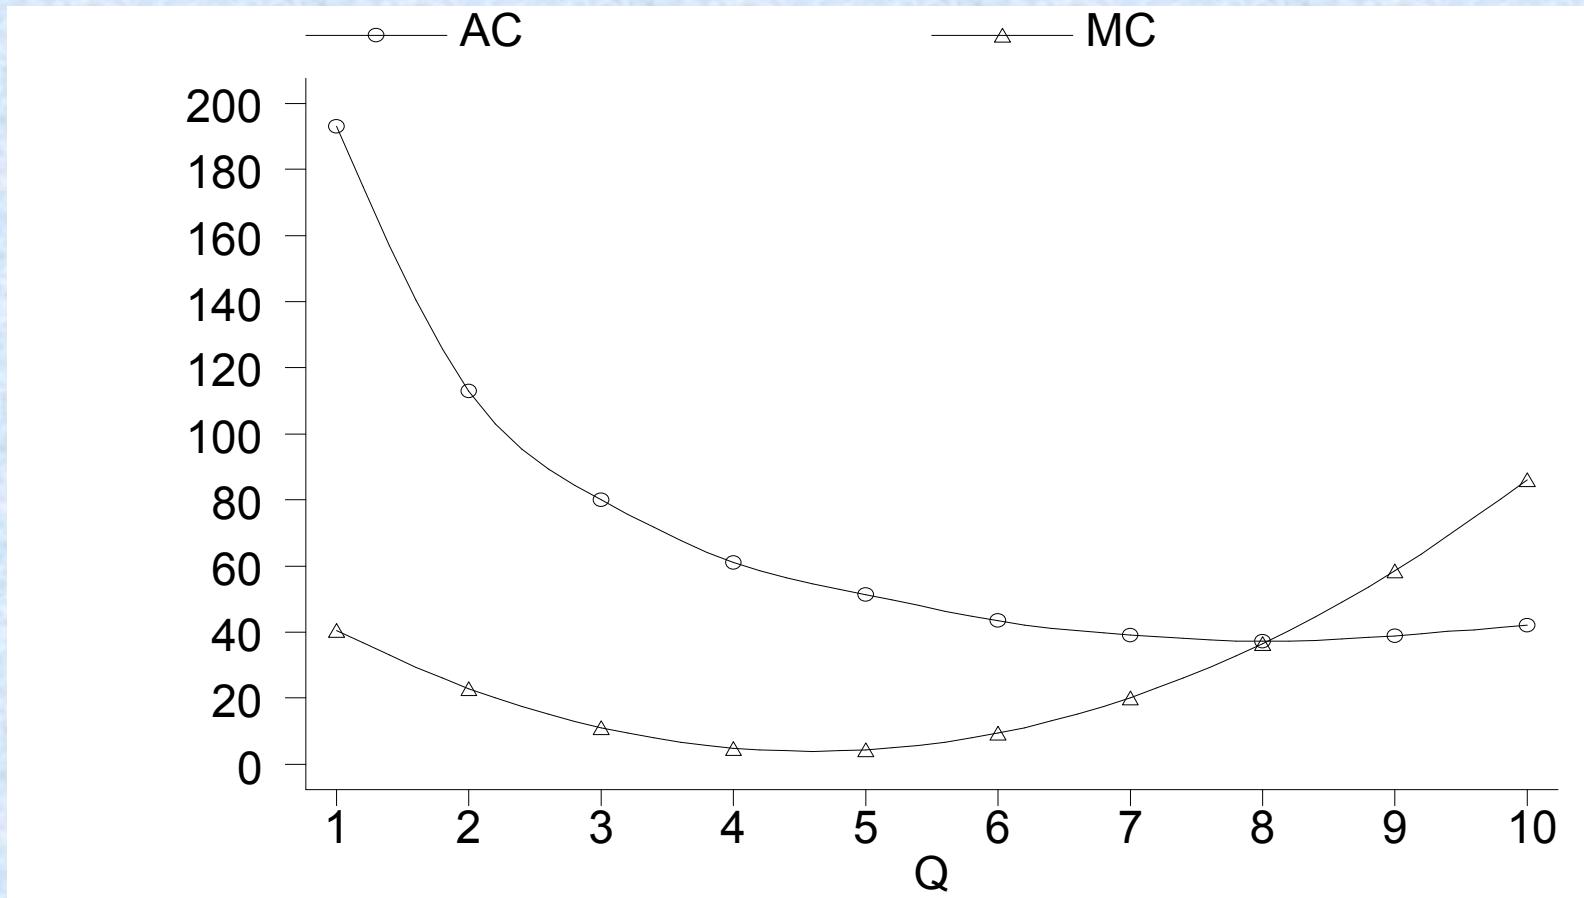
$$TC(Q) = b_0 + b_1 Q + b_2 Q^2 + b_3 Q^3$$



$$0 \leq TC(0) = b_0; \quad b_3 Q^3 \underset{Q \rightarrow +\infty}{\sim} TC(Q) \approx +\infty \Rightarrow b_3 \geq 0$$

## ОГРАНИЧЕНИЯ В ОБОБЩЕННОЙ МОДЕЛИ

$$MC(Q) = b_1 + 2b_2Q + 3b_3Q^2 \quad AC(Q) = \frac{b_0}{Q} + b_1 + b_2Q + b_3Q^2$$



$$0 \leq MC(0) = b_1; \quad MC(Q) \geq 0 \Rightarrow b_2^2 - 3b_1b_3 \leq 0$$

# ОГРАНИЧЕНИЯ В ОБОБЩЕННОЙ МОДЕЛИ

$$TC(Q) = b_0 + b_1 Q + b_2 Q^2 + b_3 Q^3 + \varepsilon$$

. reg TC Q3 Q2 Q

Source	SS	df	MS	Number of obs	= 10
<hr/>					
Model	38918.1562	3	12972.7187	F( 3, 6)	= 1202.22
Residual	64.7438228	6	10.7906371	Prob > F	= 0.0000
<hr/>					
Total	38982.90	9	4331.43333	R-squared	= 0.9983
<hr/>					
				Adj R-squared	= 0.9975
				Root MSE	= 3.2849

TC	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
<hr/>					
Q3	.9395882	.0591056	15.90	0.000	.794962 1.084214
Q2	-12.96154	.9856646	-13.15	0.000	-15.37337 -10.5497
Q	63.47766	4.778607	13.28	0.000	51.78483 75.17049
_cons	141.7667	6.375322	22.24	0.000	126.1668 157.3665
<hr/>					

. di \_b[ Q2]^2-3\*\_b[Q]\*\_b[Q3]

-10.927103

. testnl \_b[ Q2]^2=3\*\_b[Q]\*\_b[Q3]

(1) \_b[ Q2]^2 = 3\*\_b[Q]\*\_b[Q3]

F(1, 6) = 35.31

Prob > F = 0.0010

. ovtest

Ramsey RESET test using powers of the fitted values of TC

Ho: model has no omitted variables

F(3, 3) = 1.76

Prob > F = 0.3270

Конец лекции