


# ТОЧНОСТЬ КОЭФФИЦИЕНТОВ РЕГРЕССИИ

Простая регрессионная модель:  $Y = \beta_1 + \beta_2 X + u$


Функция плотности  
распределения  
вероятности  $b_2$



Мы видим, что коэффициенты регрессии  $b_1$  и  $b_2$  являются случайными величинами. Они представляют точечные оценки  $\beta_1$  и  $\beta_2$ , соответственно. Последним следствием мы показываем, что точечные оценки являются несмещенными.

Простая регрессионная модель:  $Y = \beta_1 + \beta_2 X + u$

Функция плотности  
распределения  
вероятности  $b_2$



В этом же следствии мы увидим, что можем также получить оценки стандартного отклонения распределения. Это даст некоторое представление об их вероятной надежности и послужит основой для проверки гипотез.

Простая регрессионная модель:  $Y = \beta_1 + \beta_2 X + u$

$$\sigma_{b_1}^2 = \sigma_u^2 \left\{ \frac{1}{n} + \frac{\bar{X}^2}{\sum (X_i - \bar{X})^2} \right\}$$

$$\sigma_{b_2}^2 = \frac{\sigma_u^2}{\sum (X_i - \bar{X})^2}$$

Выражения (которые не решены) для дисперсий их распределений показаны выше. См. Вставку 2.3 в тексте для доказательства выражения дисперсии  $b_2$ .

Простая регрессионная модель:  $Y = \beta_1 + \beta_2 X + u$

$$\sigma_{b_1}^2 = \sigma_u^2 \left\{ \frac{1}{n} + \frac{\bar{X}^2}{\sum (X_i - \bar{X})^2} \right\}$$



$$\sigma_{b_2}^2 = \frac{\sigma_u^2}{\sum (X_i - \bar{X})^2}$$

Мы сосредоточимся на значении выражения для дисперсии  $b_2$ . Рассматривая числитель, мы видим, что дисперсия  $b_2$  пропорциональна  $\sigma_u^2$ . Этого и следовало ожидать. Чем больше разброс в модели, тем менее точными будут наши оценки.

# ТОЧНОСТЬ КОЭФФИЦИЕНТОВ РЕГРЕССИИ

Простая регрессионная модель:  $Y = \beta_1 + \beta_2 X + u$

$$Y = 2.0 + 0.5X$$





Это показано на диаграммах, представленных выше. Случайная составляющая зависимости,  $Y = 3.0 + 0.8X$  представлена пунктирной линией на обеих диаграммах одинакова.

# ТОЧНОСТЬ КОЭФФИЦИЕНТОВ РЕГРЕССИИ

Простая регрессионная модель:  $Y = \beta_1 + \beta_2 X + u$

$$Y = 2.0 + 0.5X$$





Значения  $X$  одинаковы, и одинаковые случайные числа использовались для генерирования значений остаточного члена в 20 наблюдениях.

# ТОЧНОСТЬ КОЭФФИЦИЕНТОВ РЕГРЕССИИ

Простая регрессионная модель:  $Y = \beta_1 + \beta_2 X + u$

$$Y = 2.0 + 0.5X$$



Однако, на правой диаграмме случайные числа умножились в 5 раз. Как следствие, линия регрессии, сплошная линия, намного меньше приближена к линии случайной зависимости.

Простая регрессионная модель:  $Y = \beta_1 + \beta_2 X + u$

$$\sigma_{b_1}^2 = \sigma_u^2 \left\{ \frac{1}{n} + \frac{\bar{X}^2}{\sum (X_i - \bar{X})^2} \right\}$$

$$\sigma_{b_2}^2 = \frac{\sigma_u^2}{\sum (X_i - \bar{X})^2}$$

Посмотрим на знаменатель выражения для дисперсии  $b_2$ . Чем больше сумма квадратов отклонений  $X$ , тем меньше дисперсия  $b_2$ .



Простая регрессионная модель:  $Y = \beta_1 + \beta_2 X + u$

$$\sigma_{b_1}^2 = \sigma_u^2 \left\{ \frac{1}{n} + \frac{\bar{X}^2}{\sum (X_i - \bar{X})^2} \right\}$$

$$\sigma_{b_2}^2 = \frac{\sigma_u^2}{\sum (X_i - \bar{X})^2} = \frac{\sigma_u^2}{n \text{MSD}(X)}$$

$$\text{MSD}(X) = \frac{1}{n} \sum (X_i - \bar{X})^2$$

Однако, значение суммы квадратов отклонений зависит от двух факторов: количества наблюдений и размера отклонений  $X_i$  от его выборочного среднего. Для того, чтобы различать их, будет удобно определить среднее квадратическое отклонение  $X$ ,  $\text{MSD}(X)$ .

Простая регрессионная модель:  $Y = \beta_1 + \beta_2 X + u$

$$\sigma_{b_1}^2 = \sigma_u^2 \left\{ \frac{1}{n} + \frac{\bar{X}^2}{\sum (X_i - \bar{X})^2} \right\}$$

$$\sigma_{b_2}^2 = \frac{\sigma_u^2}{\sum (X_i - \bar{X})^2} = \frac{\sigma_u^2}{n \text{MSD}(X)}$$

$$\text{MSD}(X) = \frac{1}{n} \sum (X_i - \bar{X})^2$$

Из приведенного выражения видно, что дисперсия  $b_2$  обратно пропорциональна  $n$ , числу наблюдений в выборке, которые управляют  $\text{MSD}(X)$ . Чем больше информации мы имеем, тем точнее будут оценки.

Простая регрессионная модель:  $Y = \beta_1 + \beta_2 X + u$

$$\sigma_{b_1}^2 = \sigma_u^2 \left\{ \frac{1}{n} + \frac{\bar{X}^2}{\sum (X_i - \bar{X})^2} \right\}$$

$$\sigma_{b_2}^2 = \frac{\sigma_u^2}{\sum (X_i - \bar{X})^2} = \frac{\sigma_u^2}{n \text{MSD}(X)}$$



$$\text{MSD}(X) = \frac{1}{n} \sum (X_i - \bar{X})^2$$

Третьим следствием выражения является то, что дисперсия обратно пропорциональна среднему квадратическому отклонению  $X$ . В чем причина этого?

# ТОЧНОСТЬ КОЭФФИЦИЕНТОВ РЕГРЕССИИ

Простая регрессионная модель:  $Y = \beta_1 + \beta_2 X + u$

$$Y = 2.0 + 0.5X$$

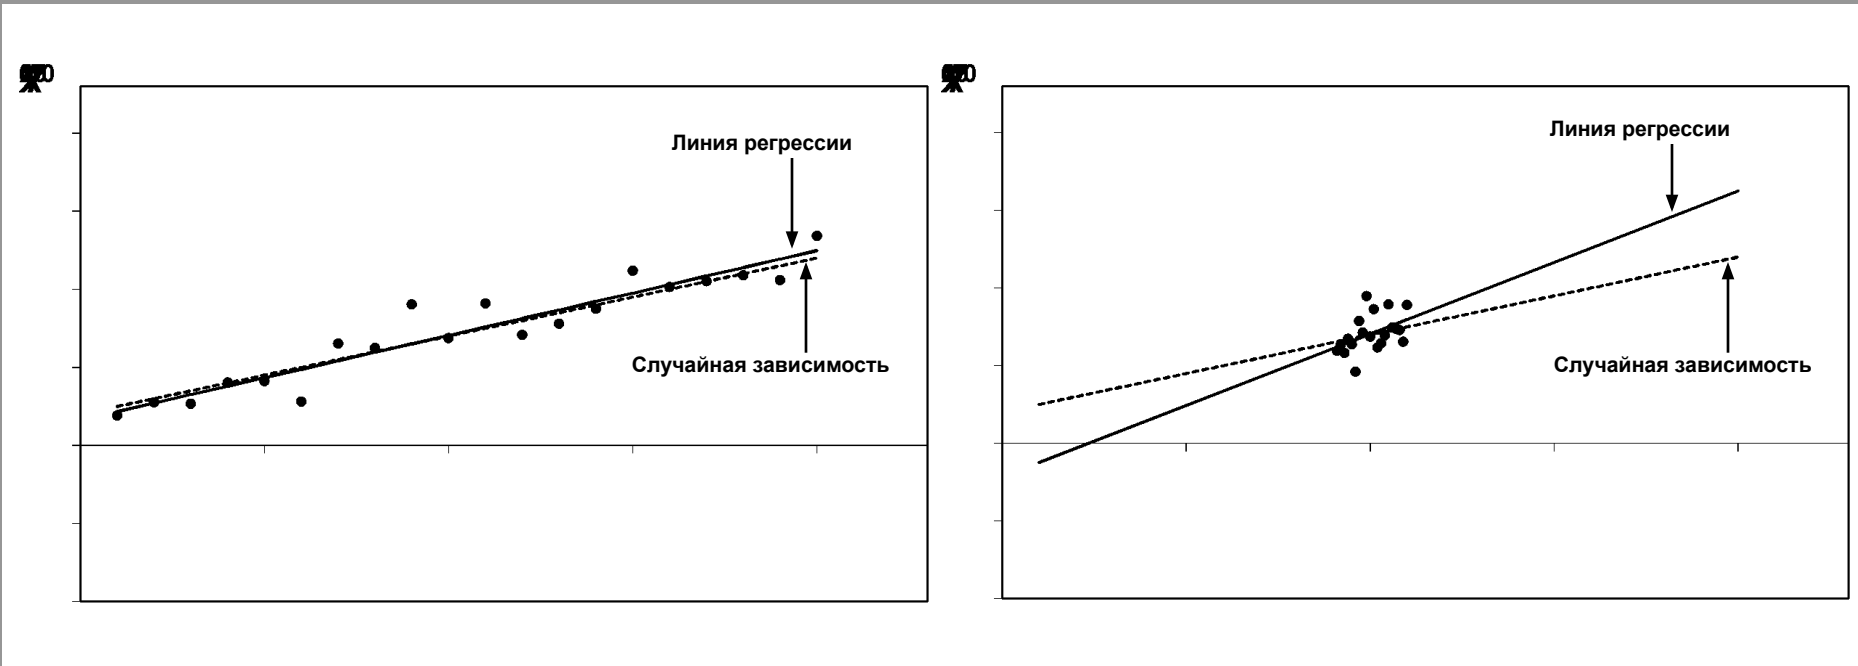


На вышеприведенных диаграммах линия случайной зависимости одинакова и для 20 значений наблюдений в распределении использовались одинаковые случайные числа.

# ТОЧНОСТЬ КОЭФФИЦИЕНТОВ РЕГРЕССИИ

Простая регрессионная модель:  $Y = \beta_1 + \beta_2 X + u$

$$Y = 2.0 + 0.5X$$





Однако, MSD ( $X$ ) намного меньше на правой диаграмме, так как значения  $X$  намного ближе друг к другу.

# ТОЧНОСТЬ КОЭФФИЦИЕНТОВ РЕГРЕССИИ

Простая регрессионная модель:  $Y = \beta_1 + \beta_2 X + u$

$$Y = 2.0 + 0.5X$$




Следовательно, на этой диаграмме положение линии регрессии более чувствительно к значениям наблюдений распределения, и, как следствие, линия регрессии, вероятно, будет относительно неточной.

## ТОЧНОСТЬ КОЭФФИЦИЕНТОВ РЕГРЕССИИ

Простая регрессионная модель:  $Y = \beta_1 + \beta_2 X + u$

$$Y = 2.0 + 0.5X$$




На рисунке показаны распределения оценок  $b_2$  для  $X = 1, 2, \dots, 20$  и  $X = 9.1, 9.2, \dots, 11$  при моделировании с 10 миллионами наблюдений.

## ТОЧНОСТЬ КОЭФФИЦИЕНТОВ РЕГРЕССИИ

Простая регрессионная модель:  $Y = \beta_1 + \beta_2 X + u$

$$Y = 2.0 + 0.5X$$



Это подтверждает, что распределение оценок, полученных с высокой дисперсией  $X$ , имеет гораздо меньшее отклонение, чем распределение с низкой дисперсией  $X$ .



Простая регрессионная модель:  $Y = \beta_1 + \beta_2 X + u$

$$\sigma_{b_1}^2 = \sigma_u^2 \left\{ \frac{1}{n} + \frac{\bar{X}^2}{\sum (X_i - \bar{X})^2} \right\} \quad \sigma_{b_2}^2 = \frac{\sigma_u^2}{\sum (X_i - \bar{X})^2} = \frac{\sigma_u^2}{n \text{MSD}(X)}$$

Конечно, как видно из выражений дисперсии, отношение MSD (X) к дисперсии  $u$  важнее, чем ее абсолютное значение.

Простая регрессионная модель:  $Y = \beta_1 + \beta_2 X + u$

$$\sigma_{b_1}^2 = \sigma_u^2 \left\{ \frac{1}{n} + \frac{\bar{X}^2}{\sum (X_i - \bar{X})^2} \right\} \quad \sigma_{b_2}^2 = \frac{\sigma_u^2}{\sum (X_i - \bar{X})^2} = \frac{\sigma_u^2}{n \text{MSD}(X)}$$

Мы не можем рассчитать теоретические дисперсии именно потому, что не знаем дисперсии остаточного члена. Однако, мы можем получить оценку  $\sigma_u^2$  из остатков.

Простая регрессионная модель:  $Y = \beta_1 + \beta_2 X + u$

$$\sigma_{b_1}^2 = \sigma_u^2 \left\{ \frac{1}{n} + \frac{\bar{X}^2}{\sum (X_i - \bar{X})^2} \right\} \quad \sigma_{b_2}^2 = \frac{\sigma_u^2}{\sum (X_i - \bar{X})^2} = \frac{\sigma_u^2}{n \text{MSD}(X)}$$

Очевидно, что разброс остатков относительно линии регрессии будет отражать неизвестный разброс  $u$  относительно линии  $Y_i = \beta_1 + b_2 X_i$  хотя в общем остаток и случайный член ни в одном из наблюдений не равны друг другу.

Простая регрессионная модель:  $Y = \beta_1 + \beta_2 X + u$

$$\sigma_{b_1}^2 = \sigma_u^2 \left\{ \frac{1}{n} + \frac{\bar{X}^2}{\sum (X_i - \bar{X})^2} \right\} \quad \sigma_{b_2}^2 = \frac{\sigma_u^2}{\sum (X_i - \bar{X})^2} = \frac{\sigma_u^2}{n \text{MSD}(X)}$$

$$\text{MSD}(e) = \frac{1}{n} \sum (e_i - \bar{e})^2 = \frac{1}{n} \sum e_i^2$$

Одной из мер разброса остатков является их средняя квадратическая ошибка,  $\text{MSD}(e)$ , которая определяется формулой, указанной на слайде. (Помните, что среднее значение остатков OLS равно нулю). Интуитивно это должно приводить к дисперсии  $u$ .

Простая регрессионная модель:  $Y = \beta_1 + \beta_2 X + u$

$$\sigma_{b_1}^2 = \sigma_u^2 \left\{ \frac{1}{n} + \frac{\bar{X}^2}{\sum (X_i - \bar{X})^2} \right\} \quad \sigma_{b_2}^2 = \frac{\sigma_u^2}{\sum (X_i - \bar{X})^2} = \frac{\sigma_u^2}{n \text{MSD}(X)}$$

$$\text{MSD}(e) = \frac{1}{n} \sum (e_i - \bar{e})^2 = \frac{1}{n} \sum e_i^2$$

Прежде чем пойти дальше, задайте себе следующий вопрос: какая прямая вероятнее будет ближе к точкам, представляющим собой выборку наблюдений по  $X$  и  $Y$ , истинная прямая  $Y = \beta_1 + \beta_2 X$  или линия регрессии  $\hat{Y} = b_1 + b_2 X$ ?

Простая регрессионная модель:  $Y = \beta_1 + \beta_2 X + u$

$$\sigma_{b_1}^2 = \sigma_u^2 \left\{ \frac{1}{n} + \frac{\bar{X}^2}{\sum (X_i - \bar{X})^2} \right\} \quad \sigma_{b_2}^2 = \frac{\sigma_u^2}{\sum (X_i - \bar{X})^2} = \frac{\sigma_u^2}{n \text{MSD}(X)}$$

$$\text{MSD}(e) = \frac{1}{n} \sum (e_i - \bar{e})^2 = \frac{1}{n} \sum e_i^2$$

Ответ – линия регрессии, так как по определению она строится таким образом, чтобы свести к минимуму сумму квадратов расстояний между ней и значениями наблюдениями.

Простая регрессионная модель:  $Y = \beta_1 + \beta_2 X + u$

$$\sigma_{b_1}^2 = \sigma_u^2 \left\{ \frac{1}{n} + \frac{\bar{X}^2}{\sum (X_i - \bar{X})^2} \right\} \quad \sigma_{b_2}^2 = \frac{\sigma_u^2}{\sum (X_i - \bar{X})^2} = \frac{\sigma_u^2}{n \text{MSD}(X)}$$

$$\text{MSD}(e) = \frac{1}{n} \sum (e_i - \bar{e})^2 = \frac{1}{n} \sum e_i^2$$

Следовательно, разброс остатков у нее меньше, чем разброс значений  $u$ , а  $\text{MSD}(e)$  имеет тенденцию занижать оценку  $\sigma_u^2$ .

Простая регрессионная модель:  $Y = \beta_1 + \beta_2 X + u$

$$\sigma_{b_1}^2 = \sigma_u^2 \left\{ \frac{1}{n} + \frac{\bar{X}^2}{\sum (X_i - \bar{X})^2} \right\} \quad \sigma_{b_2}^2 = \frac{\sigma_u^2}{\sum (X_i - \bar{X})^2} = \frac{\sigma_u^2}{n \text{MSD}(X)}$$

$$\text{MSD}(e) = \frac{1}{n} \sum (e_i - \bar{e})^2 = \frac{1}{n} \sum e_i^2$$

$$E(\text{MSD}(e)) = \frac{n-2}{n} \sigma_u^2$$

Действительно, можно показать, что математическое ожидание  $\text{MSD}(e)$ , если имеется всего одна независимая переменная, находится выражением приведенным выше.



Простая регрессионная модель:  $Y = \beta_1 + \beta_2 X + u$

$$\sigma_{b_1}^2 = \sigma_u^2 \left\{ \frac{1}{n} + \frac{\bar{X}^2}{\sum (X_i - \bar{X})^2} \right\} \quad \sigma_{b_2}^2 = \frac{\sigma_u^2}{\sum (X_i - \bar{X})^2} = \frac{\sigma_u^2}{n \text{MSD}(X)}$$

$$s_u^2 = \frac{n}{n-2} \text{MSD}(e) = \frac{n}{n-2} \frac{1}{n} \sum e_i^2 = \frac{1}{n-2} \sum e_i^2$$

Однако отсюда следует, что мы можем получить несмещенную оценку  $\sigma_u^2$ , умножив  $\text{MSD}(e)$  на  $n / (n - 2)$ . Обозначим это  $s_u^2$ .

Простая регрессионная модель:  $Y = \beta_1 + \beta_2 X + u$

$$\sigma_{b_1}^2 = \sigma_u^2 \left\{ \frac{1}{n} + \frac{\bar{X}^2}{\sum (X_i - \bar{X})^2} \right\} \quad \sigma_{b_2}^2 = \frac{\sigma_u^2}{\sum (X_i - \bar{X})^2} = \frac{\sigma_u^2}{n \text{MSD}(X)}$$

$$s_u^2 = \frac{n}{n-2} \text{MSD}(e) = \frac{n}{n-2} \frac{1}{n} \sum e_i^2 = \frac{1}{n-2} \sum e_i^2$$

$$c.o.(b_1) = s_u \sqrt{\frac{1}{n} + \frac{\bar{X}^2}{\sum (X_i - \bar{X})^2}}$$

$$c.o.(b_2) = \sqrt{\frac{s_u^2}{\sum (X_i - \bar{X})^2}}$$

Затем мы можем получить оценки стандартных отклонений распределений  $b_1$  и  $b_2$ , подставив  $s_u^2$  для  $\sigma_u^2$  в выражения дисперсии и взяв квадратные корни.

Простая регрессионная модель:  $Y = \beta_1 + \beta_2 X + u$

$$\sigma_{b_1}^2 = \sigma_u^2 \left\{ \frac{1}{n} + \frac{\bar{X}^2}{\sum (X_i - \bar{X})^2} \right\} \quad \sigma_{b_2}^2 = \frac{\sigma_u^2}{\sum (X_i - \bar{X})^2} = \frac{\sigma_u^2}{n \text{MSD}(X)}$$

$$s_u^2 = \frac{n}{n-2} \text{MSD}(e) = \frac{n}{n-2} \frac{1}{n} \sum e_i^2 = \frac{1}{n-2} \sum e_i^2$$

$$\text{s.e.}(b_1) = s_u \sqrt{\frac{1}{n} + \frac{\bar{X}^2}{\sum (X_i - \bar{X})^2}} \quad \text{s.e.}(b_2) = \sqrt{\frac{s_u^2}{\sum (X_i - \bar{X})^2}}$$

Они описываются как стандартные ошибки  $b_1$  и  $b_2$ , «оценки среднеквадратических отклонений» являются более полными.

# ТОЧНОСТЬ КОЭФФИЦИЕНТОВ РЕГРЕССИИ

```
. reg EARNINGS S
```

Source	SS	df	MS			
Model	19321.5589	1	19321.5589	Number of obs =	540	
Residual	92688.6722	538	172.283777	F( 1, 538) =	112.15	
Total	112010.231	539	207.811189	Prob > F =	0.0000	
				R-squared =	0.1725	
				Adj R-squared =	0.1710	
				Root MSE =	13.126	


  

EARNINGS	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
S	2.455321	.2318512	10.59	0.000	1.999876	2.910765
_cons	-13.93347	3.219851	-4.33	0.000	-20.25849	-7.608444

Стандартные ошибки коэффициентов всегда появляются как часть результата регрессии. Здесь представлена регрессия почасовых заработков в годы обучения, которые обсуждались на предыдущих слайдах. Стандартные ошибки появляются в столбце справа от коэффициентов.

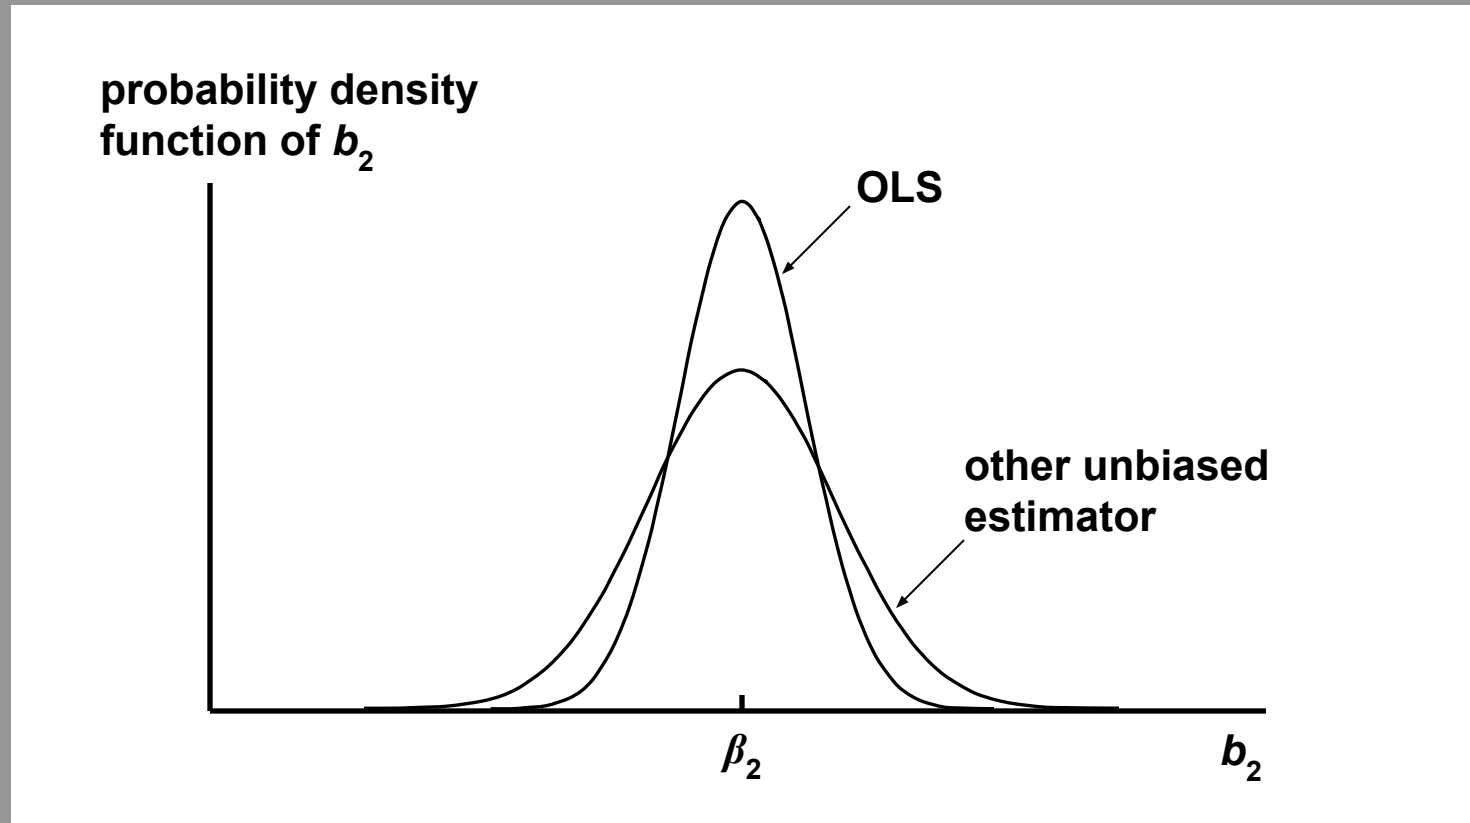
## ТОЧНОСТЬ КОЭФФИЦИЕНТОВ РЕГРЕССИИ

Простая регрессионная модель:  $Y = \beta_1 + \beta_2 X + u$



Теорема Гаусса-Маркова утверждает : при условии, что допущения модели регрессии действительны, оценки OLS являются BLUE: лучшая (наиболее эффективная) линейная (функция значений  $Y$ ) несмещенных оценок параметров.

Простая регрессионная модель:  $Y = \beta_1 + \beta_2 X + u$



Доказательство теоремы не сложное, но не является высокоприоритетным, и мы будем считать его надежным. См. Раздел 2.7 текста для доказательства простой модели регрессии.