

$$Y = \beta_1 + \beta_2 X + u$$
$$\log Y = \beta_1 + \beta_2 X + u$$

Когда альтернативные характеристики регрессионной модели имеют одну и ту же зависимую переменную, R^2 можно использовать для сравнения их пригодности.

$$Y = \beta_1 + \beta_2 X + u$$
$$\log Y = \beta_1 + \beta_2 X + u$$

Однако, когда зависимая переменная отличается, этого делать нельзя.

$$Y = \beta_1 + \beta_2 X + u$$
$$\log Y = \beta_1 + \beta_2 X + u$$

В случае линейной модели, R^2 измеряет долю дисперсии в Y , объясненную моделью. В случае полупологарифмической модели она измеряет долю дисперсии *логарифма* Y , объясненную моделью.

$$Y = \beta_1 + \beta_2 X + u$$
$$\log Y = \beta_1 + \beta_2 X + u$$

Очевидно, что они связаны, но они не совпадают, поэтому прямые сравнения бессмысленны.

$$Y = \beta_1 + \beta_2 X + u$$
$$\log Y = \beta_1 + \beta_2 X + u$$

Преобразование Бокса–Кокса:

$$\frac{Y^\lambda - 1}{\lambda} = \beta_1 + \beta_2 X + u$$

Однако доброкачественность моделей с линейной и логарифмической версиями одной и той же зависимой переменной можно сравнить косвенно, подвергнув зависимую переменную преобразованию Бокса–Кокса и приспособивая показанную модель.

$$Y = \beta_1 + \beta_2 X + u$$
$$\log Y = \beta_1 + \beta_2 X + u$$

Преобразование Бокса–Кокса:

$$\frac{Y^\lambda - 1}{\lambda} = \beta_1 + \beta_2 X + u$$

Это семейство спецификаций, зависящих от параметра λ . Определение λ является эмпирическим вопросом, как и определение других параметров.

$$Y = \beta_1 + \beta_2 X + u$$
$$\log Y = \beta_1 + \beta_2 X + u$$

Преобразование Бокса–Кокса:

$$\frac{Y^\lambda - 1}{\lambda} = \beta_1 + \beta_2 X + u$$

Модель нелинейна по параметрам, поэтому следует использовать метод нелинейной регрессии. На практике используется оценка максимального правдоподобия.

$$Y = \beta_1 + \beta_2 X + u$$
$$\log Y = \beta_1 + \beta_2 X + u$$

Преобразование Бокса–Кокса:

$$\frac{Y^\lambda - 1}{\lambda} = \beta_1 + \beta_2 X + u$$

$$\frac{Y^\lambda - 1}{\lambda} = Y - 1 \quad \text{когда } \lambda = 1$$

$$\frac{Y^\lambda - 1}{\lambda} \rightarrow \log Y \quad \text{когда } \lambda \rightarrow 0$$

Причина, по которой это преобразование представляет интерес в данном контексте, заключается в том, что спецификации с линейными и логарифмическими зависимыми переменными являются частными случаями.

$$Y = \beta_1 + \beta_2 X + u$$
$$\log Y = \beta_1 + \beta_2 X + u$$

Преобразование Бокса–Кокса:

$$\frac{Y^\lambda - 1}{\lambda} = \beta_1 + \beta_2 X + u$$

$$\frac{Y^\lambda - 1}{\lambda} = Y - 1 \quad \text{когда } \lambda = 1$$

$$\frac{Y^\lambda - 1}{\lambda} \rightarrow \log Y \quad \text{когда } \lambda \rightarrow 0$$

Ввод $\lambda = 1$ дает линейную модель. Зависимая переменная тогда $Y - 1$, а не Y , но вычитание константы из зависимой переменной не влияет на результаты регрессии, за исключением оценки перехвата.

$$Y = \beta_1 + \beta_2 X + u$$
$$\log Y = \beta_1 + \beta_2 X + u$$

Преобразование Бокса–Кокса:

$$\frac{Y^\lambda - 1}{\lambda} = \beta_1 + \beta_2 X + u$$

$$\frac{Y^\lambda - 1}{\lambda} = Y - 1 \quad \text{когда } \lambda = 1$$

$$\frac{Y^\lambda - 1}{\lambda} \rightarrow \log Y \quad \text{когда } \lambda \rightarrow 0$$

Ввод $\lambda = 0$ дает (полу)логарифмическую модель. Конечно, нельзя говорить о том, чтобы ввести λ ровно равным 0, потому что тогда зависимая переменная становится нулевой, деленной на ноль. Речь идет о предельном виде, когда λ стремится к нулю, и мы воспользовались правилом Лопиталя.

$$Y = \beta_1 + \beta_2 X + u$$
$$\log Y = \beta_1 + \beta_2 X + u$$

Преобразование Бокса–Кокса:

$$\frac{Y^\lambda - 1}{\lambda} = \beta_1 + \beta_2 X + u$$

$$\frac{Y^\lambda - 1}{\lambda} = Y - 1 \quad \text{когда } \lambda = 1$$

$$\frac{Y^\lambda - 1}{\lambda} \rightarrow \log Y \quad \text{когда } \lambda \rightarrow 0$$

Таким образом, можно подогнать общую модель и посмотреть, близок ли λ к 0 или близок к 1. Конечно, "близкий" не имеет значения в эконометрике. Чтобы подойти к этому вопросу технически, нужно проверить гипотезы: $\lambda = 0$ и $\lambda = 1$.

$$Y = \beta_1 + \beta_2 X + u$$
$$\log Y = \beta_1 + \beta_2 X + u$$

Преобразование Бокса–Кокса:

$$\frac{Y^\lambda - 1}{\lambda} = \beta_1 + \beta_2 X + u$$

$$\frac{Y^\lambda - 1}{\lambda} = Y - 1 \quad \text{когда } \lambda = 1$$

$$\frac{Y^\lambda - 1}{\lambda} \rightarrow \log Y \quad \text{когда } \lambda \rightarrow 0$$

Результатом может быть то, что один отклоняется, а другой не отклоняется, но, конечно, возможно, что ни один из них не отклоняется или оба отклоняются, всё зависит от выбранного вами уровня значимости.

$$Y = \beta_1 + \beta_2 X + u$$
$$\log Y = \beta_1 + \beta_2 X + u$$

Преобразование Бокса–Кокса:

$$\frac{Y^\lambda - 1}{\lambda} = \beta_1 + \beta_2 X + u$$

$$\frac{Y^\lambda - 1}{\lambda} = Y - 1 \quad \text{когда } \lambda = 1$$

$$\frac{Y^\lambda - 1}{\lambda} \rightarrow \log Y \quad \text{когда } \lambda \rightarrow 0$$

Если вы заинтересованы только в сравнении соответствий линейных и логарифмических спецификаций, существует короткая процедура, которая включает только стандартные регрессии наименьших квадратов.

$$Y = \beta_1 + \beta_2 X + u$$
$$\log Y = \beta_1 + \beta_2 X + u$$

$$Y^* = Y / \text{среднее геометрическое } Y$$

Первый шаг - разделить наблюдения по зависимой переменной на их среднее геометрическое. Будем называть преобразованную переменную Y^* .

$$Y = \beta_1 + \beta_2 X + u$$
$$\log Y = \beta_1 + \beta_2 X + u$$

$$Y^* = Y / \text{среднее геометрическое } Y$$

$$Y^* = \beta'_1 + \beta'_2 X + u$$
$$\log Y^* = \beta'_1 + \beta'_2 X + u$$

Теперь вы регрессируете Y^* и $\log_e Y^*$, оставляя правую часть уравнения без изменений. (Параметрам были даны простые оценки, чтобы подчеркнуть, что коэффициенты не будут оценками исходных β_1 и β_2).

$$Y = \beta_1 + \beta_2 X + u$$
$$\log Y = \beta_1 + \beta_2 X + u$$

$$Y^* = Y / \text{среднее геометрическое } Y$$

$$Y^* = \beta'_1 + \beta'_2 X + u$$
$$\log Y^* = \beta'_1 + \beta'_2 X + u$$

Остаточные суммы квадратов теперь прямо сопоставимы. Таким образом, спецификация с меньшим RSS обеспечивает лучшую подгонку.

$$Y = \beta_1 + \beta_2 X + u$$
$$\log Y = \beta_1 + \beta_2 X + u$$

$$Y^* = Y / \text{среднее геометрическое } Y$$

$$Y^* = \beta_1' + \beta_2' X + u$$
$$\log Y^* = \beta_1' + \beta_2' X + u$$

Мы будем использовать преобразование для сравнения приступов линейной и полулогарифмической версий простого уравнения заработной платы, используя набор данных *EAW*E Data Set 21.

$$e^{\frac{1}{n} \sum \log Y_i}$$

Первый шаг - вычислить среднее геометрическое зависимой переменной. Самый простой способ сделать это - взять экспоненту среднего значения логарифма зависимой переменной.

$$e^{\frac{1}{n} \sum \log Y_i} = e^{\frac{1}{n} \log (Y_1 Y_2 \dots Y_n)}$$

Сумма логарифмов Y равна логарифму произведений Y .

$$e^{\frac{1}{n} \sum \log Y_i} = e^{\frac{1}{n} \log (Y_1 Y_2 \dots Y_n)}$$
$$= e^{\log (Y_1 Y_2 \dots Y_n)^{\frac{1}{n}}}$$

Теперь мы используем правило, согласно которому $a \log X$ совпадает с выражением $\log X^a$

$$\begin{aligned} e^{\frac{1}{n} \sum \log Y_i} &= e^{\frac{1}{n} \log (Y_1 Y_2 \dots Y_n)} \\ &= e^{\log (Y_1 Y_2 \dots Y_n)^{\frac{1}{n}}} = (Y_1 Y_2 \dots Y_n)^{\frac{1}{n}} \end{aligned}$$

И, наконец, мы используем тот факт, что экспонента логарифма X сводится к X .

$$\begin{aligned}
 e^{\frac{1}{n} \sum \log Y_i} &= e^{\frac{1}{n} \log (Y_1 Y_2 \dots Y_n)} \\
 &= e^{\log (Y_1 Y_2 \dots Y_n)^{\frac{1}{n}}} = (Y_1 Y_2 \dots Y_n)^{\frac{1}{n}}
 \end{aligned}$$

```
. sum LGEARN
```

Variable	Obs	Mean	Std. Dev.	Min	Max
LGEARN	500	2.824265	.553001	.6931472	4.642948

LGEARN уже определен как логарифм *EARNINGS*. Мы находим его среднее. В программе Stata это делается с помощью команды «sum».

СРАВНЕНИЕ ЛИНЕЙНЫХ И ЛОГАРИФМИЧЕСКИХ ХАРАКТЕРИСТИК

$$\begin{aligned} e^{\frac{1}{n} \sum \log Y_i} &= e^{\frac{1}{n} \log (Y_1 Y_2 \dots Y_n)} \\ &= e^{\log (Y_1 Y_2 \dots Y_n)^{\frac{1}{n}}} = (Y_1 Y_2 \dots Y_n)^{\frac{1}{n}} \end{aligned}$$

```
. sum LGEARN
```

Variable	Obs	Mean	Std. Dev.	Min	Max
-----+-----					
LGEARN	500	2.824265	.553001	.6931472	4.642948

```
. gen EARNSTAR = EARNINGS/exp(2.8243)
```

Затем мы определяем *EARNSTAR*, разделив *EARNINGS* на экспоненту среднего значения *LGEARN*.

СРАВНЕНИЕ ЛИНЕЙНЫХ И ЛОГАРИФМИЧЕСКИХ ХАРАКТЕРИСТИК

$$\begin{aligned} e^{\frac{1}{n} \sum \log Y_i} &= e^{\frac{1}{n} \log (Y_1 Y_2 \dots Y_n)} \\ &= e^{\log (Y_1 Y_2 \dots Y_n)^{\frac{1}{n}}} = (Y_1 Y_2 \dots Y_n)^{\frac{1}{n}} \end{aligned}$$

```
. sum LGEARN
```

Variable	Obs	Mean	Std. Dev.	Min	Max
-----+-----					
LGEARN	500	2.824265	.553001	.6931472	4.642948

```
. gen EARNSTAR = EARNINGS/exp(2.8243)
```

```
. gen LGEARNST = ln(EARNSTAR)
```

Мы также определяем LGEARNST, логарифм EARNSTAR.

СРАВНЕНИЕ ЛИНЕЙНЫХ И ЛОГАРИФМИЧЕСКИХ ХАРАКТЕРИСТИК

```
. reg EARNSTAR S EXP
```

Source	SS	df	MS			
Model	30.7698527	2	15.3849264	Number of obs =	500	
Residual	216.958472	497	.436536161	F(2, 497) =	35.24	
Total	247.728325	499	.496449549	Prob > F =	0.0000	
				R-squared =	0.1242	
				Adj R-squared =	0.1207	
				Root MSE =	.66071	

EARNSTAR	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
S	.1114334	.0132792	8.39	0.000	.0853432	.1375236
EXP	.0583614	.0124543	4.69	0.000	.0338918	.0828311
_cons	-.8705654	.254515	-3.42	0.001	-1.370623	-.3705073

Вот регрессия *EARNSTAR* на *S* и *EXP*. Остаточная сумма квадратов равна 217,0.

СРАВНЕНИЕ ЛИНЕЙНЫХ И ЛОГАРИФМИЧЕСКИХ ХАРАКТЕРИСТИК

```
. reg LGEARNST S EXP
```

Source	SS	df	MS			
Model	21.2104061	2	10.6052031	Number of obs =	500	
Residual	131.388814	497	.264363811	F(2, 497) =	40.12	
Total	152.59922	499	.30581006	Prob > F =	0.0000	
				R-squared =	0.1390	
				Adj R-squared =	0.1355	
				Root MSE =	.51416	

LGearnst	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
S	.0916942	.0103338	8.87	0.000	.0713908	.1119976
EXP	.0405521	.009692	4.18	0.000	.0215098	.0595944
_cons	-1.624505	.1980634	-8.20	0.000	-2.013649	-1.23536

Мы запускаем параллельную регрессию для *LGearnst*. Остаточная сумма квадратов равна 131,4. Таким образом, мы заключаем, что полулогарифмическая версия лучше подходит.

СРАВНЕНИЕ ЛИНЕЙНЫХ И ЛОГАРИФМИЧЕСКИХ ХАРАКТЕРИСТИК

```
. boxcox EARNINGS S EXP
```

```

                                     Number of obs   =           500
                                     LR chi2(2)       =           76.08
Log likelihood = -1785.403           Prob > chi2     =           0.000
    
```

```

-----+-----
      EARNINGS |          Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]
-----+-----
      /theta   |   .1088657     .05362     2.03   0.042     .0037726     .2139589
    
```

```

-----+-----
      Test          Restricted      LR statistic      P-value
      H0:          log likelihood      chi2          Prob > chi2
-----+-----
theta = -1         -2025.7902          480.77          0.000
theta = 0          -1787.4901           4.17          0.041
theta = 1          -1912.8953          254.98          0.000
    
```

Вот результат для полной регрессии Бокса-Кокса. Параметр, который мы обозначили λ (lambda), называется «theta» в программе Stata. Он оценивается в 0.11. Поскольку он ближе к 0, чем к 1, он указывает, что зависимая переменная должна быть логарифмической, а не линейной.

СРАВНЕНИЕ ЛИНЕЙНЫХ И ЛОГАРИФМИЧЕСКИХ ХАРАКТЕРИСТИК

```
. boxcox EARNINGS S EXP
```

```

                                     Number of obs   =           500
                                     LR chi2(2)       =           76.08
Log likelihood = -1785.403           Prob > chi2    =           0.000
    
```

```

-----
      EARNINGS |          Coef.   Std. Err.      z    P>|z|     [95% Conf. Interval]
-----+-----
      /theta   |   .1088657     .05362     2.03   0.042     .0037726     .2139589
-----
    
```

```

-----
      Test                Restricted      LR statistic      P-value
      H0:                log likelihood      chi2              Prob > chi2
-----
theta = -1              -2025.7902           480.77            0.000
theta = 0               -1787.4901            4.17              0.041
theta = 1              -1912.8953           254.98            0.000
-----
    
```

Однако даже значение 0 не (полностью) лежит в 95-процентном доверительном интервале. (Тест вероятностей логарифма объясняется в главе 10.).