

тесты на функциональную форму

лекция 14

ПРОЦЕДУРЫ ПОШАГОВОГО ОТБОРА

1. ПОСЛЕДОВАТЕЛЬНОГО ПРИСОЕДИНЕНИЯ
2. ПОСЛЕДОВАТЕЛЬНОГО УДАЛЕНИЯ
3. ПРИСОЕДИНЕНИЯ-УДАЛЕНИЯ
4. УДАЛЕНИЯ-ПРИСОЕДИНЕНИЯ

См.:

*Магнус, Катышев, Пересецкий «Эконометрика.
Начальный курс»*

*Айвазян, Мхитарян «Прикладная статистика и
эконометрика»*

ПРОЦЕДУРЫ ПОШАГОВОГО ОТБОРА

STATA:

```
sw reg var_y (varlist1) var_x1... (...),  
[ pr(level) | pe(level) | pr(level) pe(level) | pr(level) pe(level) forward ]  
[hier] [lockterm1] [lr] options
```

<i>pr(#)</i>	backward selection
<i>pr(#) hier</i>	backward hierarchical selection
<i>pr(#) pe(#)</i>	backward stepwise
<i>pe(#)</i>	forward selection
<i>pe(#) hier</i>	forward hierarchical selection
<i>pr(#) pe(#) forward</i>	forward stepwise

ПРОЦЕДУРЫ ПОШАГОВОГО ОТБОРА

```
. reg EARNINGS MALE ETHWHITE COLLBARG URBAN ASVABC AGE S
```

Source	SS	df	MS	Number of obs = 570		
-----+-----				F(7, 562) = 26.33		
Model	9852.78065	7	1407.54009	Prob > F	= 0.0000	
Residual	30041.8558	562	53.4552594	R-squared	= 0.2470	
-----+-----				Adj R-squared	= 0.2376	
Total	39894.6364	569	70.1135965	Root MSE	= 7.3113	

EARNINGS	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
-----+-----						
MALE	3.45469	.623498	5.54	0.000	2.230019	4.679361
ETHWHITE	.8424168	.9654416	0.87	0.383	-1.053898	2.738731
COLLBARG	1.253548	.9858559	1.27	0.204	-.682864	3.18996
URBAN	1.033109	.772808	1.34	0.182	-.4848363	2.551054
ASVABC	.1732071	.0435075	3.98	0.000	.0877499	.2586642
AGE	.2590228	.1433373	1.81	0.071	-.0225194	.540565
S	.9598976	.1622137	5.92	0.000	.6412785	1.278517
_cons	-20.36929	4.880397	-4.17	0.000	-29.95534	-10.78325

ПРОЦЕДУРЫ ПОШАГОВОГО ОТБОРА

.sw reg EARNINGS MALE ETHWHITE COLLBARG URBAN ASVABC AGE S, pe(.15)

begin with empty model

p = 0.0000 < 0.1500 adding S

p = 0.0000 < 0.1500 adding MALE

p = 0.0000 < 0.1500 adding ASVABC

p = 0.0565 < 0.1500 adding AGE

.sw reg EARNINGS MALE ETHWHITE COLLBARG URBAN ASVABC AGE S, pr(.15)

begin with full model

p = 0.3833 >= 0.1500 removing ETHWHITE

p = 0.2300 >= 0.1500 removing URBAN

p = 0.2013 >= 0.1500 removing COLLBARG

•	Source	SS	df	MS	Number of obs =	570
•	-----+-----				F(4, 565) =	45.05
•	Model	9647.38895	4	2411.84724	Prob > F =	0.0000
•	Residual	30247.2475	565	53.5349513	R-squared =	0.2418
•	-----+-----				Adj R-squared =	0.2365
•	Total	39894.6364	569	70.1135965	Root MSE =	7.3168

EARNINGS	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
-----+-----						
MALE	3.542326	.6215357	5.70	0.000	2.321524	4.763129
S	.9885847	.1598943	6.18	0.000	.6745249	1.302645
ASVABC	.182249	.0415634	4.38	0.000	.1006114	.2638866
AGE	.2735131	.143115	1.91	0.056	-.0075893	.5546155
_cons	-20.05516	4.855838	-4.13	0.000	-29.59285	-10.51746
-----+-----						

ПРОЦЕДУРЫ ПОШАГОВОГО ОТБОРА

```
. sw reg EARNINGS MALE ETHWHITE COLLBARG URBAN ASVABC AGE S, pe(.05) hier
      begin with empty model
p = 0.0000 < 0.0500 adding MALE
p = 0.0057 < 0.0500 adding ETHWHITE
p = 0.0897 >= 0.0500 testing COLLBARG
```

Source	SS	df	MS	Number of obs = 570
-----+-----				F(2, 567) = 19.08
Model	2515.78772	2	1257.89386	Prob > F = 0.0000
Residual	37378.8487	567	65.9238954	R-squared = 0.0631
-----+-----				Adj R-squared = 0.0598
Total	39894.6364	569	70.1135965	Root MSE = 8.1194

EARNINGS	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
-----+-----					
MALE	3.655179	.6887306	5.31	0.000	2.302404 5.007953
ETHWHITE	2.766774	.9974825	2.77	0.006	.8075625 4.725986
_cons	8.915434	.9826909	9.07	0.000	6.985275 10.84559

ПРОЦЕДУРЫ ПОШАГОВОГО ОТБОРА

. sw reg EARNINGS AGE S ASVABC COLLBARG MALE URBAN ETHWHITE, pr(.15) hier

begin with full model

p = 0.3833 >= 0.1500 removing ETHWHITE

p = 0.2300 >= 0.1500 removing URBAN

p = 0.0000 < 0.1500 keeping MALE

Source	SS	df	MS	Number of obs = 570
-----+-----				F(5, 564) = 36.41
Model	9734.90813	5	1946.98163	Prob > F = 0.0000
Residual	30159.7283	564	53.4746955	R-squared = 0.2440
-----+-----				Adj R-squared = 0.2373
Total	39894.6364	569	70.1135965	Root MSE = 7.3126

EARNINGS	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
-----+-----						
AGE	.2612717	.1433541	1.82	0.069	-.0203015	.5428448
S	.9839398	.1598455	6.16	0.000	.6699746	1.297905
ASVABC	.1830015	.0415442	4.40	0.000	.1014014	.2646017
COLLBARG	1.255857	.9816639	1.28	0.201	-.6723063	3.184021
MALE	3.487598	.6226571	5.60	0.000	2.264588	4.710608
_cons	-19.73568	4.859525	-4.06	0.000	-29.28065	-10.1907

ТЕСТЫ НА ФУНКЦИОНАЛЬНУЮ ФОРМУ

1. **RESET тест Рамсея**
2. **J-тест Дэвидсона и МакКиннона**
3. **PE-тест МакКиннона**
4. **Метод Зарембки**
5. **Тест Кокса-Бокса**
6. **РС-тест Амемии (Акаике)**
7. **Информационный критерий Шварца**
8. **Информационный критерий Акаике**

RESET тест Рамсея

Regression Equation Specification Error Test

$$H_0 : y_t = \mathbf{x}_t \boldsymbol{\beta} + \varepsilon_t; \quad \mathbf{x}_t = (x_{1t}, \dots, x_{kt}); \quad t = 1, \dots, n$$

$$H_1 : y_t = \mathbf{x}_t \boldsymbol{\beta} + \alpha_2 \hat{y}_t^2 + \dots + \alpha_m \hat{y}_t^m + \varepsilon_t$$

$$H_1 : \boldsymbol{\alpha} = \mathbf{0}$$

$$H'_1 : y_t = \mathbf{x}_t \boldsymbol{\beta} + \gamma_{21} x_{1t}^2 + \dots + \gamma_{m1} x_{1t}^m + \dots + \delta_1 x_{1t} x_{2t} + \dots + \varepsilon_t \sim$$

$$H'_1 : \boldsymbol{\gamma} = \mathbf{0}, \boldsymbol{\delta} = \mathbf{0}$$

RESET тест Рамсея

Regression Equation Specification Error Test

```
. reg EARNINGS MALE ASVABC AGE S
```

Source	SS	df	MS	Number of obs =	570
<hr style="border-top: 1px dashed black;"/>					
Model	5971.29146	4	1492.82286	F(4, 565) =	26.01
Residual	32425.7456	565	57.3907002	Prob > F =	0.0000
<hr style="border-top: 1px dashed black;"/>					
Total	38397.0371	569	67.4816117	R-squared =	0.1555
				Adj R-squared =	0.1495
				Root MSE =	7.5757

EARNINGS	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
<hr style="border-top: 1px dashed black;"/>						
MALE	2.873136	.6445776	4.46	0.000	1.607075	4.139197
ASVABC	.1258984	.0434857	2.90	0.004	.040485	.2113119
AGE	.1794028	.1450898	1.24	0.217	-.1055785	.4643842
S	.8348173	.1601258	5.21	0.000	.5203028	1.149332
_cons	-12.03274	5.008224	-2.40	0.017	-21.86975	-2.195733
<hr style="border-top: 1px dashed black;"/>						

```
. ovtest
```

Ramsey RESET test using powers of the fitted values of EARNINGS
 Ho: model has no omitted variables
 F(3, 562) = 3.26
 Prob > F = 0.0213

```
. ovtest,rhs
```


Ramsey RESET test using powers of the independent variables
 Ho: model has no omitted variables
 F(9, 556) = 2.50
 Prob > F = 0.0082

Выбор переменных регрессии: вложенные и невложенные модели


Вложенная модель является частным случаем (ограниченной версией) более общей модели

Невложенные модели имеют разные наборы переменных

ВЛОЖЕННЫЕ МОДЕЛИ



НЕВЛОЖЕННЫЕ МОДЕЛИ



$$\hat{Y}_i = b_0 + b_1 X_{1i} + b_2 X_{2i}$$

$$\hat{Y}_i^{\text{влож}} = b'_0 + b'_1 X_{1i}$$

$$\hat{Y}_i^A = b_0 + b_1 X_{1i} + b_2 X_{2i}$$

$$\hat{Y}_i^B = b'_0 + b'_1 X_{1i} + b'_2 Z_i$$

Вложенные модели непосредственно сравнимы.
Сравнение невложенных моделей возможно только с помощью специальных процедур.

Ж-тест Дэвидсона-МакКиннона Сравнение невложенных моделей

$$A: \mathbf{y} = \mathbf{x}\boldsymbol{\beta} + \boldsymbol{\varepsilon}; \quad \mathbf{x} = (\mathbf{x}_1, \dots, \mathbf{x}_k)$$

$$B: \mathbf{y} = \mathbf{z}\boldsymbol{\gamma} + \mathbf{v}; \quad \mathbf{z} = (\mathbf{z}_1, \dots, \mathbf{z}_m)$$

$$C: \mathbf{y} = \mathbf{x}\boldsymbol{\beta}(1 - \delta) + \mathbf{z}\boldsymbol{\gamma}\delta + \mathbf{u}$$

$$\delta = 0: C = A; \quad \delta = 1: C = B$$

$\delta, \boldsymbol{\beta}, \boldsymbol{\gamma}$ не могут быть идентифицированы одновременно

Ж-тест Дэвидсона-МакКиннона Сравнение невложенных моделей

$$A: \mathbf{y} = \mathbf{x}\boldsymbol{\beta} + \boldsymbol{\varepsilon}; \quad \mathbf{x} = (\mathbf{x}_1, \dots, \mathbf{x}_k)$$

$$B: \mathbf{y} = \mathbf{z}\boldsymbol{\gamma} + \mathbf{v}; \quad \mathbf{z} = (\mathbf{z}_1, \dots, \mathbf{z}_m) \Rightarrow \hat{\boldsymbol{\gamma}}; \hat{\mathbf{y}}_B$$

$$\mathbf{y} = \mathbf{x}\boldsymbol{\beta}(1 - \delta) + \mathbf{z}\hat{\boldsymbol{\gamma}}\delta + \mathbf{u} = \mathbf{x}\boldsymbol{\beta}^* + \delta\hat{\mathbf{y}}_B, \quad \boldsymbol{\beta}^* = \boldsymbol{\beta}(1 - \delta)$$

$$H_0: \delta = 0$$

$$H_1: \delta \neq 0$$

$$\delta = 0 \Rightarrow \text{p lim } \hat{\delta} = 0, \quad t = \frac{\hat{\delta}}{\text{s.e.}\hat{\delta}} \sim N(0,1)$$

J-тест Дэвидсона-МакКиннона
Сравнение невложенных моделей

$$A: \mathbf{y} = \mathbf{x}\boldsymbol{\beta} + \boldsymbol{\varepsilon}; \quad \mathbf{x} = (\mathbf{x}_1, \dots, \mathbf{x}_k) \Rightarrow \hat{\boldsymbol{\beta}}; \hat{\mathbf{y}}_A$$

$$B: \mathbf{y} = \mathbf{z}\boldsymbol{\gamma} + \mathbf{v}; \quad \mathbf{z} = (\mathbf{z}_1, \dots, \mathbf{z}_m)$$

$$\mathbf{y} = \mathbf{x}\hat{\boldsymbol{\beta}}\delta + \mathbf{z}\boldsymbol{\gamma}(1 - \delta) + \mathbf{u} = \hat{\mathbf{y}}_A\delta + \mathbf{z}\boldsymbol{\gamma}^*, \quad \boldsymbol{\gamma}^* = \boldsymbol{\gamma}(1 - \delta)$$

$$H_0: \delta = 0$$

$$H_1: \delta \neq 0$$

$$\delta = 0 \Rightarrow \text{p lim } \hat{\delta} = 0, \quad t = \frac{\hat{\delta}}{\text{s.e.}\hat{\delta}} \sim N(0,1)$$

J-тест ошибочной спецификации Дэвидсона-МакКиннона для невложенных моделей

$$\hat{Y}_i^A = b_0 + b_1 X_{1i} + b_2 X_{2i}$$

$$\hat{Y}_i^B = b'_0 + b'_1 X_{1i} + b'_2 Z_i$$

1. Оценивается уравнение регрессии (A)
2. Расчетные значения зависимой переменной из модели (A) включаются в модель (B) в качестве дополнительной объясняющей переменной

$$Y_i^B = b''_0 + b''_1 X_{1i} + b''_2 Z_i + b''_3 \hat{Y}_i^A + \varepsilon_i$$

3. Проводится оценка улучшения модели по F -критерию
4. Делается симметричная процедура

J-тест ошибочной спецификации Дэвидсона-МакКиннона для невложенных моделей

В результате применения теста возможны четыре случая:

1. Модель (A) значительно улучшается, а (B) – нет.

Вывод: выбираем модель (B).

2. Модель (B) значительно улучшается, а (A) – нет.

Вывод: выбираем модель (A).

3. Обе модели значительно улучшаются.

Вывод: ни одна из них не пригодна.

4. Обе модели улучшаются не значительно.

Вывод: данных недостаточно, чтобы различить качество моделей.

РЕ-тест МакКиннона
сравнение невложенных моделей

$$A: \mathbf{y} = \mathbf{x}\boldsymbol{\beta} + \boldsymbol{\varepsilon}_1 \Rightarrow \hat{\boldsymbol{\beta}}, \hat{\mathbf{y}}$$

$$B: \ln(\mathbf{y}) = \mathbf{x}\boldsymbol{\gamma} + \boldsymbol{\varepsilon}_2 \Rightarrow \hat{\boldsymbol{\gamma}}, \widehat{\ln(\mathbf{y})}$$

$$C: \mathbf{y} = \mathbf{x}\boldsymbol{\beta} + \delta \left(\ln(\hat{\mathbf{y}}) - \widehat{\ln(\mathbf{y})} \right) + \mathbf{u}$$

$$\delta = 0: C = A$$

H_{00} : $\delta = 0 \Rightarrow$ верна линейная модель

H_{01} : $\delta \neq 0 \Rightarrow$ линейная модель не верна

$$\delta = 0 \Rightarrow p \lim \hat{\delta} = 0, \quad t = \frac{\hat{\delta}}{s.e.\hat{\delta}} \sim N(0,1)$$

РЕ-тест МакКиннона сравнение невложенных моделей

$$A: \mathbf{y} = \mathbf{x}\boldsymbol{\beta} + \boldsymbol{\varepsilon}_1 \Rightarrow \hat{\boldsymbol{\beta}}, \hat{\mathbf{y}}$$

$$B: \ln(\mathbf{y}) = \mathbf{x}\boldsymbol{\gamma} + \boldsymbol{\varepsilon}_2 \Rightarrow \hat{\boldsymbol{\gamma}}, \widehat{\ln(\mathbf{y})}$$

$$D: \ln(\mathbf{y}) = \mathbf{x}\boldsymbol{\gamma} + \rho \left(\hat{\mathbf{y}} - \exp \left[\widehat{\ln(\mathbf{y})} \right] \right) + \mathbf{v}$$

$$\rho = 0: D = B$$

H_{10} : $\rho = 0 \Rightarrow$ верна лог-линейная модель

H_{11} : $\rho \neq 0 \Rightarrow$ лог-линейная модель не верна

$$\rho = 0 \Rightarrow \text{plim } \hat{\boldsymbol{\delta}} = 0, \quad t = \frac{\hat{\boldsymbol{\delta}}}{s.e.\hat{\boldsymbol{\delta}}} \sim N(0,1)$$

РЕ-тест МакКиннона сравнение невложенных моделей

$$A: \mathbf{y} = \mathbf{x}\boldsymbol{\beta} + \boldsymbol{\varepsilon}_1$$

$$B: \ln(\mathbf{y}) = \mathbf{x}\boldsymbol{\gamma} + \boldsymbol{\varepsilon}_2$$

$$C: \mathbf{y} = \mathbf{x}\boldsymbol{\beta} + \delta \left(\ln(\hat{\mathbf{y}}) - \widehat{\ln(\mathbf{y})} \right) + \mathbf{u}$$

$$D: \ln(\mathbf{y}) = \mathbf{x}\boldsymbol{\gamma} + \rho \left(\hat{\mathbf{y}} - \exp \left[\widehat{\ln(\mathbf{y})} \right] \right) + \mathbf{v}$$

Исходы:

1. $H_{00}, H_{11} \Rightarrow \delta = 0$ проходит, $\rho = 0$ не проходит \Rightarrow выбираем модель A
2. $H_{01}, H_{10} \Rightarrow \delta = 0$ не проходит, $\rho = 0$ проходит \Rightarrow выбираем модель B
3. $H_{00}, H_{10} \Rightarrow \delta = 0$ проходит, $\rho = 0$ проходит \Rightarrow модели эквивалентны
4. $H_{01}, H_{10} \Rightarrow \delta = 0$ не проходит, $\rho = 0$ не проходит \Rightarrow модели не адекватны

РЕ-тест МакКиннона сравнение невложенных моделей

```
. reg EARNINGS S
```

```
-----  
EARNINGS |   Coef.      Std. Err.   t   P>|t|   [95% Conf. Interval]  
-----+-----  
          S |  1.073055   .1324501   8.10  0.000   .8129028  1.333206  
          _cons | -1.391004  1.820305  -0.76  0.445  -4.966354  2.184347  
-----
```

```
. predict EARN_hat  
. g lg_EARN_hat=log( EARN_hat)
```

```
. g lgEarn=log( EARNINGS)  
. reg lgEarn S
```

```
-----  
lgEarn |   Coef.      Std. Err.           t   P>|t|   [95% Conf. Interval]  
-----+-----  
          S |  .0792256   .0082061   9.65  0.000   .0631077  .0953435  
          _cons |  1.358919   .1127785  12.05  0.000   1.137406  1.580433  
-----
```

```
. predict lgEARN_hat  
. g EARN_exp_log=exp( lgEARN_hat)  
  
. g dEARN= EARN_hat- EARN_exp_log  
. g dLgEARN= lg_EARN_hat- lgEARN_hat
```

PE-тест МакКиннона сравнение невлоченных моделей

```
. reg EARNINGS S dLgEARN
```

```
-----  
EARNINGS |   Coef.   Std. Err.   t   P>|t|   [95% Conf. Interval]  
-----+-----  
      S |  1.089211  .135206   8.06  0.000   .8236454  1.35477  
dLgEARN | -5.783632  9.591753  -0.60  0.547  -24.62334  13.05607  
   _cons | -0.8961894  1.997658  -0.45  0.654  -4.819902  3.027523  
-----
```

```
. reg lgEarn S dEARN
```

```
-----  
lgEarn |   Coef.   Std. Err.   t   P>|t|   [95% Conf. Interval]  
-----+-----  
      S |  .0723465  .0112963   6.40  0.000   .0501589  .0945342  
dEARN |  .0582987  .0657774   0.89  0.376  -.0708984  .1874957  
   _cons |  1.362541  .1128738  12.07  0.000   1.140839  1.584243  
-----
```

Метод Зарембки

Применим для выбора из двух форм моделей (несравнимых непосредственно), в одной из которых зависимая переменная входит с логарифмом, а в другой - нет

Метод позволяет сравнить линейную и логарифмическую регрессии и оценить значимость наблюдаемых различий

Сравнение различных моделей парной регрессии

Метод Зарембки

1. Вычисляем среднее геометрическое значений зависимой переменной и все ее значения делятся на это среднее

$$Y_i^* = Y_i / \sqrt[n]{Y_1 Y_2 \dots Y_n} = Y_i / e^{\frac{1}{n}(\ln Y_1 + \ln Y_2 + \dots + \ln Y_n)}$$

2. Рассчитываются линейная и логарифмическая регрессии и сравниваются значения их суммы квадратов остатков (SSR)

$$Y_i^* = \alpha_1 + \beta_1 X_i + u_i; SSR_1$$

$$\ln Y_i^* = \alpha_2 + \beta_2 X_i + u_i; SSR_2$$

3. Вычисляем χ^2 -статистику для оценки значимости различий

$$\chi^2 = \left(\frac{n}{2} \right) \cdot \left| \ln \frac{SSR_1}{SSR_2} \right|$$

4. Сравниваем с критическим значением χ^2 -распределения с одной степенью свободы, различия значимы, если $\chi^2 > \chi^2_{\text{крит.}}$

Метод Зарембки

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

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

$Y^* = Y /$ среднее геометрическое Y

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

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

$$\frac{n}{2} \log_e \frac{\text{larger } RSS}{\text{smaller } RSS} \quad \chi^2(1)$$

Метод Зарембки

$$Y^* = (Y_1 Y_2 \dots Y_n)^{\frac{1}{n}}$$

. means EARNINGS

Variable	Type	Obs	Mean	[95% Conf. Interval]	
EARNINGS	Arithmetic	570	13.11782	12.44201	13.79364
	Geometric	570	11.36039	10.88473	11.85684
	Harmonic	570	10.00975	9.617686	10.43514

. g EARNSTAR= EARNINGS/11.36039

. g LGEARNSTAR=log(EARNSTAR)

Метод Зарембки

$$EARN^* = EARNINGS / \text{среднее геометрическое } EARNINGS$$

. reg EARNSTAR S

Source	SS	df	MS	
Model	30.818438	1	30.818438	Number of obs = 570
Residual	266.698183	568	.469539054	F(1, 568) = 65.64
Total	297.516621	569	.52287631	Prob > F = 0.0000
				R-squared = 0.1036
				Adj R-squared = 0.1020
				Root MSE = .68523

EARNSTAR	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
S	.0944558	.0116589	8.10	0.000	.0715559 .1173557
_cons	-.1224433	.1602326	-0.76	0.445	-.4371641 .1922775

. reg LGEARNSTAR S

Source	SS	df	MS	
Model	21.6812541	1	21.6812541	Number of obs = 570
Residual	132.120642	568	.232606765	F(1, 568) = 93.21
Total	153.801896	569	.270302103	Prob > F = 0.0000
				R-squared = 0.1410
				Adj R-squared = 0.1395
				Root MSE = .48229

LGEARNSTAR	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
S	.0792256	.0082061	9.65	0.000	.0631077 .0953435
_cons	-1.071213	.1127785	-9.50	0.000	-1.292727 -.8496997

Метод Зарембки

$$\frac{n}{2} \log_e \frac{\text{larger } RSS}{\text{smaller } RSS} = \frac{570}{2} \log_e \frac{266.7}{132.1} = 200.2$$

$$\chi_{\text{crit}}^2 = 10.83, 1 \text{ d.f, } 0.1\%$$

**Полулогарифмическая модель
больше подходит на 0.1% уровне
значимости**

Сравнение различных моделей парной регрессии

Метод Бокса-Кокса (Box-Cox)

Идея метода: переменная

$$\frac{Y^\lambda - 1}{\lambda}$$

при $\lambda=1$ превращается в линейную функцию

$$\frac{Y^1 - 1}{1}$$

а при $\lambda \rightarrow 0$ переходит в логарифм

$$\frac{Y^\lambda - 1}{\lambda} \rightarrow \ln Y$$

Плавно изменяя λ , можно постепенно перейти от линейной регрессии к логарифмической, все время сравнивая качество

Сравнение различных моделей парной регрессии

Метод Бокса-Кокса (Box-Cox)

1. Преобразуем зависимую переменную по методу Заремки

$$Y_i^* = Y_i / \sqrt[n]{Y_1 Y_2 \dots Y_n} = Y_i / e^{\frac{1}{n}(\ln Y_1 + \ln Y_2 + \dots + \ln Y_n)}$$

2. Рассчитываем новые переменные (преобразование Бокса-Кокса) при значениях λ от 1 до 0.

$$Y_{i(B-C)} = (Y_i^{*\lambda} - 1) / \lambda$$

и

$$X_{i(B-C)} = (X_i^\lambda - 1) / \lambda$$

3. Рассчитываем регрессии для новых переменных при значениях

λ от 1 до 0.

$$Y_{i(B-C)} = \alpha + \beta X_{i(B-C)} + u_i$$

4. Выбираем минимальное значение суммы квадратов остатков (SSR), выбираем одну из крайних регрессий, к которой ближе точка минимума.

BOX-COX TESTS

$$EARN^* = EARNINGS / \text{geometric mean of } EARNINGS$$

```
. boxcox EARNSTAR AGE S SEX , model(theta) nolog
```

```

                                Number of obs =   570
                                LR chi2(4)   =  122.13
Log likelihood = -367.8914        Prob > chi2   =   0.000
-----+-----
EARNSTAR |   Coef.  Std. Err.   z  P>|z|   [95% Conf. Interval]
-----+-----
 /lambda |   .6167905   .634108   0.97  0.331   -0.6260383   1.859619
 /theta  |  -0.2561972   .0677446  -3.78  0.000   -0.3889742  -0.1234203
-----+-----

```

```

-----+-----
Test          Restricted
H0:           log likelihood   chi2   Prob > chi2
-----+-----
theta=lambda = -1   -423.15698   110.53   0.000
theta=lambda = 0   -376.24123   16.70    0.000
theta=lambda = 1   -579.52174   423.26   0.000
-----+-----

```

Estimates of scale-variant parameters

```

-----+-----
                                |   Coef.
-----+-----
Notrans |
   _cons | -1.921976
-----+-----
Trans   AGE | .026491
        S  | .2225095
-----+-----
        /sigma | .4613885
-----+-----

```

BOX-COX TESTS

$$EARN^* = EARNINGS / \text{geometric mean of } EARNINGS$$

```
. boxcox EARNSTAR AGE S SEX , model(rhsonly) nolog
      Estimating full model
      Number of obs =    570
      LR chi2(4)    =   88.29
Log likelihood = -579.35478      Prob > chi2    =    0.000
```

EARNSTAR	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
+-----					
/lambda	1.442164	.7869089	1.83	0.067	-.1001486 2.984477

Test	Restricted	LR statistic	P-Value
H0:	log likelihood	chi2	Prob > chi2
+-----			
lambda = -1	-585.58984	12.47	0.000
lambda = 0	-581.35271	4.00	0.046
lambda = 1	-579.52174	0.33	0.563

Estimates of scale-variant parameters

	Coef.
+-----	
Notrans	
_cons	-.4541757
+-----	
Trans	
AGE	.0052884
S	.030497
SEX	.2244905
+-----	
/sigma	.6686285

BOX-COX TESTS

$$EARN^* = EARNINGS / \text{geometric mean of } EARNINGS$$

```
. boxcox EARNSTAR AGE S SEX , model(lhsonly) nolog
                                Number of obs =    570
                                LR chi2(3)   =   121.78
Log likelihood = -368.06337        Prob > chi2   =    0.000
```

```
-----
EARNSTAR |   Coef.  Std. Err.   z   P>|z|   [95% Conf. Interval]
-----+-----
 /theta |  -0.252988  .0674564  -3.75  0.000  -0.3852001  -0.1207759
-----
```

```
-----
Test      Restricted   LR statistic   P-Value
H0:      log likelihood   chi2   Prob > chi2
-----+-----
theta = -1  -422.73619    109.35    0.000
theta = 0   -375.39583    14.66    0.000
theta = 1   -579.52174    422.92    0.000
-----
```

Estimates of scale-variant parameters

```
-----
          |   Coef.
-----+-----
Notrans   |
          |
AGE |   .0075793
S |   .081562
SEX |   .2278146
_cons | -1.743971
-----+-----
/sigma |   .4615277
-----
```


BOX-COX TESTS

$$EARN^* = EARNINGS / \text{geometric mean of } EARNINGS$$

```
. boxcox lgEARNSTAR AGE S SEX , model(rhsonly) nolog
      Number of obs =   570
      LR chi2(4)    =  120.20
Log likelihood = -375.35439      Prob > chi2    =   0.000
```

```
-----+-----
lgEARNSTAR |   Coef.  Std. Err.   z  P>|z|   [95% Conf. Interval]
-----+-----
   /lambda | .811331  .6457532   1.26  0.209   - .454322   2.076984
-----+-----
```

```
-----+-----
Test      Restricted   LR statistic   P-Value
H0:      log likelihood   chi2     Prob > chi2
-----+-----
lambda = -1  -380.30004     9.89     0.002
lambda = 0   -376.24127     1.77     0.183
lambda = 1   -375.39587     0.08     0.773
-----+-----
```

Estimates of scale-variant parameters

```
-----+-----
          |   Coef.
-----+-----
Notrans  |
   _cons | -1.690962
-----+-----
Trans    |
   AGE   | .0182433
   S     | .1343269
   SEX   | .2448187
-----+-----
   /sigma | .4674691
-----+-----
```

Тест ошибочной спецификации Амемии (Акаике)

Является вариантом скорректированного коэффициента детерминации и превосходит его

$$PC = \frac{RSS \cdot (n + m)}{n - m}$$

Выбирается уравнение с меньшим значением PC

Смысл теста Амемии в том, что он позволяет минимизировать среднюю ошибку оценки b

$$MSE = Var(b) + (\text{смещение } b)^2$$

ИНФОРМАЦИОННЫЕ КРИТЕРИИ

$t = 1, \dots, n$

1. $y_t = f(\mathbf{X}_t, \boldsymbol{\varepsilon}_t); \quad \mathbf{X}_t = (X_{1t}, \dots, X_{kt})$

2. $y_t = g(\mathbf{Z}_t, \mathbf{v}_t); \quad \mathbf{Z}_t = (Z_{1t}, \dots, Z_{mt})$

AIC (Akaike information criterion):

$$AIC1 = \frac{2k}{n} \ln \left(\frac{RSS}{n} \right); \quad AIC2 = e^{\frac{2k}{n}} \frac{RSS}{n}$$

SIC (Schwarz information criterion):

$$SIC1 = \frac{k \ln(n)}{n} \ln \left(\frac{RSS}{n} \right); \quad SIC2 = n^{\frac{k}{n}} \frac{RSS}{n}$$

Первые множители - kind of degree of freedom penalty factor

Соответственно:

**ЧЕМ МЕНЬШЕ ЗНАЧЕНИЕ ИНФОРМАЦИОННОГО КРИТЕРИЯ,
ТЕМ МОДЕЛЬ ЛУЧШЕ**

BOX-COX TESTS

$$EARN^* = EARNINGS / \text{geometric mean of } EARNINGS$$

. reg EARNSTAR S

Source	SS	df	MS	
Model	30.818438	1	30.818438	Number of obs = 570
Residual	266.698183	568	.469539054	F(1, 568) = 65.64
Total	297.516621	569	.52287631	Prob > F = 0.0000

R-squared = 0.1036
Adj R-squared = 0.1020
Root MSE = .68523

. icomp

EARNSTAR	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
S	.0944558	.0116589	8.10	0.000	.0715559 .1173557
_cons	-.1224433	.1602326	-0.76	0.445	-.4371641 .1922775

Information criteria
AIC = 1186.66424
SBIC = 1191.00988
ICOMP = 1191.96900

. reg LGEARNSTAR S

Source	SS	df	MS	
Model	21.6812541	1	21.6812541	Number of obs = 570
Residual	132.120642	568	.232606765	F(1, 568) = 93.21
Total	153.801896	569	.270302103	Prob > F = 0.0000

R-squared = 0.1410
Adj R-squared = 0.1395
Root MSE = .48229

. icomp

LGEARNSTAR	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
S	.0792256	.0082061	9.65	0.000	.0631077 .0953435
_cons	-1.071213	.1127785	-9.50	0.000	-1.292727 -.8496997

Information criteria
AIC = 786.29502
SBIC = 790.64065
ICOMP = 791.59977

ИНФОРМАЦИОННЫЕ КРИТЕРИИ

$$EARN^* = EARNINGS / \text{geometric mean of } EARNINGS$$

```
. quietly reg EARNSTAR S
. fitstat, saving(IC)
```

Measures of Fit for regress of EARNSTAR

Log-Lik Intercept Only:	-623.498	Log-Lik Full Model:	-592.332
D(568):	1184.664	LR(1):	62.331
		Prob > LR:	0.000
R2:	0.104	Adjusted R2:	0.102
AIC:	2.085	AIC*n:	1188.664
BIC:	-2419.657	BIC':	-55.985

(Indices saved in matrix fs_IC)

```
. quietly reg lgEARNSTAR S
. fitstat, force u(IC)
```

Measures of Fit for regress of lgEARNSTAR

	Current	Saved	Difference
Model:	regress	regress	
N:	570	570	0
Log-Lik Intercept Only:	-435.453	-623.498	188.044
Log-Lik Full Model:	-392.148	-592.332	200.185
D:	784.295(568)	1184.664(568)	-400.369(0)
LR:	86.611(1)	62.331(1)	24.281(0)
Prob > LR:	0.000	0.000	-0.000
R2:	0.141	0.104	0.037
Adjusted R2:	0.139	0.102	0.037
AIC:	1.383	2.085	-0.702
AIC*n:	788.295	1188.664	-400.369
BIC:	-2820.026	-2419.657	-400.369
BIC':	-80.266	-55.985	-24.281

Конец лекции