

Ekonometrija 1

Sedme vaje:

Preverjanje specifikacije regresijskega modela. Vpliv linearnih transformacij spremenljivk na ocene parametrov regresijske funkcije.

Na sedmih vajah bomo najprej izvedli Ramseyev RESET test, ki je namenjen preverjanju pravilnosti specifikacije regresijskega modela ter Box-Coxov test, ki ga uporabljamo pri odločanju med linearnim in dvojno logaritemskim modelom. Nato bomo proučili še vpliv linearnih transformacij na ocene parametrov regresijske funkcije.



Primer 1: Na podlagi spodnjih podatkov (datoteka `stroski.dta`) o obsegu proizvodnje določene dobrine (Q ; v kosih) in o celotnih stroških (C ; v denarnih enotah) ocenite linearno funkcijo celotnih stroškov.

Q	1	2	3	4	5	6	7	8	9	10
C	150	220	250	260	265	280	295	350	410	520

S pomočjo ustreznega testa preverite ustreznost takšne specifikacije in pojasnite temeljno slabost uporabljenega testa. Kakšno specifikacijo funkcije celotnih stroškov predlagate?

Izpis rezultatov obdelav v programskem paketu Stata:

```
. regress c q
```


Source	SS	df	MS	Number of obs =	10
Model	84480	1	84480	F(1, 8) =	51.32
Residual	13170	8	1646.25	Prob > F =	0.0001
Total	97650	9	10850	R-squared =	0.8651
				Adj R-squared =	0.8483
				Root MSE =	40.574

c	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
q	32	4.467051	7.16	0.000	21.69896 42.30104
_cons	124	27.71732	4.47	0.002	60.08374 187.9163

```
. predict ce, resid
```

```
. predict chat, xb
```

```
. scatter ce chat
```



```
. gen c2=chat^2
```

```
. gen c3=chat^3
```

```
. regress c q c2 c3
```

Source	SS	df	MS	Number of obs =	10
Model	97437.2086	3	32479.0695	F(3, 6) =	915.80
Residual	212.791375	6	35.4652292	Prob > F =	0.0000
Total	97650	9	10850	R-squared =	0.9978
				Adj R-squared =	0.9967
				Root MSE =	5.9553

c	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
q	365.2392	27.13037	13.46	0.000	298.8536 431.6249
c2	-.0402067	.0029539	-13.61	0.000	-.0474347 -.0329787
c3	.0000481	3.27e-06	14.71	0.000	.0000401 .0000561
_cons	584.8318	30.1545	19.39	0.000	511.0464 658.6172

```
. display invFtail(2,6,0.05)
```

```
5.1432528
```

```
. display Ftail(2,6,180.95)
```

```
4.338e-06
```



Primer 2: Na podlagi podatkov za Slovenijo (razdobje 1965–1989), ocenite linearno in dvojno logaritemsko funkcijo porabe (datoteka potrosnja1.dta):

$$OP_t = \beta_1 + \beta_2 OD_t + \beta_3 SOC_t + u_t,$$

$$\ln OP_t = \beta_1 + \beta_2 \ln OD_t + \beta_3 \ln SOC_t + u_t,$$

pri čemer so spremenljivke naslednje (vse v cenah iz leta 1972):

- ♦ OP_t : osebna poraba v mio DIN;
- ♦ OD_t : osebni dohodki v mio DIN;
- ♦ SOC_t : socialni prejemki v mio DIN.

Razložite postopek primerjave razlagalne moči regresijskih modelov na podlagi vrednosti determinacijskih koeficientov. Ali lahko zavrtnemo ničelno domnevo, da sta modela empirično enakovredna?

Izpis rezultatov obdelav v programskem paketu Stata:

* Primerjava multiplih determinacijskih koeficientov:

```
. gen lop=log(op)
. gen lod=log(od)
. gen lsoc=log(soc)

. regress op od soc
```

Source	SS	df	MS	Number of obs =	25
Model	3.67855587	2	1.83927794	F(2, 22) =	253.82
Residual	.1594234	22	.007246518	Prob > F =	0.0000
				R-squared =	0.9585
				Adj R-squared =	0.9547
Total	3.83797927	24	.159915803	Root MSE =	.08513

op	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
od	.6648524	.0872809	7.62	0.000	.4838429 .8458619
soc	.9483866	.283467	3.35	0.003	.360512 1.536261
_cons	.2653599	.0937114	2.83	0.010	.0710144 .4597054

. ereturn list

scalars:

```
e(N) = 25
e(df_m) = 2
e(df_r) = 22
e(F) = 253.8154037665093
e(r2) = .9584616308434277
e(rmse) = .0851264833658064
e(mss) = 3.678555870555993
e(rss) = .159423399745036
e(r2_a) = .9546854154655575
e(ll) = 27.7148810369553
e(ll_0) = -12.04934047424811
e(rank) = 3
```

matrices:

```
e(b) : 1 x 3
e(V) : 3 x 3
```

functions:

```
e(sample)
```

```
. scalar opaz=e(N)
. scalar par=e(rank)
. scalar nvklin=e(rss)
```

```
. regress lop lod lsoc
```

Source	SS	df	MS	Number of obs =	25
Model	1.11851042	2	.559255212	F(2, 22) =	279.30
Residual	.044051471	22	.00200234	Prob > F =	0.0000
				R-squared =	0.9621
				Adj R-squared =	0.9587
Total	1.16256189	24	.048440079	Root MSE =	.04475

lop	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
lod	.6994262	.1117262	6.26	0.000	.4677203 .9311321
lsoc	.1758547	.0753965	2.33	0.029	.0194919 .3322175
_cons	.3604694	.1452971	2.48	0.021	.0591417 .661797

```
. scalar nvklog=e(rss)
```

```
. display opaz, par, nvklin, nvklog
```

```
25 3 .1594234 .04405147
```

```
. qui regress lop lod lsoc
```

```
. predict yloghat, xb
```

```
. gen antilyloghat=exp(yloghat)
```

```
. correlate op antilyloghat
```

```
(obs=25)
```

	op antily~t	
op	1.0000	
antilyloghat	0.9793	1.0000

```
. return list
```

```
scalars:
```

```
    r(N) = 25
    r(rho) = .9792916410344565
```

```
matrices:
```

```
    r(C) : 2 x 2
```

```
. scalar r2p=r(rho)^2
```

```
. display r2p
```

```
.95901212
```

```
* Box-Coxov test (originalni postopek):
```

```
. means op
```

Variable	Type	Obs	Mean	[95% Conf. Interval]
op	Arithmetic	25	1.985546	1.820478 2.150614
	Geometric	25	1.942643	1.773935 2.127395
	Harmonic	25	1.89542	1.724275 2.104283

```
. return list
```

```
scalars:
```

```
    r(ub_h) = 2.104283291203963
    r(lb_h) = 1.724275335263516
    r(Var_h) = .0160941132749612
```

```

r(mean_h) = 1.895420251551919
r(ub_g) = 2.127395190730542
r(lb_g) = 1.773934675261189
r(Var_g) = .0484400787132108
r(mean_g) = 1.942642555083358
r(N_pos) = 25
r(ub) = 2.150614442816441
r(lb) = 1.820477571496302
r(Var) = .1599158029292095
r(mean) = 1.985546007156372
r(N) = 25

```

```
. scalar gmean=r(mean_g)
```

```
. display gmean
```

```
1.9426426
```

```
. scalar lstat=(opaz/2)*abs(log(nvklin/(gmean^2)/nvklog))
```

```
. display lstat
```

```
.52366949
```

```
. display invchi2tail(1,0.05)
```

```
3.8414588
```

```
. display chi2tail(1,lstat)
```

```
.46928056
```

```
. display nvklin/(gmean^2), nvklog
```

```
.04224412 .04405147
```

```
* Box-Coxov test (modificirani postopek):
```

```
. gen opt=op/gmean
```

```
. regress opt od soc
```

Source	SS	df	MS	Number of obs =	25
Model	.974746187	2	.487373094	F(2, 22) =	253.82
Residual	.042244111	22	.001920187	Prob > F =	0.0000
Total	1.0169903	24	.042374596	R-squared =	0.9585
				Adj R-squared =	0.9547
				Root MSE =	.04382

opt	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
od	.3422413	.0449289	7.62	0.000	.2490643 .4354182
soc	.4881941	.1459182	3.35	0.003	.1855782 .79081
_cons	.1365974	.0482391	2.83	0.010	.0365556 .2366392

```
. scalar nvklint=e(rss)
```

```
. scalar lstatmod=(opaz/2)*abs(log(nvklint/nvklog))
```

```
. display lstatmod
```

```
.52367237
```

```
. display invchi2tail(1,0.05)
```

```
3.8414588
```

```
. display chi2tail(1,lstatmod)
```

```
.46927934
```

```
. display nvklint, nvklog
```

```
.04224411 .04405147
```

Primer 3: Za 10 evropskih držav smo proučevali odvisnost števila avtomobilov na 1.000 prebivalcev ($AVTO$) od bruto domačega proizvoda na prebivalca (v USD) (BDP) in števila izdanih vozniških dovoljenj v milijonih (DOV) ter ocenili naslednjo regresijsko funkcijo:

$$\widehat{AVTO} = 17,5701 + 0,02187BDP + 2,78452DOV \quad R^2 = 0,9223$$

$$t: \quad (0,39) \quad (6,18) \quad (3,23) \quad s_e = 36,34$$

Zapišite regresijsko funkcijo z ocenami vseh pripadajočih parametrov, če bi bila odvisna spremenljivka število avtomobilov na 100 prebivalcev, število vozniških dovoljenj izraženo v tisočih, bruto domači proizvod na prebivalca pa v evrih (upoštevajte 1 EUR = 1,15 USD).

Primer 4: Na podlagi podatkov za preteklo leto smo za 100 slučajno izbranih gospodinjstev ocenili naslednjo funkcijo odvisnosti višine izdatkov za poletni dopust od realnega razpoložljivega dohodka:

$$\widehat{\ln DOP} = -11,1 + 1,45 \ln RRD \quad R^2 = 0,935 \quad s_e = 0,284$$

$$(-4,1) \quad (7,3)$$

Pri tem smo z DOP označili izdatke za dopust v 1.000 SIT, z RRD pa realni razpoložljivi dohodek prav tako v 1.000 SIT. Kakšne bi bile ocene parametrov te funkcije, če bi bili obe spremenljivki izraženi v SIT (namesto v 1.000 SIT, kot do sedaj)?

■