

Ekonometrija 1

Dvanajste vaje:

Odsotnost koreliranosti slučajne spremenljivke in avtokorelacija.

Na dvanajstih vajah bomo nadaljevali z obravnavo in preverjanjem predpostavke o odsotnosti avtokorelacije v klasičnem linearnem regresijskem modelu. Spoznali bomo različne teste za preverjanje morebitne prisotnosti avtokorelacije in postopek ocenjevanja regresijskih modelov, kadar je v modelu prisotna avtokorelacija.



Primer 1: Na podlagi četrtnih podatkov za štiriletno obdobje 1980–1984 smo ocenjevali odvisnost osebne porabe (*OP*) od bruto domačega proizvoda (*BDP*) in dobili naslednje vrednosti ostankov ocenjenega regresijskega modela potrošne funkcije (glejte datoteko *potrosnja_ostanki.dta*):

t	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
e_t	0,7	-1	0,5	-1	1	-0,2	1	-1,5	0,5	-1,5	1,3	-1	1,2	-0,6	1	-0,4

Preverite ustrezno domnevo o prisotnosti avtokorelacije četrtega reda, ocenite njen koeficient in ga razložite. Katero metodo ocenjevanja bi uporabili, da bi prišli do NENALICE ocen regresijskih koeficientov? Ob upoštevanju izračunane ocene koeficienta avtokorelacije zapišite model, ki bi ga ocenjevali pri uporabi te metode.

Izpis rezultatov obdelav v programskem paketu Stata:

```
. tsset kvartal
      time variable: kvartal, 1980q1 to 1983q4
      delta: 1 quarter

. gen eop4=eop[_n-4]
(4 missing values generated)

. gen eopkv=eop^2

. gen eop4kv=eop4^2
(4 missing values generated)

. gen eeop4kv=(eop-eop4)^2
(4 missing values generated)

. gen eeop4prod=eop*eop4
(4 missing values generated)
```

. list kvartal eop eopkv eop4 eop4kv eeop4kv eeop4prod

	kvartal	eop	eopkv	eop4	eop4kv	eeop4kv	eeop4p~d
1.	1980q1	.7	.49
2.	1980q2	-1	1
3.	1980q3	.5	.25
4.	1980q4	-1	1
5.	1981q1	1	1	.7	.49	.09	.7
6.	1981q2	-.2	.04	-1	1	.64	.2
7.	1981q3	1	1	.5	.25	.25	.5
8.	1981q4	-1.5	2.25	-1	1	.25	1.5
9.	1982q1	.5	.25	1	1	.25	.5
10.	1982q2	-1.5	2.25	-.2	.04	1.69	.3
11.	1982q3	1.3	1.69	1	1	.09	1.3
12.	1982q4	-1	1	-1.5	2.25	.25	1.5
13.	1983q1	1.2	1.44	.5	.25	.4900001	.6
14.	1983q2	-.6	.36	-1.5	2.25	.8099999	.9
15.	1983q3	1	1	1.3	1.69	.09	1.3
16.	1983q4	-.4	.16	-1	1	.36	.4

. tabstat eop eopkv eop4 eop4kv eeop4kv eeop4prod, stat(sum)

stats	eop	eopkv	eop4	eop4kv	eeop4kv	eeop4p~d
sum	-4.47e-08	15.18	-1.2	12.22	5.26	9.7

. regress eop eop4, nocons

Source	SS	df	MS	Number of obs = 12		
Model	7.6996727	1	7.6996727	F(1, 11)	=	17.87
Residual	4.74032732	11	.430938848	Prob > F	=	0.0014
				R-squared	=	0.6189
				Adj R-squared	=	0.5843
Total	12.44	12	1.03666667	Root MSE	=	.65646

eop	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
eop4	.7937807	.1877899	4.23	0.001	.3804579	1.207103

Primer 2: Za Slovenijo so na podlagi podatkov za obdobje tridesetih let proučevali umrljivost zaradi bolezni srca in ožilja (*UBSO*) v odvisnosti od prodaje cigaret (*CIG*) in alkoholnih pijač (*ALK*), vse na 1.000 prebivalcev, starejših od 18 let in dobili naslednje rezultate:

$$\widehat{UBSO} = 139,7 + 10,706CIG + 26,749ALK.$$

Izračunali so tudi koeficient avtokorelacije prvega reda v višini $\hat{\rho}_1 = 0,35$.

- a) S pomočjo Durbin-Watsonovega testa preverite, ali je v modelu prisotna avtokorelacija prvega reda. Pojasnite vaše ugotovitve.
- b) Na podlagi ostankov zgornjega modela so ocenili tudi naslednji regresijski model:

$$\hat{e}_t = 113,6 - 4,675CIG_t + 0,361ALK_t + 0,259e_{t-1}$$

$$t_j: (1,4) \quad (-3,1) \quad (0,1) \quad (2,4)$$

in ugotovili, da je determinacijski koeficient enak 0,425. Pojasnite, zakaj so ocenjevali model na podlagi ostankov in do kakšne ugotovitve so prišli.

- c) Zapišite model, ki bi ga ocenili, da bi prišli do NENALICE ocen regresijskih koeficientov modela umrljivosti zaradi bolezni srca in ožilja. Pojasnite metodo, ki bi jo pri tem uporabili.

■

Primer 3: Na podlagi četrtnih podatkov za ZDA za obdobje 1976q1–1990q4 ocenite naslednjo funkcijo povpraševanja po novih avtomobilih (glejte datoteko `avtotrg.dta`):

$$AVTOP_t = \beta_1 + \beta_2 CENA_t + \beta_3 RRDP_t + \beta_4 OM_t + u_t.$$

Pri tem imajo posamezne spremenljivke naslednji pomen:

- ◆ *AVTOP*: število prodanih novih avtomobilov na 1.000 prebivalcev;
- ◆ *CENA*: indeks cen novih avtomobilov (1982q1=100);
- ◆ *RRDP*: realni razpoložljivi dohodek na prebivalca (v 1.000 USD);
- ◆ *OM*: referenčna obrestna mera pri poslovnih bankah (v %).

- a) S pomočjo Wallisovega testa preverite, ali je v modelu prisotna avtokorelacija četrtega reda. Pojasnite vaše ugotovitve.
- b) S pomočjo Breusch–Godfreyevega testa preverite, ali je v modelu prisotna avtokorelacija prvega in četrtega reda. Pojasnite vaše ugotovitve.
- c) S pomočjo metode PNK–PDE odpravite prisotnost avtokorelacije tistega reda, pri katerem ste zavrnilo ničelno domnevo o odsotnosti avtokorelacije.
- d) Nazadnje s pomočjo Newey–Westove robustne cenilke variance izračunajte nepristranske standardne napake ocen parametrov. Katero predpostavko klasičnega linearnega regresijskega modela ste pri tem sprostili in kako?

Izpis rezultatov obdelav v programskem paketu Stata:

```
. tsset kvartal
      time variable: kvartal, 1976q1 to 1990q4
              delta: 1 quarter

. regress avtop cena rrdp om
```

Source	SS	df	MS	
Model	85.0940388	3	28.3646796	Number of obs = 60
Residual	50.1162514	56	.894933061	F(3, 56) = 31.69
				Prob > F = 0.0000
				R-squared = 0.6293
				Adj R-squared = 0.6095
				Root MSE = .94601
Total	135.21029	59	2.29169983	

avtop	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
cena	-.1062054	.0200516	-5.30	0.000	-.1463737 -.0660371
rrdp	1.241812	.4282211	2.90	0.005	.3839823 2.099642
om	-.1344411	.042009	-3.20	0.002	-.2185954 -.0502869
_cons	7.012139	3.027984	2.32	0.024	.9463581 13.07792

. predict eavto, resid

. gen eavto1=eavto[_n-1]

(1 missing value generated)

. gen eavto2=eavto[_n-2]

(2 missing values generated)

. gen eavto3=eavto[_n-3]

(3 missing values generated)

. gen eavto4=eavto[_n-4]

(4 missing values generated)

. * Analiza prisotnosti avtokorelacije - Wallisov test

. gen eavtokv=eavto^2

. gen eavto4kv=eavto4^2

(4 missing values generated)

. gen eeavto4kv=(eavto-eavto4)^2

(4 missing values generated)

. gen eeavto4prod=eavto*eavto4

(4 missing values generated)

. list kvartal eavto eavtokv eavto4 eavto4kv eeavto4kv eeavto4prod

	kvartal	eavto	eavtokv	eavto4	eavto4kv	eeavto4kv	eeavto4prod
1.	1976q1	-1.067209	1.138935
2.	1976q2	.5253704	.276014
3.	1976q3	-1.456546	2.121525
4.	1976q4	-.5159836	.266239
5.	1977q1	-.582527	.3393378	-1.067209	1.138935	.2349165	.6216781
6.	1977q2	1.252402	1.56851	.5253704	.276014	.5285746	.6579747
7.	1977q3	-.9657158	.9326069	-1.456546	2.121525	.2409139	1.406609
8.	1977q4	.0304209	.0009254	-.5159836	.266239	.2985578	-.0156967
9.	1978q1	-.7090446	.5027443	-.582527	.3393378	.0160067	.4130377
10.	1978q2	2.306667	5.320712	1.252402	1.56851	1.111475	2.888874
11.	1978q3	-.1883967	.0354933	-.9657158	.9326069	.6042249	.1819376
12.	1978q4	.6686234	.4470572	.0304209	.0009254	.4073024	.0203401
...							
54.	1989q2	.6095216	.3715166	.5555025	.3085831	.0029181	.3385908
55.	1989q3	-.2026313	.0410595	-.6689267	.4474629	.2174313	.1355455
56.	1989q4	-1.759974	3.097507	-.5935605	.352314	1.360519	1.044651
57.	1990q1	-.6735533	.4536741	-.5637868	.3178556	.0120487	.3797405
58.	1990q2	-.1304011	.0170044	.6095216	.3715166	.5474855	-.0794823
59.	1990q3	-.8716098	.7597036	-.2026313	.0410595	.4475322	.1766154
60.	1990q4	-1.050922	1.104437	-1.759974	3.097507	.5027543	1.849595

```
. tabstat eavto eavtokv eavto4 eavto4kv eeavto4kv eeavto4prod, stat(sum)
```

stats	eavto	eavtokv	eavto4	eavto4kv	eeavto~v	eeavto~d
sum	2.11e-07	50.11625	2.726486	47.78143	46.20951	23.94273

```
. regress eavto eavto4, nocons
```

Source	SS	df	MS	Number of obs =	56
Model	11.9974278	1	11.9974278	F(1, 55) =	19.23
Residual	34.3161111	55	.623929294	Prob > F =	0.0001
				R-squared =	0.2590
				Adj R-squared =	0.2456
Total	46.313539	56	.827027482	Root MSE =	.78989

eavto	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
eavto4	.5010886	.1142715	4.39	0.000	.2720833 .7300939

```
. scalar rho4=_b[eavto4]
```

```
. display rho4
```

```
.50108856
```

```
. * Analiza prisotnosti avtokorelacije - Breusch-Godfreyev test (LM-test)
```

```
. regress eavto cena rrdp om eavto1
```

Source	SS	df	MS	Number of obs =	59
Model	1.96779105	4	.491947762	F(4, 54) =	0.57
Residual	46.9902221	54	.870189298	Prob > F =	0.6888
				R-squared =	0.0402
				Adj R-squared =	-0.0309
Total	48.9580131	58	.844103674	Root MSE =	.93284

eavto	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
cena	.000112	.0198404	0.01	0.996	-.0396656 .0398895
rrdp	-.0573849	.4234228	-0.14	0.893	-.9062965 .7915268
om	-.0090774	.0418563	-0.22	0.829	-.0929943 .0748394
eavto1	.1955674	.1336053	1.46	0.149	-.0722951 .4634298
_cons	.7134742	3.012302	0.24	0.814	-5.325827 6.752776

```
. scalar lm=e(N)*e(r2)
```

```
. display lm, invchi2tail(1,0.05), chi2tail(1,lm)
```

```
2.3714131 3.8414588 .12357515
```

```
. qui regress avtop cena rrdp om
```

```
. estat bgodfrey, nomiss0
```

```
Breusch-Godfrey LM test for autocorrelation
```

lags(p)	chi2	df	Prob > chi2
1	2.371	1	0.1236

```
H0: no serial correlation
```

. estat bgodfrey

Breusch-Godfrey LM test for autocorrelation

lags(p)	chi2	df	Prob > chi2
1	2.216	1	0.1366

H0: no serial correlation

. regress eavto cena rrdp om eavto1 eavto2 eavto3 eavto4

Source	SS	df	MS	Number of obs =	56
Model	14.3397788	7	2.04853983	F(7, 48) =	3.09
Residual	31.8608665	48	.663768051	Prob > F =	0.0091
				R-squared =	0.3104
				Adj R-squared =	0.2098
Total	46.2006453	55	.840011733	Root MSE =	.81472

eavto	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
cena	-.0081954	.0176914	-0.46	0.645	-.0437664 .0273756
rrdp	-.0202633	.3717259	-0.05	0.957	-.7676683 .7271417
om	-.0129544	.0382697	-0.34	0.736	-.0899007 .0639919
eavto1	.1590121	.1251251	1.27	0.210	-.0925687 .410593
eavto2	.0195439	.1244907	0.16	0.876	-.2307614 .2698492
eavto3	-.0108442	.1231711	-0.09	0.930	-.2584964 .236808
eavto4	.4962443	.1209597	4.10	0.000	.2530386 .7394501
_cons	1.21177	2.697192	0.45	0.655	-4.211298 6.634837

. scalar lm=e(N)*e(r2)

. display lm, invchi2tail(4,0.05), chi2tail(4,lm)

17.381307 9.487729 .00162948

. qui regress avtop cena rrdp om

. estat bgodfrey, lags(4) nomiss0

Breusch-Godfrey LM test for autocorrelation

lags(p)	chi2	df	Prob > chi2
4	17.381	4	0.0016

H0: no serial correlation

. estat bgodfrey, lags(4)

Breusch-Godfrey LM test for autocorrelation

lags(p)	chi2	df	Prob > chi2
4	16.031	4	0.0030

H0: no serial correlation

. * Odpravljanje avtokorelacije 4. reda - Cenilka PNK-PDE

. gen avtopt=avtop-rho4*avtop[_n-4]

(4 missing values generated)

. gen cenat=cena-rho4*cena[_n-4]

(4 missing values generated)

```
. gen rrdpt=rrdp-rho4*rrdp[_n-4]
(4 missing values generated)
```

```
. gen omt=om-rho4*om[_n-4]
(4 missing values generated)
```

```
. regress avtopt cenat rrdpt omt
```

Source	SS	df	MS	Number of obs =	56
Model	29.766538	3	9.92217934	F(3, 52) =	16.51
Residual	31.249213	52	.600946404	Prob > F =	0.0000
Total	61.015751	55	1.10937729	R-squared =	0.4879
				Adj R-squared =	0.4583
				Root MSE =	.77521

avtopt	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
cenat	-.1615359	.0252778	-6.39	0.000	-.2122596 -.1108122
rrdpt	2.045067	.4390604	4.66	0.000	1.164028 2.926106
omt	-.1053125	.0426628	-2.47	0.017	-.1909217 -.0197033
_cons	1.919934	1.622358	1.18	0.242	-1.335566 5.175434

```
. scalar b1=_b[_cons]/(1-rho4)
. display b1
3.8482452
```

```
. gen avtoptfit=b1+_b[cenat]*cena+_b[rrdpt]*rrdp+_b[omt]*om
```

```
. correlate avtop avtoptfit
(obs=60)
```

	avtop	avtoptfit
avtop	1.0000	
avtoptfit	0.7858	1.0000

```
. scalar r2p=r(rho)^2
. display r2p
.61754546
```

```
. * Newey-Westova metoda korekcije MNKVD standardnih napak
```

```
. newey avtop cena rrdp om, lag(4)
```

```
Regression with Newey-West standard errors          Number of obs =          60
maximum lag: 4                                     F( 3, 56) =          31.49
                                                    Prob > F =          0.0000
```

	Coef.	Newey-West Std. Err.	t	P> t	[95% Conf. Interval]
cena	-.1062054	.022225	-4.78	0.000	-.1507274 -.0616834
rrdp	1.241812	.4820666	2.58	0.013	.2761169 2.207508
om	-.1344411	.0281841	-4.77	0.000	-.1909006 -.0779817
_cons	7.012139	3.344186	2.10	0.041	.3129298 13.71135