

MANUAL STATA 10.1: TESTES DE AUTOCORRELAÇÃO, ESTACIONARIDADE, CO-INTEGRAÇÃO, CAUSALIDADE DE GRANGER E MODELOS ARIMA

Renata Rojas Guerra *

PASSO 1: Gerando as variáveis[†]

Variável Logarítmica: `gen logvar = log(var1)`

Variável de tempo anual: `gen time = y(1980)+_n-1`

Variável de tempo mensal: `gen time = m(1980m1)+_n-1`

Variável de tempo trimestral: `gen time = q(1980q1)+_n-1`

PASSO 2: Declarar que é série temporal

Statistics > Time Series > Setup and Utilities > Declarare dataset to be time-series data

Selecionar Time variable (variável de tempo) e periodicidade (daily, weekly, monthly, quarterly, half-yearly, yearly generic – diário, semanal, mensal, trimestral, semestral, anual)

Comando: `tsset time, yearly`[‡]

PASSO 3: Rodar regressão

Comando: `reg var1 var2`

PASSO 4: Teste d de Durbin Watson para auto-correlação

Comando: `dwstat`

Output 01: Exemplo baseado na regressão “`reg logrpd logdcp logpib`” – tabela 21.1 Gujarati 4º edição

* Estudante do curso de Ciências Econômicas da Universidade Federal de Santa Maria e integrante do Grupo de Pesquisa em Agronegócios - UFSM. E-mail: renata.objetivajr@yahoo.com.br

[†] É importante destacar que as variáveis são nomeadas a critério do pesquisador, sendo as nomeações utilizadas no presente manual apenas ilustrativas.

[‡] Este exemplo trata apenas de séries anuais. Assim, ao utilizar o comando para declarar a série temporal é importante lembrar que este varia de acordo com a periodicidade das mesmas.

```
. dwstat  
Durbin-watson d-statistic( 3, 88) = .5613739
```

Ho: Ausência de Autocorrelação

Compara-se o valor calculado da estatística d com os valores críticos dL e dU, encontrados na Tabela D.5 do Apêndice D – Gujarati.

Se $d_{calc} < d_L$ – há autocorrelação positiva

Se $d_L < d_{calc} < d_U$ – zona de indecisão

Se $d_U < d_{calc} < 4 - d_U$ – não há autocorrelação

Se $4 - d_U < d_{calc} < 4 - d_L$ – zona de indecisão

Se $4 - d_L < d_{calc}$ – há autocorrelação negativa

No exemplo d_{calc} 0,56 é menor que d_L 1,575, ou seja, há autocorrelação positiva.

PASSO 5: Regressão espúria

```
. reg logrpd logdcp logpib
```

Source	SS	df	MS			
Model	2.58463385	2	1.29231692	Number of obs =	88	
Residual	.014330049	85	.000168589	F(2, 85) =	7665.50	
				Prob > F	= 0.0000	
				R-squared	= 0.9945	
				Adj R-squared	= 0.9944	
Total	2.5989639	87	.029873148	Root MSE	= .01298	

logrpd	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
logdcp	.8943569	.1104107	8.10	0.000	.6748308	1.113883
logpib	.0491394	.124155	0.40	0.693	-.197714	.2959929
_cons	.5217883	.1727425	3.02	0.003	.1783299	.8652467

Compara-se o valor do R^2 com a estatística d de Durbin-Watson pois “um $R^2 > d$ é uma boa regra de bolso para se suspeitar que a regressão seja espúria”.

No exemplo, como o valor de $R^2 = 0,9945$ é maior que $d = 0,5613$ há fortes razões para se acreditar que a regressão é espúria.

PASSO 6: Teste Breusch-Godfrey ou teste LM – uma alternativa ao teste d

Gerar resíduo: predict u, residuals

Verificar número de defasagem do resíduo através dos critérios de informação de Akaike e

Schwarz: varsoc u

Selection-order criteria
Sample: 1971q1 - 1991q4

Number of obs = 84

lag	LL	LR	df	p	FPE	AIC	HQIC	SBIC
0	246.989				.000167	-5.85689	-5.84526	-5.82795
1	276.76	59.541*	1	0.000	.000084	-6.54191	-6.51864	-6.48403*
2	278.482	3.4444	1	0.063	.000083*	-6.5591*	-6.5242*	-6.47229
3	278.54	.11599	1	0.733	.000085	-6.53667	-6.49014	-6.42092
4	278.659	.23668	1	0.627	.000087	-6.51568	-6.45752	-6.37099

Endogenous: u
Exogenous: _cons

Para o caso de divergência entre estes resultados opta-se, embasado pelo princípio da parcimônia, pela utilização da menor defasagem indicada por um destes critérios, neste caso uma defasagem.

Comando: qui regress log logrpd logdcp logpib

Comando para o teste LM: estat bgodfrey, lags(1)

Breusch-Godfrey LM test for autocorrelation

lags(ρ)	chi2	df	Prob > chi2
1	45.182	1	0.0000

H0: no serial correlation

Para este exemplo, ao observar que existe 0% de probabilidades de aceitar a hipótese nula de ausência de autocorrelação, a mesma pode ser rejeitada. Observa-se que esse resultado converge com aqueles obtidos através do teste d de Durbin-Watson.

PASSO 7: Procedimento Iterativo de Cochrane-Orcutt – Medida corretiva para autocorrelação

Statistics > timeseries > prais winstein regression

Selecionar variável dependente e independente, dentre as Options selecionar “Single-lag OLS of residuals” e marcar o quadro “Cochrane-Orcutt transformation”

Comando: Orcutt prais logrpd logdcp logpib, rhotype(regress) corc

```
. prais logrpd logdcp logpib, rhotype(regress) corc
```

```
Iteration 0: rho = 0.0000
Iteration 1: rho = 0.7043
Iteration 2: rho = 0.7418
Iteration 3: rho = 0.7474
Iteration 4: rho = 0.7485
Iteration 5: rho = 0.7487
Iteration 6: rho = 0.7487
Iteration 7: rho = 0.7487
Iteration 8: rho = 0.7487
Iteration 9: rho = 0.7487
```

Cochrane-Orcutt AR(1) regression -- iterated estimates

Source	SS	df	MS			
Model	.149837762	2	.074918881	Number of obs =	87	
Residual	.006373248	84	.000075872	F(2, 84) =	987.44	
Total	.15621101	86	.001816407	Prob > F =	0.0000	
				R-squared =	0.9592	
				Adj R-squared =	0.9582	
				Root MSE =	.00871	

	logrpd	logdcp	logpib	_cons	rho
Coef.	.5987303	.3615925	.2588602		.7487009
Std. Err.	.1243159	.1374901	.2391571		
t	4.82	2.63	1.08		
P> t	0.000	0.010	0.282		
[95% Conf. Interval]	.3515144 .8459462	.0881784 .6350066	-.21673 .7344503		

```
Durbin-watson statistic (original) 0.561374
Durbin-watson statistic (transformed) 2.254137
```

O valor em destaque refere-se à estatística d de Durbin-Watson após a aplicação do procedimento iterativo de Cochrane-Orcutt. Neste exemplo, como $d_{calc} = 2,25$ é maior que o limite crítico $d_U = 1,721$, concluí-se que este procedimento corrigiu o problema de autocorrelação do modelo, caso contrário seria necessária a busca de outras medidas de correção.

PASSO 8: Teste Dickey Fuller Aumentado (ADF) – teste de estacionaridade

Primeiramente é necessário saber o número de defasagens da série através dos critérios de informação de Akaike e Schwarz. Aqui novamente, se houver divergências entre AIC e BIC opta-se, embasado pelo princípio da parcimônia, pela utilização da menor defasagem indicada por um destes critérios.

Comando: `varsoc logrpd`

Selection-order criteria
Sample: 1971q1 - 1991q4

Number of obs = 84

lag	LL	LR	df	p	FPE	AIC	HQIC	SBIC
0	33.8402				.026788	-.781909	-.770276	-.752971
1	263.812	459.94*	1	0.000	.000115*	-6.23363*	-6.21036*	-6.17575*
2	264.011	.3967	1	0.529	.000117	-6.21454	-6.17964	-6.12772
3	264.047	.07358	1	0.786	.00012	-6.19161	-6.14507	-6.07585
4	264.966	1.8373	1	0.175	.00012	-6.18967	-6.1315	-6.04498

Endogenous: logrpd
Exogenous: _cons

Como ambos os critérios apontaram para a utilização de uma defasagem, aplica-se o teste.

Comando: `dfuller logrpd, lags(1)`

Augmented Dickey-Fuller test for unit root

Number of obs = 86

	Test Statistic	1% Critical Value	Interpolated Dickey-Fuller 5% Critical Value	10% Critical Value
$z(t)$	-1.531	-3.530	-2.901	-2.586

Mackinnon approximate p-value for $z(t)$ = 0.5182

Lags = número de defasagens, atribuídas através dos critérios AIC e BIC

H_0 : há uma raiz unitária, a série temporal é não estacionária.

Neste caso aceita-se a hipótese nula de ausência de estacionaridade pois $dfuller$ calculado é menor que $dfuller$ crítico, até mesmo para o nível de significância de 10%.

PASSO 9: Teste Phillips-Perron – outro teste de estacionaridade

Comando: `pperron var1, lags(1)`

Phillips-Perron test for unit root		Interpolated Dickey-Fuller		
Test Statistic	1% Critical Value	5% Critical Value	10% Critical Value	
Z(rho)	-0.911	-19.566	-13.596	-10.922
Z(t)	-1.649	-3.528	-2.900	-2.585

Number of obs = 87
Newey-West lags = 1

Mackinnon approximate p-value for Z(t) = 0.4576

O teste também aceitou a hipótese nula de ausência de estacionaridade a 10%, convergindo com os resultados do ADF, porém nem sempre isto ocorre.

PASSO 10: Gerando variáveis diferenciadas

Os modelos diferenciados são uma das mais comuns medidas corretivas a serem aplicadas quando a série não é estacionária em nível, desta forma é preciso gerar a variável diferenciada, encontrar o novo número de defasagens e reaplicar o teste de Dickey-Fuller para as mesmas.

Comando para gerar variável diferenciada: `gen diflogrpd = d1.logrpd`

Comando para identificar novas defasagens: `varsoc diflogrpd`

Comando para o novo ADF: `dfuller diflogrpd, lags(0)`

```
. dfuller dlogrpd
```

Dickey-Fuller test for unit root		Interpolated Dickey-Fuller		
Test Statistic	1% Critical Value	5% Critical Value	10% Critical Value	
Z(t)	-9.681	-3.530	-2.901	-2.586

Number of obs = 86

Mackinnon approximate p-value for Z(t) = 0.0000

Como é possível observar no Output, no exemplo a série não possui raiz unitária em sua primeira diferença, pois, as estatísticas calculadas são maiores que as críticas, até mesmo para o

nível de significância de 1%. Assim, rejeita-se H_0 , a série é estacionária em primeira diferença, é $I(1)$.

PASSO 11: Teste de Co-integração de Johansen

Para que duas séries sejam co-integradas é necessário que estas tenham a mesma ordem de integração. Assim, antes da realização de qualquer teste afim de verificar a existência de uma relação de longo prazo entre as variáveis, é necessário certificar-se de que as mesmas são integradas de mesma ordem (através de testes de estacionaridade como ADF e Phillips-Perron).

Após esta apuração passa-se à aplicação do teste de Johansen o qual é baseado no teste do Traço e no Teste de Máximo Autovalor.

Isto pode ser verificado através do *rank*, o qual leva a rejeitar a hipótese nula de que não há nenhum vetor de co-integração ($r=0$), ao considerar a estatística calculada maior do que a tabelada ao nível de confiança de 99%. Enquanto a hipótese nula de que existe um vetor de co-integração deve ser aceita ao nível de 99%, pois, o valor desta estatística é menor do que a tabelada, confirmando assim a existência de um vetor de co-integração no modelo.

No que diz respeito ao teste de máximo auto-valor, este leva a rejeitar a hipótese nula de que não há nenhum vetor de co-integração ($r=0$), ao considerar a estatística calculada maior do que a tabelada ao nível de confiança de 99%. Já a hipótese nula de que existem dois vetores de co-integração deve ser também rejeitada ao nível de 99%, confirmando assim a existência de um vetor de co-integração no modelo. Confirmada a existência de co-integração no modelo parte-se para a estimação do modelo de longo prazo.

Comando para ver o número de defasagens para o modelo como um todo: `varsoc lnrpd lndcp lnpiib`

Comando para estimar a regressão de longo prazo normalizada por Johansen: `vec lnrpd lndcp lnpiib, lags(1)`

Vector error-correction model

Sample: 1970q3 - 1984q2 No. of obs = 56
 AIC = -20.59003
 Log likelihood = 593.5207 HQIC = -20.35165
 Det(Sigma_ml) = 1.25e-13 SBIC = -19.97519

Equation	Parms	RMSE	R-sq	chi2	P>chi2
D_lnrpd	5	.010384	0.4735	45.85919	0.0000
D_lndcp	5	.006603	0.6700	103.555	0.0000
D_lnpib	5	.008989	0.5855	72.03793	0.0000

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
D_lnrpd						
_ce1	-0.0490594	.0387051	-1.27	0.205	-.12492	.0268012
L1.						
lnrpd						
LD.	-.2116217	.1555801	-1.36	0.174	-.516553	.0933096
lndcp						
LD.	.7072258	.3468671	2.04	0.041	.0273787	1.387073
lnpib						
LD.	-.2319255	.1978513	-1.17	0.241	-.6197069	.1558559
_cons	.0027918	.0022049	1.27	0.205	-.0015298	.0071134
D_lndcp						
_ce1	-.1219048	.0246142	-4.95	0.000	-.1701477	-.0736619
L1.						
lnrpd						
LD.	.0746956	.0989398	0.75	0.450	-.1192229	.2686142
lndcp						
LD.	-.2897811	.2205872	-1.31	0.189	-.7221241	.142562
lnpib						
LD.	.1127606	.1258219	0.90	0.370	-.1338457	.359367
_cons	.0018629	.0014022	1.33	0.184	-.0008854	.0046111
D_lnpib						
_ce1	-.1319114	.0335047	-3.94	0.000	-.1975794	-.0662434
L1.						
lnrpd						
LD.	.1367296	.1346765	1.02	0.310	-.1272314	.4006907
lndcp						
LD.	.1776466	.3002624	0.59	0.554	-.4108569	.76615
lnpib						
LD.	.0209356	.1712682	0.12	0.903	-.3147439	.356615
_cons	-.0027599	.0019087	-1.45	0.148	-.0065008	.0009811

Cointegrating equations

Equation	Parms	chi2	P>chi2
_ce1	2	281.8366	0.0000

Identification: beta is exactly identified
 Johansen normalization restriction imposed

beta	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
_ce1	1					
lnrpd	-4.011826	.5896917	-6.80	0.000	-5.1676	-2.856051
lndcp	3.537045	.6755388	5.24	0.000	2.213014	4.861077
lnpib	-5.757113					
_cons						

A estimação do modelo de longo prazo é dada pelos valores contidos no elipse. Assim, temos:

$$\text{Logrpd} = 5,757113 + 4,011826 \text{ logdcp} - 3,537045 \text{ logpib}$$

IMPORTANTE!!! Na estimação final do modelo de longo prazo normalizado por Johansen todos os parâmetros devem ter seu sinal invertido.

Os valores contidos no octógono referem-se à variável do Mecanismo de Correção de Erros para o curto prazo. O primeiro representa o valor de tal parâmetro enquanto o segundo representa a probabilidade $p > |z|$ de rejeitar H_0 : O modelo está em equilíbrio de curto prazo - $\alpha = 0$.

Assim, como no exemplo $p > |z|$ é de 20,5% rejeita-se H_0 , o modelo não está em equilíbrio de curto prazo. Deve-se interpretar o parâmetro da seguinte forma: 4,9% das discrepâncias entre o RPD de longo prazo e o de curto prazo são corrigidas dentro de um trimestre. Além disso, cabe ressaltar que para que haja a correção do erro é necessário que o parâmetro esteja contido no intervalo]-1,1[. Caso contrário, a série será explosiva, ou seja, o valor defasado de RPD é elevado demais para estar em equilíbrio.

PASSO 12: Teste de Causalidade de Granger

Para a efetivação do teste a estacionaridade da série é condição necessária. Assim, antes da realização de qualquer outro procedimento, é preciso aplicar testes de estacionaridade como ADF e Phillips-Perron. Posteriormente, posteriormente estima-se o modelo por meio do método de Var.

Comando: `var estoquevar1 var1`

Comando para realização do teste de causalidade de Granger: `vargranger`

A partir desses resultados observa-se os valores da estatística $p > \chi^2$, a qual tem por hipótese nula a afirmação de que não há causalidade de Granger entre as variáveis do modelo.

Granger causality wald tests

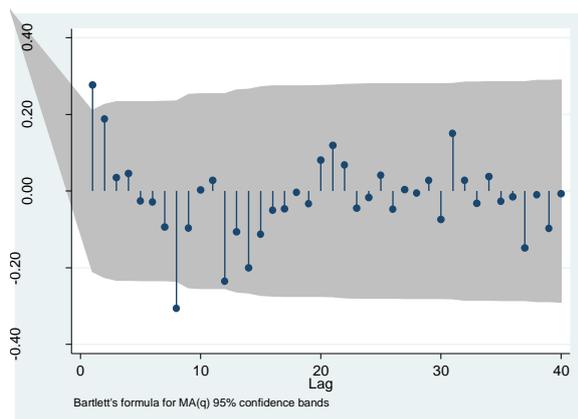
Equation	Excluded	chi2	df	Prob > chi2
dfrpd dfrpd dfrpd	dfdc dfpb ALL	17.795 11.209 29.849	2 2 4	0.000 0.004 0.000
dfdc dfdc dfdc	dfrpd dfpb ALL	.35996 1.0505 1.2261	2 2 4	0.835 0.591 0.874
dfpb dfpb dfpb	dfrpd dfdc ALL	3.9489 23.747 28.166	2 2 4	0.139 0.000 0.000

Neste exemplo é possível observar que todas as variáveis causam rpd (valores no elipse), nenhuma causa o dcp (valores no octógono) e apenas o dcp causa o PIB (valores no losango) não havendo relação de bicausalidade de Granger entre as variáveis. A flecha indica a relação de causalidade, ou seja, testa-se sempre a hipótese que as variáveis da segunda coluna causam as da primeira. Esta é válida para todos os quadrantes.

PASSO 13: Metodologia Box-Jenkins – Estimação dos Modelos de Previsão (ARIMA)

Para a estimação dos modelos ARIMA a estacionaridade da série é condição necessária,. Assim, antes da realização de qualquer outro procedimento, é preciso realizar testes de estacionaridade como ADF e Phillips-Perron. Posteriormente, faz-se a Função de correlação amostral (FAC) no intuito de identificar as defasagens a serem inclusas no modelo. Segue abaixo um exemplo onde se utilizam os dados do logaritmo neperiano do PIB – Tabela 21.1 do Gujarati.

Comando: `ac dflnpb`



Comando: `corrgram dflnpb`

LAG	AC	PAC	Q	Prob>Q	-1 [Autocorrelation]	0	1	-1 [Partial]	0	1 Autocor]
1	0.2770	0.2777	6.907	0.0086						
2	0.1883	0.1178	10.137	0.0063						
3	0.0348	-0.0470	10.249	0.0166						
4	0.0459	0.0332	10.446	0.0336						
5	-0.0256	-0.0491	10.508	0.0621						
6	-0.0286	-0.0156	10.586	0.1020						
7	-0.0935	-0.0828	11.431	0.1209						
8	-0.3060	-0.2945	20.606	0.0083						
9	-0.0964	0.0969	21.528	0.0105						
10	0.0030	0.0961	21.529	0.0177						
11	0.0276	0.0052	21.606	0.0276						
12	-0.2351	-0.3439	27.313	0.0070						
13	-0.1059	0.0287	28.486	0.0077						
14	-0.2005	-0.1256	32.751	0.0031						
15	-0.1127	-0.0411	34.118	0.0033						
16	-0.0501	-0.1436	34.392	0.0048						
17	-0.0461	0.0278	34.626	0.0070						
18	-0.0032	0.1154	34.627	0.0105						
19	-0.0331	-0.0432	34.752	0.0150						
20	0.0809	-0.1355	35.508	0.0176						
21	0.1194	0.0939	37.182	0.0160						
22	0.0684	-0.0494	37.739	0.0196						
23	-0.0441	-0.1216	37.974	0.0256						
24	-0.0166	-0.1191	38.008	0.0346						
25	0.0415	0.1159	38.223	0.0440						
26	-0.0476	-0.1630	38.51	0.0543						
27	0.0035	-0.1452	38.512	0.0701						
28	-0.0048	-0.0230	38.515	0.0890						
29	0.0279	0.0888	38.619	0.1092						
30	-0.0740	-0.2159	39.363	0.1178						

==more==

Ao observar os dois outputs é possível perceber que as defasagens 1,8 e 12 parecem estatisticamente diferentes de zero de modo que estas serão acrescentadas no modelo. Salienta-se ainda que, a partir dos resultados do teste ADF é possível constatar que a série do LnPIB é integrada de ordem 1 de modo que temos, PROVISORIAMENTE, um modelo ARI cuja estimação segue abaixo:

Comando: arima dflnpb, ar(1,8,12)

```
(setting optimization to BHHH)
Iteration 0: log likelihood = 290.00504
Iteration 1: log likelihood = 290.36949
Iteration 2: log likelihood = 290.41029
Iteration 3: log likelihood = 290.41453
Iteration 4: log likelihood = 290.41518
(switching optimization to BFGS)
Iteration 5: log likelihood = 290.41528
Iteration 6: log likelihood = 290.41531
```

ARIMA regression

```
Sample: 1970q2 - 1991q4      Number of obs   =      87
                             Wald chi2(3)           =     33.64
Log likelihood = 290.4153    Prob > chi2      =     0.0000
```

dflnpb	Coef.	OPG Std. Err.	z	P> z	[95% Conf. Interval]	
dflnpb						
_cons	.0061486	.0007784	7.90	0.000	.004623	.0076743
ARMA						
ar						
L1.	.2574502	.085357	3.02	0.003	.0901536	.4247467
L8.	-.3092161	.0854079	-3.62	0.000	-.4766126	-.1418197
L12.	-.2773256	.1062478	-2.61	0.009	-.4855675	-.0690837
/sigma	.0084799	.0005777	14.68	0.000	.0073477	.0096122

Posteriormente são gerados os resíduos e sua respectiva FAC a fim de identificar o número de médias móveis a serem incluídas no modelo:

LAG	AC	PAC	Q	Prob>Q	-1 [Autocorrelation]	0	1	-1 [Partial Autocor]	0	1
1	-0.0280	-0.0281	.07035	0.7908						
2	0.1587	0.1592	2.366	0.3064						
3	-0.0509	-0.0510	2.6044	0.4567						
4	-0.0707	-0.0866	3.0712	0.5460						
5	-0.0945	-0.0898	3.9148	0.5618						
6	-0.0210	0.0074	3.9569	0.6825						
7	-0.0838	-0.0729	4.6367	0.7042						
8	-0.0539	-0.0637	4.9212	0.7660						
9	0.0211	0.0217	4.9652	0.8373						
10	0.1258	0.1432	6.556	0.7666						
11	0.0661	0.0410	7.0017	0.7989						
12	-0.0220	-0.0851	7.0517	0.8542						
13	0.0714	0.0635	7.5846	0.8696						
14	-0.1998	-0.1632	11.817	0.6210						
15	-0.1174	-0.1237	13.299	0.5792						
16	-0.1524	-0.1312	15.833	0.4647						
17	-0.0686	0.0061	16.353	0.4989						
18	-0.0485	-0.0363	16.617	0.5495						
19	0.0088	-0.0621	16.626	0.6152						
20	-0.0774	-0.1867	17.318	0.6323						
21	0.0858	0.0723	18.182	0.6375						
22	0.0055	-0.0557	18.186	0.6949						
23	-0.0264	-0.0792	18.27	0.7427						
24	-0.1028	-0.1749	19.568	0.7211						
25	0.0094	0.1346	19.579	0.7685						
26	-0.1010	-0.1167	20.874	0.7484						
27	-0.0525	-0.1481	21.23	0.7754						
28	0.0109	-0.0322	21.246	0.8150						
29	0.0724	0.1304	21.946	0.8224						
30	-0.0845	-0.2330	22.917	0.8186						

O correlograma sugere que as defasagens 2, 10 e 14 são estatisticamente diferentes de zero, por conseguinte, as incluiremos no modelo.

Comando: **arima dflnpb, ar(1,8,12) ma(2,10,14)**

```
(setting optimization to BHHH)
Iteration 0: log likelihood = 286.36858
Iteration 1: log likelihood = 292.40567
Iteration 2: log likelihood = 292.98814
Iteration 3: log likelihood = 293.05331
Iteration 4: log likelihood = 293.08025
(switching optimization to BFGS)
Iteration 5: log likelihood = 293.09412
Iteration 6: log likelihood = 293.11152
Iteration 7: log likelihood = 293.11542
Iteration 8: log likelihood = 293.11558
Iteration 9: log likelihood = 293.11561
Iteration 10: log likelihood = 293.11562
```

ARIMA regression

```
Sample: 1970q2 - 1991q4      Number of obs   =      87
Log likelihood = 293.1156    Wald chi2(6)    =     43.76
                             Prob > chi2         =     0.0000
```

df\l\npb	Coef.	OPG Std. Err.	z	P> z	[95% Conf. Interval]	
df\l\npb						
_cons	.0061309	.0009156	6.70	0.000	.0043362	.0079255
ARMA						
ar						
L1.	.2240765	.0898709	2.49	0.013	.0479328	.4002203
L8.	-.335362	.094227	-3.56	0.000	-.5200435	-.1506805
L12.	-.266644	.1079606	-2.47	0.014	-.4782428	-.0550452
ma						
L2.	.1656575	.0947385	1.75	0.080	-.0200265	.3513416
L10.	.1333275	.1012232	1.32	0.188	-.0650664	.3317214
L14.	-.1227807	.108483	-1.13	0.258	-.3354035	.089842
/sigma	.0081897	.0006419	12.76	0.000	.0069316	.0094479

Mas como saber qual dos dois modelos proporciona uma melhor previsão?

Para verificar qual modelo melhor se ajusta no sentido de propiciar uma melhor previsão, é realizada a estatística de Akaike e Schwarz onde são comparados os valores AIC e BIC para cada regressão estimada e, baseado no critério da parcimônia, escolhe-se aquele modelo que, dentre todos estimados, obtiver o menor valor AIC em módulo.

Comando: estat ic

Exemplo para os modelos ARI(3,1) e ARIMA(3,1,3) respectivamente:

Model	Obs	ll(null)	ll(model)	df	AIC	BIC
.	87	.	290.4153	5	-570.8306	-558.5011

Note: N=Obs used in calculating BIC; see [R] BIC note

Model	Obs	ll(null)	ll(model)	df	AIC	BIC
.	87	.	293.1156	8	-570.2312	-550.504

Note: N=Obs used in calculating BIC; see [R] BIC note

A partir desses resultados e admitindo-se o critério da parcimônia concluímos que o modelo ARIMA(3,1,3) ajusta-se melhor.

IMPORTANTE!! A identificação das defasagens dos modelos ARIMA é intuitiva, desta forma, o ideal é estimar regressões alternativas como por exemplo arima dflnpb, ar(1,8,12) ma(2,10,); arima dflnpb, ar(1,8,12) ma(2); arima dflnpb, ar(1,8,12) ma(10,14); arima dflnpb, ar(1,8)... e verificar a estatística AIC para cada uma delas, para assim evitar o caso de excluir alguma variável importante do modelo, ou de haver alguma que seja desnecessária.

REFERÊNCIAS

GUJARATI, D. **Econometria Básica**. 4ª Edição, Rio de Janeiro: Elsevier, 2006.