

# Métodos de Previsão

## Parte II: Métodos Estocásticos - Exemplos


# Exemplo 1: $pe$

O ficheiro “pe.dta” contém dados relativos à variável  $pe$ , que representa o PER (Price/Earnings Ratio) anual médio do índice bolsista Standard & Poors entre os anos de 1871 e 2002. Quanto mais alto for o valor deste rácio, mais caras estarão as acções relativamente aos lucros que as empresas conseguem gerar.

1. Represente graficamente a evolução de  $pe$  ao longo do período considerado e apresente a ACF e a PACF.
2. Teste se  $pe$  poderá ser considerada ruído branco.
3. Ignore o facto de a série parecer não estacionária e considere a sua descrição pelos seguintes modelos.
  - a) AR(1) com e sem constante
  - b) AR(2)
  - c) MA(1) e MA(2)
  - d) ARMA(1,1)

# Exemplo 1: pe – Questão 1

```
. line pe year, title("Exemplo PE") ytitle(Pe) xtitle(Year)  
xlabel(1871 1900 1925 1950 1975 2000) ylabel(5 10 15 20 25 30 35  
40)
```



# Exemplo 1: pe – Questão 1

```
. tsset year
      time variable: year, 1871 to 2002
              delta: 1 unit
. corrgram pe, lags(20)
```

LAG	AC	PAC	Q	Prob>Q	-1	0	1	-1	0	1
					[Autocorrelation]			[Partial Autocor]		
1	0.7923	0.9262	84.757	0.0000		-----		-----		
2	0.6041	-0.0713	134.42	0.0000		-----				
3	0.4976	0.1528	168.37	0.0000		-----				
4	0.3682	-0.0313	187.1	0.0000		-----				
5	0.2982	0.1778	199.48	0.0000		-----				
6	0.2602	-0.0395	208.99	0.0000		-----				
7	0.2054	-0.0850	214.96	0.0000		-----				
8	0.1453	-0.1369	217.97	0.0000		-----				
9	0.0888	0.0284	219.1	0.0000		-----				
10	0.0095	-0.0669	219.11	0.0000		-----				
11	-0.0943	-0.1484	220.41	0.0000		-----				
12	-0.1621	-0.0479	224.29	0.0000		-----				
13	-0.2216	-0.1759	231.58	0.0000		-----				
14	-0.2411	0.1047	240.29	0.0000		-----				
15	-0.2265	0.0457	248.05	0.0000		-----				
...										

Rejeita-se a  $H_0$  de pe ser ruído branco

# Exemplo 1: pe – Questão 3 a

```
. arima pe, ar(1)
...
ARIMA regression
Sample: 1871 - 2002                Number of obs   =       132
                                   Wald chi2(1)       =       461.87
Log likelihood = -315.2307         Prob > chi2     =       0.0000
-----+-----
           |               OPG
           |   Coef.   Std. Err.   z    P>|z|   [95% Conf. Interval]
-----+-----
pe
   _cons |   15.95301   2.686906   5.94   0.000   10.68678   21.21925
-----+-----
ARMA
   ar |
   L1. |   .9144731   .0425512   21.49   0.000   .8310744   .9978718
-----+-----
   /sigma |   2.617762   .1425919   18.36   0.000   2.338287   2.897237
-----+-----
```

Note: The test of the variance against zero is one sided, and the two-sided confidence interval is truncated at zero.

# Exemplo 1: pe – Questão 3 a

```
. arima pe, ar(1) noconst
```

```
...
```

```
ARIMA regression
```

```
Sample: 1871 - 2002
```

```
Number of obs = 132
```

```
Wald chi2(1) = 8374.10
```

```
Log likelihood = -318.0714
```

```
Prob > chi2 = 0.0000
```

```
-----  
                |                OPG  
                |      Coef.   Std. Err.   z   P>|z|   [95% Conf. Interval]  
-----+-----  
ARMA            |  
    ar          |  
    L1.         |   .9929394   .0108506   91.51   0.000   .9716726   1.014206  
-----+-----  
    /sigma      |   2.649951   .1479643   17.91   0.000   2.359947   2.939956  
-----
```

Note: The test of the variance against zero is one sided, and the two-sided confidence interval is truncated at zero.

# Exemplo 1: pe – Questão 3 b

```
. arima pe, ar(1 2)
...
ARIMA regression
Sample: 1871 - 2002                Number of obs   =       132
                                   Wald chi2(2)        =       458.49
Log likelihood = -314.8832         Prob > chi2      =       0.0000
-----+-----
              |               OPG
              |      Coef.   Std. Err.   z    P>|z|    [95% Conf. Interval]
-----+-----+-----
pe
   _cons |    15.69143   2.357176   6.66  0.000   11.07145   20.31141
-----+-----+-----
ARMA
   ar |
   L1. |    .9770795   .0805527   12.13  0.000   .8191992   1.13496
   L2. |   -.0769714   .0855294   -0.90  0.368   -.244606   .0906632
-----+-----+-----
   /sigma |    2.611682   .14715    17.75  0.000   2.323273   2.900091
-----+-----
```

Note: The test of the variance against zero is one sided, and the two-sided confidence interval is truncated at zero.

# Exemplo 1: pe – Questão 3 b

```
. arima pe, ar(1/2)
...
ARIMA regression
Sample: 1871 - 2002                Number of obs   =       132
                                   Wald chi2(2)         =       458.49
Log likelihood = -314.8832         Prob > chi2      =       0.0000
-----+-----
                |               OPG
                |      Coef.   Std. Err.   z    P>|z|    [95% Conf. Interval]
-----+-----+-----
pe              |
  _cons         |   15.69143   2.357176   6.66  0.000   11.07145   20.31141
-----+-----+-----
ARMA            |
  ar           |
    L1.         |    .9770795   .0805527  12.13  0.000    .8191992    1.13496
    L2.         |   -.0769714   .0855294  -0.90  0.368   -.244606    .0906632
-----+-----+-----
  /sigma        |    2.611682    .14715   17.75  0.000    2.323273    2.900091
-----+-----
```

Note: The test of the variance against zero is one sided, and the two-sided confidence interval is truncated at zero.



# Exemplo 1: pe – Questão 3 c

```
. arima pe, ma(1)
...
ARIMA regression
Sample: 1871 - 2002                Number of obs   =       132
                                   Wald chi2(1)       =       228.25
Log likelihood = -349.5133         Prob > chi2     =       0.0000
-----+-----
              |                OPG
              |                Coef.   Std. Err.   z    P>|z|    [95% Conf. Interval]
-----+-----+-----
pe           |
  _cons     |   14.66386   .630688   23.25  0.000   13.42773   15.89999
-----+-----+-----
ARMA        |
  ma       |
  L1.     |    .7912549  .0523736  15.11  0.000   .6886046   .8939052
-----+-----+-----
  /sigma   |    3.404723  .1689592  20.15  0.000   3.073569   3.735877
-----+-----
```

Note: The test of the variance against zero is one sided, and the two-sided confidence interval is truncated at zero.

# Exemplo 1: pe – Questão 3 c

```
. arima pe, ma(1 2)
...
ARIMA regression
Sample: 1871 - 2002                Number of obs   =       132
                                   Wald chi2(2)       =       278.13
Log likelihood = -335.6916         Prob > chi2     =       0.0000
-----+-----
                |                OPG
                |      Coef.   Std. Err.   z    P>|z|    [95% Conf. Interval]
-----+-----
pe
   _cons |    14.71384   .7385909   19.92   0.000   13.26623   16.16145
-----+-----
ARMA
   ma |
   L1. |    1.005193   .0630981   15.93   0.000   .8815226   1.128863
   L2. |    .392862   .0727632    5.40   0.000   .2502487   .5354752
-----+-----
   /sigma |    3.065221   .1407891   21.77   0.000   2.789279   3.341162
-----+-----
```

Note: The test of the variance against zero is one sided, and the two-sided confidence interval is truncated at zero.

# Exemplo 1: pe – Questão 3 d

```
. arima pe, arima(1,0,1)
```

```
...
```

```
ARIMA regression
```

```
Sample: 1871 - 2002
```

```
Number of obs = 132
```

```
Wald chi2(2) = 381.93
```

```
Log likelihood = -314.7261
```

```
Prob > chi2 = 0.0000
```

```
-----+-----
```

	pe	Coef.	OPG Std. Err.	z	P> z	[95% Conf. Interval]	
pe							
	_cons	15.62051	2.254371	6.93	0.000	11.20203	20.039
ARMA							
	ar						
	L1.	.8822417	.0546467	16.14	0.000	.7751361	.9893474
	ma						
	L1.	.1229756	.092581	1.33	0.184	-.0584798	.3044311
	/sigma	2.60862	.1435057	18.18	0.000	2.327354	2.889886

```
-----+-----
```

```
Note: The test of the variance against zero is one sided, and the two-sided confidence interval is truncated at zero.
```


## Exemplo 2: air

O ficheiro “airline.dta” contém dados relativos à variável *air*, que representa o número de passageiros para voos internacionais de uma companhia aérea entre Janeiro de 1949 e Dezembro de 1960. Logaritmize a variável para estabilizar a variância, obtendo  $\ln air$ .


1. Represente graficamente a evolução de  $\ln air$  e de  $\ln air$  sujeito à primeira diferença e à primeira diferença sazonal,  $\nabla \nabla_{12} \ln air$ . O objectivo será modelar esta última série, a qual, como não exhibe tendência, será modelada sem constante.
2. Estime e escreva o modelo SARIMA(0,1,1)(0,1,1)<sub>12</sub>

# Exemplo 2: air – Questão 1

```
. line air time, title("Exemplo Airline") ytitle(air) xtitle(Month)
```




```
. gen lnair=ln(air)  
. line lnair time, title("Exemplo Airline") ytitle(lnair)  
xtitle(Month)
```



# Exemplo 2: air – Questão 1

```
. line DS12.lnair time, title("Exemplo Airline") ytitle(lnair)  
xtitle(Month)
```



# Exemplo 2: air – Questão 2

```
. arima lnair, arima(0,1,1) sarima(0,1,1,12) noconstant
```

ou

```
. arima DS12.lnair, ma(1) mma(1, 12) noconstant
```

...

ARIMA regression

Sample: 14 - 144

Number of obs = 131

Wald chi2(2) = 84.53

Log likelihood = 244.6965

Prob > chi2 = 0.0000

		OPG				
DS12.lnair	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
-----						
ARMA						
ma						
L1.	-.4018324	.0730307	-5.50	0.000	-.5449698	-.2586949
-----						
ARMA12						
ma						
L1.	-.5569342	.0963129	-5.78	0.000	-.745704	-.3681644
-----						
/sigma	.0367167	.0020132	18.24	0.000	.0327708	.0406625
-----						

$$\nabla \nabla_{12} \widehat{\ln air}_t = -0.402\varepsilon_{t-1} - 0.557\varepsilon_{t-12} + 0.224\varepsilon_{t-13} + \varepsilon_t$$

# Exemplo 3: $pe$


Considere de novo o ficheiro “pe.dta”.

1. Considere ainda primeira diferença de  $pe$  e represente graficamente. O seu objectivo será modelar esta série,  $\nabla pe$ .
2. Proponha um modelo adequado para  $\nabla pe$ .
3. Represente no mesmo gráfico os valores do PER observados e estimados de acordo com o modelo escolhido.
4. Utilize o modelo autorregressivo escolhido para prever o valor do PER de 2003.



# Exemplo 3: pe – Questão 1

```
. tsset year  
    time variable:  year, 1871 to 2002  
    delta: 1 unit  
  
. line d.pe year, title("Exemplo PE") ytitle(Pe) xtitle(Year)  
xlabel(1871 1900 1925 1950 1975 2000) ylabel(-10 -5 0 5 10)
```



# Exemplo 3: pe – Questão 2

```
. corrgram d.pe, lags(20)
```

LAG	AC	PAC	Q	Prob>Q	-1	0	1	-1	0	1
					[Autocorrelation]			[Partial Autocor]		
1	0.0095	0.0096	.01204	0.9126						
2	-0.1799	-0.1878	4.3819	0.1118	-			-		
3	-0.0149	-0.0124	4.4122	0.2203						
4	-0.1353	-0.1904	6.9227	0.1400	-			-		
5	0.0358	0.0267	7.1001	0.2133						
6	0.1224	0.0656	9.1871	0.1633						
7	0.0882	0.1106	10.281	0.1732						
8	-0.0574	-0.0538	10.747	0.2164						
9	-0.0271	0.0317	10.852	0.2860						
10	0.0567	0.0917	11.314	0.3336						
11	-0.0362	-0.0133	11.504	0.4020						
12	0.0740	0.0978	12.307	0.4214						
13	-0.0977	-0.1657	13.717	0.3940				-		
14	-0.1009	-0.0925	15.234	0.3623						
15	0.0899	0.0535	16.448	0.3529						
16	0.0400	0.0314	16.69	0.4059						
17	-0.0061	-0.0258	16.696	0.4751						
18	-0.0411	-0.0875	16.956	0.5261						
19	-0.0071	0.0107	16.964	0.5923						
20	-0.0407	-0.0591	17.224	0.6384						

## Exemplo 3: pe – Questão 2

O correlograma e o teste Q de Ljung-Box sugerem que  $\nabla pe$  é um ruído branco. Contudo, tendo em conta que os 2º e 4º defasamentos figuram como os mais importantes a nível da FAC como da FACP e os p-values do teste Q apresentam nestes dois casos os seus valores mais baixos, tentar-se-à utilizar os modelo AR(4) e MA(4).

Modelo AR(4):

```
. arima d.pe, ar(1 2 3 4)
```

ou

```
. arima d.pe, ar(1/4)
```

# Exemplo 3: pe – Questão 2

(...)

ARIMA regression

Sample: 1872 - 2002

Number of obs = 131

Wald chi2(4) = 9.52

Log likelihood = -308.9161

Prob > chi2 = 0.0493

```
-----+-----
          |                OPG
          |      Coef.  Std. Err.      z    P>|z|    [95% Conf. Interval]
-----+-----
pe
   _cons |   .1752718   .1703764    1.03   0.304   - .1586598   .5092034
-----+-----
ARMA
   ar    |
   L1.   |   .0008674   .0823877    0.01   0.992   - .1606096   .1623444
   L2.   |  - .2214944   .0833387   -2.66   0.008   - .3848351  - .0581536
   L3.   |  - .0073054   .0823118   -0.09   0.929   - .1686335   .1540227
   L4.   |  - .1850712   .0865071   -2.14   0.032   - .3546219  - .0155204
-----+-----
   /sigma |   2.556033   .1519277   16.82   0.000    2.25826    2.853806
-----+-----
```

Note: The test of the variance against zero is one sided, and the two-sided confidence interval is truncated at zero.

# Exemplo 3: pe – Questão 2

Obtém-se desde já o AIC e o BIC, para comparar posteriormente com outros modelos

```
. estat ic
```

```
Akaike's information criterion and Bayesian information criterion
```

```
-----  
Model | Obs ll(null) ll(model) df AIC BIC  
-----+-----  
. | 131 . -308.9161 6 629.8322 647.0834  
-----
```

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

# Exemplo 3: pe – Questão 2

Só os 2º e 4º defasamentos são significativos, pelo que se reestimaré o modelo sem os outros defasamentos.

```
. arima d.pe, ar(2 4)
ARIMA regression
Sample: 1872 - 2002                Number of obs   =       131
                                   Wald chi2(2)       =        9.50
Log likelihood = -308.9199         Prob > chi2     =       0.0087
-----+-----
              |               OPG
              |   Coef.   Std. Err.   z    P>|z|   [95% Conf. Interval]
-----+-----
pe
   _cons |   .1753001   .1693041   1.04   0.300   -.1565299   .5071301
-----+-----
ARMA
   ar |
   L2. |  -.2216121   .0833293   -2.66   0.008   -.3849345   -.0582897
   L4. |  -.1852938   .085853    -2.16   0.031   -.3535626   -.0170249
-----+-----
   /sigma |   2.555985   .1456    17.55   0.000   2.270614   2.841355
-----+-----
```

Note: The test of the variance against zero is one sided, and the two-sided confidence interval is truncated at zero.

# Exemplo 3: pe – Questão 2

```
. estat ic
```

```
Akaike's information criterion and Bayesian information criterion
```

```
-----  
Model |      Obs  ll(null)  ll(model)      df      AIC      BIC  
-----+-----  
. |      131      . -308.9199      4    625.8399    637.3407  
-----
```

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

O AIC e o BIC são menores neste caso: prefere-se este AR ao primeiro

Prossegue-se com o modelo MA(4), e uma sua versão onde só o termo de ordem 2 é usado, visto ser o unico significativo. Apresentam-se também o AIC e o BIC

# Exemplo 3: pe – Questão 2

```
. arima d.pe, ma(1 2 3 4)
```

```
...
```

```
ARIMA regression
```

```
Sample: 1872 - 2002
```

```
Number of obs = 131
```

```
Wald chi2(4) = 7.84
```

```
Log likelihood = -309.5093
```

```
Prob > chi2 = 0.0977
```

```
-----+-----
```

	D.pe	Coef.	OPG Std. Err.	z	P> z	[95% Conf. Interval]	
pe							
	_cons	.1712493	.1754391	0.98	0.329	-.172605	.5151036
ARMA							
	ma						
	L1.	.0162427	.0859527	0.19	0.850	-.1522214	.1847068
	L2.	-.201134	.089496	-2.25	0.025	-.376543	-.025725
	L3.	.0124789	.0825532	0.15	0.880	-.1493225	.1742803
	L4.	-.1130738	.0860986	-1.31	0.189	-.281824	.0556763
	/sigma	2.568016	.146746	17.50	0.000	2.280399	2.855633

```
-----+-----
```

Note: The test of the variance against zero is one sided, and the two-sided confidence interval is truncated at zero.



# Exemplo 3: pe – Questão 2

```
. estat ic
```

```
Akaike's information criterion and Bayesian information criterion
```

```
-----
```

Model	Obs	ll(null)	ll(model)	df	AIC	BIC
.	131	.	-309.5093	6	631.0187	648.2699

```
-----
```

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

# Exemplo 3: pe – Questão 2

```
. arima d.pe, ma(2)
```

```
...
```

```
ARIMA regression
```

```
Sample: 1872 - 2002
```

```
Number of obs = 131
```

```
Wald chi2(1) = 8.67
```

```
Log likelihood = -310.2145
```

```
Prob > chi2 = 0.0032
```

```
-----
```

		OPG				[95% Conf. Interval]	
	D.pe	Coef.	Std. Err.	z	P> z		
-----							
pe							
	_cons	.1763215	.1798076	0.98	0.327	-.1760948	.5287379
-----							
ARMA							
	ma						
	L2.	-.2502222	.0849742	-2.94	0.003	-.4167686	-.0836759
-----							
	/sigma	2.582132	.1435329	17.99	0.000	2.300813	2.863451
-----							

Note: The test of the variance against zero is one sided, and the two-sided confidence interval is truncated at zero.

# Exemplo 3: pe – Questão 2

```
. estat ic
```

```
Akaike's information criterion and Bayesian information criterion
```

Model	Obs	ll(null)	ll(model)	df	AIC	BIC
.	131	.	-310.2145	3	626.429	635.0546

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

O AIC e o BIC são menores neste caso do que no MA(4). Comparando com o AR(2 4), o AIC é agora maior, mas o BIC é menor. Prefere-se o AR(2 4)

$$\widehat{\nabla pe}_t = 0.175 - 0.222\nabla pe_{t-2} - 0.185\nabla pe_{t-4}$$

De seguida, verifica-se se os resíduos do modelo selecionado são ruído branco

# Exemplo 3: pe – Questão 2

```
. quietly arima D.pe, ar(2 4)
. predict u, resid
(1 missing value generated)
. corrgram u, lags(20)
```

LAG	AC	PAC	Q	Prob>Q	-1	0	1	-1	0	1
					[Autocorrelation]			[Partial Autocor]		
1	0.0052	0.0053	.00363	0.9519						
2	0.0068	0.0076	.00987	0.9951						
3	0.0138	0.0150	.03581	0.9982						
4	-0.0041	-0.0042	.03812	0.9998						
5	0.0437	0.0509	.30211	0.9976						
6	0.0564	0.0695	.74568	0.9935						
7	0.0798	0.0994	1.6415	0.9770						
8	-0.0319	-0.0299	1.7854	0.9869						
9	-0.0263	-0.0319	1.8843	0.9932						
10	0.0760	0.0903	2.7153	0.9874						
11	-0.0439	-0.0503	2.9953	0.9908						
12	0.0625	0.0687	3.5677	0.9900						
13	-0.1116	-0.1407	5.4075	0.9651					-	
14	-0.0934	-0.1311	6.7068	0.9454					-	
15	0.0728	0.0919	7.5017	0.9422						
16	0.0026	0.0194	7.5028	0.9623						
17	-0.0271	-0.0458	7.6146	0.9741						
18	-0.0755	-0.1057	8.4928	0.9704						
19	-0.0374	-0.0623	8.7103	0.9780						

# Exemplo 3: pe – Questão 3

```
. predict pehat, y  
(1 missing value generated)
```

Faz-se a replica de alguns valores previstos: 132, 2, 3, 4, 5 e 6:

$$\widehat{pe}_t = pe_{t-1} + \nabla \widehat{pe}_t = pe_{t-1} + 0.175 - 0.222 \nabla pe_{t-2} - 0.185 \nabla pe_{t-4} = \\ = pe_{t-1} + 0.175 - 0.222(pe_{t-2} - pe_{t-3}) - 0.185(pe_{t-4} - pe_{t-5})$$

```
. display pe[131]+0.1758268-0.2218146*(pe[130]-pe[129])-0.1854346*(pe[128]-  
pe[127])
```

33.055166

```
. display pe[1]+0.1758268
```

11.904997

```
. display pe[2]+0.1758268
```

12.257907

```
. display pe[3]+0.1758268-0.2218146*(pe[2]-pe[1])
```

10.857586

```
. display pe[4]+0.1758268-0.2218146*(pe[3]-pe[2])
```

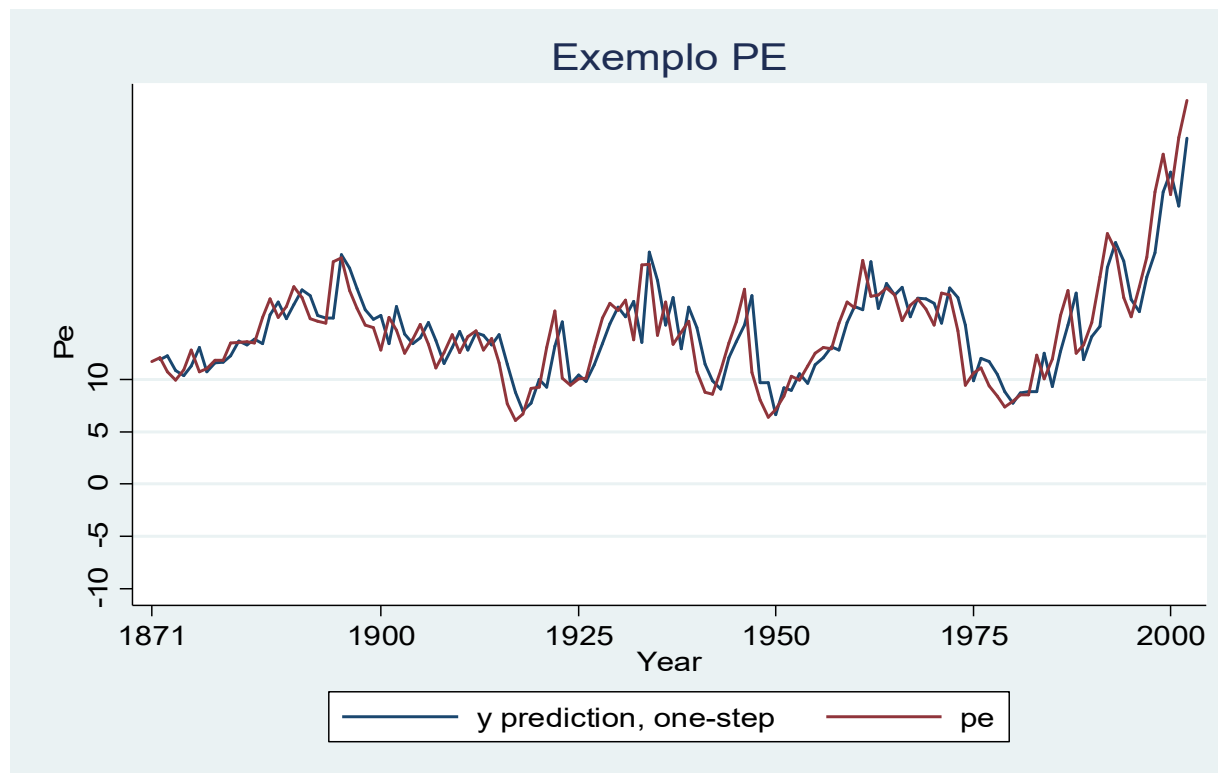
10.403857

```
. display pe[5]+0.1758268-0.2218146*(pe[4]-pe[3])-0.1854346*(pe[2]-pe[1])
```

11.252369

# Exemplo 3: pe – Questão 3

```
.line pehat pe year, title("Exemplo PE") ytitle(Pe) xtitle(Year)  
xlabel(1871 1900 1925 1950 1975 2000) ylabel(-10 -5 0 5 10)
```



# Exemplo 3: pe – Questão 4

Previsão fora da amostra:

$$\begin{aligned}\widehat{pe}_{2003} &= pe_{2002} + \nabla \widehat{pe}_{2003} \\ &= pe_{2002} + 0.175 - 0.222 \nabla pe_{2001} - 0.185 \nabla pe_{1999} \\ &= pe_{2002} + 0.175 - 0.222(pe_{2001} - pe_{2000}) - 0.185(pe_{1999} - pe_{1998})\end{aligned}$$

```
. display pe[132]+0.1758268-0.2218146*(pe[131]-pe[130]) -  
0.1854346*(pe[129]-pe[128])  
35.036628
```

## Exemplo 4: vinho rose – Questão 2


O ficheiro “vinho.dta” contém dados relativos à venda de vinho rosé na Austrália (milhares de litros) entre Janeiro de 1980 e Junho de 1994; para análise em excel, ver Caiado (2016), p. 214-221

1. Crie uma variável para datar os dados e represente graficamente a série.
2. Apresente a FAC e a FACP e discuta a eventual necessidade de aplicar diferenças. Represente ainda a série resultante das eventuais diferenciações.
3. Represente a FAC e a FACP da série proposta em 2. e proponha modelos que potencialmente a poderão descrever.
4. Para os modelos em análise, realize previsão, dentro e fora da amostra (neste caso para 4 meses) e represente graficamente.



# Exemplo 4: vinho rose – Questão 1

```
. generate time = m(1980m1) + _n -1  
. format t %tm  
. tsset time  
    time variable:  time, 1980m1 to 1994m6  
        delta: 1 month  
  
. line vendas time, title("Exemplo Vinho Rosé") ytitle(Vendas) xtitle(Month)
```



# Exemplo 4: vinho rose – Questão 2

```
. corrgram vendas, lags(36)
```

LAG	AC	PAC	Q	Prob>Q	-1	0	1	-1	0	1
					[Autocorrelation]			[Partial Autocor]		
1	0.5659	0.5710	56.694	0.0000	-----			-----		
2	0.4445	0.1903	91.874	0.0000	----			-		
3	0.4995	0.3023	136.56	0.0000	----			--		
4	0.4517	0.1150	173.32	0.0000	----					
5	0.4273	0.1288	206.4	0.0000	----			-		
6	0.3628	0.0027	230.39	0.0000	--					
7	0.4029	0.1449	260.15	0.0000	----			-		
8	0.4162	0.1067	292.11	0.0000	----					
9	0.4293	0.1750	326.32	0.0000	----			-		
10	0.4076	0.0832	357.34	0.0000	----					
11	0.4423	0.1924	394.1	0.0000	----			-		
12	0.6431	0.5584	472.28	0.0000	-----			-----		
13	0.3787	-0.1457	499.57	0.0000	----			-		
14	0.3124	0.1226	518.25	0.0000	--					
15	0.3305	-0.0250	539.29	0.0000	--					
16	0.2978	-0.0449	556.48	0.0000	--					
17	0.2832	-0.0688	572.12	0.0000	--					
18	0.2261	-0.0109	582.15	0.0000	-					
19	0.2270	-0.0243	592.34	0.0000	-					
20	0.2312	0.0026	602.97	0.0000	-					
21	0.2450	-0.1201	614.98	0.0000	-					
22	0.1985	-0.0803	622.92	0.0000	-					
...										

# Exemplo 4: vinho rose – Questão 2

...						
23	0.2578	0.1015	636.39	0.0000	--	
24	0.4517	0.2787	678.04	0.0000	---	--
25	0.2264	-0.0145	688.58	0.0000	-	
26	0.1847	0.0523	695.63	0.0000	-	
27	0.2159	0.0079	705.34	0.0000	-	
28	0.1805	0.0203	712.18	0.0000	-	
29	0.1539	-0.0037	717.18	0.0000	-	
30	0.0970	-0.0219	719.18	0.0000		
31	0.1046	-0.0582	721.52	0.0000		
32	0.1296	-0.0304	725.15	0.0000	-	
33	0.1575	-0.0038	730.53	0.0000	-	
34	0.1107	-0.0316	733.21	0.0000		
35	0.1757	0.0787	740.02	0.0000	-	
36	0.3464	0.1078	766.65	0.0000	--	

A FAC decai lentamente para zero, especialmente nos lags sazonais 12, 24 e 36.


A FACP difere de zero em alguns lags iniciais e nos lags sazonais. Aplicar-se-à uma diferença para eliminar a tendência acrescida de diferenciação sazonal:

$\nabla\nabla_{12}vendas$

# Exemplo 4: vinho rose – Questão 2

```
. gen dd12vendas=DS12.vendas  
(13 missing values generated)
```

```
. line dd12vendas time, title("Exemplo Vinho rosé") ytitle(dd12Vendas)  
xtitle(Month)
```



# Exemplo 4: vinho rose – Questão 3

```
. corrgram dd12vendas, lags(36)
```

LAG	AC	PAC	Q	Prob>Q	-1	0	1	-1	0	1
					[Autocorrelation]			[Partial Autocor]		
1	-0.2816	-0.2819	13.003	0.0003	--			--		
2	-0.3046	-0.4177	28.313	0.0000	--			---		
3	0.0482	-0.2520	28.698	0.0000				--		
4	0.0124	-0.2716	28.724	0.0000				--		
5	0.0705	-0.1360	29.56	0.0000				-		
6	-0.0059	-0.0929	29.566	0.0000						
7	-0.0712	-0.1180	30.429	0.0001						
8	-0.0837	-0.2558	31.631	0.0001				--		
9	0.1040	-0.1626	33.498	0.0001				-		
10	0.1735	0.0733	38.728	0.0000	-					
11	0.0603	0.3098	39.364	0.0000				--		
12	-0.3735	-0.1142	63.938	0.0000	--					
13	0.0678	-0.0120	64.753	0.0000						
14	0.0717	-0.0814	65.67	0.0000						
15	0.0647	-0.0472	66.424	0.0000						
16	-0.0321	-0.0818	66.61	0.0000						
17	-0.0871	-0.0920	67.992	0.0000						
18	0.0563	-0.0903	68.574	0.0000						
19	0.0458	-0.0745	68.962	0.0000						
20	0.0469	-0.0492	69.37	0.0000						
21	-0.0909	-0.0802	70.919	0.0000						
22	-0.0021	0.0192	70.92	0.0000						
...										

# Exemplo 4: vinho rose – Questão 3

...						
23	-0.0221	0.0672	71.013	0.0000		
24	0.0058	-0.1264	71.019	0.0000		-
25	0.0503	-0.0344	71.508	0.0000		
26	0.0055	0.0417	71.514	0.0000		
27	-0.0259	0.0427	71.645	0.0000		
28	-0.0133	-0.0673	71.68	0.0000		
29	0.0140	-0.0786	71.719	0.0000		
30	0.0303	0.0338	71.902	0.0000		
31	-0.0499	-0.0419	72.405	0.0000		
32	-0.0224	-0.0640	72.507	0.0001		
33	0.0679	0.0331	73.451	0.0001		
34	-0.0677	-0.0834	74.397	0.0001		
35	0.0536	0.0008	74.994	0.0001		
36	0.0028	-0.0681	74.996	0.0001		

Parece ser de tipo MA, com a FAC a decair rapidamente para zero, excepto nos dois primeiros lags e no lag sazonal 12. A FACP vai mais lentamente para zero, sendo relevante no lag 12. Sugere SARIMA(0,1,2)(0,1,1)<sub>12</sub> ou SARIMA(0,1,2)(1,1,1)<sub>12</sub> ou SARIMA(0,1,0)(1,1,1)<sub>12</sub>; ver Caiado (2016), que considera o primeiro e o ultimo modelo.

# Exemplo 4: vinho rose – Questão 3

```

. arima vendas, arima(0,1,2) sarima(0,1,1,12)
ARIMA regression
Sample: 1981m2 - 1994m6                Number of obs   =       161
                                         Wald chi2(3)    =       405.22
Log likelihood = -711.3635              Prob > chi2     =       0.0000
-----+-----
          |               OPG
DS12.vendas |      Coef.   Std. Err.      z    P>|z|    [95% Conf. Interval]
-----+-----
vendas      |
  _cons     |   .0216596   .0771826    0.28   0.779   - .1296155   .1729347
-----+-----
ARMA        |
  ma        |
  L1.       |  -.6994655   .0742926   -9.42   0.000   - .8450764   - .5538547
  L2.       |  -.222736    .0736352   -3.02   0.002   - .3670583   - .0784137
-----+-----
ARMA12      |
  ma        |
  L1.       |  -.7504303   .0899602   -8.34   0.000   - .9267491   - .5741115
-----+-----
/sigma      |   19.30876   .9211519   20.96   0.000   17.50334    21.11419
-----+-----

. estat ic
Akaike's information criterion and Bayesian information criterion
-----+-----
Model      |      Obs   ll(null)   ll(model)      df      AIC      BIC
-----+-----
.          |      161          .   -711.3635      5    1432.727  1448.134
-----+-----

```

# Exemplo 4: vinho rose – Questão 3

```
. arima vendas, arima(0,1,2) sarima(1,1,1,12)
Sample: 1981m2 - 1994m6                Number of obs   =       161
                                         Wald chi2(4)    =       260.97
Log likelihood = -711.3432              Prob > chi2     =       0.0000
```

```
-----+-----
```

		OPG				[95% Conf. Interval]	
	Coef.	Std. Err.	z	P> z			
-----+-----							
vendas							
_cons	.0219306	.0787126	0.28	0.781	-.1323433	.1762045	
-----+-----							
ARMA							
ma							
L1.	-.7017785	.0743935	-9.43	0.000	-.8475872	-.5559699	
L2.	-.2183606	.0761528	-2.87	0.004	-.3676173	-.069104	
-----+-----							
ARMA12							
ar							
L1.	-.0291769	.1232015	-0.24	0.813	-.2706474	.2122936	
ma							
L1.	-1.366058	.2391729	-5.71	0.000	-1.834829	-.8972881	
-----+-----							
/sigma	14.14359	2.347459	6.03	0.000	9.542653	18.74452	

```
. estat ic
Akaike's information criterion and Bayesian information criterion
```

```
-----+-----
```

Model	Obs	ll(null)	ll(model)	df	AIC	BIC
.	161	.	-711.3432	6	1434.686	1453.175

```
-----+-----
```



# Exemplo 4: vinho rose – Questão 3

```
. arima vendas, arima(0,1,0) sarima(1,1,1,12)
Sample: 1981m2 - 1994m6                Number of obs   =       161
                                         Wald chi2(2)    =       82.99
Log likelihood = -749.6455              Prob > chi2     =       0.0000
```

```
-----+-----
```

	Coef.	OPG Std. Err.	z	P> z	[95% Conf. Interval]	
-----+-----						
vendas						
_cons	.008355	.8204628	0.01	0.992	-1.599723	1.616433
-----+-----						
ARMA12						
ar						
L1.	-.029088	.1246243	-0.23	0.815	-.2733471	.2151712
ma						
L1.	-.7640793	.129483	-5.90	0.000	-1.017861	-.5102974
-----+-----						
/sigma	24.60413	1.146557	21.46	0.000	22.35692	26.85134

```
. estat ic
```

Akaike's information criterion and Bayesian information criterion

```
-----+-----
```

Model	Obs	ll(null)	ll(model)	df	AIC	BIC
.	161	.	-749.6455	4	1507.291	1519.617

```
-----+-----
```

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

# Exemplo 4: vinho rose – Questão 3 e 4

3.

O modelo SARIMA(0,1,2)(0,1,1)<sub>12</sub> tem menor AIC e BIC, sendo o único que tem todos os lags individualmente significativos. Contudo, para efeitos de previsão, consideram-se ainda os outros dois modelos.

4.


O primeiro passo é criar as 4 datas onde se pretende prever:

```
. tsappend, add(4)

. quietly arima vendas, arima(0,1,2) sarima(0,1,1,12)
. predict outvendashat1, y dynamic(tm(1994m7))
(13 missing values generated)
. quietly arima vendas, arima(0,1,2) sarima(1,1,1,12)
. predict outvendashat2, y dynamic(tm(1994m7))
(13 missing values generated)
. quietly arima vendas, arima(0,1,0) sarima(1,1,1,12)
. predict outvendashat3, y dynamic(tm(1994m7))
(13 missing values generated)
. line vendas outvendashat1 outvendashat2 outvendashat3 time, title("Exemplo
Vinho rosé") ytitle(Vendas) xtitle(Month)
```

# Exemplo 4: vinho rose – Questão 4

```
. line vendas outvendashat1 outvendashat2 outvendashat3 time, title("Exemplo  
Vinho rosé") ytitle(Vendas) xtitle(Month)
```



# Exemplo 5: Consumo

O ficheiro “Cons6794.dta” contém dados trimestrais relativos ao consumo de bens não duradouros e ao rendimento disponível para os anos de 1967 a 1994. Ambas as variáveis estão medidas a preços constantes de 1987.

1. Analise a estacionaridade das duas séries. Se necessário, faça as transformações necessárias que lhe permitam obter séries estacionárias.
2. Estime um modelo  $ADL(4,4)$  para o consumo. Teste a hipótese de que o rendimento não causa à Granger o consumo.
4. Analise a adequação do modelo escolhido na alínea anterior através de um conjunto de testes de diagnóstico.
5. Preveja o consumo por 4 trimestres, utilizando o modelo escolhido e, apenas para exemplificar, o modelo  $ADL(4,4)$ . Compare as previsões através de um gráfico.

# Exemplo 5: Consumo – Questão 1

Sugere-se a utilização de um comando único, que apresenta o teste para vários lags, usando regressões baseadas no MMQ generalizado.

```
. gen t=[_n]
```

```
. tsset t
```

```
time variable: t, 1 to 109
```

## Consumo

Tipicamente, na variável em níveis  $H_0$  não é rejeitada.

Considerando a sua primeira diferença, apenas em dois casos se conclui pela não rejeição. Assim, conclui-se que a série é  $I(1)$

# Exemplo 5: Consumo – Questão 1

```
. dfgls cons
```

```
DF-GLS for cons
```

```
Number of obs = 96
```

```
Maxlag = 12 chosen by Schwert criterion
```

[lags]	DF-GLS tau Test Statistic	1% Critical Value	5% Critical Value	10% Critical Value
12	-2.543	-3.569	-2.761	-2.488
11	-2.582	-3.569	-2.790	-2.515
10	-2.376	-3.569	-2.818	-2.542
9	-2.283	-3.569	-2.845	-2.568
8	-2.236	-3.569	-2.872	-2.592
7	-2.536	-3.569	-2.897	-2.616
6	-2.535	-3.569	-2.922	-2.639
5	-2.687	-3.569	-2.945	-2.660
4	-2.859	-3.569	-2.967	-2.680
3	-3.287	-3.569	-2.987	-2.699
2	-2.370	-3.569	-3.006	-2.716
1	-2.305	-3.569	-3.022	-2.730

```
Opt Lag (Ng-Perron seq t) = 3 with RMSE 5.167441
```

```
Min SC = 3.474936 at lag 3 with RMSE 5.167441
```

```
Min MAIC = 3.560532 at lag 1 with RMSE 5.538298
```

# Exemplo 5: Consumo – Questão 1

```
. dfgls d.cons
```

```
DF-GLS for D.cons
```

```
Number of obs = 95
```

```
Maxlag = 12 chosen by Schwert criterion
```

[lags]	DF-GLS tau Test Statistic	1% Critical Value	5% Critical Value	10% Critical Value
12	-2.899	-3.570	-2.760	-2.486
11	-2.762	-3.570	-2.789	-2.514
10	-2.796	-3.570	-2.817	-2.541
9	-3.134	-3.570	-2.845	-2.567
8	-3.394	-3.570	-2.872	-2.592
7	-3.827	-3.570	-2.898	-2.616
6	-3.605	-3.570	-2.922	-2.640
5	-3.928	-3.570	-2.946	-2.661
4	-3.945	-3.570	-2.968	-2.681
3	-3.924	-3.570	-2.988	-2.700
2	-3.524	-3.570	-3.007	-2.717
1	-5.535	-3.570	-3.024	-2.732

```
Opt Lag (Ng-Perron seq t) = 3 with RMSE 5.38552
```

```
Min SC = 3.541899 at lag 2 with RMSE 5.46873
```

```
Min MAIC = 3.991358 at lag 2 with RMSE 5.46873
```

# Exemplo 5: Consumo – Questão 1

## Rendimento

Os resultados para a série em níveis indicam o mesmo número não rejeições e de rejeições... Admite-se a presença de raiz unitária e testa-se a primeira diferença. Aqui  $H_0$  é sempre rejeitada. O rendimento será incluído no modelo na forma de primeira diferença



# Exemplo 5: Consumo – Questão 1

```
. dfgls rend
```

```
DF-GLS for rend
```

```
Number of obs = 96
```

```
Maxlag = 12 chosen by Schwert criterion
```

[lags]	DF-GLS tau Test Statistic	1% Critical Value	5% Critical Value	10% Critical Value
12	-3.000	-3.569	-2.761	-2.488
11	-3.234	-3.569	-2.790	-2.515
10	-3.234	-3.569	-2.818	-2.542
9	-2.972	-3.569	-2.845	-2.568
8	-2.691	-3.569	-2.872	-2.592
7	-2.798	-3.569	-2.897	-2.616
6	-2.851	-3.569	-2.922	-2.639
5	-2.906	-3.569	-2.945	-2.660
4	-3.508	-3.569	-2.967	-2.680
3	-3.215	-3.569	-2.987	-2.699
2	-2.859	-3.569	-3.006	-2.716
1	-2.825	-3.569	-3.022	-2.730

```
Opt Lag (Ng-Perron seq t) = 0 [use maxlag(0)]
```

```
Min SC = 6.75181 at lag 1 with RMSE 27.89255
```

```
Min MAIC = 6.865729 at lag 1 with RMSE 27.89255
```

# Exemplo 5: Consumo – Questão 1

```
. dfgls d.rend
```

```
DF-GLS for D.rend
```

```
Number of obs = 95
```

```
Maxlag = 12 chosen by Schwert criterion
```

[lags]	DF-GLS tau Test Statistic	1% Critical Value	5% Critical Value	10% Critical Value
12	-3.737	-3.570	-2.760	-2.486
11	-3.264	-3.570	-2.789	-2.514
10	-3.100	-3.570	-2.817	-2.541
9	-3.149	-3.570	-2.845	-2.567
8	-3.539	-3.570	-2.872	-2.592
7	-4.195	-3.570	-2.898	-2.616
6	-4.370	-3.570	-2.922	-2.640
5	-4.677	-3.570	-2.946	-2.661
4	-5.077	-3.570	-2.968	-2.681
3	-4.531	-3.570	-2.988	-2.700
2	-5.447	-3.570	-3.007	-2.717
1	-7.457	-3.570	-3.024	-2.732

```
Opt Lag (Ng-Perron seq t) = 12 with RMSE 27.44396
```

```
Min SC = 6.845093 at lag 1 with RMSE 29.21292
```

```
Min MAIC = 9.107631 at lag 3 with RMSE 29.12036
```

## Exemplo 5: Consumo – Questão 2

Como as variáveis possuem raízes unitárias, o modelo de regressão deve ser construído com base nas suas primeiras diferenças. Assim, o modelo a estimar é:

$$\Delta cons_t = \beta_0 + \beta_1 \Delta cons_{t-1} + \beta_2 \Delta cons_{t-2} + \beta_3 \Delta cons_{t-3} + \beta_4 \Delta cons_{t-4} + \beta_5 \Delta rend_{t-1} + \beta_6 \Delta rend_{t-2} + \beta_7 \Delta rend_{t-3} + \beta_8 \Delta rend_{t-4} + u_t$$

# Exemplo 5: Consumo – Questão 2

```
. regress D.cons LD.cons L2D.cons L3D.cons L4D.cons LD.rend L2D.rend L3D.rend L4D.rend
```

Source	SS	df	MS	Number of obs = 104	
Model	637.491447	8	79.6864309	F( 8, 95)	= 2.63
Residual	2878.33972	95	30.2983129	Prob > F	= 0.0120
Total	3515.83117	103	34.1342832	R-squared	= 0.1813
				Adj R-squared	= 0.1124
				Root MSE	= 5.5044

D.cons	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
cons						
LD	.3202841	.1131882	2.830	0.006	.0955771	.544991
L2D	-.0486806	.1158499	-0.420	0.675	-.2786718	.1813105
L3D	.3231878	.1156217	2.795	0.006	.0936497	.5527259
L4D	-.1138674	.1133264	-1.005	0.318	-.3388487	.1111139
rend						
LD	.0066256	.0228151	0.290	0.772	-.0386681	.0519192
L2D	-.0088078	.0242377	-0.363	0.717	-.0569256	.0393101
L3D	-.0091774	.024207	-0.379	0.705	-.0572344	.0388796
L4D	-.0206126	.0230391	-0.895	0.373	-.0663509	.0251258
_cons	2.762309	.9581189	2.883	0.005	.8602028	4.664416

# Exemplo 5: Consumo – Questão 2

Para testar se o rendimento causa à Granger o consumo pode-se usar um teste  $F$  para a hipótese  $H_0: \beta_5 = \beta_6 = \beta_7 = \beta_8 = 0$

```
. test LD.rend L2D.rend L3D.rend L4D.rend
```

```
( 1) LD.rend = 0.0  
( 2) L2D.rend = 0.0  
( 3) L3D.rend = 0.0  
( 4) L4D.rend = 0.0
```

```
F( 4, 95) = 0.26  
Prob > F = 0.9020
```

Não se rejeita a hipótese nula, pelo que o rendimento não causa à Granger o consumo. Será melhor usar um modelo AR(4) para o consumo.

Alternativamente, é possível usar o comandos automáticos para o model VAR

# Exemplo 5: Consumo – Questão 2

```
. var d.cons d.rend, lags(1/4)
```

Vector autoregression

```
Sample: 6 - 109                No. of obs   =      104
Log likelihood = -796.3743      AIC          =     15.66104
FPE            = 21723.68       HQIC         =     15.84647
Det(Sigma_ml) = 15354.08       SBIC         =     16.11873
```

Equation	Parms	RMSE	R-sq	chi2	P>chi2
D_cons	9	5.50439	0.1813	23.0338	0.0033
D_rend	9	27.9545	0.1214	14.36905	0.0726

	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
-----+-----						
D_cons						
cons						
LD.	.3202841	.1081798	2.96	0.003	.1082555	.5323126
L2D.	-.0486806	.1107238	-0.44	0.660	-.2656952	.1683339
L3D.	.3231878	.1105057	2.92	0.003	.1066007	.5397749
L4D.	-.1138674	.1083119	-1.05	0.293	-.3261548	.09842
rend						
LD.	.0066256	.0218055	0.30	0.761	-.0361125	.0493637
L2D.	-.0088078	.0231652	-0.38	0.704	-.0542107	.0365952
L3D.	-.0091774	.0231359	-0.40	0.692	-.0545229	.0361681
L4D.	-.0206126	.0220196	-0.94	0.349	-.0637703	.0225451
_cons	2.762309	.9157239	3.02	0.003	.9675234	4.557095

# Exemplo 5: Consumo – Questão 2

```

...
-----+-----
D_rend |
  cons |
    LD. |   1.487511   .5493992   2.71   0.007   .4107088   2.564314
    L2D. |   .1975428   .5623188   0.35   0.725  -.9045819   1.299667
    L3D. |   .9048973   .5612113   1.61   0.107  -.1950566   2.004851
    L4D. |   .0833921   .55007     0.15   0.880  -.9947252   1.161509 |
  rend |
    LD. |  -.3396588   .1107411  -3.07   0.002  -.5567074  -.1226102
    L2D. |  -.1657128   .1176462  -1.41   0.159  -.3962952   .0648695
    L3D. |  -.0725105   .1174974  -0.62   0.537  -.3028011   .1577801
    L4D. |  -.0573809   .1118283  -0.51   0.608  -.2765604   .1617987
      |
  _cons |   19.00864   4.650572   4.09   0.000   9.893689   28.1236
-----+-----

```

```
. vargranger
```

```
Granger causality Wald tests
```

```

+-----+-----+
|          Equation          Excluded |  chi2    df Prob > chi2 |
+-----+-----+
|          D_cons           D.rend |  1.1445    4    0.887 |
|          D_cons           ALL    |  1.1445    4    0.887 |
+-----+-----+
|          D_rend           D.cons | 10.801    4    0.029 |
|          D_rend           ALL    | 10.801    4    0.029 |
+-----+-----+

```

# Exemplo 5: Consumo – Questão 3

Da alínea anterior, resulta que um modelo  $AR(4)$  para o consumo é preferível ao modelo  $ADL(4,4)$ . Reestimação do modelo:

```
. regress D.cons LD.cons L2D.cons L3D.cons L4D.cons
```

Source	SS	df	MS	Number of obs = 104		
Model	605.816387	4	151.454097	F( 4, 99)	=	5.15
Residual	2910.01478	99	29.3940887	Prob > F	=	0.0008
-----+-----				R-squared	=	0.1723
-----+-----				Adj R-squared	=	0.1389
Total	3515.83117	103	34.1342832	Root MSE	=	5.4216

D.cons	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
cons						
LD	.3366491	.0985547	3.416	0.001	.1410951	.532203
L2D	-.0683404	.0997439	-0.685	0.495	-.2662539	.1295732
L3D	.2998895	.0997236	3.007	0.003	.1020162	.4977628
L4D	-.1598272	.0987864	-1.618	0.109	-.3558409	.0361865
_cons	2.484531	.7924329	3.135	0.002	.9121725	4.05689



# Exemplo 5: Consumo – Questão 3

Teste RESET para a forma funcional:

```
. ovtest
```

```
Ramsey RESET test using powers of the fitted values of D.cons  
Ho: model has no omitted variables  
F(3, 96) = 1.33  
Prob > F = 0.2683
```

Não se rejeita a hipótese nula de correcta especificação da forma funcional do modelo.

# Exemplo 5: Consumo – Questão 3

## Teste de Breusch-Godfrey para a autocorrelação:

```
. estat bgodfrey
```

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

lags (p)	chi2	df	Prob > chi2
1	0.926	1	0.3359

```
H0: no serial correlation
```

De acordo com este teste não se rejeita a hipótese nula de não autocorrelação.

# Exemplo 5: Consumo – Questão 3

## Teste de Breusch-Pagan para a heteroscedasticidade:

```
. bpagan LD.cons L2D.cons L3D.cons L4D.cons
```

```
Breusch-Pagan LM statistic: 1.055435 Chi-sq( 4) P-value = .9013
```

\*este comando tem que ser instalado previamente


A hipótese nula de homoscedasticidade não pode ser rejeitada.

Assim, todos os testes aplicados apontam para a boa especificação do modelo.

# Exemplo 5: Consumo – Questão 4

```
. tsappend, add(4)
. quietly arima cons, arima(4,1,0)
. predict conshat, y dynamic(110)
. quietly arima cons, arima(4,1,4)
. predict conshatr, y dynamic(110)

. line cons conshat conshatr t, title("Exemplo Consumo") ytitle(Cons)
xtitle(Quarter)
```



# Exemplo 6: Consumo – Questão 1

Continue a considerar o ficheiro “Cons6794.dta”, do exemplo 4.

1. Para o modelo ARIMA(4,1,0) selecionado anteriormente, apresente dois tipos de previsão, um passo à frente e passo a passo, dentro da amostra e considerando 4 períodos fora da amostra. Represente graficamente a série original e as duas previstas.
2. Considere agora um modelo ARIMA incluindo apenas o 4º lag e repita as previsões e a representação gráfica
3. Apresente o intervalo de confiança para a previsão de 2. e represente graficamente.

# Exemplo 6: Consumo – Questão 1

```

. gen t=[_n]
. tsset t
      time variable:  t, 1 to 109
          delta: 1 unit

. arima cons, arima(4,1,0)
ARIMA regression
Sample:  2 - 109
Log likelihood = -332.9314
Number of obs   =      108
Wald chi2(4)   =      23.34
Prob > chi2    =      0.0001
-----+-----
          |               OPG
          |   Coef.   Std. Err.   z   P>|z|   [95% Conf. Interval]
-----+-----
cons     |
   _cons |   4.24415   .8722807   4.87   0.000   2.534512   5.953789
-----+-----
ARMA     |
   ar    |
   L1.   |   .3361684   .0914378   3.68   0.000   .1569536   .5153831
   L2.   |  -.0776167   .0955875  -0.81   0.417  -.2649647   .1097313
   L3.   |   .2959629   .0934891   3.17   0.002   .1127277   .479198
   L4.   |  -.1584798   .0880806  -1.80   0.072  -.3311147   .0141551
-----+-----
   /sigma |   5.269664   .3415002  15.43   0.000   4.600336   5.938992

```

# Exemplo 6: Consumo – Questão 1

```
. tsappend, add(4)
```

## Previsão um passo à frente

```
. predict chat, y  
(4 missing values generated)
```

## OU

```
. predict dchat  
(option xb assumed; predicted values)
```

```
.gen chat2=1.cons+dchat
```

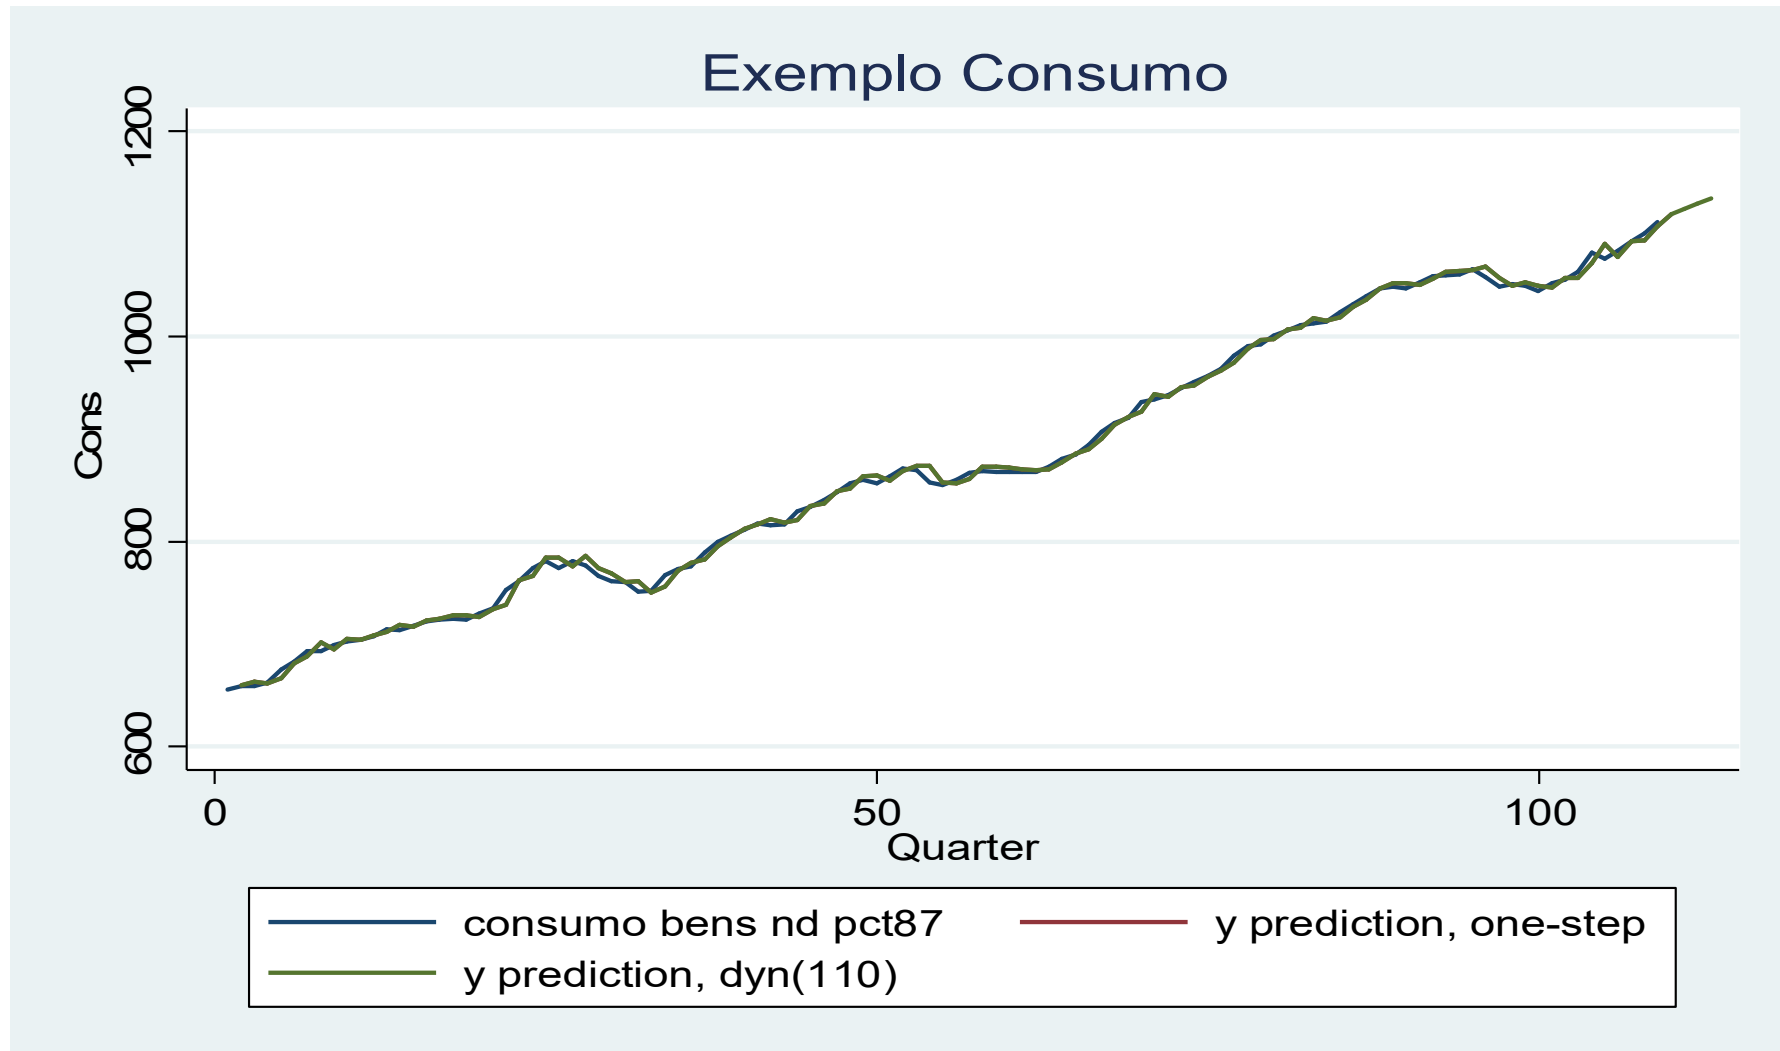
## Apenas prevê um período à frente

## Previsão passo a passo

```
. predict cphat, y dynamic(110)  
(1 missing value generated)
```

```
. line cons chat cphat t, title("Exemplo Consumo") ytitle(Cons) xtitle(Quarter)
```

# Exemplo 6: Consumo – Questão 1





# Exemplo 6: Consumo – Questão 2

```
. arima cons, ar(4)
...
ARIMA regression
Sample: 1 - 109                Number of obs   =      109
                                Wald chi2(1)      =    3229.16
Log likelihood = -502.5299      Prob > chi2     =      0.0000
-----+-----
```

		OPG				[95% Conf. Interval]	
	cons	Coef.	Std. Err.	z	P> z		
cons							
	_cons	877.8944	101.5413	8.65	0.000	678.8771	1076.912
ARMA							
	ar						
	L4.	.9942593	.0174966	56.83	0.000	.9599665	1.028552
	/sigma	22.40785	2.372829	9.44	0.000	17.7572	27.05851

```
-----+-----
```


Note: The test of the variance against zero is one sided, and the two-sided confidence interval is truncated at zero.

```
. predict c4hat, y
. predict c4phat, y dynamic(110)
```

Neste caso as duas previsões são numericamente iguais, porque há 4 lags de atraso

# Exemplo 6: Consumo – Questão 2

```
. line cons c4hat c4hat t, title("Exemplo Consumo") ytitle(Cons) xtitle(Quarter)
```




# Exemplo 6: Consumo – Questão 3

```
. quietly arima cons, ar(4)
. predict s4, stdp

. gen ilowc4hat=c4hat-1.96*s4
(4 missing values generated)
. gen iupc4hat=c4hat+1.96*s4
(4 missing values generated)

. line cons ilowc4hat iupc4hat t, title("Exemplo Consumo") ytitle(Cons)
xtitle(Quarter)
```



# Exemplo 7: Consumo – Quebra de estrutura

Considere novamente os dados em “Cons6794.dta”. Trabalhe com o modelo

$$\nabla cons_t = \beta_0 + \beta_1 \nabla rend_t$$

1. Teste a possível existência de uma quebra de estrutura em data desconhecida.
2. Suponha que se deseja testar se no momento  $t=63$  há evidência de quebra de estrutura.

# Exemplo 7: Consumo – Questão 1

```
. regress D.cons D.rend
```

Source	SS	df	MS	Number of obs	=	108
-----+-----				F(1, 106)	=	30.55
Model	807.550621	1	807.550621	Prob > F	=	0.0000
Residual	2802.00097	106	26.4339714	R-squared	=	0.2237
-----+-----				Adj R-squared	=	0.2164
Total	3609.55159	107	33.734127	Root MSE	=	5.1414
-----						
D.cons	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
-----+-----						
rend						
D1.	.097721	.0176801	5.53	0.000	.0626685	.1327735
_cons	2.419047	.5926719	4.08	0.000	1.244017	3.594077
-----						

# Exemplo 7: Consumo – Questão 1

```
. estat sbsingle
-----+----- 1 -----+----- 2 -----+----- 3 -----+----- 4 -----+----- 5
.....
.....
Test for a structural break: Unknown break date

                                Number of obs =          108

Full sample:                    2 - 109
Trimmed sample:                 19 - 93
Estimated break date:          19
Ho: No structural break

      Test           Statistic           p-value
-----+-----+-----
      swald           3.4659             0.8166
-----+-----+-----

Exogenous variables:           D.rend
Coefficients included in test: D.rend _cons
```

Não se rejeita a hipótese de ausência de quebra de estrutura em  $\nabla cons_t$

# Exemplo 7: Consumo – Questão 2

```
. gen d63=t>=63
. gen Drend63=D.rend*d63
(1 missing value generated)
. regress D.cons D.rend d63 Drend63
```

Source	SS	df	MS	Number of obs	=	108
-----+-----				F(3, 104)	=	10.99
Model	868.91979	3	289.63993	Prob > F	=	0.0000
Residual	2740.6318	104	26.3522288	R-squared	=	0.2407
-----+-----				Adj R-squared	=	0.2188
Total	3609.55159	107	33.734127	Root MSE	=	5.1334

D.cons	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
-----+-----						
rend						
D1.	.1082849	.025712	4.21	0.000	.0572969	.1592728
d63	1.804978	1.19569	1.51	0.134	-.5661192	4.176076
Drend63	-.0228284	.0354204	-0.64	0.521	-.0930685	.0474117
_cons	1.640905	.7891574	2.08	0.040	.0759763	3.205834

# Exemplo 7: Consumo – Questão 2

```
. test d63 Drend63  
( 1) d63 = 0  
( 2) Drend63 = 0
```

```
F( 2, 104) = 1.16  
Prob > F = 0.3161
```

Não se rejeita a hipótese de ausência de quebra de estrutura em  $\nabla cons_t$  nesta data