

Modelos Sazonais

Aula 06

Bueno (2011) – Seção 3.11

Enders, 2004 – Capítulo 2

Morettin (2011) – Seção 3.6

Morettin e Toloi, 2006 – Capítulo 10

Introdução

Muitas séries econômicas podem apresentar uma componente sazonal, em decorrência de safras agrícolas, férias, clima ou datas especiais como, por exemplo, Natal.

Essa tal componente sazonal pode aparecer quando são feitas observações intra-anuais para a série de interesse, isto é, os dados são registrados mensalmente, trimestralmente ou semanalmente, por exemplo.

Introdução


Um modelo clássico para séries temporais supõe que uma série temporal Z_t , $t = 1, \dots, n$, possa ser escrita como a soma de três componentes: uma tendência, uma componente sazonal e um termo aleatório:

$$Z_t = T_t + S_t + a_t, \quad t = 1, \dots, n \quad (1)$$

No *slide*, a seguir, temos um exemplo de uma série temporal com as componentes tendência e sazonalidade entrando de forma aditiva no PGD.

Exemplo

(Série temporal com componentes aditivos)



Introdução

O processo descrito em (1) é dito **aditivo** e é adequado, por exemplo, quando S_t não depende das outras componentes, como T_t .


Porém, se as amplitudes sazonais variam com a tendência, um modelo mais adequado é o multiplicativo, dado por:

$$Z_t = T_t \cdot S_t \cdot a_t, \quad t = 1, \dots, n \quad (2)$$

No *slide*, a seguir, temos um exemplo de uma série temporal com as componentes tendência e sazonalidade entrando de forma multiplicativa no PGD.

Exemplo

(Série temporal com componentes multiplicativos)



Introdução

Removendo-se as componentes T_t e S_t , em (1), o que sobra é a componente aleatória ou residual, a_t .

A suposição normal é que a_t seja um processo estocástico puramente aleatório (ruído branco).

Porém, em alguns casos, podemos considerar a_t como um processo estacionário, digamos, com média zero e variância constante.

Introdução

O problema que se apresenta é o de modelar convenientemente as três componentes T_t , S_t e a_t , com a finalidade de se fazer previsões de valores futuros da série.

O que se faz usualmente é representar $f(t) = T_t + S_t$ por alguma função suave no tempo, por exemplo, uma mistura de polinômios e funções trigonométricas ou uma mistura de polinômios e *dummies* sazonais. Deste modo, encara-se $f(t)$ como uma função determinística do tempo.

Introdução

Todavia, é possível considerar sazonalidade estocástica, por exemplo, quando esta não apresenta um padrão “bem comportado” no tempo. Assim, será necessário usar uma abordagem diferente para S_t .

Uma possível abordagem é a partir do uso dos modelos da classe SARIMA.

Todavia, o uso da FAC e da FACP na identificação e especificação de modelos para séries sazonais é um pouco mais complicado.

Observações

Há casos em que se deve estimar os parâmetros do modelo com as séries dessazonalizadas. Em geral, as séries devem ser dessazonalizadas quando no modelo de interesse entram variáveis sazonais (por exemplo, inflação) e variáveis não sazonais (por exemplo, taxa de juros).

Cuidado para não dessazonalizar séries que não apresentam sazonalidade, uma vez que esse procedimento pode distorcer o comportamento da mesma.

Observações

Existem diversos procedimentos para dessazonalizar uma série, entre eles, um dos mais utilizados é o Census X12-ARIMA. Para mais detalhes vide, por exemplo, <http://www.census.gov/srd/www/x12a/> ou manual do *software* Eviews.

Alguns Modelos Importantes

SAR(P)_S

(modelo autorregressivo puramente sazonal)

$$y_t = \Phi_1 y_{t-S} + \Phi_2 y_{t-2S} + \dots + \Phi_P y_{t-PS} + \varepsilon_t$$

que pode ser re-escrito, como

$$\left(1 - \Phi_1 L^S - \Phi_2 L^{2S} - \dots - \Phi_P L^{PS}\right) y_t = \varepsilon_t$$


⇔

$$\Phi(L^S) y_t = \varepsilon_t$$

Condição de estacionariedade: raízes da equação que envolve o polinômio autorregressivo sazonal fora do círculo unitário.


Exemplo 1

$SAR(1)_{12}$



Exemplo 1 (cont.)

SAR(1)₁₂



SMA(Q)_s

(modelo de médias móveis puramente sazonal)

$$y_t = \varepsilon_t - \Theta_1 \varepsilon_{t-s} - \Theta_2 \varepsilon_{t-2s} - \dots - \Theta_Q \varepsilon_{t-Qs}$$

que pode ser re-escrito, como

$$y_t = \left(1 - \Theta_1 L^s - \Theta_2 L^{2s} - \dots - \Theta_Q L^{Qs}\right) \varepsilon_t$$


⇔

$$y_t = \Theta(L^s) \varepsilon_t$$

Condição de invertibilidade: raízes da equação que envolve o polinômio de médias móveis sazonal fora do círculo unitário.


Exemplo 2

$SMA(1)_{12}$



Exemplo 2 (cont.)

SMA(1)₁₂



SARMA(P, Q)_S

(modelo ARMA puramente sazonal)


$$\Phi_P(L^S)y_t = \Theta_Q(L^S)\varepsilon_t$$

Condição de estacionariedade: raízes da equação que envolve o polinômio autorregressivo sazonal fora do círculo unitário.


Condição de invertibilidade: raízes da equação que envolve o polinômio de médias móveis sazonal fora do círculo unitário.

Exemplo 3

SARMA(1,1)₁₂



Exemplo 3 (cont.)



SARIMA(P, D, Q)_S

(modelo ARIMA puramente sazonal)

$$\Phi_P(L^S)\Delta_S^D y_t = \Theta_Q(L^S)\varepsilon_t$$


em que

$\Delta_S^D = (1 - L^S)^D$ – é o operador diferença sazonal

D – indica o número de diferenças sazonais (normalmente $D = 1$).

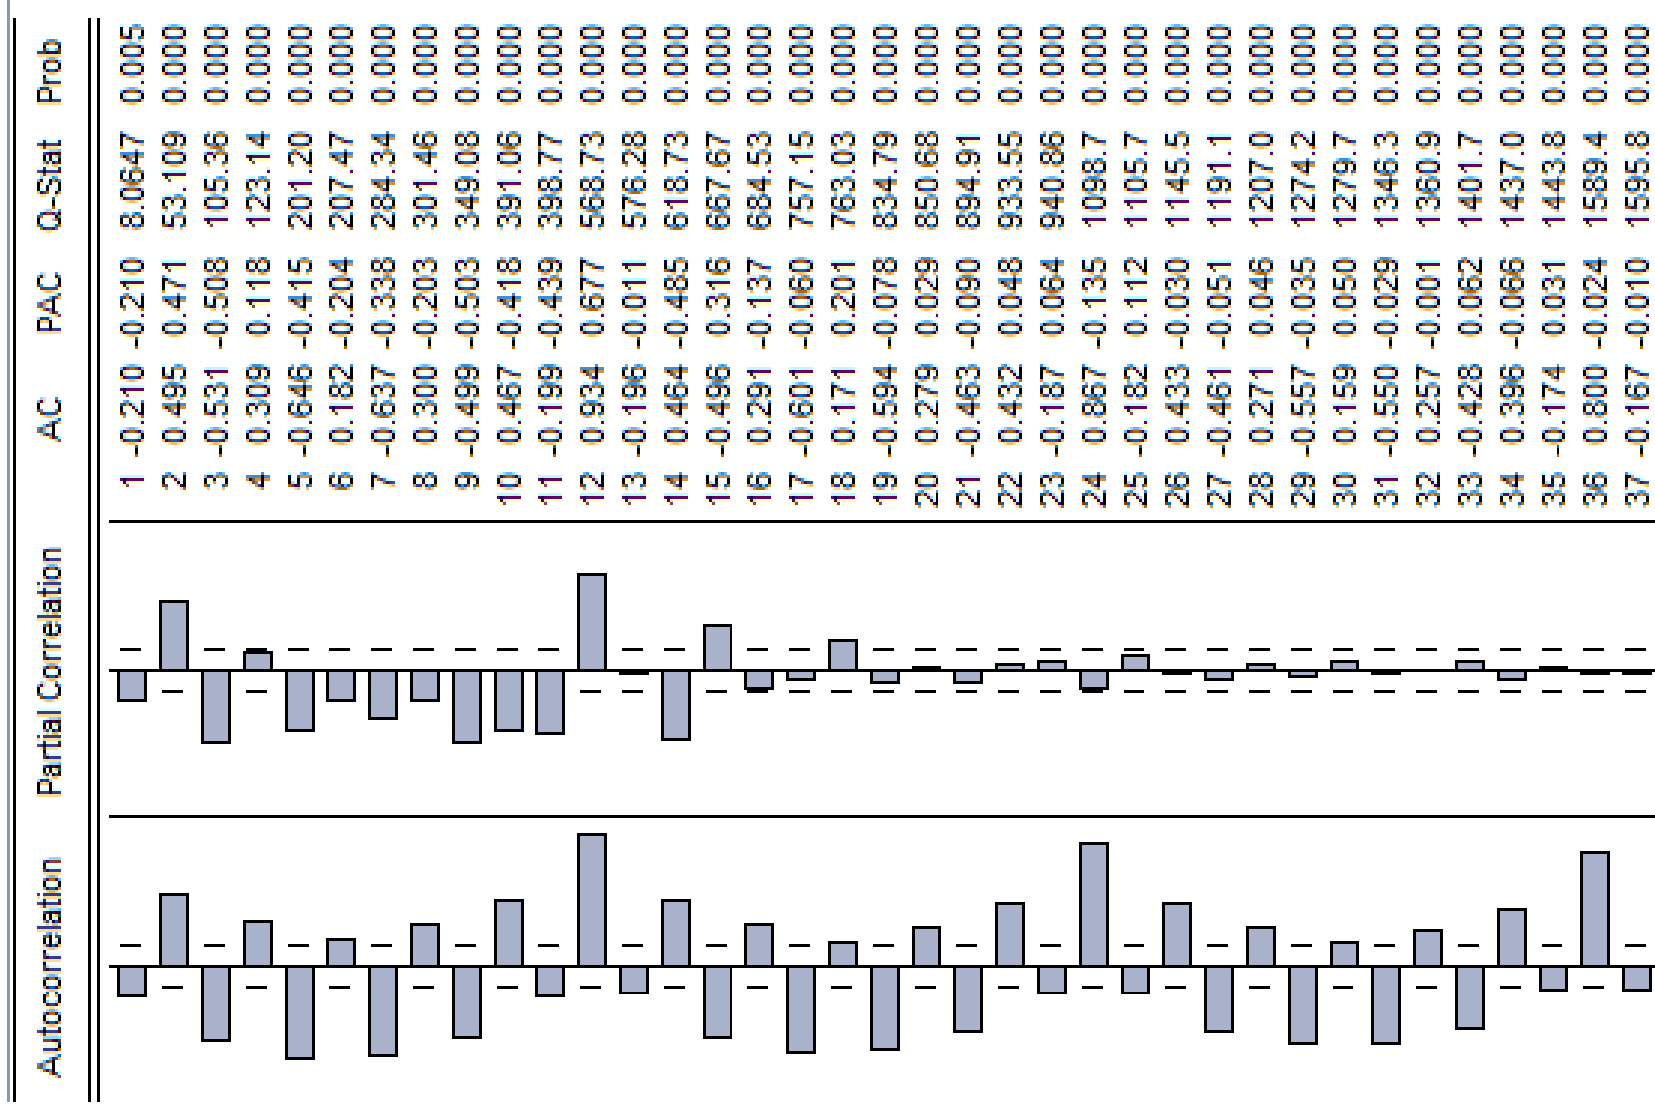
Exemplo 4

SARIMA(1,1,0)₁₂




Exemplo 4 (cont.)

SARIMA(1,1,0)₁₂




Exemplo 4

$d(y,0,12)$



Exemplo 4 (cont.)

$d(y,0,12)$



MODELO MULTIPLICATIVO GERAL

SARIMA (p, d, q) x (P, D, Q)_s

$$\phi_p(L)\Phi_P(L^S)\Delta^d\Delta_S^D y_t = \theta_q(L)\Theta_Q(L^S)\varepsilon_t$$

em que

$\Delta^d = (1 - L)^d$ – é o operador diferença simples

d – indica o número de diferenças simples (normalmente $d = 1$ ou 2).

$\Delta_S^D = (1 - L^S)^D$ – é o operador diferença sazonal


D – indica o número de diferenças sazonais (normalmente $D = 1$).

Exercício

Utilizando os dados da série mensal do número total de passageiros internacionais (em milhares de passageiros), no período de 01/1949 – 12/1960, *AIRLINE.Wf1*, responda ao que for pedido:

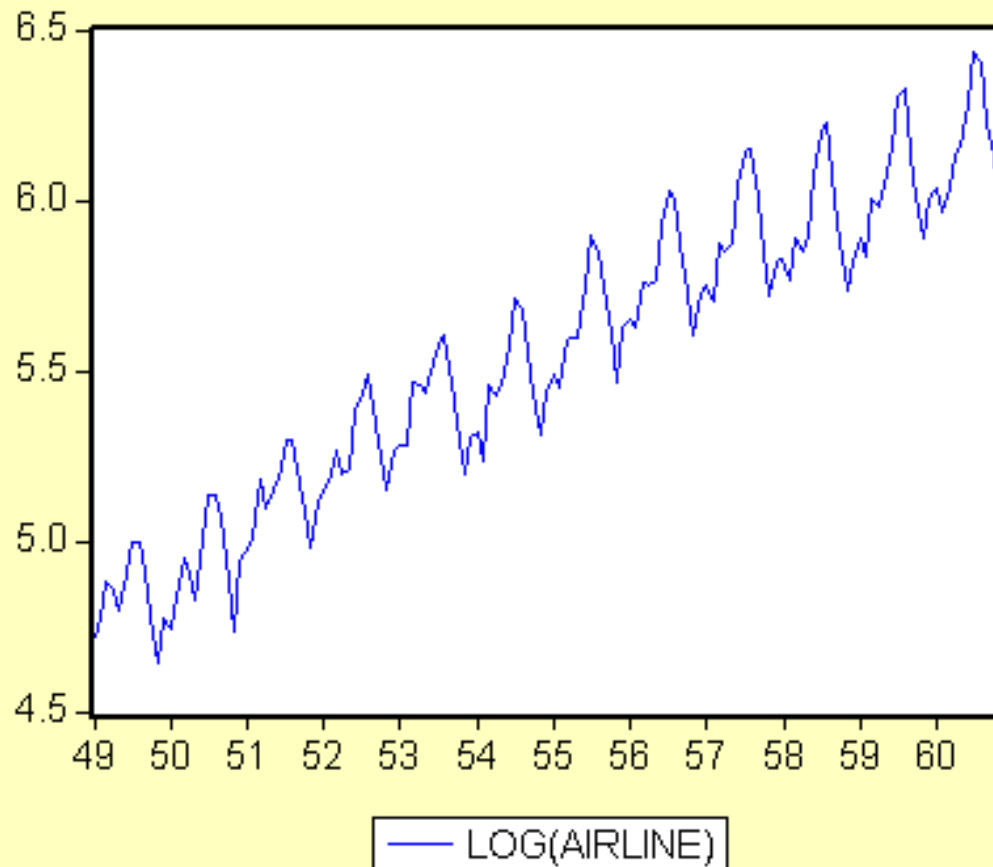
Exercício

a) Elabore o gráfico da série. Você faria alguma transformação na série? Comente.



















































Exercício – cont. (a)

Transformação: $\ln(\text{airline})$



Exercício

b) Esboce o correlograma da série transformada.
Comente.

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.954	0.954	133.72	0.000
		2	0.899	-0.118	253.36	0.000
		3	0.851	0.054	361.29	0.000
		4	0.808	0.024	459.44	0.000
		5	0.779	0.116	551.20	0.000
		6	0.756	0.044	638.37	0.000
		7	0.738	0.038	721.86	0.000
		8	0.727	0.100	803.60	0.000
		9	0.734	0.204	887.42	0.000
		10	0.744	0.064	974.33	0.000
		11	0.758	0.106	1065.2	0.000
		12	0.762	-0.042	1157.6	0.000
		13	0.717	-0.485	1240.0	0.000
		14	0.663	-0.034	1311.1	0.000
		15	0.618	0.042	1373.4	0.000
		16	0.576	-0.044	1428.0	0.000
		17	0.544	0.028	1476.9	0.000
		18	0.519	0.037	1521.9	0.000
		19	0.501	0.042	1564.1	0.000
		20	0.490	0.014	1604.9	0.000
		21	0.498	0.073	1647.3	0.000
		22	0.506	-0.033	1691.5	0.000
		23	0.517	0.061	1737.9	0.000
		24	0.520	0.031	1785.3	0.000
		25	0.484	-0.194	1826.6	0.000

Exercício

c) Desconsiderando as observações do ano de 1960, ajuste um modelo para a tendência e para a sazonalidade.

Dependent Variable: LOG(AIRLINE)

Method: Least Squares

Date: 09/12/08 Time: 14:32


Sample: 1949:01 1959:12

Included observations: 132

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	4.715209	0.019077	247.1724	0.0000
@TREND(1948:12)	0.010307	0.000132	78.30153	0.0000
FEV	-0.017531	0.024472	-0.716342	0.4752
MAR	0.118925	0.024473	4.859354	0.0000
ABR	0.076806	0.024475	3.138108	0.0021
MAI	0.072750	0.024478	2.972114	0.0036
JUN	0.195287	0.024481	7.977181	0.0000
JUL	0.295658	0.024485	12.07525	0.0000
AGO	0.288564	0.024489	11.78330	0.0000
SET	0.147494	0.024495	6.021497	0.0000
OUT	0.006278	0.024501	0.256251	0.7982
NOV	-0.134623	0.024507	-5.493194	0.0000
DEZ	-0.019028	0.024515	-0.776200	0.4392
R-squared	0.982729	Mean dependent var	5.486536	
Adjusted R-squared	0.980987	S.D. dependent var	0.416223	
S.E. of regression	0.057392	Akaike info criterion	-2.784542	
Sum squared resid	0.391963	Schwarz criterion	-2.500630	
Log likelihood	196.7798	F-statistic	564.2581	
Durbin-Watson stat	0.420944	Prob(F-statistic)	0.000000	

Exercício

d) Para o modelo estimado em (c), faça uma análise de resíduos. Comente.



Exercício


d) Para o modelo estimado em (c), faça uma análise de resíduos. Comente.

Sample: 1949:01 1959:12
Included observations: 132

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.786	0.786	83.395	0.000
		2 0.676	0.152	145.52	0.000
		3 0.526	-0.117	183.45	0.000
		4 0.432	0.023	209.21	0.000
		5 0.416	0.197	233.29	0.000
		6 0.378	0.000	253.35	0.000
		7 0.337	-0.064	269.47	0.000
		8 0.294	0.009	281.82	0.000
		9 0.299	0.161	294.70	0.000
		10 0.287	-0.001	306.65	0.000
		11 0.279	-0.042	317.99	0.000
		12 0.277	0.064	329.28	0.000
		13 0.190	-0.161	334.63	0.000
		14 0.096	-0.189	336.02	0.000
		15 0.000	-0.080	336.02	0.000
		16 -0.106	-0.124	337.73	0.000
		17 -0.104	0.104	339.38	0.000
		18 -0.130	-0.055	341.99	0.000
		19 -0.143	-0.073	345.19	0.000
		20 -0.171	-0.036	349.82	0.000
		21 -0.180	0.042	354.98	0.000
		22 -0.163	0.050	359.28	0.000
		23 -0.114	0.102	361.37	0.000
		24 -0.123	-0.117	363.86	0.000
		25 -0.133	0.051	366.77	0.000
		26 -0.168	0.011	371.47	0.000
		27 -0.232	-0.138	380.53	0.000
		28 -0.282	-0.092	394.09	0.000
		29 -0.299	0.010	409.40	0.000
		30 -0.277	0.072	422.68	0.000
		31 -0.239	0.012	432.72	0.000
		32 -0.205	-0.068	440.19	0.000
		33 -0.243	-0.144	450.74	0.000
		34 -0.225	0.059	459.89	0.000
		35 -0.220	-0.048	468.73	0.000
		36 -0.177	0.041	474.50	0.000


Exercício

e) Elabore o gráfico para $D(\text{LOG}(\text{AIRLINE}))$.



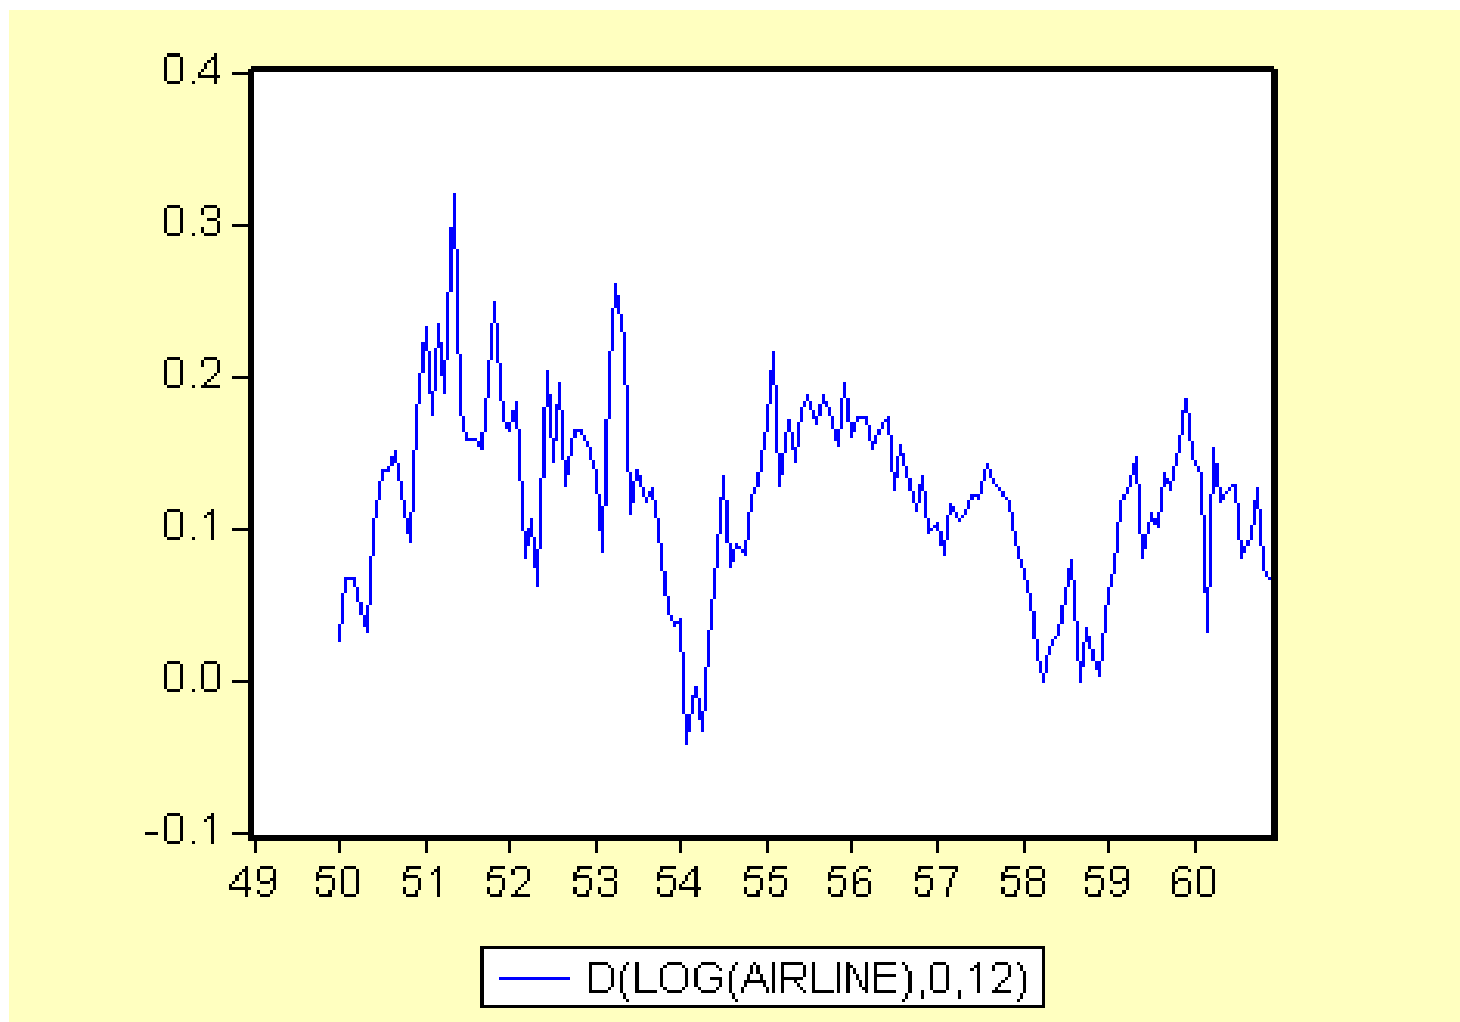
Exercício

f) Esboce o correlograma da série estudada em (e).
Comente.



Exercício


g) Elabore o gráfico para $D(\text{LOG}(\text{AIRLINE}), 0, 12)$.



Exercício

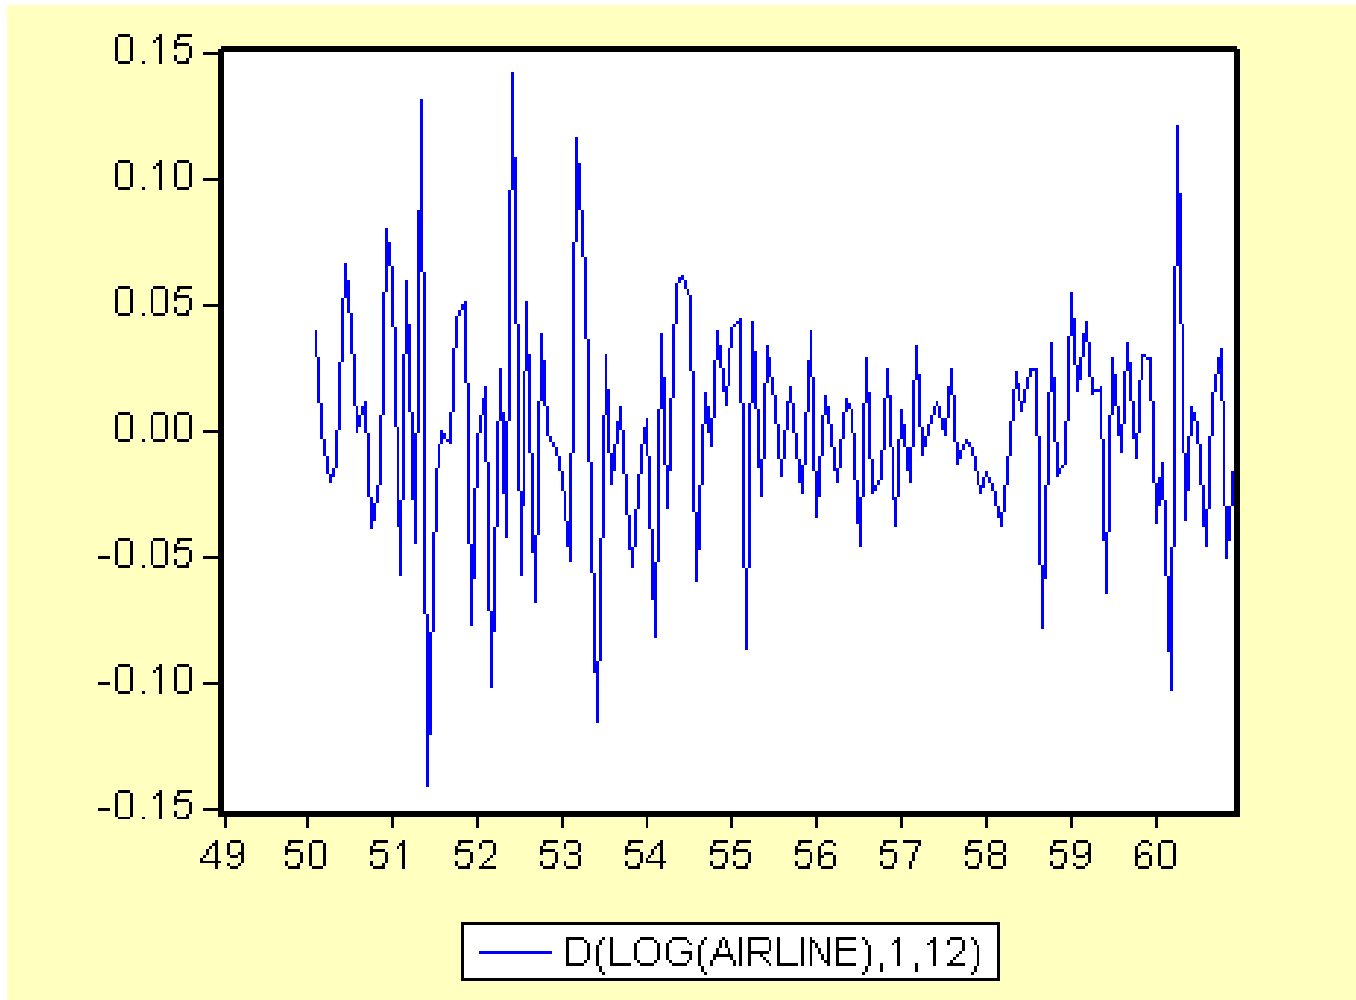
h) Esboce o correlograma da série estudada em (g).
Comente.

Correlogram of D(LOG(AIRLINE),0,12)



Exercício

i) Elabore o gráfico para $D(\text{LOG}(\text{AIRLINE}), 1, 12)$.



Exercício

j) Esboce o correlograma da série estudada em (i).
Comente.

Correlogram of D(LOG(AIRLINE),1,12)

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	-0.341	-0.341	15.596	0.000
		2	0.105	-0.013	17.086	0.000
		3	-0.202	-0.193	22.648	0.000
		4	0.021	-0.125	22.710	0.000
		5	0.056	0.033	23.139	0.000
		6	0.031	0.035	23.271	0.001
		7	-0.056	-0.060	23.705	0.001
		8	-0.001	-0.020	23.705	0.003
		9	0.176	0.226	28.147	0.001
		10	-0.076	0.043	28.987	0.001
		11	0.064	0.047	29.589	0.002
		12	-0.387	-0.339	51.473	0.000
		13	0.152	-0.109	54.866	0.000
		14	-0.058	-0.077	55.361	0.000
		15	0.150	-0.022	58.720	0.000
		16	-0.139	-0.140	61.645	0.000
		17	0.070	0.026	62.404	0.000
		18	0.016	0.115	62.442	0.000
		19	-0.011	-0.013	62.460	0.000
		20	-0.117	-0.167	64.598	0.000
		21	0.039	0.132	64.834	0.000
		22	-0.091	-0.072	66.168	0.000
		23	0.223	0.143	74.210	0.000
		24	-0.018	-0.067	74.265	0.000
		25	-0.100	-0.103	75.918	0.000

Exercício

k) Ajuste um modelo da classe

$$\text{SARIMA}(p, d, q) \times (P, D, Q)_s,$$

ou seja, um modelo

$$\phi_p(L)\Phi_P(L) (1-L)^d (1-L^{12})^D Y_t = \theta_q(L)\Theta_Q(L)\varepsilon_t,$$

para a série em estudo, não utilize as 12 últimas observações.

Exercício – cont (k)

Dependent Variable: D(LOG(AIRLINE),1,12)

Method: Least Squares

Sample (adjusted): 1950M02 1959M12

Included observations: 119 after adjustments

Convergence achieved after 8 iterations

Backcast: OFF

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(1)	-0.326651	0.087713	-3.724069	0.0003
SMA(12)	-0.577734	0.079312	-7.284348	0.0000
R-squared	0.326392	Mean dependent var		0.001322
Adjusted R-squared	0.320634	S.D. dependent var		0.045038
S.E. of regression	0.037122	Akaike info criterion		-3.732537
Sum squared resid	0.161233	Schwarz criterion		-3.685829
Log likelihood	224.0860	Durbin-Watson stat		1.986186
Inverted MA Roots	.96	.83-.48i	.83+.48i	.48-.83i
	.48+.83i	.33	.00-.96i	-.00+.96i
	-.48+.83i	-.48-.83i	-.83+.48i	-.83-.48i
	-.96			













































Exercício – cont (k)

Correlograma dos resíduos

Sample: 1950:02 1959:12

Included observations: 119

Q-statistic probabilities adjusted for 2 ARMA term(s)

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 -0.003	-0.003	0.0009	
		2 0.047	0.047	0.2745	
		3 -0.154	-0.154	3.2159	0.073
		4 -0.088	-0.092	4.1748	0.124
		5 0.063	0.080	4.6742	0.197
		6 0.059	0.047	5.1158	0.276
		7 -0.010	-0.048	5.1297	0.400
		8 -0.038	-0.033	5.3196	0.504
		9 0.090	0.129	6.3890	0.495
		10 -0.017	-0.017	6.4278	0.599
		11 0.020	-0.022	6.4797	0.691
		12 -0.011	0.020	6.4968	0.772
		13 0.019	0.048	6.5473	0.834
		14 0.033	0.017	6.6946	0.877
		15 0.038	0.022	6.8985	0.907
		16 -0.139	-0.133	9.6064	0.790
		17 0.074	0.099	10.384	0.795
		18 -0.020	-0.003	10.442	0.843
		19 -0.023	-0.085	10.517	0.881
		20 -0.103	-0.122	12.053	0.844
		21 -0.047	0.002	12.375	0.869
		22 -0.021	-0.018	12.440	0.900
		23 0.188	0.139	17.730	0.666
		24 -0.004	-0.049	17.732	0.722

Exercício – cont (k)

Considerando

$$Y_t = \log(\text{airline}_t)$$

Assim,

$$Y_t \sim \text{SARIMA}(0,1,1) \times (0,1,1)_{12} \quad (\textit{airline models})$$

e, portanto,

$$(1-L)(1-L^{12})Y_t = (1-0,326L)(1-0,578L^{12})\varepsilon_t$$

Exercício

I) Faça previsões, a partir do modelo proposto em (i). Compare os resultados previstos com os observados. Comente.

Dependent Variable: D(LOG(AIRLINE),1,12)
Method: Least Squares

Sample (adjusted): 1950M02 1959M12
Included observations: 119 after adjustment
Convergence achieved after 8 iterations
Backcast: OFF

Variable	Coefficient	Std. Error
MA(1)	-0.326651	0.08
SMA(12)	-0.577734	0.07

R-squared	0.326392	Mean
Adjusted R-squared	0.320634	S.D.
S.E. of regression	0.037122	Actual
Sum squared resid	0.161233	Sub
Log likelihood	224.0860	Durbin

Inverted MA Roots	.96	.83-
	.48+.83i	
	-.48+.83i	-.48-.83i
	-.96	-.96

Forecast

Forecast equation: UNTITLED

Series to forecast: AIRLINE D(LOG(AIRLINE),1,12)

Series names: Forecast name: airlinef S.E. (optional): seairlinef GARCH(optional):

Method: Dynamic forecast Static forecast Structural (ignore ARMA) Coef uncertainty in S.E. calc


Forecast sample: 1960m01 1960m12

Output: Forecast graph Forecast evaluation

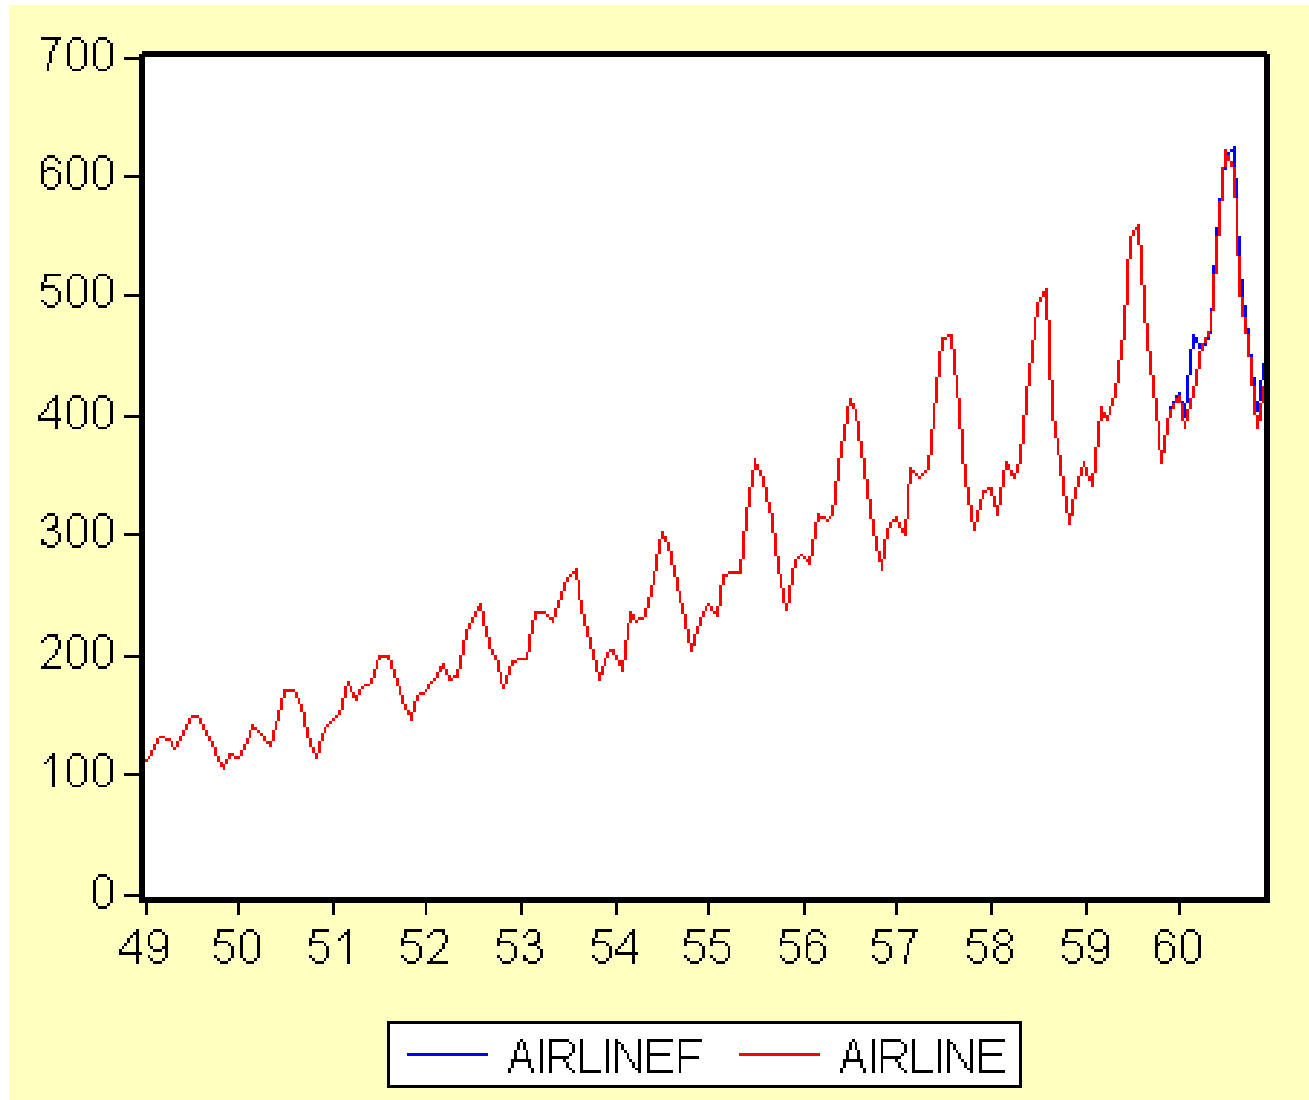
Insert actuals for out-of-sample observations

OK Cancel

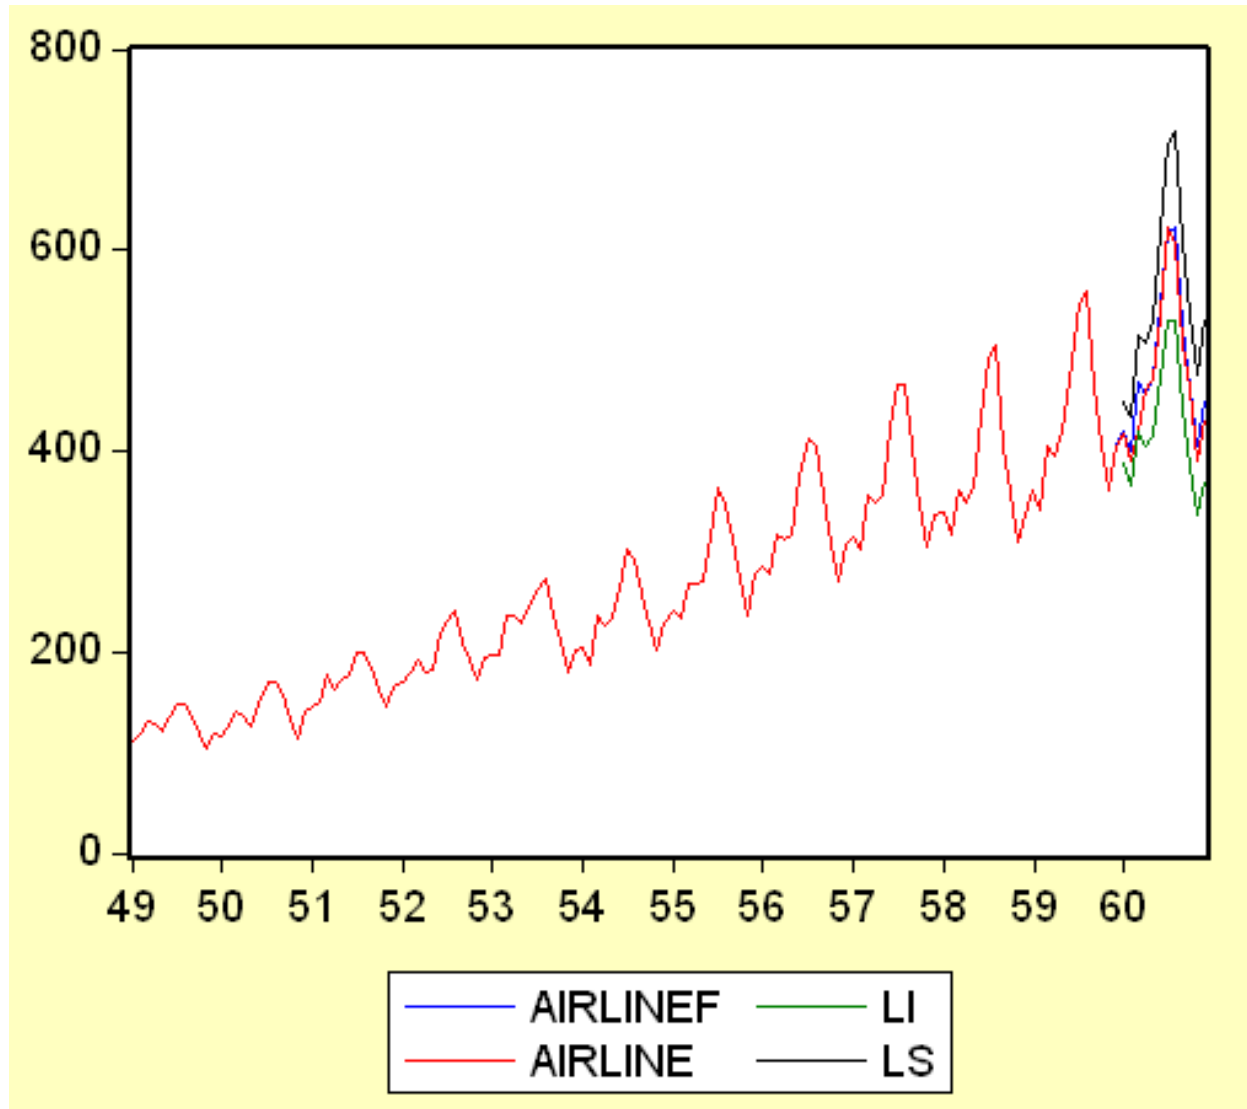
Exercício – cont. (I)




Exercício – cont. (I)



Exercício – cont. (I)



Exercício – cont. (I)




Exercícios

Exercício 1

Incorpore as observações do ano de 1960 à base de dados AIRLINE, e:

- a. re-estime o modelo final;
- b. faça uma análise de resíduos completa;
- c. preveja o número total de passageiros internacionais (em milhares de passageiros), no período de 1961:01 a 1961:12;
- d. elabore gráficos com as previsões e os respectivos ICs.

Exercício 1



Exercício 2

Escolha uma série temporal macroeconômica, coletada mensalmente, que apresente sazonalidade, com pelo menos 10 anos de observações. Ainda, desconsidere as 12 últimas observações e faça o que for pedido:

- (a) estime um modelo da classe SARIMA;
- (b) faça uma análise de resíduos completa;
- (c) faça previsões 12 passos a frente, com origem na última observação considerada na estimação;
- (d) compare os resultados obtidos em (c) com os valores originais da série para o período avaliado.