



Universidade de Coimbra

FCTUC

Séries Temporais

Modelação e Previsão de uma Série Temporal

João Marcelino
João Nuno Freitas
José Pedro Lopes
Simão Pedro Coelho

Janeiro 2020

Introdução

Este projeto, proposto pela unidade curricular de Séries Temporais, tem por base a geração e modelação estocástica de uma série temporal e uma posterior modelação e previsão de uma série real que, neste caso particular, é representada pelas cotações de fecho diárias da RAMADA, retirada do índice PSI20, no período temporal de 17-9-2018 a 14-9-2020.

A empresa RAMADA tem 80 anos de existência no ramo do aço. Entrou em 2018 para o leque das empresas existentes no PSI20, em substituição da Novabase. A RAMADA é composta, por oito empresas, das quais três são sedeadas em países da União Europeia.

1 Geração de uma Série Temporal

Neste capítulo pretende-se gerar e analisar uma série temporal $X = (X_t, t \in \{1, 2, \dots, T\})$ que verifique um processo estocástico estacionário ARMA (p, q) com erros TGARCH (r, s) de potência δ .

Depois de uma escolha conveniente e justificada dos parâmetros, obtém-se a seguinte série:

$$X_t = \frac{5}{6}X_{t-1} - \frac{1}{6}X_{t-2} + \varepsilon_t.$$

Ou seja, tem-se uma série que verifica um processo AR(2). Facilmente se verifica que este processo é estacionário, pois as raízes do polinómio AR estão fora do círculo unitário. De facto, sendo o polinómio autoregressivo dado por

$$\Phi(L) = 1 - \frac{5}{6}L + \frac{1}{6}L^2,$$

tem-se que

$$\Phi(x) = 0 \Leftrightarrow 1 - \frac{5}{6}x + \frac{1}{6}x^2 = 0 \Leftrightarrow x = 2 \vee x = 3.$$

Por fim, note-se que $\varepsilon = (\varepsilon_t, t \in \mathbb{Z})$ é um ruído branco de variância não nula.

No que diz respeito ao processo dos erros, foi escolhido trabalhar com um modelo GARCH (1, 1). Assim sendo, o processo $\varepsilon = (\varepsilon_t, t \in \mathbb{Z})$ é definido por:

$$\begin{cases} \varepsilon_t = \sigma_t Z_t \\ \sigma_t = 3 + 0.45\varepsilon_{t-1}^+ + 0.2\varepsilon_{t-1}^- \end{cases}$$

onde $\varepsilon_t^+ = \max(\varepsilon_t, 0)$ e $\varepsilon_t^- = \max(-\varepsilon_t, 0)$, com $Z = (Z_t, t \in \mathbb{Z})$ uma sucessão de variáveis aleatórias i.i.d., centradas e reduzidas, tal que Z_t é independente de $\underline{\varepsilon}_{t-1}$ para todo o $t \in \mathbb{Z}$ e com $\alpha = 0.45$ e $\beta = 0.2$ constantes reais.

Desta forma, verifica-se que o erro do processo é um GARCH (1, 1) a partir da seguinte forma:

$$\forall t \in \mathbb{Z}, V(\varepsilon_t | \underline{\varepsilon}_{t-1}) = h_t = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-1}^2 + \sum_{j=1}^p \beta_j h_{t-j}.$$

Esta representação permite estudar a estacionaridade de 2^a ordem, onde o modelo é assintoticamente estacionário no sentido fraco se os parâmetros são tais que:

$$\sum_{i=1}^q \alpha_i + \sum_{j=1}^p \beta_j < 1 \Leftrightarrow 0.45 + 0.2 < 1. \quad (1)$$

A condição inerente à equação (1) é condição necessária para a estacionaridade do processo de erro, neste caso, GARCH (1, 1).

1.1 Simulação da Série Temporal Z

Para analisar a série Z, que segue uma lei normal *standard*, começámos por gerar 1000 valores, no *EViews*, e obtivemos os seguintes resultados, figuras 1 e 2.

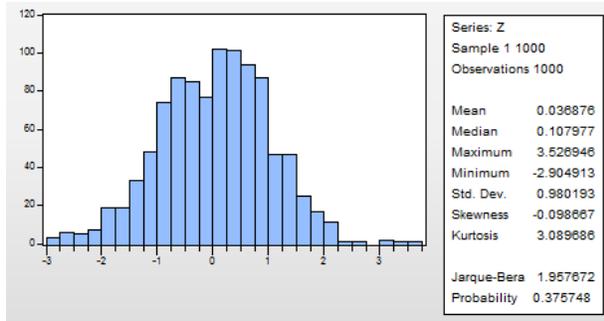


Figura 1: Histograma e resultado do teste de Jarque-Bera de Z

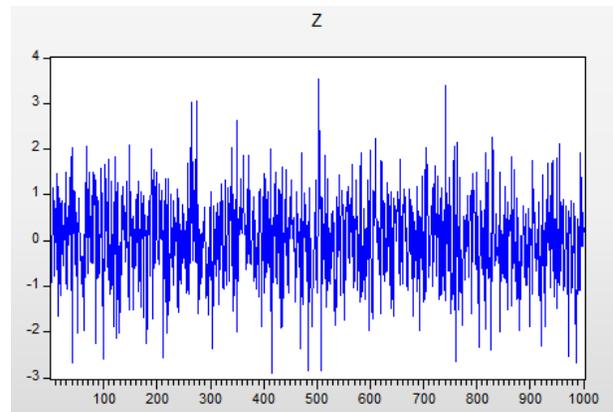


Figura 2: Trajetória da série Z

Da trajetória desta série observamos que existe um comportamento estável ao longo do tempo, isto é, não existem picos de grande volatilidade instantânea, mais ainda, conseguimos, de certa forma, enquadrar o seu gráfico entre duas retas.

O teste de Jarque-Bera testa duas hipóteses, a hipótese nula H_0 : "Z segue uma lei normal", contra a hipótese alternativa H_1 : "Z não segue uma lei normal". O p-valor associado a este teste encontra-se apresentado na figura 1 e vemos que o seu valor é 0.375748, superior aos níveis de significância usuais, logo aceita-se a normalidade.

Mais, os valores da média ($0.0368 \approx 0$), do desvio padrão ($0.980193 \approx 1$) e da curtose ($3.089 \approx 3$), reforçam que, de facto, a série Z segue uma lei normal centrada e reduzida.

1.2 Simulação da Série Temporal X

Tendo por base um processo X AR(2), teoricamente sabemos que a sucessão das autocorrelações parciais de X anula-se a partir da ordem 3. De facto, observando o correlograma de X, ver figura 5, vemos que apenas os dois primeiros valores são significativos, estando os restantes valores próximos de 0, como seria de esperar. Também é possível verificar que a

sua função autocorrelação decresce exponencialmente.

Na figura 3 verifica-se que o p-valor do teste de Jarque-Bera é nulo, o que nos leva a rejeitar a hipótese de normalidade de X e verifica-se também uma trajetória estável ao longo do tempo.

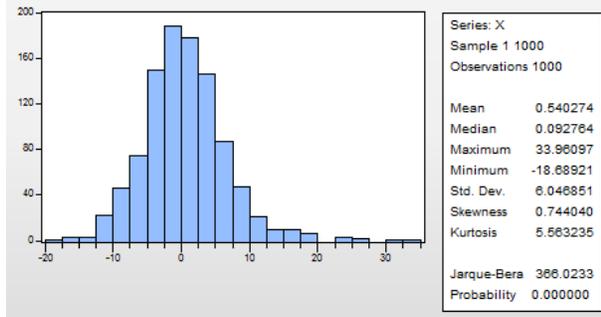


Figura 3: Histograma da série X

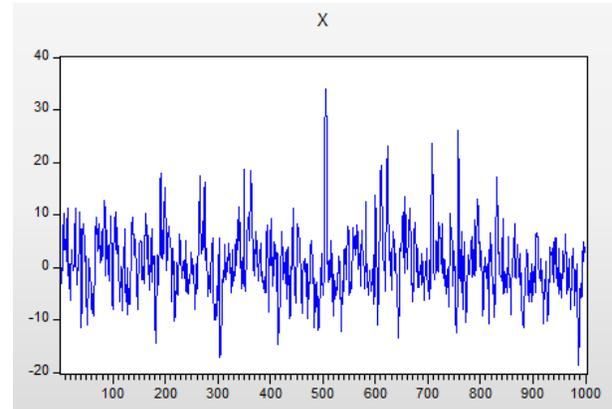


Figura 4: Trajetória da série X

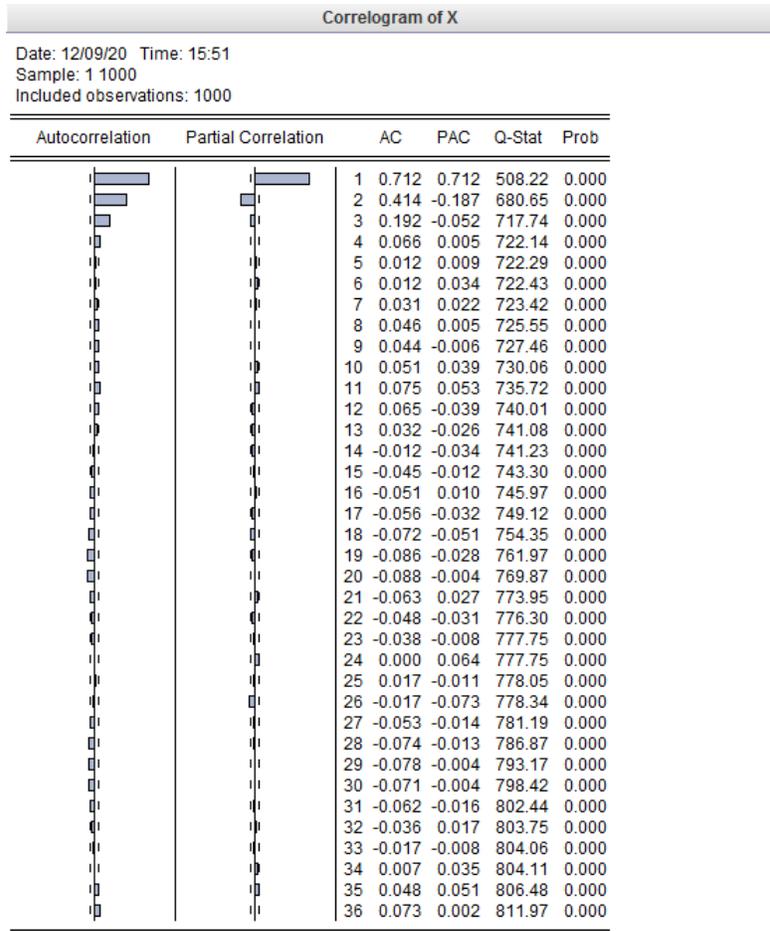


Figura 5: Correlograma da série X

1.3 Simulação do Processo $\varepsilon = (\varepsilon_t, t \in \mathbb{Z})$

As estatísticas apresentadas do processo ε eram as esperadas, ou seja, um processo de erro com características muito próximas de um ruído branco. A função de autocorrelação é nula, assim como a sucessão das autocorrelações parciais. No histograma vemos que o valor da média é 0.179816, próxima de zero, mas podia ser um valor mais próximo. O teste de Jarque-Bera diz-nos que este processo não segue uma lei normal, mas tal também não era esperado, pois não é uma condição necessária.

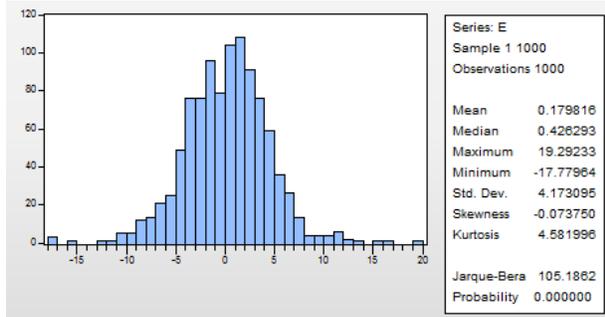


Figura 6: Histograma do processo ε

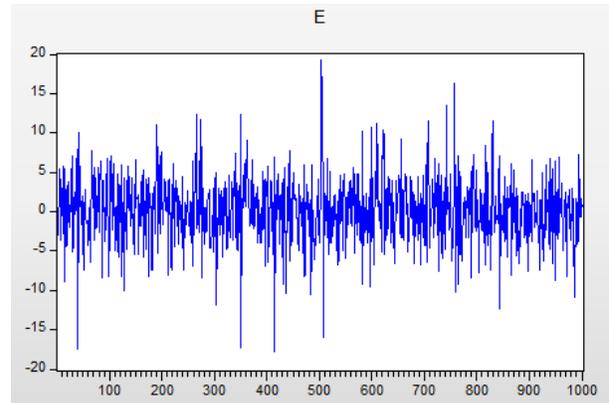


Figura 7: Trajetória do processo ε

Correlogram of E

Date: 12/09/20 Time: 15:53
 Sample: 1 1000
 Included observations: 1000

| Autocorrelation | Partial Correlation | AC | PAC | Q-Stat | Prob |
|-----------------|---------------------|-----------|--------|--------|-------|
| | | 1 0.003 | 0.003 | 0.0116 | 0.914 |
| | | 2 0.026 | 0.026 | 0.6933 | 0.707 |
| | | 3 -0.033 | -0.034 | 1.8137 | 0.612 |
| | | 4 -0.029 | -0.029 | 2.6505 | 0.618 |
| | | 5 -0.036 | -0.034 | 3.9788 | 0.552 |
| | | 6 -0.008 | -0.007 | 4.0426 | 0.671 |
| | | 7 0.016 | 0.016 | 4.3122 | 0.743 |
| | | 8 0.034 | 0.031 | 5.4650 | 0.707 |
| | | 9 -0.002 | -0.005 | 5.4686 | 0.792 |
| | | 10 -0.020 | -0.023 | 5.8764 | 0.826 |
| | | 11 0.060 | 0.063 | 9.5618 | 0.570 |
| | | 12 0.029 | 0.033 | 10.443 | 0.577 |
| | | 13 0.021 | 0.019 | 10.892 | 0.620 |
| | | 14 -0.015 | -0.014 | 11.125 | 0.676 |
| | | 15 -0.042 | -0.040 | 12.879 | 0.612 |
| | | 16 -0.009 | -0.002 | 12.961 | 0.676 |
| | | 17 0.003 | 0.010 | 12.973 | 0.738 |
| | | 18 -0.018 | -0.020 | 13.297 | 0.774 |
| | | 19 -0.029 | -0.038 | 14.136 | 0.776 |
| | | 20 -0.054 | -0.060 | 17.130 | 0.645 |
| | | 21 0.005 | 0.007 | 17.158 | 0.702 |
| | | 22 0.002 | 0.003 | 17.161 | 0.754 |
| | | 23 -0.055 | -0.063 | 20.223 | 0.628 |
| | | 24 0.019 | 0.009 | 20.591 | 0.663 |
| | | 25 0.065 | 0.065 | 24.988 | 0.463 |
| | | 26 -0.015 | -0.012 | 25.222 | 0.506 |
| | | 27 -0.026 | -0.024 | 25.923 | 0.523 |
| | | 28 -0.032 | -0.027 | 26.960 | 0.520 |
| | | 29 -0.025 | -0.023 | 27.627 | 0.538 |
| | | 30 -0.010 | -0.003 | 27.738 | 0.584 |
| | | 31 -0.040 | -0.030 | 29.411 | 0.548 |
| | | 32 0.011 | 0.005 | 29.530 | 0.592 |
| | | 33 -0.009 | -0.019 | 29.606 | 0.637 |
| | | 34 -0.024 | -0.025 | 30.206 | 0.654 |
| | | 35 0.024 | 0.027 | 30.813 | 0.671 |
| | | 36 0.062 | 0.058 | 34.801 | 0.526 |

Figura 8: Correlograma do processo ε

De seguida, analisámos também o processo do erro quadrático, ε^2 e, através do seu correlograma, verificámos que a sua sucessão das autocorrelações parciais se anula a partir da ordem 2 e que a função de autocorrelação tem um decrescimento rápido. Isto levou-nos a concluir que este processo é compatível com um AR(1).

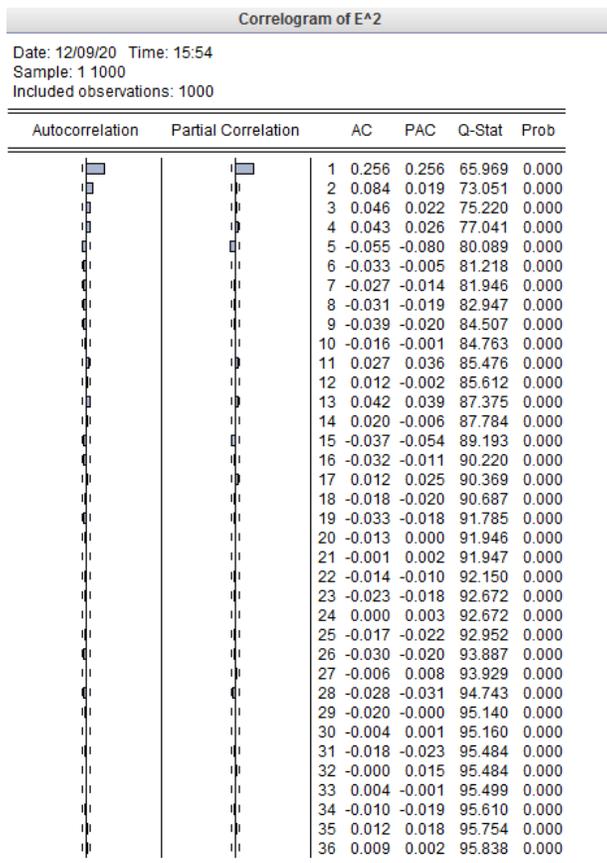


Figura 9: Correlograma de ε^2

Concluída esta análise, considerámos importante analisar o comportamento da nossa série X quando a sua estacionariedade é ameaçada, isto é, quando o seu polinómio AR tem as raízes próximas de 1.

Por exemplo, ao considerar o polinómio AR da forma

$$\Phi(L) = \left(L - \frac{101}{100}\right)\left(L - \frac{100}{101}\right),$$

onde as suas raízes são, aproximadamente, 1.01 e 0.99, obtivemos os seguintes resultados. Ver figuras 10, 11 e 12.

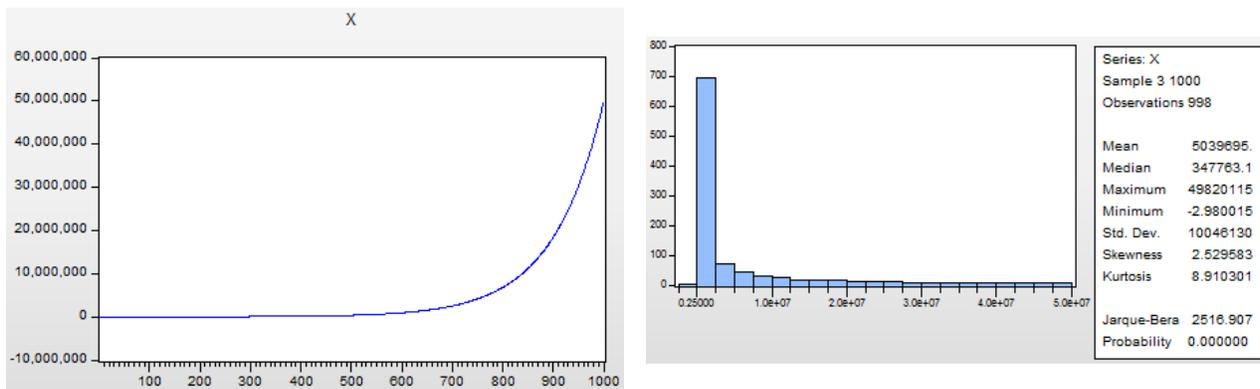


Figura 10: Trajetória de X novo

Figura 11: Histograma de X novo

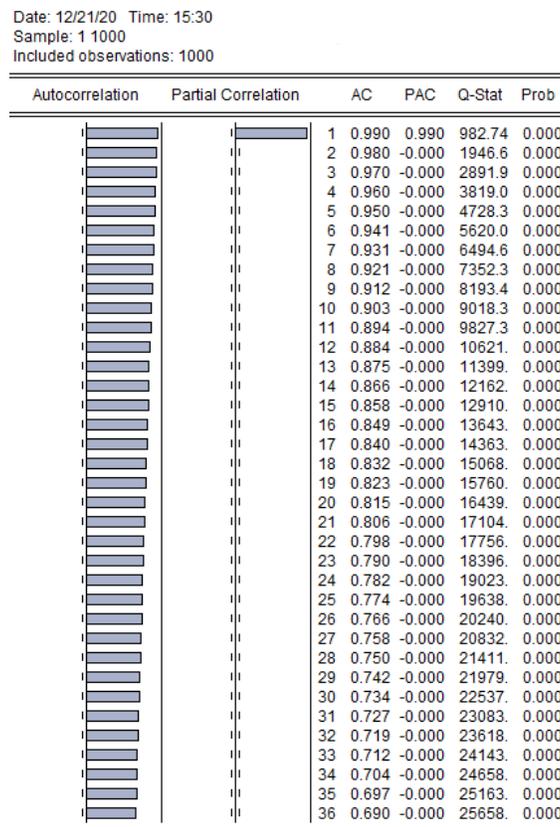


Figura 12: Correlograma de X novo

Como se pode ver na figura 10 a nova trajetória de X não apresenta um comportamento estável ao longo do tempo, tendendo para valores infinitamente grandes. Mais, na função de autocorrelação podemos verificar que não há um decrescimento exponencial.

Claro que um processo nestas condições não tem qualquer interesse para o nosso estudo, daí a importância das condições que garantem a estacionaridade do processo.

2 Análise de uma subsérie de X

Seguidamente fomos fazer o estudo de uma subsérie da nossa série X gerada na secção anterior. Para isso, considerámos estudar uma subsérie com 890 observações e são estas observações que vamos ajustar ao nosso modelo.

Depois de gerar a subsérie, analisámos o seu correlograma e, como se pode ver na figura 13, a sucessão das autocorrelações parciais anula-se a partir da ordem 3 e a correspondente função de autocorrelação decresce exponencialmente. Portanto, não se verifica qualquer alteração, ou seja, continuamos a ter características de um processo AR(2).

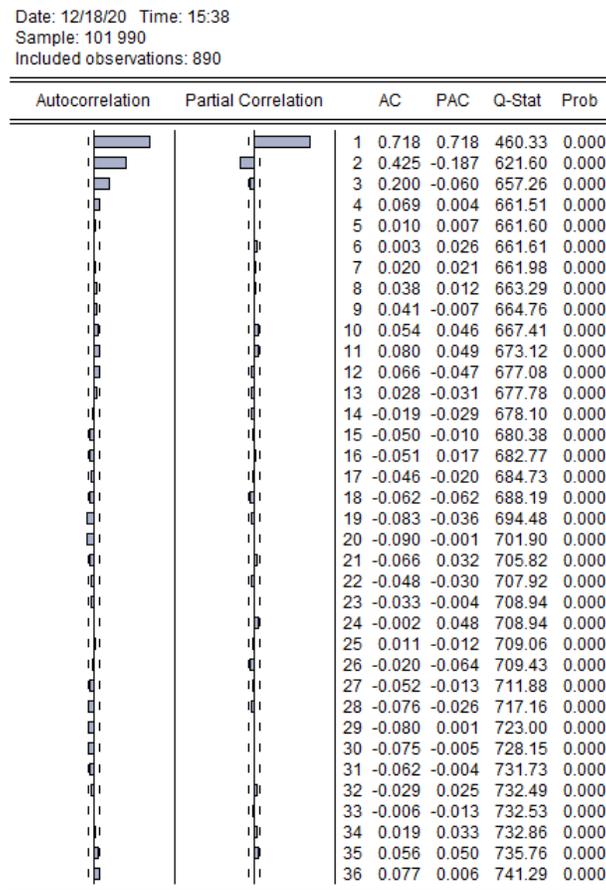


Figura 13: Correlograma da subsérie X

De seguida, procedemos à estimação da nossa série temporal X , gerada por um AR(2), com base nesta subsérie de 890 observações, através do método dos mínimos quadrados. Os resultados desse método estão ilustrados na figura 14.

Dependent Variable: X1
Method: ARMA Maximum Likelihood (OPG - BHHH)
Date: 12/18/20 Time: 18:37
Sample: 101 990
Included observations: 890
Convergence achieved after 17 iterations
Coefficient covariance computed using outer product of gradients

| Variable | Coefficient | Std. Error | t-Statistic | Prob. |
|--------------------|-------------|-----------------------|-------------|----------|
| C | 0.390397 | 0.446725 | 0.873907 | 0.3824 |
| AR(1) | 0.855665 | 0.025048 | 34.16104 | 0.0000 |
| AR(2) | -0.189851 | 0.027603 | -6.878036 | 0.0000 |
| SIGMASQ | 17.45641 | 0.634549 | 27.50994 | 0.0000 |
| R-squared | 0.534222 | Mean dependent var | | 0.412748 |
| Adjusted R-squared | 0.532644 | S.D. dependent var | | 6.125364 |
| S.E. of regression | 4.187508 | Akaike info criterion | | 5.707474 |
| Sum squared resid | 15536.21 | Schwarz criterion | | 5.729007 |
| Log likelihood | -2535.826 | Hannan-Quinn criter. | | 5.715704 |
| F-statistic | 338.7306 | Durbin-Watson stat | | 2.024860 |
| Prob(F-statistic) | 0.000000 | | | |
| Inverted AR Roots | .43+.08i | .43-.08i | | |

Figura 14: Teste de ajustamento

Como se pode verificar o modelo estimado está bem ajustado ao modelo inicial.

O primeiro p-valor apresentado, relativamente à variável C, é 0.3824, superior aos níveis de significância usuais, logo permite-nos verificar que, de facto, o nosso processo é centrado, pois foram testadas as hipóteses $H_0 : "C = 0"$ contra $H_1 : "C \neq 0"$. O segundo p-valor é relativo ao teste $H_0 : "\varphi_1 = 0"$ contra $H_1 : "\varphi_1 \neq 0"$ e sendo nulo, aceitamos H_1 porque, como sabemos, considerámos $\varphi_1 = \frac{5}{6}$ e o valor apresentado é $0.855665 \approx \frac{5}{6}$. De forma análoga se tira as mesmas conclusões para o teste efectuado ao coeficiente $\varphi_2 = -\frac{1}{6}$.

Depois analisámos o correlograma dos resíduos da estimação desta subsérie e, novamente, nada se alterou, porque os resultados apresentados na figura 16 mostram-nos que estamos perante um correlograma compatível com um ruído branco. Mais, também o correlograma do quadrado dos resíduos se mantém compatível com um AR(1), pois a sucessão das autocorrelações parciais anula-se a partir da ordem 2 e a função de autocorrelação decresce rapidamente.

De forma a termos uma melhor comparação relativamente à subsérie gerada, analisámos também o seu gráfico da trajectória e, como seria esperado, mantém-se muito semelhante ao AR(2) inicial, pois a subsérie gerada tem apenas menos 110 observações.

Posteriormente analisámos o correlograma dos resíduos e, como se pode ver na figura 16, temos características de um ruído branco. No entanto, pela a análise do correlograma do quadrado dos resíduos vemos que este não é compatível com um ruído branco, pois há dependência de primeira ordem, ou seja, a dependência do quadrado do resíduo é compatível com um modelo AR(1), figura 17.

Isto levou-nos a analisar a heteroscedasticidade dos erros e o teste efectuado encontra-se na figura 15. Neste teste são testadas as hipóteses $H_0 : "Ausência de heteroscedasticidade"$ contra $H_1 : "Presença de heteroscedasticidade"$.

Como o p-valor deste teste é identicamente nulo, então rejeitamos a hipótese nula e portanto concluímos que o nosso modelo ainda não é o mais adequado.

Heteroskedasticity Test: ARCH

| | | | |
|---------------|----------|---------------------|--------|
| F-statistic | 62.12134 | Prob. F(1,887) | 0.0000 |
| Obs*R-squared | 58.18631 | Prob. Chi-Square(1) | 0.0000 |

Test Equation:
 Dependent Variable: RESID^2
 Method: Least Squares
 Date: 01/18/21 Time: 10:26
 Sample (adjusted): 102 990
 Included observations: 889 after adjustments

| Variable | Coefficient | Std. Error | t-Statistic | Prob. |
|-------------|-------------|------------|-------------|--------|
| C | 12.96966 | 1.201929 | 10.79070 | 0.0000 |
| RESID^2(-1) | 0.255838 | 0.032460 | 7.881709 | 0.0000 |

| | | | |
|--------------------|-----------|-----------------------|----------|
| R-squared | 0.065451 | Mean dependent var | 17.44011 |
| Adjusted R-squared | 0.064398 | S.D. dependent var | 32.66485 |
| S.E. of regression | 31.59558 | Akaike info criterion | 9.746159 |
| Sum squared resid | 885475.0 | Schwarz criterion | 9.756935 |
| Log likelihood | -4330.168 | Hannan-Quinn criter. | 9.750278 |
| F-statistic | 62.12134 | Durbin-Watson stat | 1.995610 |
| Prob(F-statistic) | 0.000000 | | |

Figura 15: Heteroscedasticidade dos erros AR(2)

Correlogram of Residuals

Date: 12/21/20 Time: 16:06
 Sample: 101 990
 Included observations: 890
 Q-statistic probabilities adjusted for 2 ARMA terms

| Autocorrelation | Partial Correlation | AC | PAC | Q-Stat | Prob |
|-----------------|---------------------|--------|--------|--------|-------|
| 1 | | -0.014 | -0.014 | 0.1635 | |
| 2 | | 0.044 | 0.044 | 1.8818 | |
| 3 | | -0.025 | -0.024 | 2.4406 | 0.118 |
| 4 | | -0.021 | -0.023 | 2.8198 | 0.244 |
| 5 | | -0.029 | -0.027 | 3.5680 | 0.312 |
| 6 | | -0.010 | -0.010 | 3.6624 | 0.454 |
| 7 | | 0.007 | 0.008 | 3.7028 | 0.593 |
| 8 | | 0.036 | 0.036 | 4.8965 | 0.557 |
| 9 | | -0.008 | -0.009 | 4.9504 | 0.666 |
| 10 | | -0.015 | -0.019 | 5.1438 | 0.742 |
| 11 | | 0.067 | 0.069 | 9.1887 | 0.420 |
| 12 | | 0.031 | 0.036 | 10.068 | 0.435 |
| 13 | | 0.013 | 0.009 | 10.225 | 0.510 |
| 14 | | -0.015 | -0.015 | 10.425 | 0.579 |
| 15 | | -0.047 | -0.046 | 12.395 | 0.496 |
| 16 | | -0.016 | -0.011 | 12.614 | 0.557 |
| 17 | | 0.015 | 0.023 | 12.817 | 0.616 |
| 18 | | -0.009 | -0.008 | 12.884 | 0.681 |
| 19 | | -0.028 | -0.040 | 13.623 | 0.694 |
| 20 | | -0.062 | -0.067 | 17.090 | 0.517 |
| 21 | | 0.006 | 0.008 | 17.119 | 0.582 |
| 22 | | -0.001 | 0.003 | 17.120 | 0.645 |
| 23 | | -0.043 | -0.049 | 18.814 | 0.597 |
| 24 | | 0.015 | 0.005 | 19.023 | 0.644 |
| 25 | | 0.055 | 0.054 | 21.754 | 0.535 |
| 26 | | -0.018 | -0.012 | 22.046 | 0.576 |
| 27 | | -0.016 | -0.013 | 22.271 | 0.620 |
| 28 | | -0.039 | -0.035 | 23.658 | 0.595 |
| 29 | | -0.021 | -0.024 | 24.057 | 0.627 |
| 30 | | -0.016 | -0.010 | 24.286 | 0.666 |
| 31 | | -0.046 | -0.033 | 26.270 | 0.611 |
| 32 | | 0.019 | 0.018 | 26.602 | 0.644 |
| 33 | | -0.006 | -0.012 | 26.635 | 0.690 |
| 34 | | -0.017 | -0.021 | 26.888 | 0.723 |
| 35 | | 0.024 | 0.022 | 27.429 | 0.741 |
| 36 | | 0.065 | 0.063 | 31.343 | 0.598 |

Figura 16: Correlograma dos resíduos da estimação

Correlogram of Residuals Squared

Date: 12/21/20 Time: 16:07
 Sample: 101 990
 Included observations: 890

| Autocorrelation | Partial Correlation | AC | PAC | Q-Stat | Prob |
|-----------------|---------------------|--------|--------|--------|------|
| 1 | 0.256 | 0.256 | 58.421 | 0.000 | |
| 2 | 0.057 | -0.009 | 61.352 | 0.000 | |
| 3 | 0.040 | 0.029 | 62.777 | 0.000 | |
| 4 | 0.052 | 0.038 | 65.228 | 0.000 | |
| 5 | -0.046 | -0.075 | 67.155 | 0.000 | |
| 6 | -0.021 | 0.008 | 67.535 | 0.000 | |
| 7 | -0.020 | -0.018 | 67.898 | 0.000 | |
| 8 | -0.026 | -0.018 | 68.501 | 0.000 | |
| 9 | -0.045 | -0.029 | 70.340 | 0.000 | |
| 10 | -0.022 | -0.005 | 70.786 | 0.000 | |
| 11 | 0.013 | 0.024 | 70.934 | 0.000 | |
| 12 | 0.022 | 0.016 | 71.364 | 0.000 | |
| 13 | 0.050 | 0.045 | 73.611 | 0.000 | |
| 14 | 0.034 | 0.006 | 74.664 | 0.000 | |
| 15 | -0.032 | -0.053 | 75.578 | 0.000 | |
| 16 | -0.032 | -0.016 | 76.509 | 0.000 | |
| 17 | 0.024 | 0.036 | 77.051 | 0.000 | |
| 18 | 0.004 | -0.007 | 77.064 | 0.000 | |
| 19 | -0.033 | -0.027 | 78.082 | 0.000 | |
| 20 | -0.007 | 0.009 | 78.129 | 0.000 | |
| 21 | 0.007 | 0.005 | 78.169 | 0.000 | |
| 22 | -0.014 | -0.010 | 78.343 | 0.000 | |
| 23 | -0.026 | -0.017 | 78.965 | 0.000 | |
| 24 | -0.000 | 0.003 | 78.965 | 0.000 | |
| 25 | -0.038 | -0.048 | 80.314 | 0.000 | |
| 26 | -0.029 | -0.006 | 81.063 | 0.000 | |
| 27 | -0.022 | -0.010 | 81.501 | 0.000 | |
| 28 | -0.026 | -0.020 | 82.133 | 0.000 | |
| 29 | -0.020 | 0.000 | 82.503 | 0.000 | |
| 30 | -0.004 | -0.003 | 82.522 | 0.000 | |
| 31 | -0.012 | -0.016 | 82.660 | 0.000 | |
| 32 | -0.003 | 0.006 | 82.670 | 0.000 | |
| 33 | 0.003 | 0.003 | 82.676 | 0.000 | |
| 34 | -0.003 | -0.013 | 82.685 | 0.000 | |
| 35 | 0.008 | 0.008 | 82.740 | 0.000 | |
| 36 | 0.011 | 0.010 | 82.845 | 0.000 | |

Figura 17: Correlograma do quadrado dos resíduos

De seguida, procedemos à estimação do nosso modelo por um processo AR-GARCH com base numa subsérie com 890 observações.

```

Dependent Variable: X1
Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)
Date: 12/18/20 Time: 18:47
Sample (adjusted): 103 990
Included observations: 888 after adjustments
Convergence achieved after 30 iterations
Coefficient covariance computed using outer product of gradients
Presample variance: backcast (parameter = 0.7)
GARCH = C(4) + C(5)*RESID(-1)^2 + C(6)*GARCH(-1)

```

| Variable | Coefficient | Std. Error | z-Statistic | Prob. |
|----------|-------------|------------|-------------|--------|
| C | -0.336416 | 0.333837 | -1.007725 | 0.3136 |
| AR(1) | 0.805827 | 0.036060 | 22.34716 | 0.0000 |
| AR(2) | -0.158756 | 0.033354 | -4.759702 | 0.0000 |

| Variance Equation | | | | |
|-------------------|----------|----------|----------|--------|
| | | | | |
| C | 9.759638 | 1.083929 | 9.003944 | 0.0000 |
| RESID(-1)^2 | 0.473656 | 0.062977 | 7.521141 | 0.0000 |
| GARCH(-1) | 0.012442 | 0.047716 | 0.260743 | 0.7943 |

| | | | |
|--------------------|-----------|-----------------------|----------|
| R-squared | 0.532180 | Mean dependent var | 0.421965 |
| Adjusted R-squared | 0.531122 | S.D. dependent var | 6.125911 |
| S.E. of regression | 4.194696 | Akaike info criterion | 5.599053 |
| Sum squared resid | 15571.99 | Schwarz criterion | 5.631411 |
| Log likelihood | -2479.980 | Hannan-Quinn criter. | 5.611422 |
| Durbin-Watson stat | 1.912306 | | |

| | | |
|-------------------|-----|-----|
| Inverted AR Roots | .46 | .34 |
|-------------------|-----|-----|

Figura 18: Teste de ajustamento

Analogamente ao teste de ajustamento feito anteriormente, podemos observar na figura 18 que primeiro p-valor apresentado, relativamente à variável C, é 0.3136, superior aos níveis de significância usuais, logo permite-nos verificar que a subsérie tem por base um processo centrado, pois foram testadas as hipóteses $H_0 : "C = 0"$ contra $H_1 : "C \neq 0"$.

O segundo p-valor é relativo ao teste $H_0 : "\varphi_1 = 0"$ contra $H_1 : "\varphi_1 \neq 0"$ e sendo nulo, aceitamos H_1 porque, como sabemos, considerámos $\varphi_1 = \frac{5}{6}$ e o valor apresentado é $0.805827 \approx \frac{5}{6}$. De forma análoga se tira as mesmas conclusões para o teste efectuado ao coeficiente $\varphi_2 = -\frac{1}{6}$. Depois analisámos novamente o correlograma dos resíduos da estimação desta subsérie e agora podemos verificar que deixa de existir dependência de segunda ordem no correlograma do quadrado dos resíduos, tendo assim correlogramas compatíveis com ruídos brancos. Vejam-se as figuras 20 e 21 e o teste de heteroscedasticidade apresentado na figura 19, que nos garante a ausência de heteroscedasticidade nos erros, pois o p-valor é 0.7231, superior a qualquer nível de significância usual.

Heteroskedasticity Test: ARCH

| | | | |
|---------------|----------|---------------------|--------|
| F-statistic | 0.125640 | Prob. F(1,885) | 0.7231 |
| Obs*R-squared | 0.125906 | Prob. Chi-Square(1) | 0.7227 |

Test Equation:
 Dependent Variable: WGT_RESID^2
 Method: Least Squares
 Date: 01/18/21 Time: 10:30
 Sample (adjusted): 104 990
 Included observations: 887 after adjustments

| Variable | Coefficient | Std. Error | t-Statistic | Prob. |
|-----------------|-------------|------------|-------------|--------|
| C | 1.010268 | 0.059926 | 16.85846 | 0.0000 |
| WGT_RESID^2(-1) | -0.011909 | 0.033598 | -0.354458 | 0.7231 |

| | | | |
|--------------------|-----------|-----------------------|----------|
| R-squared | 0.000142 | Mean dependent var | 0.998347 |
| Adjusted R-squared | -0.000988 | S.D. dependent var | 1.476512 |
| S.E. of regression | 1.477242 | Akaike info criterion | 3.620482 |
| Sum squared resid | 1931.285 | Schwarz criterion | 3.631278 |
| Log likelihood | -1603.684 | Hannan-Quinn criter. | 3.624609 |
| F-statistic | 0.125640 | Durbin-Watson stat | 1.998200 |
| Prob(F-statistic) | 0.723080 | | |

Figura 19: Heteroscedasticidade dos erros AR-GARCH

Correlogram of Standardized Residuals

Date: 12/21/20 Time: 16:04
 Sample: 101 990
 Included observations: 888
 Q-statistic probabilities adjusted for 2 ARMA terms

| Autocorrelation | Partial Correlation | AC | PAC | Q-Stat | Prob* |
|-----------------|---------------------|--------|--------|--------|-------|
| 1 | 0.006 | 0.006 | 0.0310 | | |
| 2 | 0.047 | 0.047 | 1.9785 | | |
| 3 | -0.030 | -0.030 | 2.7687 | 0.096 | |
| 4 | -0.021 | -0.023 | 3.1650 | 0.205 | |
| 5 | -0.037 | -0.034 | 4.3585 | 0.225 | |
| 6 | 0.004 | 0.006 | 4.3753 | 0.358 | |
| 7 | 0.016 | 0.018 | 4.6019 | 0.466 | |
| 8 | 0.035 | 0.032 | 5.6933 | 0.458 | |
| 9 | -0.009 | -0.012 | 5.7644 | 0.568 | |
| 10 | -0.012 | -0.015 | 5.8879 | 0.660 | |
| 11 | 0.063 | 0.067 | 9.4538 | 0.396 | |
| 12 | 0.045 | 0.049 | 11.319 | 0.333 | |
| 13 | 0.016 | 0.010 | 11.548 | 0.399 | |
| 14 | -0.000 | -0.003 | 11.548 | 0.483 | |
| 15 | -0.045 | -0.043 | 13.351 | 0.421 | |
| 16 | -0.022 | -0.015 | 13.774 | 0.467 | |
| 17 | 0.005 | 0.014 | 13.797 | 0.541 | |
| 18 | 0.009 | 0.008 | 13.877 | 0.608 | |
| 19 | -0.040 | -0.052 | 15.353 | 0.570 | |
| 20 | -0.056 | -0.064 | 18.172 | 0.444 | |
| 21 | 0.008 | 0.015 | 18.234 | 0.507 | |
| 22 | -0.011 | -0.006 | 18.338 | 0.565 | |
| 23 | -0.038 | -0.046 | 19.674 | 0.542 | |
| 24 | 0.021 | 0.013 | 20.091 | 0.577 | |
| 25 | 0.048 | 0.045 | 22.166 | 0.510 | |
| 26 | -0.006 | -0.003 | 22.200 | 0.567 | |
| 27 | -0.022 | -0.016 | 22.645 | 0.598 | |
| 28 | -0.040 | -0.035 | 24.122 | 0.569 | |
| 29 | -0.031 | -0.031 | 24.985 | 0.575 | |
| 30 | -0.022 | -0.013 | 25.448 | 0.603 | |
| 31 | -0.066 | -0.055 | 29.469 | 0.441 | |
| 32 | 0.037 | 0.036 | 30.703 | 0.430 | |
| 33 | -0.014 | -0.015 | 30.882 | 0.472 | |
| 34 | -0.032 | -0.039 | 31.824 | 0.476 | |
| 35 | 0.016 | 0.016 | 32.059 | 0.514 | |
| 36 | 0.050 | 0.049 | 34.342 | 0.451 | |

*Probabilities may not be valid for this equation specification.

Figura 20: Correlograma dos resíduos da estimação AR-GARCH

Correlogram of Standardized Residuals Squared

Date: 12/21/20 Time: 16:02
 Sample: 101 990
 Included observations: 888

| Autocorrelation | Partial Correlation | AC | PAC | Q-Stat | Prob* |
|-----------------|---------------------|--------|--------|--------|-------|
| 1 | -0.012 | -0.012 | 0.1263 | 0.722 | |
| 2 | -0.014 | -0.014 | 0.2993 | 0.861 | |
| 3 | -0.013 | -0.014 | 0.4609 | 0.927 | |
| 4 | 0.028 | 0.028 | 1.1839 | 0.881 | |
| 5 | -0.063 | -0.063 | 4.7442 | 0.448 | |
| 6 | 0.012 | 0.011 | 4.8669 | 0.561 | |
| 7 | -0.031 | -0.032 | 5.7390 | 0.571 | |
| 8 | 0.011 | 0.008 | 5.8386 | 0.665 | |
| 9 | -0.001 | 0.002 | 5.8401 | 0.756 | |
| 10 | -0.021 | -0.026 | 6.2288 | 0.796 | |
| 11 | -0.005 | -0.002 | 6.2522 | 0.856 | |
| 12 | -0.005 | -0.010 | 6.2720 | 0.902 | |
| 13 | 0.051 | 0.052 | 8.5991 | 0.802 | |
| 14 | 0.028 | 0.029 | 9.3306 | 0.809 | |
| 15 | -0.008 | -0.008 | 9.3829 | 0.857 | |
| 16 | -0.017 | -0.015 | 9.6601 | 0.884 | |
| 17 | -0.009 | -0.015 | 9.7397 | 0.914 | |
| 18 | -0.016 | -0.012 | 9.9758 | 0.933 | |
| 19 | -0.027 | -0.026 | 10.655 | 0.935 | |
| 20 | 0.012 | 0.013 | 10.794 | 0.951 | |
| 21 | -0.030 | -0.032 | 11.613 | 0.949 | |
| 22 | 0.007 | 0.004 | 11.657 | 0.964 | |
| 23 | -0.009 | -0.008 | 11.735 | 0.974 | |
| 24 | 0.002 | -0.001 | 11.738 | 0.983 | |
| 25 | -0.024 | -0.020 | 12.253 | 0.984 | |
| 26 | -0.031 | -0.041 | 13.132 | 0.983 | |
| 27 | -0.014 | -0.016 | 13.322 | 0.987 | |
| 28 | -0.016 | -0.023 | 13.548 | 0.990 | |
| 29 | -0.018 | -0.016 | 13.834 | 0.992 | |
| 30 | -0.012 | -0.013 | 13.978 | 0.994 | |
| 31 | -0.006 | -0.011 | 14.017 | 0.996 | |
| 32 | 0.003 | 0.004 | 14.025 | 0.998 | |
| 33 | 0.009 | 0.004 | 14.101 | 0.998 | |
| 34 | 0.008 | 0.008 | 14.156 | 0.999 | |
| 35 | -0.004 | -0.007 | 14.172 | 0.999 | |
| 36 | 0.020 | 0.016 | 14.526 | 0.999 | |

*Probabilities may not be valid for this equation specification.

Figura 21: Correlograma do quadrado dos resíduos da estimação AR-GARCH

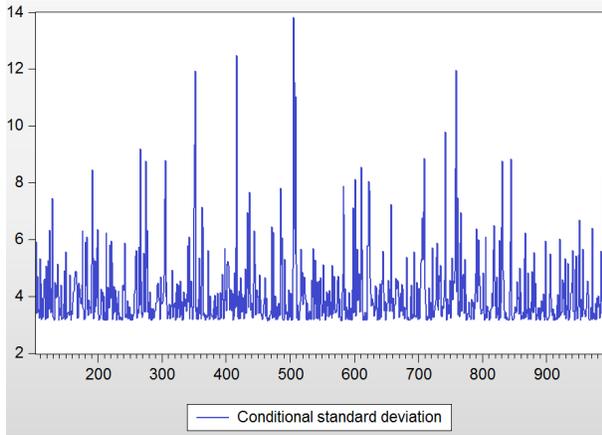


Figura 22: Variância condicional da série observada

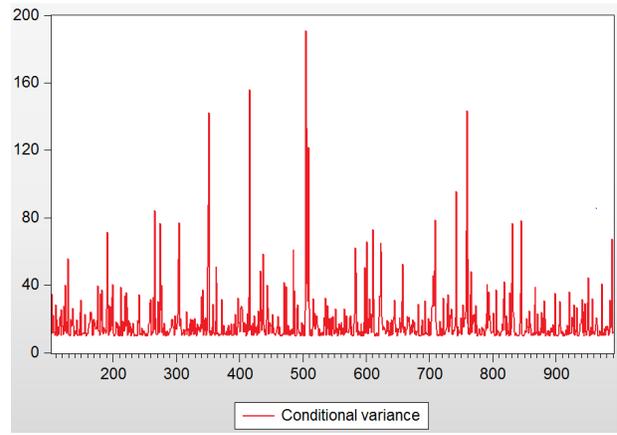


Figura 23: Variância condicional da série estimada

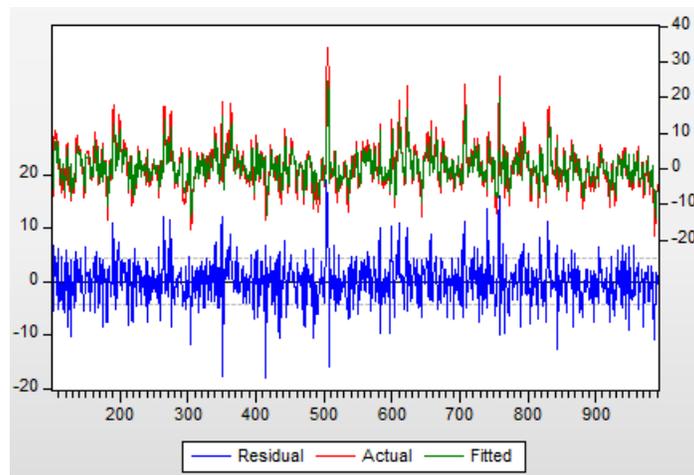


Figura 24: Trajetória das séries observada e estimada e trajetória do resíduo associado

Seguidamente decidimos fazer a estimação da nossa série temporal X , gerada por um $AR(2)$, com base numa subsérie com apenas 390 observações, para verificarmos se continuamos a ter características de um processo AR de ordem 2, através do método dos mínimos quadrados. Os resultados desse método estão ilustrados na figura 25.

Dependent Variable: X2
Method: ARMA Maximum Likelihood (OPG - BHHH)
Date: 12/21/20 Time: 16:13
Sample: 101 490
Included observations: 390
Convergence achieved after 14 iterations
Coefficient covariance computed using outer product of gradients

| Variable | Coefficient | Std. Error | t-Statistic | Prob. |
|--------------------|-------------|-----------------------|-------------|----------|
| C | 0.424239 | 0.649537 | 0.653140 | 0.5141 |
| AR(1) | 0.767077 | 0.041522 | 18.47401 | 0.0000 |
| AR(2) | -0.110144 | 0.049690 | -2.216609 | 0.0272 |
| SIGMASQ | 17.11923 | 0.997715 | 17.15844 | 0.0000 |
| R-squared | 0.480905 | Mean dependent var | | 0.502388 |
| Adjusted R-squared | 0.476871 | S.D. dependent var | | 5.750112 |
| S.E. of regression | 4.158921 | Akaike info criterion | | 5.700319 |
| Sum squared resid | 6676.498 | Schwarz criterion | | 5.740997 |
| Log likelihood | -1107.562 | Hannan-Quinn criter. | | 5.716444 |
| F-statistic | 119.2008 | Durbin-Watson stat | | 1.997612 |
| Prob(F-statistic) | 0.000000 | | | |
| Inverted AR Roots | .58 | .19 | | |

Figura 25: Teste de ajustamento para a subsérie com 390 observações

Como se pode ver o modelo estimado não está compatível com o nosso modelo inicial. O primeiro p-valor apresentado, relativamente à variável C, é 0.5141, superior aos níveis de significância usuais, logo permite-nos verificar que o nosso processo é centrado, pois foram testadas as hipóteses $H_0 : "C = 0"$ contra $H_1 : "C \neq 0"$. O segundo p-valor é relativo ao teste $H_0 : "\varphi_1 = 0"$ contra $H_1 : "\varphi_1 \neq 0"$ e sendo nulo, aceitamos H_1 porque, como sabemos, considerámos $\varphi_1 = \frac{5}{6}$ e o valor apresentado é $0.767077 \approx \frac{5}{6}$, mas mais afastado do valor estimado quando se considerou uma subsérie com 890 observações. Relativamente ao terceiro p-valor apresentado concluímos que, para níveis de significância 0.01, o coeficiente φ_2 é zero, pois é aceite a hipótese nula. Isto diz-nos que o nosso modelo ficaria melhor ajustado a um modelo AR de ordem 1 para níveis de significância de 0.01. O correlograma dos resíduos da estimação desta subsérie é compatível com um ruído branco, como se pode verificar na figura 26. Novamente o correlograma do quadrado dos resíduos mantém-se compatível com um AR(1), mas muito próximo de um ruído branco se for ignorado as autocorrelações de ordem 1. Depois voltamos a testar a heteroscedasticidade dos erros e obtivemos um p-valor nulo, rejeitando assim a hipótese de ausência de heteroscedasticidade.

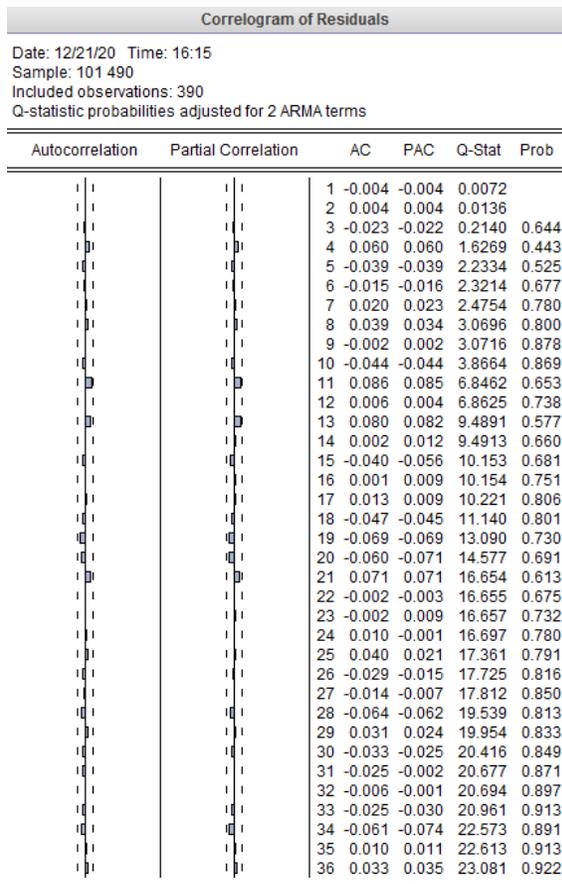


Figura 26: Correlograma dos resíduos da subsérie com 390 observações

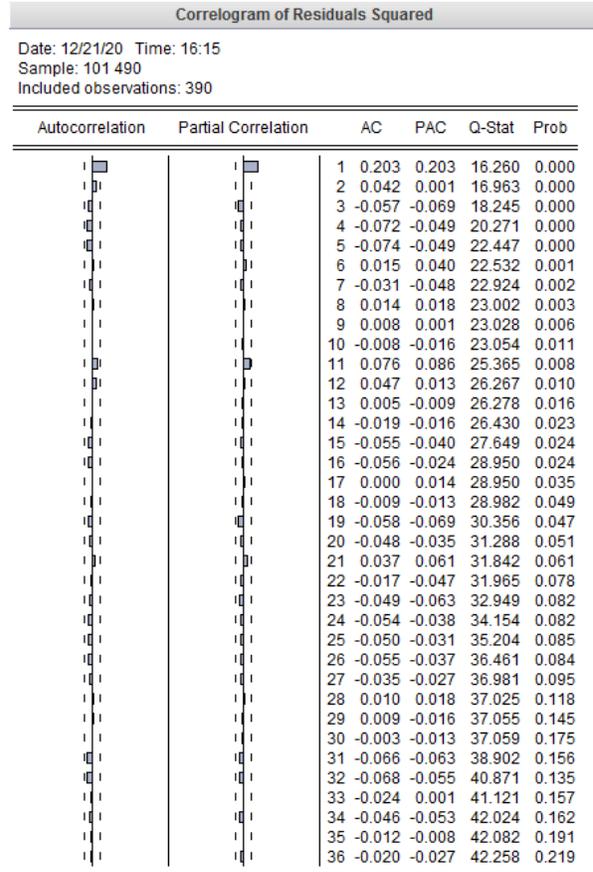


Figura 27: Correlograma do quadrado dos resíduos da subsérie com 390 observações

Assim, procedemos à estimação do nosso modelo por um processo AR-GARCH com base numa subsérie com 390 observações.

Dependent Variable: X2
Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)
Date: 12/21/20 Time: 16:16
Sample (adjusted): 103 490
Included observations: 388 after adjustments
Convergence achieved after 33 iterations
Coefficient covariance computed using outer product of gradients
Presample variance: backcast (parameter = 0.7)
GARCH = C(4) + C(5)*RESID(-1)^2 + C(6)*GARCH(-1)

| Variable | Coefficient | Std. Error | z-Statistic | Prob. |
|----------|-------------|------------|-------------|--------|
| C | -0.014677 | 0.597790 | -0.024551 | 0.9804 |
| AR(1) | 0.760319 | 0.060988 | 12.46669 | 0.0000 |
| AR(2) | -0.098401 | 0.056785 | -1.732864 | 0.0831 |

| Variance Equation | | | | |
|-------------------|----------|----------|----------|--------|
| C | 11.75584 | 2.778545 | 4.230933 | 0.0000 |
| RESID(-1)^2 | 0.322719 | 0.084249 | 3.830556 | 0.0001 |
| GARCH(-1) | 0.003401 | 0.151591 | 0.022432 | 0.9821 |

| | | | |
|--------------------|-----------|-----------------------|----------|
| R-squared | 0.482585 | Mean dependent var | 0.523945 |
| Adjusted R-squared | 0.479897 | S.D. dependent var | 5.749087 |
| S.E. of regression | 4.146137 | Akaike info criterion | 5.638595 |
| Sum squared resid | 6618.325 | Schwarz criterion | 5.699848 |
| Log likelihood | -1087.887 | Hannan-Quinn criter. | 5.662881 |
| Durbin-Watson stat | 1.980343 | | |

| | | |
|-------------------|-----|-----|
| Inverted AR Roots | .59 | .17 |
|-------------------|-----|-----|

Figura 28: Teste de ajustamento para a subsérie com 390 observações

Por fim, analisámos novamente o correlograma dos resíduos da estimação desta subsérie e agora podemos verificar que deixa de existir dependência de segunda ordem no correlograma do quadrado dos resíduos, tendo assim correlogramas compatíveis com ruídos brancos. Vejam-se as figuras 29 e 30.

É conveniente reforçar a análise feita até agora com a análise dos critérios presentes nos testes de ajustamento. Desta forma, iremos abordar os testes de Akaike, Schwarz, log-likelihood e, por fim, o r-quadrado.

O teste de Akaike (AIC) e Schwarz (BIC) estimam a quantidade relativa de informação perdida por um determinado modelo, ou seja, quanto menos informações um modelo perde, maior a qualidade do mesmo. Assim sendo, quanto menor o valor destas estatísticas, melhor será o modelo. Será de esperar que os modelos com menos observações tenham maior valor AIC e BIC.

O teste de r-quadrado (R^2) é uma medida estatística que nos indica o quão próximos estão os dados dos valores do nosso modelo, ou seja, o seu valor é a percentagem de dados que são explicados pelo modelo. Esta estatística varia entre 0 e 1.

Por fim, o teste de log-likelihood é um método cujo objetivo é encontrar coeficientes que maximizem o valor da função de verosimilhança, ou seja, encontrar um conjunto de parâmetros que produzem um modelo mais aproximado com a teoria. Esta estatística é sempre negativa e será tão melhor quanto maior for o seu valor.

Pela análise dos testes de ajustamento para o modelo com diferentes observações, obtém-se a seguinte tabela:

| Modelo | AIC | BIC | R^2 | Log-likelihood |
|-----------------|----------|----------|----------|----------------|
| 890 observações | 5.707474 | 5.729007 | 0.534222 | -2535.826 |
| 390 observações | 5.700319 | 5.740997 | 0.480905 | -1107.562 |

Da tabela anterior pode-se verificar que, com a perda de observações, existe uma diminuição do R^2 e do BIC. Isto era de esperar pois, com menos observações, menor a percentagem de dados explicados pelo modelo (diminuição de 53% para 48%) e, com menos observações, mais informação perdida, ou seja, menor a qualidade do modelo e maior a estatística BIC.

A análise da estatística de log-likelihood é mais pertinente quando se tenciona comparar modelos diferentes, por exemplo, AR(5) com MA(1). Desta forma, como estamos a comparar o mesmo modelo mas com observações diferentes, esta estatística não nos ajuda.

Correlogram of Standardized Residuals

Date: 12/21/20 Time: 16:16
Sample: 101 490
Included observations: 388
Q-statistic probabilities adjusted for 2 ARMA terms

| Autocorrelation | Partial Correlation | AC | PAC | Q-Stat | Prob* |
|-----------------|---------------------|-----------|--------|--------|-------|
| | | 1 0.003 | 0.003 | 0.0029 | |
| | | 2 0.005 | 0.004 | 0.0109 | |
| | | 3 -0.037 | -0.037 | 0.5378 | 0.463 |
| | | 4 0.054 | 0.055 | 1.7078 | 0.426 |
| | | 5 -0.036 | -0.037 | 2.2319 | 0.526 |
| | | 6 -0.021 | -0.023 | 2.4147 | 0.660 |
| | | 7 0.014 | 0.018 | 2.4880 | 0.778 |
| | | 8 0.028 | 0.022 | 2.7982 | 0.834 |
| | | 9 -0.011 | -0.009 | 2.8428 | 0.899 |
| | | 10 -0.037 | -0.035 | 3.3788 | 0.908 |
| | | 11 0.092 | 0.092 | 6.7850 | 0.659 |
| | | 12 0.029 | 0.026 | 7.1345 | 0.713 |
| | | 13 0.069 | 0.070 | 9.0627 | 0.616 |
| | | 14 0.006 | 0.017 | 9.0797 | 0.696 |
| | | 15 -0.042 | -0.055 | 9.7902 | 0.711 |
| | | 16 0.005 | 0.013 | 9.8010 | 0.777 |
| | | 17 -0.004 | -0.003 | 9.8073 | 0.832 |
| | | 18 -0.052 | -0.052 | 10.900 | 0.816 |
| | | 19 -0.077 | -0.076 | 13.351 | 0.712 |
| | | 20 -0.048 | -0.056 | 14.288 | 0.710 |
| | | 21 0.071 | 0.072 | 16.358 | 0.633 |
| | | 22 0.003 | -0.001 | 16.361 | 0.694 |
| | | 23 -0.005 | -0.002 | 16.371 | 0.748 |
| | | 24 0.004 | -0.007 | 16.377 | 0.797 |
| | | 25 0.033 | 0.013 | 16.838 | 0.817 |
| | | 26 -0.037 | -0.024 | 17.402 | 0.831 |
| | | 27 -0.025 | -0.020 | 17.666 | 0.856 |
| | | 28 -0.058 | -0.057 | 19.097 | 0.832 |
| | | 29 0.019 | 0.014 | 19.255 | 0.861 |
| | | 30 -0.023 | -0.005 | 19.473 | 0.883 |
| | | 31 -0.043 | -0.020 | 20.265 | 0.884 |
| | | 32 0.003 | 0.008 | 20.270 | 0.909 |
| | | 33 -0.042 | -0.052 | 21.012 | 0.912 |
| | | 34 -0.056 | -0.071 | 22.368 | 0.897 |
| | | 35 0.009 | 0.013 | 22.399 | 0.918 |
| | | 36 0.018 | 0.013 | 22.544 | 0.933 |

*Probabilities may not be valid for this equation specification.

Figura 29: Correlograma do quadrado dos resíduos da subsérie com 390 garch

Correlogram of Standardized Residuals Squared

Date: 12/21/20 Time: 16:17
Sample: 101 490
Included observations: 388

| Autocorrelation | Partial Correlation | AC | PAC | Q-Stat | Prob* |
|-----------------|---------------------|-----------|--------|--------|-------|
| | | 1 -0.010 | -0.010 | 0.0422 | 0.837 |
| | | 2 0.044 | 0.044 | 0.7954 | 0.672 |
| | | 3 -0.041 | -0.040 | 1.4428 | 0.696 |
| | | 4 -0.056 | -0.059 | 2.6692 | 0.615 |
| | | 5 -0.083 | -0.081 | 5.3814 | 0.371 |
| | | 6 0.072 | 0.075 | 7.4635 | 0.280 |
| | | 7 -0.050 | -0.046 | 8.4446 | 0.295 |
| | | 8 0.037 | 0.021 | 9.0020 | 0.342 |
| | | 9 0.076 | 0.078 | 11.299 | 0.256 |
| | | 10 -0.036 | -0.040 | 11.804 | 0.298 |
| | | 11 0.052 | 0.055 | 12.897 | 0.300 |
| | | 12 -0.035 | -0.036 | 13.381 | 0.342 |
| | | 13 0.009 | 0.022 | 13.411 | 0.417 |
| | | 14 0.020 | 0.029 | 13.574 | 0.482 |
| | | 15 -0.024 | -0.038 | 13.811 | 0.540 |
| | | 16 -0.059 | -0.043 | 15.205 | 0.510 |
| | | 17 -0.011 | -0.028 | 15.256 | 0.577 |
| | | 18 -0.012 | 0.002 | 15.318 | 0.640 |
| | | 19 -0.025 | -0.032 | 15.580 | 0.685 |
| | | 20 -0.045 | -0.068 | 16.404 | 0.691 |
| | | 21 0.014 | 0.021 | 16.479 | 0.742 |
| | | 22 0.003 | -0.003 | 16.482 | 0.791 |
| | | 23 -0.026 | -0.036 | 16.765 | 0.821 |
| | | 24 -0.052 | -0.058 | 17.878 | 0.809 |
| | | 25 -0.023 | -0.019 | 18.091 | 0.839 |
| | | 26 -0.054 | -0.040 | 19.288 | 0.824 |
| | | 27 -0.009 | -0.022 | 19.323 | 0.858 |
| | | 28 0.001 | -0.001 | 19.323 | 0.888 |
| | | 29 -0.004 | -0.006 | 19.330 | 0.913 |
| | | 30 -0.014 | -0.021 | 19.416 | 0.931 |
| | | 31 -0.060 | -0.071 | 20.937 | 0.914 |
| | | 32 -0.047 | -0.048 | 21.858 | 0.911 |
| | | 33 0.005 | 0.014 | 21.867 | 0.931 |
| | | 34 -0.050 | -0.055 | 22.945 | 0.925 |
| | | 35 -0.006 | -0.021 | 22.958 | 0.941 |
| | | 36 -0.017 | -0.038 | 23.077 | 0.953 |

*Probabilities may not be valid for this equation specification.

Figura 30: correlograma resíduos quadrados 390 garch

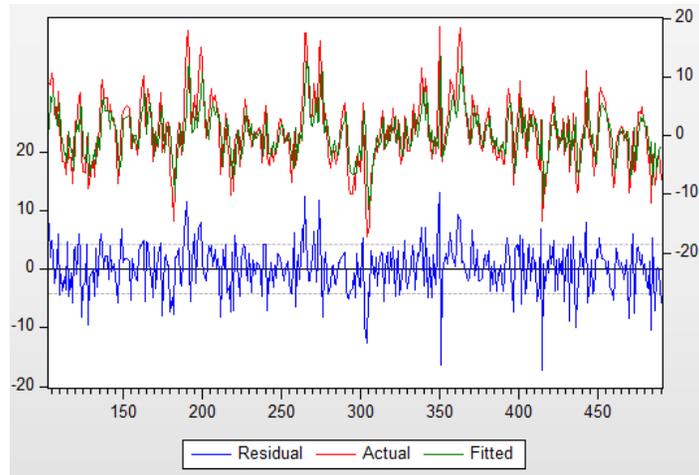


Figura 31: Trajetoria da subsérie com 390 observações

Modelação de uma série real

Nesta secção vamos abordar um exemplo prático considerando uma série temporal real relativa às cotações de fecho diárias da F. Ramada, retirada do índice PSI 20, entre 17-9-2018 e 14-9-2020. Foram-nos fornecidos os dados relativamente a esta empresa e pretende-se encontrar o melhor modelo estocástico da classe ARMA, com erros condicionalmente heteroscedásticos, que descreve a dinâmica subjacente a esta série temporal.

Analisando os dados que foram disponibilizados e o gráfico da trajetória da série podemos concluir que esta apresenta uma tendência decrescente ao longo de todo o seu período.

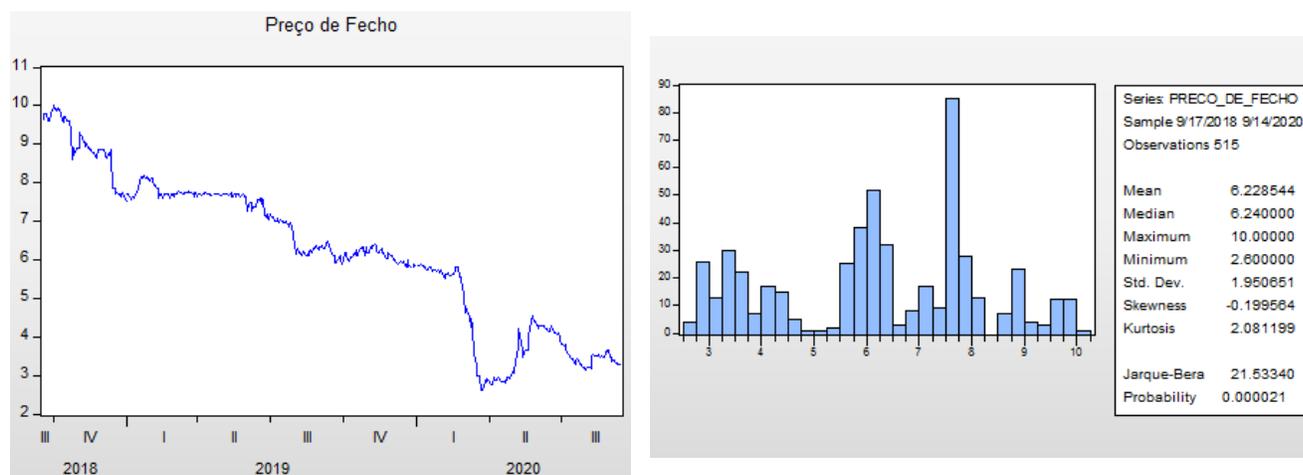


Figura 32: Cotação de fecho da ação da F. Ramada

Figura 33: Análise descritiva da série F. Ramada

Através da análise descritiva observamos que a série apresenta uma distribuição com média aproximadamente igual a 6.23, desvio-padrão 1.95 e, como a curtose tem valor inferior a 3, concluímos que se trata de uma distribuição pláticurta.

A partir do p-valor do teste Jarque-Bera, claramente inferior aos níveis de significância usuais, reforça-se a hipótese de que estamos perante uma distribuição não gaussiana.

De seguida, analisámos o correlograma da série e verifica-se que a autocorrelação não tem um decréscimo acentuado. Aliado a este comportamento a autocorrelação parcial de ordem 1 apresenta um valor muito próximo da unidade, desta forma, recorreremos ao teste de Dickey-Fuller para confirmar a não estacionaridade da série. De facto, como o p-valor deste teste é 0.7679, superior a qualquer nível de significância usual, aceitamos a hipótese nula, ou seja, aceitamos a não estacionaridade da série.

Isto justifica a necessidade de diferenciar a nossa série da forma

$$X_t - X_{t-1} = Y_t.$$

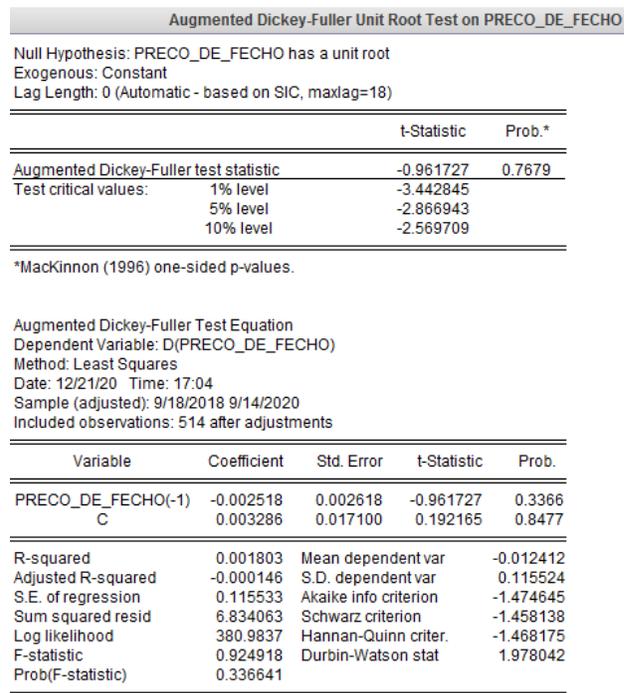
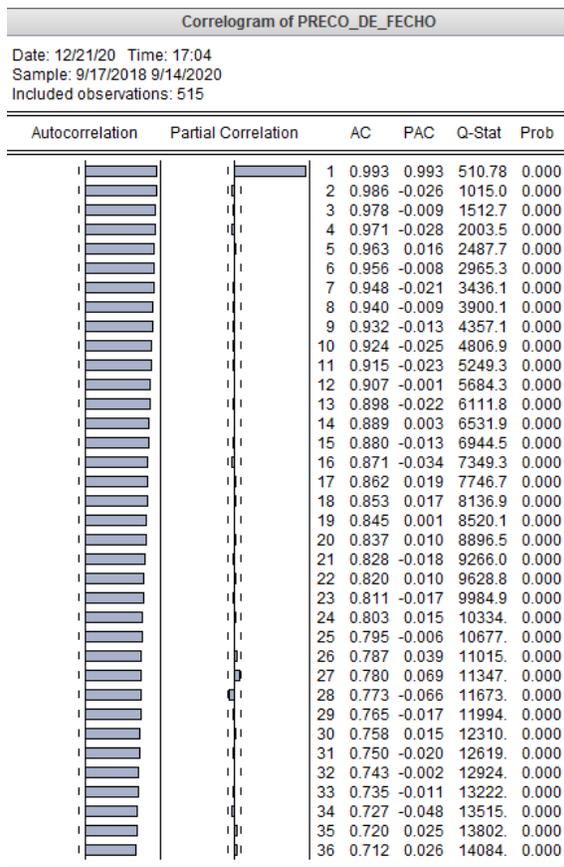


Figura 35: Teste de Dickey-Fuller

Figura 34: Correlograma da série F. Ramada

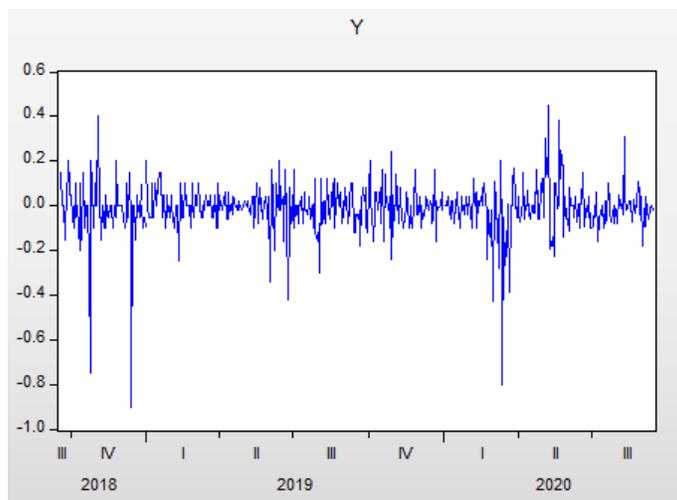


Figura 36: Trajetória da série diferenciada

Analisando o correlograma da série diferenciada, verificamos que as autocorrelações e as autocorrelações parciais não diferem muito de zero, pelo que concluímos que estamos perante um ruído branco. Mais, no teste de Dickey-Fuller, obtivemos um p-valor nulo, o que nos leva a aceitar a hipótese de estacionaridade da série.

No que respeita à análise descritiva verificamos que a sua média é aproximadamente zero, o desvio-padrão 0.12 e a sua curtose é, aproximadamente, 17.75, pelo que estamos claramente perante uma distribuição leptocúrtica e, portanto, não gaussiana.

Apesar das nossas autocorrelações evidenciarem todas as características de um ruído branco para a série diferenciada, note-se que a autocorrelação parcial de ordem 3 gera dúvidas em relação à sua proximidade de zero. Desta forma decidimos ver o comportamento da série segundo um modelo AR(3).

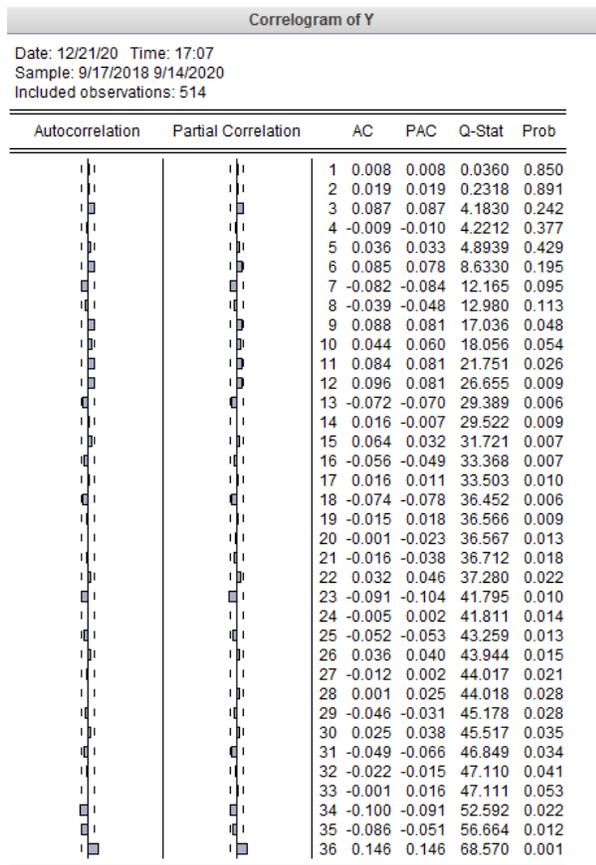


Figura 37: Correlograma da série diferenciada

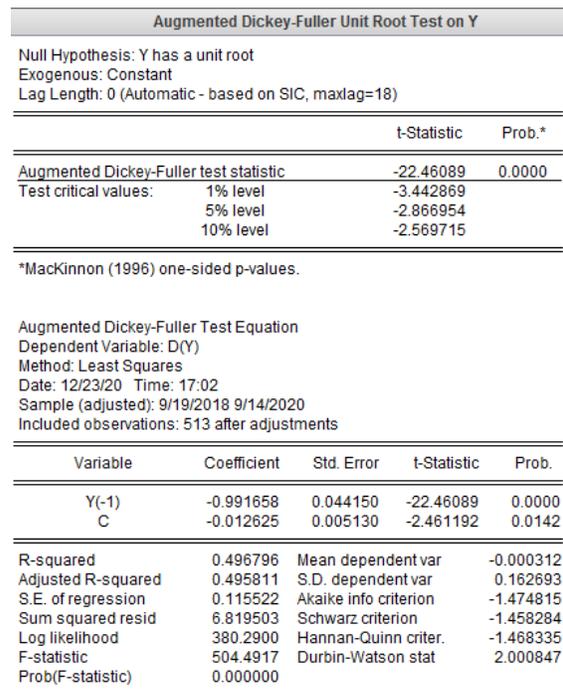


Figura 38: Teste de Dickey-Fuller da série diferencial

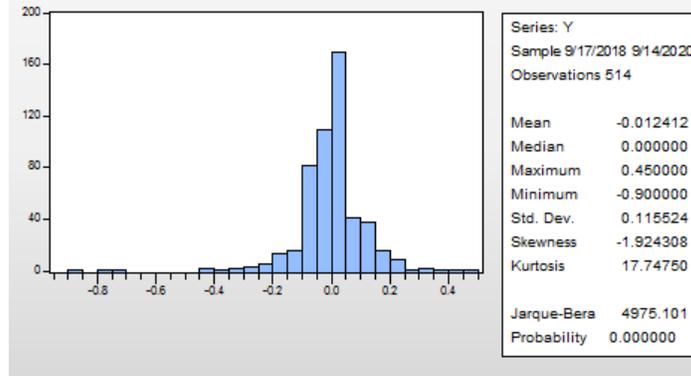


Figura 39: Análise descritiva da série diferenciada

Com base no teste de ajustamento, apresentado na figura 32, tiramos algumas conclusões relativamente à possibilidade da série seguir um modelo AR(3) da forma

$$X_t = \varphi_1 X_{t-1} + \varphi_2 X_{t-2} + \varphi_3 X_{t-3} + \varepsilon_t.$$

O primeiro p-valor apresentado, relativamente à variável C, é 0.0595, superior aos níveis de significância usuais, logo permite-nos verificar que, de facto, o nosso processo é centrado, pois foram testadas as hipóteses $H_0 : "C = 0"$ contra $H_1 : "C \neq 0"$. O segundo p-valor é relativo ao teste $H_0 : "\varphi_1 = 0"$ contra $H_1 : "\varphi_1 \neq 0"$ e sendo 0.8675, aceitamos H_0 . De forma análoga se tira as mesmas conclusões para φ_2 . Em relação φ_3 , aceitamos a hipótese H_0 para níveis de significância iguais ou inferiores a 0.01. No entanto, ao nível de significância 0.05 rejeitamos H_0 , a favor da hipótese que φ_3 existe e tem o valor aproximado de 0.089.

Dependent Variable: Y
Method: ARMA Maximum Likelihood (OPG - BHHH)
Date: 01/15/21 Time: 15:41
Sample: 9/18/2018 9/14/2020
Included observations: 514
Convergence achieved after 13 iterations
Coefficient covariance computed using outer product of gradients

| Variable | Coefficient | Std. Error | t-Statistic | Prob. |
|----------|-------------|------------|-------------|--------|
| C | -0.012366 | 0.006548 | -1.888545 | 0.0595 |
| AR(1) | 0.006533 | 0.039139 | 0.166925 | 0.8675 |
| AR(2) | 0.018688 | 0.036269 | 0.515270 | 0.6066 |
| AR(3) | 0.086811 | 0.040430 | 2.147196 | 0.0322 |
| SIGMASQ | 0.013213 | 0.000407 | 32.48709 | 0.0000 |

| | | | |
|--------------------|----------|-----------------------|-----------|
| R-squared | 0.008038 | Mean dependent var | -0.012412 |
| Adjusted R-squared | 0.000242 | S.D. dependent var | 0.115524 |
| S.E. of regression | 0.115510 | Akaike info criterion | -1.469191 |
| Sum squared resid | 6.791378 | Schwarz criterion | -1.427925 |
| Log likelihood | 382.5822 | Hannan-Quinn criter. | -1.453017 |
| F-statistic | 1.031100 | Durbin-Watson stat | 1.994444 |
| Prob(F-statistic) | 0.390556 | | |

| | | | |
|-------------------|-----|-----------|-----------|
| Inverted AR Roots | .46 | -.23+.37i | -.23-.37i |
|-------------------|-----|-----------|-----------|

Figura 40: Teste de ajustamento

Seguidamente, com a análise do correlograma dos resíduos, podemos verificar que este corresponde a um ruído branco, conclusão também retirada através do correlograma do quadrado dos resíduos.

| Correlogram of Residuals | | | | | | |
|-----------------------------------------------------|---------------------|----|--------|--------|--------|-------|
| Date: 01/15/21 Time: 15:37 | | | | | | |
| Sample: 9/17/2018 9/14/2020 | | | | | | |
| Included observations: 514 | | | | | | |
| Q-statistic probabilities adjusted for 3 ARMA terms | | | | | | |
| Autocorrelation | Partial Correlation | AC | PAC | Q-Stat | Prob | |
| | | 1 | 0.001 | 0.001 | 0.0004 | |
| | | 2 | -0.003 | -0.003 | 0.0041 | |
| | | 3 | -0.007 | -0.007 | 0.0303 | |
| | | 4 | -0.005 | -0.005 | 0.0420 | 0.838 |
| | | 5 | 0.038 | 0.038 | 0.7858 | 0.675 |
| | | 6 | 0.072 | 0.072 | 3.4720 | 0.324 |
| | | 7 | -0.089 | -0.090 | 7.6244 | 0.106 |
| | | 8 | -0.053 | -0.053 | 9.0912 | 0.105 |
| | | 9 | 0.073 | 0.076 | 11.920 | 0.064 |
| | | 10 | 0.056 | 0.056 | 13.592 | 0.059 |
| | | 11 | 0.086 | 0.080 | 17.504 | 0.025 |
| | | 12 | 0.083 | 0.087 | 21.182 | 0.012 |
| | | 13 | -0.075 | -0.059 | 24.180 | 0.007 |
| | | 14 | 0.007 | 0.000 | 24.204 | 0.012 |
| | | 15 | 0.065 | 0.045 | 26.427 | 0.009 |
| | | 16 | -0.048 | -0.053 | 27.667 | 0.010 |
| | | 17 | 0.015 | 0.014 | 27.780 | 0.015 |
| | | 18 | -0.079 | -0.072 | 31.084 | 0.009 |
| | | 19 | -0.012 | 0.010 | 31.167 | 0.013 |
| | | 20 | 0.006 | -0.015 | 31.189 | 0.019 |
| | | 21 | -0.008 | -0.043 | 31.223 | 0.027 |
| | | 22 | 0.039 | 0.051 | 32.061 | 0.031 |
| | | 23 | -0.095 | -0.108 | 36.912 | 0.012 |
| | | 24 | -0.004 | -0.002 | 36.919 | 0.017 |
| | | 25 | -0.054 | -0.053 | 38.478 | 0.016 |
| | | 26 | 0.048 | 0.032 | 39.756 | 0.016 |
| | | 27 | -0.012 | -0.002 | 39.832 | 0.022 |
| | | 28 | 0.009 | 0.026 | 39.875 | 0.030 |
| | | 29 | -0.047 | -0.026 | 41.084 | 0.030 |
| | | 30 | 0.027 | 0.037 | 41.489 | 0.037 |
| | | 31 | -0.041 | -0.057 | 42.393 | 0.040 |
| | | 32 | -0.009 | -0.011 | 42.438 | 0.051 |
| | | 33 | -0.013 | 0.007 | 42.533 | 0.064 |
| | | 34 | -0.096 | -0.098 | 47.648 | 0.028 |
| | | 35 | -0.081 | -0.050 | 51.247 | 0.017 |
| | | 36 | 0.152 | 0.148 | 64.083 | 0.001 |

Figura 41: Correlograma dos resíduos

| Correlogram of Residuals Squared | | | | | | |
|----------------------------------|---------------------|----|--------|--------|--------|-------|
| Date: 01/15/21 Time: 15:37 | | | | | | |
| Sample: 9/17/2018 9/14/2020 | | | | | | |
| Included observations: 514 | | | | | | |
| Autocorrelation | Partial Correlation | AC | PAC | Q-Stat | Prob | |
| | | 1 | 0.050 | 0.050 | 1.2964 | 0.255 |
| | | 2 | 0.050 | 0.047 | 2.5793 | 0.275 |
| | | 3 | 0.028 | 0.023 | 2.9859 | 0.394 |
| | | 4 | 0.000 | -0.004 | 2.9860 | 0.560 |
| | | 5 | 0.003 | 0.000 | 2.9894 | 0.702 |
| | | 6 | 0.056 | 0.056 | 4.6174 | 0.594 |
| | | 7 | 0.054 | 0.049 | 6.1248 | 0.525 |
| | | 8 | 0.063 | 0.053 | 8.1835 | 0.416 |
| | | 9 | 0.051 | 0.039 | 9.5355 | 0.389 |
| | | 10 | 0.008 | -0.003 | 9.5695 | 0.479 |
| | | 11 | -0.008 | -0.015 | 9.6028 | 0.566 |
| | | 12 | -0.011 | -0.015 | 9.6685 | 0.645 |
| | | 13 | 0.056 | 0.054 | 11.300 | 0.586 |
| | | 14 | -0.013 | -0.024 | 11.383 | 0.656 |
| | | 15 | -0.014 | -0.027 | 11.483 | 0.718 |
| | | 16 | -0.015 | -0.023 | 11.605 | 0.771 |
| | | 17 | -0.030 | -0.030 | 12.085 | 0.795 |
| | | 18 | -0.010 | -0.005 | 12.140 | 0.840 |
| | | 19 | -0.011 | -0.011 | 12.206 | 0.877 |
| | | 20 | -0.022 | -0.021 | 12.469 | 0.899 |
| | | 21 | -0.037 | -0.037 | 13.207 | 0.901 |
| | | 22 | -0.019 | -0.014 | 13.405 | 0.921 |
| | | 23 | -0.007 | 0.006 | 13.435 | 0.942 |
| | | 24 | -0.022 | -0.011 | 13.704 | 0.953 |
| | | 25 | -0.011 | -0.001 | 13.768 | 0.966 |
| | | 26 | -0.006 | -0.002 | 13.786 | 0.976 |
| | | 27 | -0.024 | -0.014 | 14.088 | 0.980 |
| | | 28 | -0.022 | -0.011 | 14.354 | 0.984 |
| | | 29 | 0.078 | 0.092 | 17.711 | 0.950 |
| | | 30 | -0.028 | -0.024 | 18.146 | 0.956 |
| | | 31 | -0.015 | -0.018 | 18.276 | 0.966 |
| | | 32 | -0.017 | -0.017 | 18.429 | 0.973 |
| | | 33 | -0.021 | -0.012 | 18.668 | 0.979 |
| | | 34 | 0.012 | 0.023 | 18.751 | 0.984 |
| | | 35 | 0.001 | -0.003 | 18.752 | 0.989 |
| | | 36 | 0.264 | 0.266 | 57.376 | 0.013 |

Figura 42: Correlograma dos resíduos quadráticos

Assim, resta testar a heteroscedasticidade do modelo AR(3).

Como podemos ver na figura 35, o p-valor do teste de heteroscedasticidade é 0.2575, superior a qualquer nível de significância usual, logo aceitamos a hipótese nula, ou seja, estamos na presença de um processo de erro homocedástico.

| Heteroskedasticity Test: ARCH | | | | |
|----------------------------------------------|-------------|-----------------------|-------------|--------|
| F-statistic | 1.284850 | Prob. F(1,511) | 0.2575 | |
| Obs*R-squared | 1.286644 | Prob. Chi-Square(1) | 0.2567 | |
| Test Equation: | | | | |
| Dependent Variable: RESID^2 | | | | |
| Method: Least Squares | | | | |
| Date: 01/15/21 Time: 15:36 | | | | |
| Sample (adjusted): 9/19/2018 9/14/2020 | | | | |
| Included observations: 513 after adjustments | | | | |
| Variable | Coefficient | Std. Error | t-Statistic | Prob. |
| C | 0.012525 | 0.002430 | 5.153952 | 0.0000 |
| RESID^2(-1) | 0.050081 | 0.044182 | 1.133512 | 0.2575 |
| R-squared | 0.002508 | Mean dependent var | 0.013188 | |
| Adjusted R-squared | 0.000556 | S.D. dependent var | 0.053437 | |
| S.E. of regression | 0.053422 | Akaike info criterion | -3.017287 | |
| Sum squared resid | 1.458363 | Schwarz criterion | -3.000756 | |
| Log likelihood | 775.9342 | Hannan-Quinn criter. | -3.010807 | |
| F-statistic | 1.284850 | Durbin-Watson stat | 2.004266 | |
| Prob(F-statistic) | 0.257531 | | | |

Figura 43: Heteroscedasticidade do modelo AR(3)

Podemos ver que através do *Eviews* podemos ainda comparar a nossa série estimada com a série diferenciada, bem como a trajetória do resíduo associado.

Por fim, recorremos ao forecast e como o erro associado à série diferenciada é um ruído branco, por definição, temos que $E(\varepsilon_t) = 0$ e que $E(\varepsilon_t^2)$ existe e é independente de t .

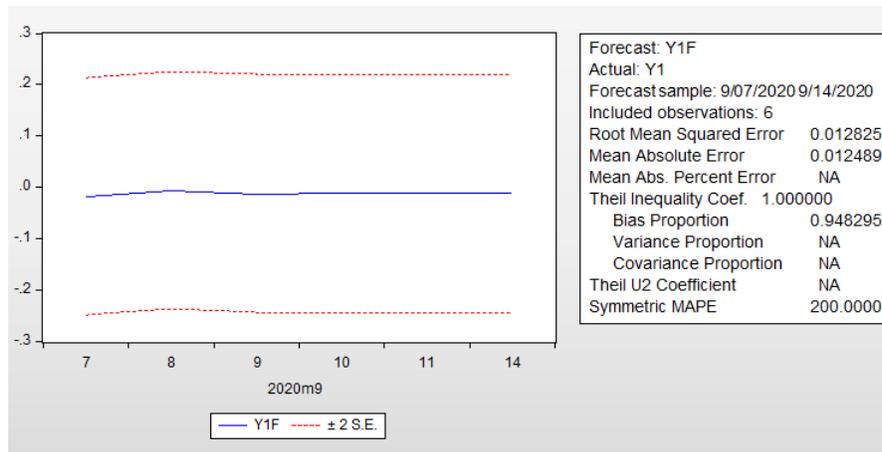


Figura 44: Forecast

Através da análise da figura 44, podemos verificar que $E(\varepsilon_t)$ é um valor relativamente próximo de zero. A vermelho e tracejado temos a representação de $E(\varepsilon_t^2)$, que, como podemos ver, se mantém com poucas oscilações ao longo do tempo, o que nos permite concluir que $E(\varepsilon_t^2)$ existe e é independente de t , tal como seria de esperar.

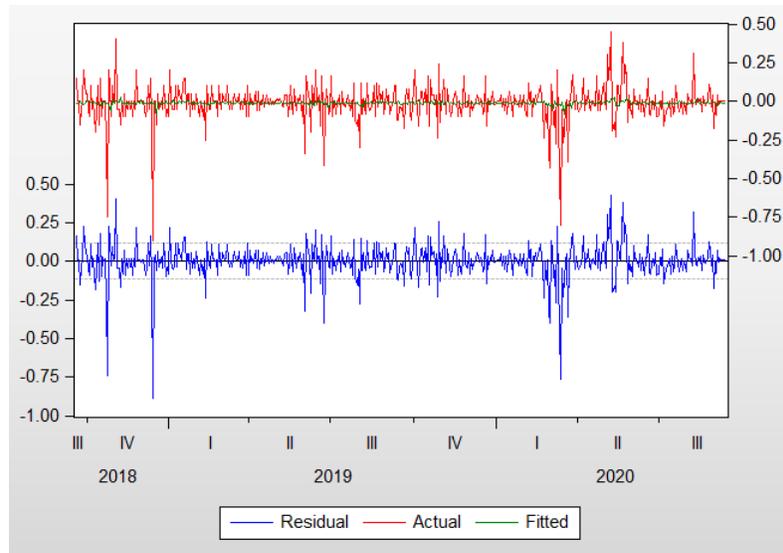


Figura 45: Trajetória das séries observada e estimada e trajetória do resíduo associado

Considerações Finais

A realização deste projeto computacional permitiu-nos aplicar alguns resultados teóricos abordados na cadeira de Séries Temporais, assim como a respetiva análise de conhecimentos adquiridos ao longo do semestre. Através da utilização do software *Eviews* foi possível modelar séries e realizar previsões, o que nos permitiu consolidar os conhecimentos adquiridos nas aulas. Além disso, é de salientar a relevante componente prática do trabalho, que nos levou a prever uma série temporal representada pelas cotações de fecho diárias da F Ramada, dando-nos assim a conhecer uma aplicação bastante prática desta disciplina.

Bibliografia

Gonçalves, E., N. Mendes-Lopes, Séries Temporais. Modelações lineares e não lineares. (slides disponibilizados 2020/2021)