

Universidade do Minho
Escola de Economia e Gestão

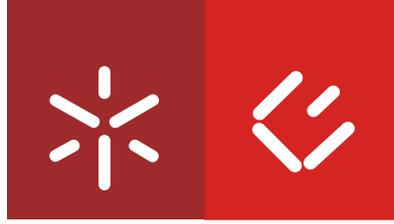
Ana Catarina Soares Ramos

**Previsão do risco no mercado
de commodities de energia**

Ana Catarina Soares Ramos | Previsão do risco no mercado de commodities de energia

UMinho | 2021

dezembro de 2021



Universidade do Minho
Escola de Economia e Gestão

Ana Catarina Soares Ramos

**Previsão do risco no mercado
de commodities de energia**

Dissertação de Mestrado
Mestrado em Economia Monetária, Bancária e Financeira

Trabalho efetuado sob a orientação da
Professora Doutora Cristina Amado

Direitos de autor e condições de utilização do trabalho por terceiros

Este é um trabalho académico que pode ser utilizado por terceiros desde que respeitadas as regras e boas práticas internacionalmente aceites, no que concerne aos direitos de autor e direitos conexos.

Assim, o presente trabalho pode ser utilizado nos termos previstos na licença abaixo indicada.

Caso o utilizador necessite de permissão para poder fazer um uso do trabalho em condições não previstas no licenciamento indicado, deverá contactar o autor, através do RepositóriUM da Universidade do Minho.



Atribuição-NãoComercial-Compartilhalgal
CC BY-NC-SA

<https://creativecommons.org/licenses/by-nc-sa/4.0/>

Agradecimentos

PAIS. Aos meus pais tudo. Toda a gratidão, amor, vida. A eles que são a base da minha educação. A eles que me permitiram chegar aqui.

TIAGO. A ele que viveu as minhas dores e as minhas conquistas. A ele que é o meu herói e não sabe.

IRMÃS. Às minhas irmãs que são dos amores mais lindos que vivo.

PROFESSORA. À minha orientadora, mentora, conselheira, paciente e atenciosa, à minha professora que é amiga e me fez acabar algo que não me achava capaz. Muito à professora.

AMIGOS. Aos amigos que me aturaram, que me ajudaram e que se lamentaram comigo. Sorte é ter amigos.

A todos eles, com muito amor, o meu maior agradecimento, porque grandes conquistas partilham-se com grandes pessoas!

“O próprio viver é morrer, porque não temos um dia a mais na nossa vida que não tenhamos nisso um dia a menos.”

Fernando Pessoa

Declaração de integridade

Declaro ter atuado com integridade na elaboração do presente trabalho académico e confirmo que não recorri à prática de plágio nem a qualquer forma de utilização indevida ou falsificação de informações ou resultados em nenhuma das etapas conducente à sua elaboração.

Mais declaro que conheço e que respeitei o Código de Conduta Ética da Universidade do Minho.

Resumo

Previsão do risco no mercado de commodities de energia

A presente dissertação de mestrado é baseada no estudo da previsão do risco no mercado de commodities de energia, dentre elas a Gasolina, o Gás Natural, o Petróleo, o Petróleo de Aquecimento, o Querosene e por fim o Propano, sendo que cada energia é estudada em três espaços temporais distintos.

Inicialmente são apresentados graficamente os retornos da energia, a autocorrelação e a autocorrelação parcial, posteriormente os preços e por fim novamente a autocorrelação depois de ser eliminada a autocorrelação que estava presente nos dados inicialmente. Posteriormente são também analisadas as estatísticas descritivas em cada energia e em cada um dos três períodos de tempo a ser estudados, onde estão presentes os resultados do teste Ljung-Box, antes e depois da eliminação da autocorrelação inicial.

Por fim, é estudada a volatilidade em cada energia, para tal são analisados quatro modelos GARCH, dentre eles o S-GARCH, o E-GARCH, o GJR-GARCH e o T-GARCH, este estudo é reproduzido em gráficos de volatilidade e posteriormente numa tabela que contempla os resultados de estimação dos modelos em questão, para que nos seja possível decidir o mais indicado para o estudo de cada uma das energias.

Palavras-Chave: Autocorrelação, commodities, energias, modelos, volatilidade.

Abstract

Forecasting risk in the energy commodities market

This master's work is based on the study of risk prediction in the energy commodity market, more specifically Gasoline, Natural Gas, Oil, Heating Oil, Kerosene and Propane, with each energy being studied in three temporal periods.

In a first phase, energy returns, autocorrelation and partial autocorrelation are graphically presented, followed by prices and finally autocorrelation after eliminating the autocorrelation that was initially present in the data. Afterwards, I analyze the descriptive statistics in each energy and in each of the three time periods to be studied, where the results of the Ljung-Box test are present, before and after the elimination of the initial autocorrelation.

Finally, the volatility of each energy is studied, analyzing four GARCH models, including the S-GARCH, the E-GARCH, the GJR-GARCH and the T-GARCH. This study is reproduced in volatility graphs and later in a table that includes the estimation results of the models in question, so that it is possible for us to decide the most suitable model for the study of each energy.

Keywords: Autocorrelation; Commodities; Energies; Models; Volatility

Índice

Direitos de autor e condições de utilização do trabalho por terceiros	II
Agradecimentos.....	III
Declaração de integridade	IV
Resumo	V
Abstract	VI
Índice	VII
Índice de tabelas	X
Índice de gráficos	XI
Índice de figuras.....	XV
Abreviaturas e Siglas.....	XV
Introdução	1
1. Revisão de literatura	3
2. Metodologia econométrica.....	7
3. Análise de dados	12
3.1 - Análise das rendibilidades da Gasolina	13
3.1.1 – Estatísticas descritivas das rendibilidades da Gasolina	13
3.1.2 – Estimação dos modelos de volatilidade do tipo GARCH	15
3.2 – Análise das rendibilidades do Gás Natural.....	17
3.2.1 – Estatísticas descritivas das rendibilidades do Gás Natural.....	17
3.2.2 – Estimação dos modelos de volatilidade do tipo GARCH	19
3.3 – Análise das rendibilidades do Petróleo.....	21
3.3.1 – Estatísticas descritivas das rendibilidades do Petróleo.....	21
3.3.2 – Estimação dos modelos de volatilidade do tipo GARCH	23
3.4 – Análise das rendibilidades do Petróleo de Aquecimento	25
3.4.1 – Estatísticas descritivas das rendibilidades do Petróleo de Aquecimento	25
3.4.2 – Estimação dos modelos de volatilidade do tipo GARCH	27
3.5 – Análise das rendibilidades do Querosene	29
3.5.1 – Estatísticas descritivas das rendibilidades do Querosene	29
3.5.2 – Estimação dos modelos de volatilidade do tipo GARCH	31
3.6 – Análise das rendibilidades do Propano.....	33
3.6.1 – Estatísticas descritivas das rendibilidades do Propano.....	33
3.6.2 – Estimação dos modelos de volatilidade do tipo GARCH	35

3.7 – Análise do Value at Risk	37
3.7.1 – Value at Risk das commodities em estudo	38
Conclusão.....	41
Referências bibliográficas	42
Anexos.....	43
Anexo 1 – Análise das rendibilidades da Gasolina.....	44
Subamostra 1	45
Subamostra 2	46
Estudo da volatilidade da Gasolina na subamostra 1	47
Estudo da volatilidade da Gasolina na subamostra 2	48
Anexo 2 – Análise das rendibilidades do Gás Natural.....	49
Subamostra 1	50
Subamostra 2	51
Estudo da volatilidade do Gás Natural na subamostra 1	52
Estudo da volatilidade do Gás Natural na subamostra 2.....	53
Anexo 3 – Análise das rendibilidades do Petróleo	54
Subamostra 1	55
Subamostra 2	56
Estudo da volatilidade do Petróleo na subamostra 1	56
Estudo da volatilidade do Petróleo na subamostra 2	58
Anexo 4 – Análise das rendibilidades do Petróleo de Aquecimento.....	59
Subamostra 1	60
Subamostra 2	60
Estudo da volatilidade do Petróleo de Aquecimento na subamostra 1.....	62
Estudo da volatilidade do Petróleo de Aquecimento na subamostra 2.....	63
Anexo 5 – Análise das rendibilidades do Querosene	64
Subamostra 1	65
Subamostra 2	66
Estudo da volatilidade do Querosene na subamostra 1	66
Estudo da volatilidade do Querosene na subamostra 2	68
Anexo 6 – Análise das rendibilidades do Propano.....	68
Subamostra 1	70
Subamostra 2	71
Estudo da volatilidade do Propano na subamostra 1.....	72

Estudo da volatilidade do Propano na subamostra 2.....	73
Anexo 7 – Estudo do Value at Risk.....	74
Na Gasolina.....	74
No Gás Natural.....	75
No Petróleo.....	76
No Petróleo de Aquecimento.....	77
No Querosene.....	78
No Propano.....	79
Anexo 8 – Script do R.....	80

Índice de tabelas

Tabela 1 – Gasolina - Amostra Completa	13
Tabela 2 - Resultados da estimação dos modelos do tipo GARCH na Gasolina	15
Tabela 3 - Gás Natural - Amostra total	17
Tabela 4 - Resultados da estimação dos modelos do tipo GARCH no Gás Natural	19
Tabela 5 – Petróleo - Amostra Total.....	21
Tabela 6 - Resultados da estimação dos modelos do tipo GARCH no Petróleo.....	23
Tabela 7 - Petróleo de Aquecimento - Amostra Completa	25
Tabela 8 - Resultados da estimação dos modelos do tipo GARCH no Petróleo de Aquecimento	27
Tabela 9 - Querosene - Amostra Completa	29
Tabela 10 - Resultados da estimação dos modelos do tipo GARCH no Querosene	31
Tabela 11 - Propano – Amostra Completa.....	33
Tabela 12 - Resultados da estimação dos modelos do tipo GARCH no Propano.....	35
Tabela 13 - Dados do Value at Risk na Gasolina	39
Tabela 14 - Dados do Value at Risk no Gás Natural	39
Tabela 15 - Dados do Value at Risk no Petróleo.....	39
Tabela 16 - Dados do Value at Risk no Petróleo de Aquecimento	40
Tabela 17 - Dados do Value at Risk no Querosene.....	40
Tabela 18 - Dados do Value at Risk no Propano	40
Tabela 19 - Gasolina – Subamostra 1.....	44
Tabela 20 – Gasolina – Subamostra 2	44
Tabela 21 – Gás Natural – Subamostra 1	49
Tabela 22 - Gás Natural – Subamostra 2	49
Tabela 23 - Petróleo – Subamostra 1	54
Tabela 24 - Petróleo – Subamostra 2	54
Tabela 25 - Petróleo de Aquecimento – Subamostra 1.....	59
Tabela 26 - Petróleo de Aquecimento – Subamostra 2.....	59
Tabela 27 - Querosene – Subamostra 1	64
Tabela 28 - Querosene – Subamostra 2	64
Tabela 29 - Propano – Subamostra 1	69
Tabela 30 - Propano – Subamostra 2	69

Índice de gráficos

Gráfico 1 - Retornos da Gasolina entre 3 de junho de 1986 e 14 de setembro de 2020	14
Gráfico 2 - Autocorrelação da série de retornos	14
Gráfico 3 - Autocorrelação parcial da série de retornos.....	14
Gráfico 4 - Autocorrelação da série de retornos, pós eliminação de autocorrelação.....	14
Gráfico 5 - Volatilidades da Gasolina no modelo S-GARCH	16
Gráfico 6 - Volatilidades da Gasolina no modelo E-GARCH	16
Gráfico 7 - Volatilidades da Gasolina no modelo GJR-GARCH	16
Gráfico 8 - Volatilidades da Gasolina no modelo T-GARCH	16
Gráfico 9 - Retornos do Gás Natural entre 8 de janeiro de 1997 e 15 de setembro de 2020	18
Gráfico 10 – Autocorrelação da série de retornos	18
Gráfico 11 – Autocorrelação parcial da série de retornos.....	18
Gráfico 12 - Autocorrelação da série de retornos, pós eliminação de autocorrelação.....	18
Gráfico 13 – Volatilidades do Gás Natural no modelo S-GARCH.....	20
Gráfico 14 - Volatilidades do Gás Natural no modelo E-GARCH	20
Gráfico 15 - Volatilidades do Gás Natural no modelo GJR-GARCH.....	20
Gráfico 16 - Volatilidades do Gás Natural no modelo T-GARCH.....	20
Gráfico 17 - Retornos do Petróleo entre 21 de maio de 1987 e 14 de setembro de 2020	22
Gráfico 18 - Autocorrelação da série de retornos	22
Gráfico 19 – Autocorrelação parcial da série de retornos.....	22
Gráfico 20 - Autocorrelação da série de retornos, pós eliminação de autocorrelação.....	22
Gráfico 21 - Volatilidades do Petróleo no modelo S-GARCH.....	24
Gráfico 22 - Volatilidades do Petróleo no modelo E-GARCH.....	24
Gráfico 23 - Volatilidades do Petróleo no modelo GJR-GARCH	24
Gráfico 24 - Volatilidades do Petróleo no modelo T-GARCH.....	24
Gráfico 25 – Retornos do Petróleo de Aquecimento entre 3 de junho de 1986 e 14 de setembro de 2020	26
Gráfico 26 - Autocorrelação da série de retornos	26
Gráfico 27 – Autocorrelação parcial da série de retornos.....	26
Gráfico 28 - Autocorrelação da série de retornos, pós eliminação de autocorrelação.....	26
Gráfico 29 - Volatilidades do Petróleo de Aquecimento no modelo S-GARCH	28
Gráfico 30 - Volatilidades do Petróleo de Aquecimento no modelo E-GARCH	28
Gráfico 31 - Volatilidades do Petróleo de Aquecimento no modelo GJR-GARCH	28
Gráfico 32 - Volatilidades do Petróleo de Aquecimento no modelo T-GARCH	28
Gráfico 33 – Retornos do Querosene entre 3 de abril de 1990 e 14 de setembro de 2020	30
Gráfico 34 - Autocorrelação da série de retornos	30
Gráfico 35 - Autocorrelação da série de retornos, pós eliminação de autocorrelação.....	30
Gráfico 36 – Autocorrelação parcial da série de retornos.....	30
Gráfico 37 - Volatilidades do Querosene no modelo S-GARCH.....	32
Gráfico 38 - Volatilidades do Querosene no modelo E-GARCH	32
Gráfico 39 - Volatilidades do Querosene no modelo GJR-GARCH	32
Gráfico 40 - Volatilidades do Querosene no modelo T-GARCH	32
Gráfico 41 – Retornos do Propano entre 10 de julho de 1992 e 14 de setembro de 2020.....	34
Gráfico 42 - Autocorrelação da série de retornos	34

Gráfico 43 – Autocorrelação parcial da série de retornos.....	34
Gráfico 44 - Autocorrelação da série de retornos, pós eliminação de autocorrelação.....	34
Gráfico 45 - Volatilidades do Propano no modelo S-GARCH	36
Gráfico 46 - Volatilidades do Propano no modelo E-GARCH	36
Gráfico 47 - Volatilidades do Propano no modelo GJR-GARCH.....	36
Gráfico 48 - Volatilidades do Propano no modelo T-GARCH.....	36
Gráfico 49 - Retornos da Gasolina entre 3 de junho de 1986 a 30 de dezembro de 2016.....	45
Gráfico 50 – Autocorrelação da série de retornos	45
Gráfico 51 – Autocorrelação parcial da série de retornos.....	45
Gráfico 52 - Preços da Gasolina entre 3 de junho de 1986 a 30 de dezembro de 2016.....	45
Gráfico 53 - Autocorrelação da série de retornos, pós eliminação de autocorrelação.....	45
Gráfico 54 - Retornos da Gasolina entre 3 de janeiro de 2017 e 14 de setembro de 2020.....	46
Gráfico 55 - Autocorrelação da série de retornos	46
Gráfico 56 - Autocorrelação parcial da série de retornos.....	46
Gráfico 57 - Preços da Gasolina entre 3 de janeiro de 2017 e 14 de setembro de 2020.....	46
Gráfico 58 - Autocorrelação da série de retornos, pós eliminação de autocorrelação.....	46
Gráfico 59 - Volatilidades da Gasolina no modelo S-GARCH	47
Gráfico 60 - Volatilidades da Gasolina no modelo E-GARCH	47
Gráfico 61 - Volatilidades da Gasolina no modelo GJR-GARCH	47
Gráfico 62 - Volatilidades da Gasolina no modelo T-GARCH	47
Gráfico 63 - Volatilidades da Gasolina no modelo S-GARCH	48
Gráfico 64 - Volatilidades da Gasolina no modelo E-GARCH	48
Gráfico 65 - Volatilidades da Gasolina no modelo GJR-GARCH	48
Gráfico 66 - Volatilidades da Gasolina no modelo T-GARCH	48
Gráfico 67 - Retornos do Gás Natural entre 8 de janeiro de 1997 e 29 de dezembro de 2016	50
Gráfico 68 – Autocorrelação da série de retornos	50
Gráfico 69 – Autocorrelação parcial da série de retornos.....	50
Gráfico 70 – Preços do Gás Natural entre 8 de janeiro de 1997 e 29 de dezembro de 2016	50
Gráfico 71 – Autocorrelação da série de retornos pós eliminação da autocorrelação	50
Gráfico 72 - Retornos do Gás Natural entre 3 de janeiro de 2017 e 15 de setembro de 2020	51
Gráfico 73 – Autocorrelação da série de retornos	51
Gráfico 74 – Autocorrelação parcial da série de retornos.....	51
Gráfico 75 – Preços do Gás Natural entre 3 de janeiro de 2017 e 15 de setembro de 2020	51
Gráfico 76 – Autocorrelação da série de retornos, pós eliminação de autocorrelação	51
Gráfico 77 - Volatilidades do Gás Natural no modelo S-GARCH	52
Gráfico 78 - Volatilidades do Gás Natural no modelo E-GARCH	52
Gráfico 79 - Volatilidades do Gás Natural no modelo GJR-GARCH.....	52
Gráfico 80 - Volatilidades do Gás Natural no modelo T-GARCH.....	52
Gráfico 81 - Volatilidades do Gás Natural no modelo S-GARCH	53
Gráfico 82 - Volatilidades do Gás Natural no modelo E-GARCH	53
Gráfico 83 - Volatilidades do Gás Natural no modelo GJR-GARCH.....	53
Gráfico 84 - Volatilidades do Gás Natural no modelo T-GARCH.....	53
Gráfico 85 – Retornos do Petróleo entre 21 de maio de 1987 e 30 de dezembro de 2016	55
Gráfico 86 - Autocorrelação da série de retornos	55
Gráfico 87 – Autocorrelação parcial da série de retornos.....	55

Gráfico 88 – Preços do Petróleo entre 21 de maio de 1987 e 30 de dezembro de 2016	55
Gráfico 89 - Autocorrelação da série de retornos, pós eliminação de autocorrelação.....	55
Gráfico 90 – Retornos do Petróleo entre 3 de janeiro de 2017 e 14 de setembro de 2020	56
Gráfico 91 - Autocorrelação da série de retornos	56
Gráfico 92 – Autocorrelação parcial da série de retornos.....	56
Gráfico 93 – Preços do Petróleo entre 3 de janeiro de 2017 e 14 de setembro de 2020	56
Gráfico 94 - Autocorrelação da série de retornos, pós eliminação de autocorrelação.....	56
Gráfico 95 - Volatilidades do Petróleo no modelo S-GARCH.....	57
Gráfico 96 - Volatilidades do Petróleo no modelo E-GARCH.....	57
Gráfico 97 - Volatilidades do Petróleo no modelo GJR-GARCH	57
Gráfico 98 - Volatilidades do Petróleo no modelo T-GARCH.....	57
Gráfico 99 - Volatilidades do Petróleo no modelo S-GARCH.....	58
Gráfico 100 - Volatilidades do Petróleo no modelo E-GARCH.....	58
Gráfico 101 - Volatilidades do Petróleo no modelo GJR-GARCH.....	58
Gráfico 102 - Volatilidades do Petróleo no modelo T-GARCH.....	58
Gráfico 103 - Retornos do Petróleo de Aquecimento entre 3 de junho de 1986 e 30 de dezembro de 2016.....	60
Gráfico 104 - Autocorrelação da série de retornos	60
Gráfico 105 – Autocorrelação parcial da série de retornos.....	60
Gráfico 106 – Preços do Petróleo de Aquecimento entre 3 de junho de 1986 e 30 de dezembro de 2016.....	60
Gráfico 107 - Autocorrelação da série de retornos, pós eliminação de autocorrelação.....	60
Gráfico 108 - Retornos do Petróleo de Aquecimento entre 3 de janeiro de 2017 e 14 de setembro de 2020	61
Gráfico 109 - Autocorrelação da série de retornos	61
Gráfico 110 – Autocorrelação parcial da série de retornos.....	61
Gráfico 111 – Preços do Petróleo de Aquecimento entre 3 de janeiro de 2017 e 14 de setembro de 2020.....	61
Gráfico 112 - Autocorrelação da série de retornos, pós eliminação de autocorrelação.....	61
Gráfico 113 - Volatilidades do Petróleo de Aquecimento no modelo S-GARCH	62
Gráfico 114 - Volatilidades do Petróleo de Aquecimento no modelo E-GARCH	62
Gráfico 115 - Volatilidades do Petróleo de Aquecimento no modelo GJR-GARCH	62
Gráfico 116 - Volatilidades do Petróleo de Aquecimento no modelo T-GARCH	62
Gráfico 117 - Volatilidades do Petróleo de Aquecimento no modelo S-GARCH	63
Gráfico 118 - Volatilidades do Petróleo de Aquecimento no modelo E-GARCH	63
Gráfico 119 - Volatilidades do Petróleo de Aquecimento no modelo GJR-GARCH	63
Gráfico 120 - Volatilidades do Petróleo de Aquecimento no modelo T-GARCH	63
Gráfico 121 – Retornos do Querosene entre 3 de abril de 1990 e 30 de dezembro de 2016	65
Gráfico 122 - Autocorrelação da série de retornos	65
Gráfico 123 – Autocorrelação parcial da série de retornos.....	65
Gráfico 124 – Preços do Querosene entre 3 de abril de 1990 e 30 de dezembro de 2016	65
Gráfico 125 - Autocorrelação da série de retornos, pós eliminação de autocorrelação.....	65
Gráfico 126 - Retornos do Querosene entre 3 de janeiro de 2017 e 14 de setembro de 2020.....	66
Gráfico 127 - Autocorrelação da série de retornos	66
Gráfico 128 – Autocorrelação parcial da série de retornos.....	66
Gráfico 129 - Preços do Querosene entre 3 de janeiro de 2017 e 14 de setembro de 2020.....	66
Gráfico 130 - Autocorrelação da série de retornos, pós eliminação de autocorrelação.....	66
Gráfico 131 - Volatilidades do Querosene no modelo S-GARCH	67
Gráfico 132 - Volatilidades do Querosene no modelo E-GARCH.....	67

Gráfico 133 - Volatilidades do Querosene no modelo GJR-GARCH	67
Gráfico 134 - Volatilidades do Querosene no modelo T-GARCH	67
Gráfico 135 - Volatilidades do Querosene no modelo S-GARCH	68
Gráfico 136 - Volatilidades do Querosene no modelo E-GARCH	68
Gráfico 137 - Volatilidades do Querosene no modelo GJR-GARCH	68
Gráfico 138 - Volatilidades do Querosene no modelo T-GARCH	68
Gráfico 139 - Retornos do Propano entre 10 de julho de 1992 e 31 de dezembro de 2015	70
Gráfico 140 - Autocorrelação da série de retornos	70
Gráfico 141 – Autocorrelação parcial da série de retornos.....	70
Gráfico 142 – Preços do Propano entre 10 de julho de 1992 e 31 de dezembro de 2015	70
Gráfico 143 - Autocorrelação da série de retornos, pós eliminação de autocorrelação.....	70
Gráfico 144 – Retornos do Propano entre 4 de janeiro de 2016 e 14 de setembro de 2020	71
Gráfico 145 - Autocorrelação da série de retornos	71
Gráfico 146 – Autocorrelação parcial da série de retornos.....	71
Gráfico 147 – Preços do Propano entre 4 de janeiro de 2016 e 14 de setembro de 2020	71
Gráfico 148 - Autocorrelação da série de retornos, pós eliminação de autocorrelação.....	71
Gráfico 149 - Volatilidades do Propano no modelo S-GARCH	72
Gráfico 150 - Volatilidades do Propano no modelo E-GARCH	72
Gráfico 151 - Volatilidades do Propano no modelo GJR-GARCH.....	72
Gráfico 152 - Volatilidades do Propano no modelo T-GARCH.....	72
Gráfico 153 - Volatilidades do Propano no modelo S-GARCH	73
Gráfico 154 - Volatilidades do Propano no modelo E-GARCH	73
Gráfico 155 - Volatilidades do Propano no modelo GJR-GARCH.....	73
Gráfico 156 - Volatilidades do Propano no modelo T-GARCH.....	73
Gráfico 157 – Subamostra 1	74
Gráfico 158 – Subamostra 1	74
Gráfico 159 – Subamostra 2	74
Gráfico 160 – Subamostra 2	74
Gráfico 161 - Amostra Completa	74
Gráfico 162 - Amostra Completa	74
Gráfico 163 – Subamostra 1	75
Gráfico 164 – Subamostra 1	75
Gráfico 165 – Subamostra 2	75
Gráfico 166 – Subamostra 2	75
Gráfico 167 - Amostra Completa	75
Gráfico 168 - Amostra Completa	75
Gráfico 169 – Subamostra 1	76
Gráfico 170 – Subamostra 1	76
Gráfico 171 – Subamostra 2	76
Gráfico 172 – Subamostra 2	76
Gráfico 173 - Amostra Completa	76
Gráfico 174 - Amostra Completa	76
Gráfico 175 – Subamostra 1	77
Gráfico 176 – Subamostra 1	77
Gráfico 177 – Subamostra 2	77

Gráfico 178 – Subamostra 2	77
Gráfico 179 - Amostra Completa	77
Gráfico 180 - Amostra Completa	77
Gráfico 181 – Subamostra 1	78
Gráfico 182 – Subamostra 1	78
Gráfico 183 – Subamostra 2	78
Gráfico 184 – Subamostra 2	78
Gráfico 185 - Amostra Completa	78
Gráfico 186 - Amostra Completa	78
Gráfico 187 – Subamostra 1	79
Gráfico 188 – Subamostra 1	79
Gráfico 189 – Subamostra 2	79
Gráfico 190 – Subamostra 2	79
Gráfico 191 - Amostra Completa	79
Gráfico 192 - Amostra Completa	79

Índice de figuras

Figura 1 - Script do VaR.....	37
-------------------------------	----

Abreviaturas e Siglas

E-GARCH: Exponencial Garch Model

ES: Expected Shortfall

EVT-SWARCH/EVT-GARCH: Extreme Value Theory de Swarh/Garch

GJR-GARCH: Glosten Jagannathan and Runkle Garch Model

S-GARCH: Standard Garch Model

T-GARCH: Threshold Garch Model

VaR: Value at Risk

Introdução

O retorno de um investimento está relacionado com o risco que este tem implícito, com base no Modelo de Precificação de Ativos Financeiros. O mercado de *commodities* é caracterizado por um elevado risco, sendo que a elevada volatilidade é característica deste mercado, assim sendo, falamos em ganhos e perdas. Contínuos processos de desregulamentação levaram assim a um crescimento dos mercados de energia. Isto permitiu que as exposições ao risco aumentassem, incluídas assim as compras e vendas de commodities do mercado de energia.

Além dos detentores de recursos físicos, as instituições financeiras incluídas, como bancos e fundos hedge, participam cada vez mais de mercados para satisfazer os pedidos dos seus clientes, para ganhar ou proteger o risco de exposição da energia, bem como negociar por conta própria, o que leva assim a uma maior exposição ao risco do preço das energias.

Os mercados de futuros têm como foco principal mitigar os riscos do preço das commodities e indicar qual a expectativa futura para o preço.

O objetivo principal desta dissertação é investigar os modelos existentes na literatura que combinam simultaneamente as flutuações dos ciclos económicos e variações de volatilidade de curto prazo e que resultam numa avaliação de risco superior comparativamente a modelos de volatilidade da família GARCH. Serão assim utilizadas medidas para quantificar o risco de mercado como o Value at Risk (VaR) e o Expected Shortfall (ES), numa análise comparativa de diferentes modelos aplicada ao mercado de energia. Espera-se que os modelos não-estacionários de volatilidade tenham um melhor desempenho do que os modelos que não permitem oscilações de longo prazo na volatilidade. O uso de comparações entre diferentes modelos permite melhorar os resultados obtidos, uma vez que existe a possibilidade de estudar uma maior quantidade de informação.

O comércio de commodities é conhecido como tendo uma elevada incerteza em relação ao preço de mercado, o que torna assim a previsão dos preços um ponto importante para todos os intervenientes neste mercado. Para os investidores, os modelos de previsão de preços são cruciais para tomar decisões no que toca à exposição da sua carteira relativamente ao mercado, visto que o mercado futuro de commodities é bastante utilizado para diversificar carteiras de investimento.

Podemos afirmar então que, qualquer variação no preço das commodities, afeta as economias de todos os países, daí a importância de conhecer o preço futuro para evitar estas perdas.

Atualmente, sendo cada vez mais necessário gerir riscos financeiros e a previsão de riscos desempenha um papel fundamental no setor financeiro, então, sendo a base da investigação avaliar o desempenho da previsão de densidade das medidas de risco do mercado, como o Value at Risk (VaR) e o Expected Shortfall (ES), aplicados a *commodity prices* dos mercados de energia, o objetivo principal é analisar e responder à questão a que me propus. O estudo será baseado em modelos de volatilidade GARCH, e medidas de avaliação dos riscos dos preços das commodities como o VaR e o ES, sendo o estudo realizado com base em comparações entre diferentes modelos, com o intuito de entender se os modelos com mudanças na volatilidade nos remetem para uma avaliação de risco mais elevada.

O risco de commodities é resultante do risco implícito na mudança dos preços das commodities e da sua volatilidade. A volatilidade é um dos conceitos mais importantes no setor financeiro, é medida pelo desvio padrão, e é usada frequentemente como uma medida bruta do risco total de ativos financeiros. Muitos modelos VaR para medir o risco de mercado solicitam a estimativa ou previsão de um parâmetro de volatilidade. Aqui, o estudo através de modelos GARCH é devido ao facto de estes permitirem modelar a volatilidade de uma série ao longo do tempo.

Esta dissertação de mestrado é desenvolvida com base nos dados históricos da gasolina, do gás natural, do petróleo, do petróleo de aquecimento, do querosene e finalmente, do propano, na seguinte estrutura: no capítulo 1 será apresentada uma revisão de literatura onde serão apresentadas as contribuições científicas e uma breve introdução das medidas de risco de mercado mais relevantes neste tema de investigação. O capítulo 2 apresenta a especificação da metodologia econométrica a aplicar na análise empírica, apresentando os modelos e identificando as variáveis e métodos considerados na aplicação empírica. No capítulo 3 será apresentada uma análise descritiva dos dados, incluindo o estudo de quatro modelos do tipo GARCH e ainda a análise do Value at Risk como medida de avaliação do risco dos preços das energias em estudo. Finalmente, serão apresentadas algumas considerações finais.

1. Revisão de literatura

Na presente secção é apresentada a literatura que vai de encontro ao tema que está a ser abordado. Serão então explorados os conceitos e as problemáticas relacionados com esta temática, enquadrando cada um desses conceitos com a literatura existente.

Dada a crescente necessidade de gerir riscos financeiros, a previsão de riscos desempenha um papel fundamental no setor bancário e financeiro.

Como referido anteriormente, as medidas de risco de mercado aqui abordadas serão o VaR e ES. O VaR é uma medida probabilística de um intervalo de valores que um ativo ou carteira de ativos de uma empresa pode perder devido à volatilidade do mercado. Dado um nível de confiança α , o VaR é a percentagem α da distribuição de retorno da carteira. O ES é uma estatística usada para quantificar o risco de uma carteira. Dado um certo nível de confiança, esta medida representa a perda esperada quando é maior que o valor do VaR calculado com esse nível de confiança. Assim como no VaR, o ES apresenta dois parâmetros de cálculo, o horizonte de tempo (T) e o nível de confiança (α), sendo representado pela perda esperada durante o período (T), sabendo que a perda está condicionada a ser maior que a α -ésima percentagem da distribuição de perdas.

A literatura existente sobre formação dos preços no mercado de energia é bastante abrangente. Enquanto alguns estudos se centram na modelização estatística e matemática das suas propriedades estocásticas, outros aplicam modelos económicos de equilíbrio das funções oferta e procura. Neste estudo debruçamo-nos sobre a análise das causas de volatilidade presente no preço do mercado de energias, com o objetivo de poder definir modelos que melhor permitam a valoração de ativos derivados do mercado de energia.

Dada a complexidade da série de preços do mercado de energias, é difícil alcançar um modelo de comportamento estocástico em tempo contínuo que capte de modo útil a dinâmica da variável implícita e permita quantificar ativos derivados de forma precisa. A análise da série de preços e da sua volatilidade realizada numa perspetiva de tempo, apresenta a vantagem de ser mais flexível e realista, o que possibilita uma modelização no tempo do comportamento observado do preço e a identificação das principais características e fatores que determinam a sua dinâmica e volatilidade no período sob consideração.

Atualmente há diversos modelos de previsão que incluem a importância da volatilidade nos seus parâmetros. Alguns deles consideram a volatilidade como constante ao longo do tempo (modelos ARIMA), enquanto outros consideram-na como uma variável correlacionada aos seus valores passados (modelos GARCH).

A especificação do processo de volatilidade condicional é a chave entre vários componentes de qualquer gestão de risco, especialmente para horizontes curtos (McNeil, Frey e Embrechts, 2015). Contribuições científicas acerca da utilização de modelos de séries temporais para modelar a volatilidade proliferaram desde o modelo ARCH proposto por Engle (1982) e a sua generalização, por Bollerslev (1986) e a partir daí, múltiplas extensões do modelo GARCH foram propostas por vários autores.

Um modelo de risco apropriado deve ser capaz de acomodar as propriedades dos retornos financeiros. Danielsson (2011) refere-se aos modelos de volatilidade de regime único como parte da culpa da grande crise financeira ser deles: *“(...) o processo estocástico que governa os preços de mercado é muito diferente durante os tempos de stress comparado aos tempos normais. Precisamos de modelos diferentes durante a crise e não-crise, e é preciso cuidado ao desenhar conclusões de dados de não-crise sobre o que acontece em crise, e vice-versa”*.

O modelo paramétrico de heteroscedasticidade condicional mais popular é o modelo GARCH, introduzido por Bollerslev (1986). Uma alternativa paramétrica a este modelo de escala de localização, é vincular uma estrutura do tipo GARCH a uma mistura discreta de distribuições normais, denominado de modelo MixN(n,g) (Kuester et al. 2006). É possível que ocorram ocasionalmente saltos no nível de volatilidade que podem ser capturados por uma componente que tenha uma elevada variância e constante, sendo assim este um modelo que produz pouca perda de qualidade do ajuste na amostra e maior capacidade de previsão, como argumentam Haas, Mittnik e Paoletta (2004).

Engle e Manganelli (2004) formulam a abordagem de VaR condicionada, denominada de CAViaR, que é favorável à suposição de que as rendibilidades contêm informações suficientes para a previsão. Todos os modelos incondicionais produzem violações VaR agrupadas. No que diz respeito aos modelos VaR condicionais, estes remetem-nos para previsões VaR muito mais voláteis.

O modelo Extreme Value Theory de Swarch (EVT-SWARCH) proposto por McNeil e Frey (2000), exhibe os recursos necessários para medir a volatilidade de uma série de retornos financeiros e para enfrentar a não normalidade devido a mudanças estruturais, podendo ser uma medida alternativa do

risco de cauda. Segundo McNeil e Frey (2000), o cálculo de estimativas VaR usando o modelo EVT condicional através do modelo GARCH foi com o propósito de fazer comparações entre modelos. Akaike (1974) propôs uma regra para escolher entre diferentes modelos com diferentes números de parâmetros. De acordo com o critério de Akaike e a função de máxima verossimilhança, o modelo EVT-SWARCH supera o modelo EVT-GARCH, fornecendo valores mais altos entre todos os índices no período da amostra.

Os testes dentro da amostra, medem a qualidade de cada modelo no ajuste dos dados. Os testes fora da amostra, atuando como backtest, comparam o retorno real com as previsões diárias do VaR ao longo do período da amostra, com o intuito de avaliar o desempenho de cada modelo na previsão de estimativas VaR. Dentro da amostra, os parâmetros são estimados pelo método da máxima verossimilhança usando dados da amostra; fora da amostra (backtesting), os modelos são testados novamente para examinar quão bem os modelos preveem perdas extremas no futuro, avaliando assim o desempenho de cada modelo na previsão VaR.

No que toca ao modelo SWARCH, podemos afirmar que pode controlar melhor a persistência de volatilidade via cadeia de Markov, e consegue verificar o ponto das mudanças estruturais, sendo que o desempenho do modelo SWARCH condicional nas previsões VaR, melhora à medida que os níveis de confiança aumentam. Já o modelo GARCH, que possui configurações de volatilidade linear é, no entanto, menos sensível à mudança de retorno de volatilidade devido a mudanças estruturais (Lin e Li (2004)). Os testes de cobertura incondicional medem o desempenho dos modelos VaR com base na proporção de falhas na amostra, enquanto os testes de cobertura condicional testam os valores de cobertura incondicional como a independência das séries. Normalmente, podemos assumir que os modelos condicionais baseados em EVT, especialmente o modelo EVT-GARCH, têm um desempenho melhor que o incondicional; sendo que as estimativas diárias do VaR pelos modelos condicionais de EVT são ajustadas com a mudança de volatilidade. É concluído assim, com base no estudo de Bystrom (2004) que, ambos os modelos condicionais podem capturar melhor as mudanças atuais do mercado do que os modelos incondicionais. Concluindo, ambos os modelos EVT-GARCH e SWARCH superam os outros modelos no que toca à captura da dinâmica da condição de mercado.

Segundo González-Pedraz et al. (2014), tanto análises dentro como fora da amostra mostram a importância de caudas pesadas e assimetria positiva na distribuição de fatores de risco das energias. O autor analisa os riscos do preço da energia numa perspectiva de um sistema multivariado, procurando incluir todos os recursos da energia nos mercados desregulados, como a grande volatilidade, picos de

preços, correlação variável no tempo, dependência nos extremos e padrões de reversão da média, e para isso considera-se uma especificação econométrica com condições condicionais, volatilidades e correlações variáveis no tempo, nas quais o vetor segue uma distribuição hiperbólica generalizada (GH), o que permite assim analisar o risco de ativos de energia.

González-Pedraz et al. (2014) para modelar as características do vetor dos fatores de risco da energia e aperfeiçoá-lo, propõe uma especificação econométrica flexível com média, variância e correlação condicionais, variáveis no tempo, que acomodam a presença de retornos em séries de dependência, heteroscedasticidade e efeitos de alavancagem.

Como dito anteriormente o modelo paramétrico de heteroscedasticidade condicional mais popular é o modelo GARCH, introduzido por Bollerslev (1986). Mais à frente a volatilidade das energias a ser estudadas será analisada com base no modelo standard, designado de S-GARCH, no modelo E-GARCH, GJR-GARCH e por fim T-GARCH.

O modelo E-GARCH foi criado de forma a ultrapassar alguns dos pontos fracos dos modelos GARCH (Nelson, 1991), designado de modelo exponencial tinha o objetivo de ultrapassar o problema maior dos modelos GARCH, que exigiam muitas restrições nos seus parâmetros de forma a garantir a positividade da variância condicionada, ou seja, tinha como objetivo principal capturar assimetrias das séries financeiras, o que podemos designar de “efeito de alavancagem”. Assim sendo, o modelo E-GARCH permite capturar assimetrias e permite que alguns coeficientes sejam negativos, tendo em vista a especificação em log.

Tratando-se agora do modelo GJR-GARCH, este foi criado com o intuito de tratar a ocorrência do efeito de alavancagem, assim, Glosten, Jagannathan e Runkle (1993) desenvolveram o modelo em questão, que captura o efeito de alavancagem caso a variável dummy seja igual a 1, que acontece quando o retorno é negativo.

Por fim, o modelo T-GARCH trata-se da análise da heteroscedasticidade condicional auto-regressivo limiar generalizada, foi criado por Jean Michel Zakoian (1994) e podemos afirmar que este modelo é semelhante ao falado anteriormente, o GJR-GARCH, sabendo que a especificação destes se refere ao desvio padrão condicional ao invés da variância condicional.

2. Metodologia econométrica

Sendo o objetivo desta dissertação a previsão do risco no mercado de commodities de energia, ou seja, avaliar o risco dos preços nas energias, concentramo-nos em modelos de avaliação de risco, como o VaR e o ES.

O conceito de Value at Risk (VaR) é amplamente utilizado no setor financeiro para exposições a riscos para fins regulatórios e estabelecer restrições comerciais nas decisões de investimento, como é argumentado pelo autor González-Pedraz et al. (2014). Kuester et al. (2006) define VaR como sendo uma medida de risco financeiro, definida como a perda máxima possível, em valor, que uma carteira de ativos pode gerar num determinado horizonte de tempo e com um nível de confiança pré-estabelecido. Ou seja, podemos afirmar que o VaR é uma medida de probabilidade de um intervalo de valores que permite conhecer as perdas, devido à volatilidade dum mercado, a que um ativo ou carteira de ativos está sujeito. Esta volatilidade inclui efeitos como mudanças das taxas de juro, taxas de câmbios, preços de mercadorias e outros riscos do mercado. Na prática, a previsão desta medida de risco é dificultada pelo facto de as rendibilidades financeiras exibirem propriedades estatísticas não padronizadas, não sendo distribuídas independente e identicamente (iid) e, além disso, não sendo normalmente distribuídas. Refletem-se assim em três factos, sendo eles a volatilidade, a curtose e a assimetria leve dos retornos.

A medida de risco de mercado Expected Shortfall (ES) produz benefícios adicionais ao VaR, podendo ser denominada de Conditional Value At Risk (CVaR), Average Value At Risk (AVaR) ou Expected Tail Loss (ETL). É uma estatística usada para quantificar o risco de uma carteira. Segundo González-Pedraz et al. (2014), as medidas de risco ES lidam bem com os problemas que são encontrados no VaR, e descrevem melhor o risco de cauda. Sendo o ES definido como a perda esperada, condicional na perda que excede o VaR num determinado horizonte, isto é, a perda média da carteira na $\alpha\%$ nos piores casos.

De um modo geral, se um investimento mostrou estabilidade ao longo do tempo, o VaR pode ser suficiente para gerir os riscos numa carteira de investimento. No entanto, quanto menos estável o investimento, maior a probabilidade de o VaR não fornecer uma abordagem completa dos riscos. O ES tenta abordar as problemáticas do modelo VaR, que é uma técnica estatística usada para medir o nível de risco financeiro dentro de uma empresa ou carteira de investimentos num período

específico. Embora o VaR represente uma perda no pior caso associada a uma probabilidade e um horizonte de tempo, o ES representa a perda esperada se esse limite do pior cenário for ultrapassado.

Relativamente a abordagens estatísticas do VaR, segundo Kuester et al. (2006), no que toca à escala de localização, a previsão do modelo VaR do período h com base em informações até ao momento t , é

$$\widehat{VaR}_{t+h} = -(\hat{\mu}_{t+h} + \hat{\sigma}_{t+h} Q_{\lambda}(z)) \quad (1)$$

onde $Q_{\lambda}(z)$ é o quantil- λ implícito em f_z , que é a localização-zero. Modelos paramétricos homocedásticos permitem uma média condicional variável no tempo, possivelmente capturada por um processo ARMA(p,q), ou seja,

$$\mu_t = a_0 + \sum_{i=1}^p a_i r_{t-i} + \sum_{j=1}^q b_j e_{t-j} \quad (2)$$

com $\sigma_t \equiv \sigma$, $t=1, \dots, T$ e onde r_{t-i} é o retorno dos ativos no portfólio no período t , e e_{t-j} é uma série temporal. Os modelos paramétricos de heteroscedasticidade condicional, que permitem que o parâmetro de escala seja uma função de informações passadas, são frequentemente usados. O mais popular é o modelo GARCH(r,s),

$$\sigma_t^2 = c_0 + \sum_{i=1}^r c_i e_{t-i}^2 + \sum_{j=1}^s d_j \sigma_{t-j}^2 \quad (3)$$

introduzido por Bollerslev (1986), com $\sigma_t \equiv \sigma$, $t=1, \dots, T$ e onde e_{t-i}^2 é uma série temporal e σ_{t-j}^2 é a variância.

Relativamente a especificações CAViaR, estas incluem VaR_{t-1} como sendo a variável explicativa em x_t , para se adaptar a séries de volatilidade e média. Uma função de r_{t-1} também é incluída, para vincular o quantil condicional a retornar as inovações, sendo o modelo CAViaR dado por,

$$VaR_t = VaR_{t-1} + \beta [I(r_{t-1} \leq -VaR_{t-1}) - \lambda] \quad (4)$$

Podemos assim concluir que, como normalmente na gestão de riscos o $\lambda \leq 0,05$, o valor de VaR_t aumenta bruscamente quando ocorre uma violação, e diminui lentamente caso contrário.

Hamilton e Susmel (1994) afirmaram que, numa parametrização SWARCH, o processo de séries temporais é influenciado pelo regime não observado, S_t , daí a razão pela qual optam pela utilização do modelo em questão. Seja Y_t expresso como,

$$Y_t = \eta_{S_t} + \lambda_{S_t} Y_{t-1} + \omega_t \quad (5)$$

onde $\omega_t \sim iid N(0, \sigma^2)$ e S_t é independente de ω_t , para todo o t . A estimativa do VaR usando o modelo EVT condicional por meio do modelo SWARCH pode ser computada como,

$$VaR_{p,sw} = \mathcal{R}_{n+1} + \frac{\delta_n}{\xi_n} \left[\left(\frac{1-p}{n/N} \right)^{-\xi_n} - 1 \right] \quad (6)$$

onde \mathcal{R}_{n+1} são os resíduos tidos como limite aleatório para estimar a quantidade excedente do limite nos primeiros n resíduos.

Seguindo o modelo de Lin e Shen (2006) para estimar o VaR usando a distribuição de t-Student, sendo que esta distribuição gera valores mais extremos do que uma distribuição normal, juntamente com um modelo GARCH temos que, em $p\%$ da distribuição de t-Student, a estimativa do VaR é expressa como,

$$VaR_{p,sat} = -t_{p,v} \sigma \sqrt{\frac{3 + \kappa}{3 + 2\kappa}} \quad (7)$$

onde $t_{p,v}$ representa o correspondente valor- t crítico e κ é o excesso de curtose.

Considerando as seis commodities estudadas, seja $F_{i,t}$ o preço de ajuste no momento t , de um contrato de futuro de energia i . Assume-se que o valor W_t de um determinado portfólio de energia é determinado por uma combinação linear de futuros $F_{i,t}$ de modo que,

$$W_t = \sum_{i=1}^6 q_{i,t} F_{i,t} = \sum_{i=1}^{36} w_{i,t} = w_t \iota_6 \quad (8)$$

onde as quantidades $q_{i,t}$ definem o tamanho e o sinal da exposição para commodities de energia i , $w_t = (w_{1,t}, \dots, w_{6,t})' (q_{1,t} F_{1,t}, \dots, q_{6,t} F_{6,t})'$ define o peso do portfólio em dólares de cada commodity de energia e ι_6 é um vetor 6×1 de uns. Assim, o retorno do período h (em dólares) num portfólio de energia no momento t , é dado por,

$$\Delta W_t(h) = W_t - W_{t-h} = R_t(h) W_{t-h} = w'_{t-h} (\exp(r_t(h)) - \iota_6) \quad (9)$$

onde $R_t(h)$ é o retorno líquido do portfólio no período- h , $r_t(h) = \sum_{k=0}^{h-1} r_{t-k}$ é um vetor 6×1 dos retornos do log no período- h e r_t é o vetor de rendibilidades de log num período no tempo t , sendo que os log-retornos de energia $r_{i,t}$ constituem o vetor de fatores de risco. Assim sendo, o modelo

multivariado de fatores de risco aqui presente representa, o comportamento conjunto das seis commodities.

Consideradas as duas medidas de risco aqui estudadas, VaR e ES, relativamente ao VaR, sendo considerado o quantil- α da distribuição condicional das alterações do portfólio $\Delta W_t(h)$, sendo α o nível de confiança e h o horizonte,

$$P(\Delta W_t(h) \leq VaR_t(\alpha, h) | \mathcal{F}_{t-1}) = \alpha. \quad (10)$$

Já o ES é definido como a perda esperada condicional, na perda que excede o VaR num determinado horizonte h ,

$$ES_t(\alpha, h) = \mathbb{E}[(\Delta W_t(h) | \Delta W_t(h) \leq VaR_t(\alpha, h)) | \mathcal{F}_{t-1}]. \quad (11)$$

Finalmente, para a estudar a volatilidade, serão estimados quatro modelos, o standard, S-GARCH, e três modelos do tipo GARCH, entre eles, E-GARCH, GJR-GARCH E T-GARCH.

O modelo proposto por Bollerslev (1986) designado por GARCH(1,1) ou S-GARCH(1,1) é definido por:

$$r_t = \sqrt{h_t} \varepsilon_t \quad (12)$$

$$h_t = \alpha_0 + \alpha_1 r_{t-1}^2 + \beta_1 h_{t-1}$$

em que ε_t são variáveis independentes e identicamente distribuídas com média zero e $\alpha_0 > 0$, e geralmente é suposto que os erros ε_t sigam uma distribuição normal ou t-Student.

O modelo exponencial E-GARCH(1,1), proposto por Nelson (1991) é dado por:

$$r_t = \sqrt{h_t} \varepsilon_t \quad (13)$$

$$\log(h_t) = \alpha_0 + \alpha_1 \frac{|\varepsilon_{t-1}| + \gamma_1 \varepsilon_{t-1}}{h_{t-1}} + \beta_1 \ln(h_{t-1})$$

onde observamos que quando ε_{t-1} é positivo, o efeito total de ε_{t-1} é $(1 + \gamma_1)|\varepsilon_{t-1}|$. Quando ε_{t-1} é negativo, o efeito total é de $(1 - \gamma_1)|\varepsilon_{t-1}|$. Assim sendo, para que os retornos negativos tenham um maior impacto na volatilidade espera-se que $\gamma_1 < 0$. Podemos assim concluir que esta assimetria responde mais rapidamente a retornos negativos do que positivos, aqui representado o efeito de alavancagem.

O modelo GJR-GARCH(1,1) é dado por:

$$R_t = \sigma_t \varepsilon_t, \sigma_t^2 = \alpha_0 + (\alpha_1 + \gamma_1 N_{t-1}) R_{t-1}^2 + \beta_1 \sigma_{t-1}^2 \quad (14)$$

onde N_{t-1} é uma variável indicadora que assume valor um se $R_{t-1} < 0$ e zero caso contrário. Assim, um R_{t-1} positivo contribui com $\alpha_1 R_{t-1}^2$ para a volatilidade (σ_t^2), enquanto um R_{t-1} negativo contribui com $(\alpha_1 + \gamma_1) R_{t-1}^2$ para a volatilidade. Então, considerando o parâmetro $\gamma_1 > 0$, o modelo usa zero como limite para separar o impacto de choques anteriores.

Por fim, o modelo T-GARCH, proposto por Zakoian (1994) é um modelo não linear, neste caso a volatilidade é dada por:

$$h_t = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \gamma_1 S_{t-1} \varepsilon_{t-1}^2 + \beta_1 h_{t-1} \quad (15)$$

em que,

$$S_{t-1} = \begin{cases} 1, & \text{se } \varepsilon_{t-1} < 0 \\ 0, & \text{se } \varepsilon_{t-1} \geq 0 \end{cases} \quad (16)$$

Se $\gamma_1 \neq 0$, concluímos assimetria, sabendo que ε_{t-1}^2 tem diferentes efeitos na volatilidade, dependendo se se trata de um ε_{t-1} positivo ou negativo.

3. Análise de dados

Para realizar estudos relacionados com a previsão do risco do mercado das commodities da energia, irão ser analisados dados de seis energias, como dito anteriormente, que serão a gasolina, gás natural, petróleo, petróleo de aquecimento, querosene e propano. Neste caso particular, para o estudo que se pretende desenvolver será construída uma base de dados constituída por dados referentes ao maior número de intervalos de tempo possível, para comparar a eficiência da previsão do risco nas diferentes energias em questão, estes dados foram retirados do organismo oficial de Estatística do Departamento de Energia dos EUA, conhecido por Energy Information Administration (EIA). Relativamente ao espaço temporal da amostra, para melhores resultados, serão analisados os dados numa subamostra 1 com 30 anos de estudo, a subamostra 2 com 3 anos e a amostra completa, com dados históricos diários retirados do organismo oficial de Estatística do Departamento de Energia dos EUA conhecido por Energy Information Administration (EIA), onde poderemos ver os momentos em que houve um maior impacto mundial em cada uma das commodities aqui estudadas, e tentar entender o porquê desse acontecimento, baseando-nos também nas estatísticas descritivas sendo que estas se dividem em medidas de localização, de dispersão e de forma, estudando modelos do tipo GARCH e por fim tendo em consideração também resultados de estudo do VaR. É de interesse selecionar um horizonte temporal sob o qual existam bases fidedignas e o mais completas possível.

Analisar séries temporais leva-nos a identificar padrões não aleatórios na série temporal de uma variável de interesse, sendo que esta avaliação que é feita a dados passados, permite de certa forma prever acontecimentos futuros.

3.1 - Análise das rendibilidades da Gasolina

3.1.1 – Estatísticas descritivas das rendibilidades da Gasolina

Tabela 1 – Gasolina - Amostra Completa

AMOSTRA COMPLETA				
8384 observações desde 3 de Junho 1986, a 14 de Setembro 2020	Retornos-log		Retornos ao quadrado	
Média	0		1.41	
Mediana	0.06		0.4	
Desvio Padrão	1.19		5.15	
Mínimo	-13.05		0	
Máximo	10.21		170.41	
Curtose	14.3045		509.1714	
Assimetria	-0.4677985		19.23058	
Testes de hipótese	Estatística de teste	p-value	Estatística de teste	p-value
Jarque Bera	4.49E+04	<2.2e-16	9.00E+07	<2.2e-16
ARCH(4)	1.09E+03	0.00E+00	2.10E+02	0.00E+00
ADF	-6.41E+01	<2.2e-16	-4.48E+01	<2.2e-16
Ljung Box (lag=10)	28.021	1.79E-03	2252.3	<2.2e-16
Ljung Box (lag=20)	70.48	1.52E-07	2723	<2.2e-16
AR(1)				
Ljung Box (lag=10)	11.637	3.10E-01	2250.5	<2.2e-16
Ljung Box (lag=20)	18.689	5.42E-01	2728.4	<2.2e-16

Da análise das estatísticas descritivas podemos concluir que os valores da média e mediana são relativamente próximos, e são estas medidas de localização caracterizadas por acompanharem as mudanças de localização dos dados, sendo estes próximos, sugerem uma certa simetria dos dados, uma vez que a simetria significa que a média e a mediana coincidem. O desvio padrão calculado é baixo, o que nos indica que os valores são estáveis, ou seja, existe regularidade relativamente à média estimada. Os coeficientes de curtose e assimetria são medidas de forma que permitem distinguir distribuições cujas propriedades sejam iguais. Portanto, uma distribuição simétrica é caracterizada por um coeficiente de curtose igual a 3. Se o coeficiente de curtose é superior a 3, é superior ao da distribuição normal, que é o que acontece com a gasolina; relativamente à assimetria, valores próximos de zero sugerem alguma simetria, o que concluímos neste caso.

Finalmente, os testes Ljung-Box, que são ferramentas para testar o ajuste de um modelo de série temporal, ou seja, são aplicados aos resíduos de uma série temporal, após o ajustamento de um modelo e quanto menor esse valor, melhor o ajustamento do modelo escolhido, daí depois da eliminação da autocorrelação com AR(1), os valores terem descido tão significativamente.

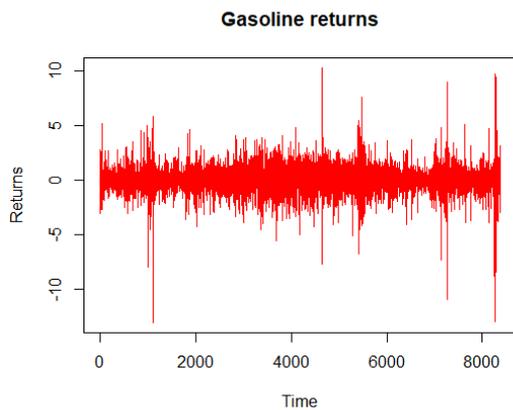


Gráfico 1 - Retornos da Gasolina entre 3 de junho de 1986 e 14 de setembro de 2020

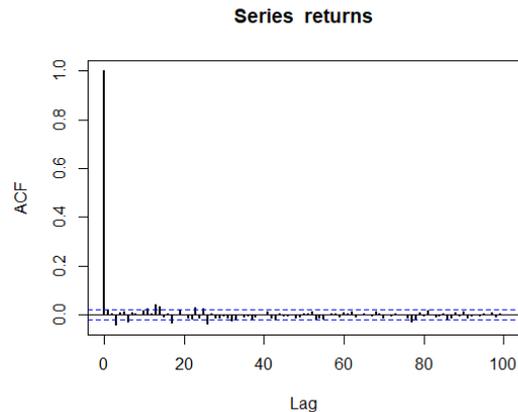


Gráfico 2 - Autocorrelação da série de retornos

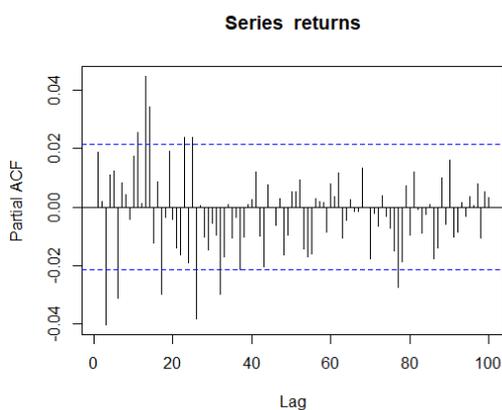


Gráfico 3 - Autocorrelação parcial da série de retornos

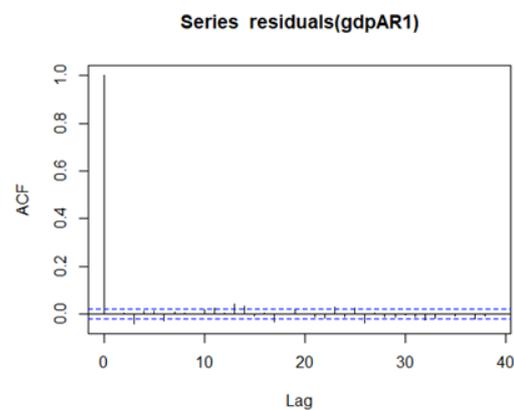


Gráfico 4 - Autocorrelação da série de retornos, pós eliminação de autocorrelação

No que toca à energia Gasolina, e tendo em conta que estamos a analisar três períodos de tempo, podemos falar das rendibilidades da energia, sendo que na subamostra 1 (Anexo 1-gráfico 49) os valores são mais uniformes do que na subamostra 2 (Anexo 1-gráfico 54), neste último caso só é visível um momento em que os valores subiram significativamente ao longo do estudo.

Relativamente à autocorrelação, esta é sempre visível, ainda que quase nula, sendo que analisamos a autocorrelação, a autocorrelação parcial e ainda a autocorrelação depois de ser realizado um teste ARIMA para eliminar a autocorrelação inicial (Anexo 1-gráficos 50, 51, 53 e 55, 56 e 58).

Pelos gráficos dos preços na subamostra 1 e na subamostra 2 (Anexo 1-gráficos 88 e 93), quase que nos é possível afirmar que são inversos, visto que na subamostra 1 temos duas subidas bruscas dos preços e na subamostra 2 temos o contrário, duas descidas acentuadas.

3.1.2 – Estimação dos modelos de volatilidade do tipo GARCH

Tabela 2 - Resultados da estimação dos modelos do tipo GARCH na Gasolina

		Resultados da estimação dos modelos do tipo GARCH											
		mu	omega	alpha 1	beta 1	gamma 1	Modelo de volatilidade	Distribuição	Log-likelihood	AIC	BIC	SIC	HQIC
IN SAMPLE	Modelo 1	0.009150 [0.011]	0.024329 [0.004]	0.101175 [0.008]	0.884132 [0.009]		S-GARCH	Normal	-10971.02	2.938	2.941	2.938	2.939
	Modelo 2	0.010826 [0.011]	0.007013 [0.002]	0.012187 [0.007]	0.977733 [0.004]	0.213599 [0.014]	E-GARCH	Normal	-10957.07	2.934	2.939	2.934	2.936
	Modelo 3	0.011616 [0.011]	0.024132 [0.004]	0.106372 [0.010]	0.88496 [0.009]	-0.011707 [0.011]	GJR-GARCH	Normal	-10970.42	2.938	2.942	2.938	2.939
	Modelo 4	0.012238 [0.011]	0.014476 [0.006]	0.081682 [0.016]	0.923677 [0.018]	0.019556 [0.046]	T-GARCH	Normal	-10853.25	2.907	2.912	2.907	2.909
OUT OF SAMPLE	Modelo 1	0.113080 [0.036]	0.053456 [0.017]	0.169857 [0.060]	0.796308 [0.049]		S-GARCH	Normal	-1305.08	2.871	2.892	2.871	2.879
	Modelo 2	0.004051 [0.030]	0.015594 [0.007]	-0.045336 [0.021]	0.97658 [0.010]	0.304793 [0.043]	E-GARCH	Normal	-1305.79	2.875	2.901	2.875	2.885
	Modelo 3	-0.000637 [0.031]	0.054697 [0.015]	0.130605 [0.031]	0.797262 [0.031]	0.069484 [0.040]	GJR-GARCH	Normal	-1303.53	2.870	2.896	2.870	2.880
	Modelo 4	0.023495 [0.025]	0.026425 [0.014]	0.093945 [0.043]	0.905630 [0.040]	0.338775 [0.258]	T-GARCH	Normal	-1275.18	2.810	2.841	2.810	2.822
AMOSTRA COMPLETA	Modelo 1	0.008757 [0.011]	0.029273 [0.007]	0.111574 [0.015]	0.870577 [0.017]		S-GARCH	Normal	-12280.91	2.931	2.934	2.931	2.932
	Modelo 2	0.007961 [0.010]	0.008406 [0.002]	0.001473 [0.007]	0.97659 [0.004]	0.233014 [0.013]	E-GARCH	Normal	-12271.20	2.929	2.933	2.929	2.930
	Modelo 3	0.009012 [0.010]	0.02926 [0.004]	0.112177 [0.009]	0.870614 [0.009]	-0.001241 [0.011]	GJR-GARCH	Normal	-12280.90	2.931	2.935	2.931	2.932
	Modelo 4	0.013221 [0.010]	0.017501 [0.016]	0.088194 [0.041]	0.091623 [0.046]	0.062120 [0.071]	T-GARCH	Normal	-12136.18	2.897	2.902	2.897	2.898

(coeficiente entre parênteses é o erro padrão robusto)

Ao analisar a tabela 2, concluímos que todos os coeficientes são estatisticamente significativos a 1%.

O modelo S-GARCH na Gasolina, nos três períodos de tempo a ser estudados, apresenta os valores todos positivos, daqui tiramos que existem períodos de volatilidade altos que são seguidos de períodos de volatilidade baixa, ou seja, os clusters de volatilidade. Nos períodos da subamostra 1 (Anexo 1) e na amostra completa tendo em conta o coeficiente gamma1, estamos perante valores positivos em E-GARCH e negativos no modelo GJR-GARCH, já na subamostra 2 (Anexo 1) o mesmo acontece no coeficiente mu e em alpha1 mas em sentido contrário, ou seja, E-GARCH com valor negativo e GJR-GARCH com valor positivo, o que nos permite tirar uma conclusão de que estamos perante existência de efeitos assimétricos na volatilidade, o que nos leva afirmar que o efeito das más notícias prevalece sobre o efeito das boas notícias.

Focando agora a atenção nos resultados do Log-likelihood, o que podemos concluir é que os valores mais baixos são resultantes do modelo T-GARCH e daí advém os valores mais baixos também em AIC, BIC, SIC e HQIC. Tudo isto nos permite eleger o modelo T-GARCH como o mais indicado para estudar a volatilidade da Gasolina, nos três períodos de tempo. Analisando os gráficos de volatilidade apresentados a seguir e no (Anexo 1-gráficos 59 a 62 e 63 a 66), temos ainda mais certezas de que este é o modelo do tipo GARCH mais indicado para estudar a volatilidade da energia em questão.

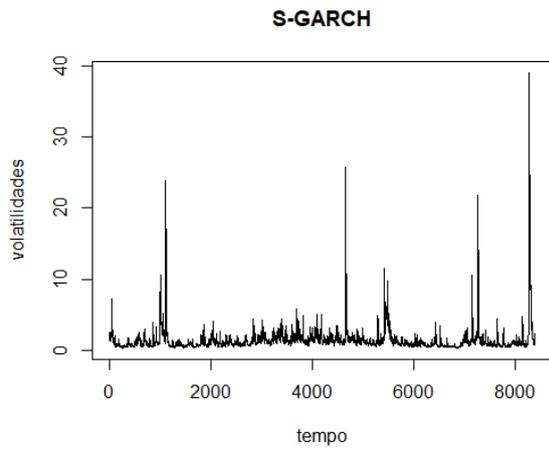


Gráfico 5 - Volatilidades da Gasolina no modelo S-GARCH

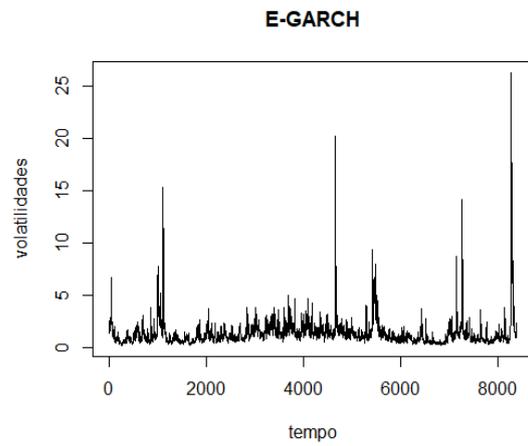


Gráfico 6 - Volatilidades da Gasolina no modelo E-GARCH

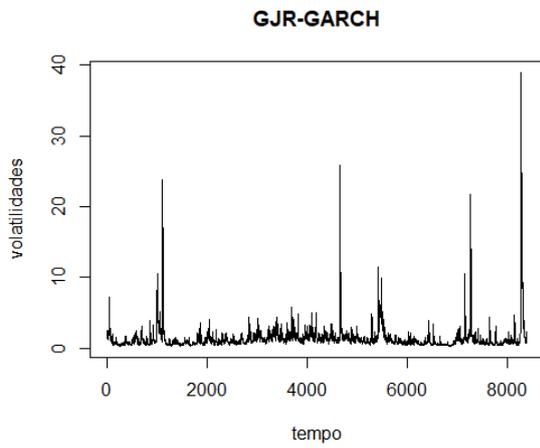


Gráfico 7 - Volatilidades da Gasolina no modelo GJR-GARCH

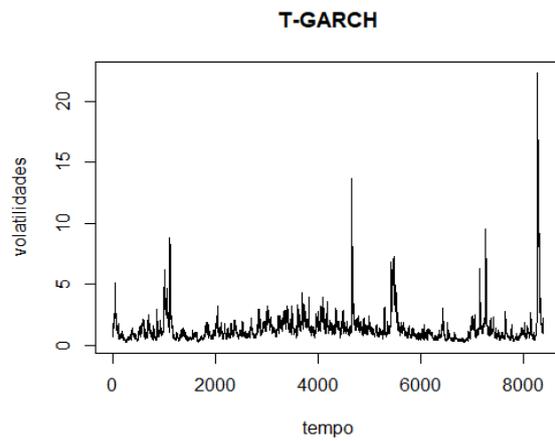


Gráfico 8 - Volatilidades da Gasolina no modelo T-GARCH

3.2 – Análise das rendibilidades do Gás Natural

3.2.1 – Estatísticas descritivas das rendibilidades do Gás Natural

Tabela 3 - Gás Natural - Amostra total

AMOSTRA COMPLETA				
5398 observações desde 8 de Janeiro 1997, a 15 de Setembro 2020	Retornos-log		Retornos ao quadrado	
Média	0		4.32	
Mediana	-0.04		0.92	
Desvio Padrão	2.08		20.32	
Mínimo	-24.68		0	
Máximo	25.04		627.21	
Curtose	23.1		459.6	
Assimetria	0.49		18.47	
Testes de hipótese	Estatística de teste	p-value	Estatística de teste	p-value
Jarque Bera	9.11E+04	<2.2e-16	4.72E+07	<2.2e-16
ARCH(4)	2.34E+03	0.00E+00	1.57E+03	0.00E+00
ADF	-6.21E+01	<2.2e-16	-2.80E+01	<2.2e-16
Ljung Box (lag=10)	212.33	<2.2e-16	2602.1	<2.2e-16
Ljung Box (lag=20)	227.36	<2.2e-16	2666.1	<2.2e-16
AR(1)				
Ljung Box (lag=10)	5.99	8.16E-01	2001.7	<2.2e-16
Ljung Box (lag=20)	28.36	1.01E-01	2080.8	<2.2e-16

Acerca das estatísticas descritivas, no que toca à média e à mediana terem valores relativamente próximos, podemos assim afirmar que existe uma certa simetria dos dados. O desvio padrão calculado é baixo e daí tiramos que os valores são estáveis e então existe regularidade relativamente à média estimada. Estamos também perante um coeficiente de curtose superior ao da distribuição normal e alguma simetria sugerida pelos valores desta serem próximos de zero.

Finalmente, os testes Ljung-Box confirmam a necessidade de eliminar a autocorrelação, visto que os outputs de AR(1) deste teste são bastante mais baixos, o que se traduz num melhor ajustamento do modelo quando aplicado aos resíduos da série temporal financeira em questão.

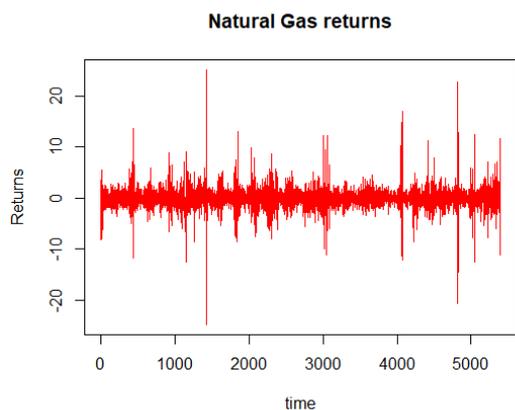


Gráfico 9 - Retornos do Gás Natural entre 8 de janeiro de 1997 e 15 de setembro de 2020

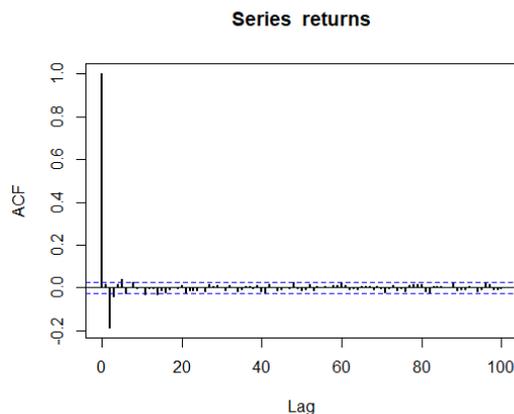


Gráfico 10 – Autocorrelação da série de retornos

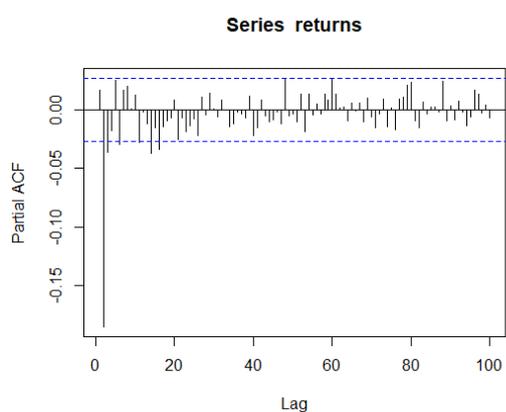


Gráfico 11 – Autocorrelação parcial da série de retornos

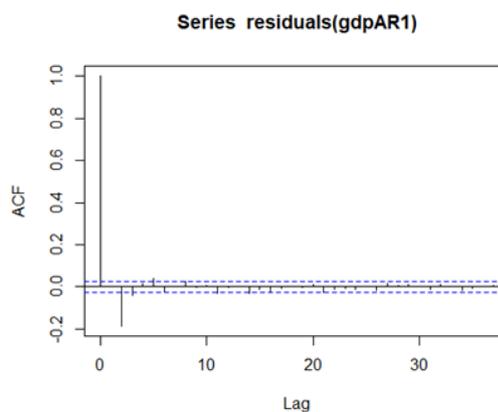


Gráfico 12 - Autocorrelação da série de retornos, pós eliminação de autocorrelação

Neste caso, em que estudamos o Gás Natural, relativamente ao estudo dos retornos das rendibilidades podemos afirmar que estes são mais abundantes na subamostra 1 (Anexo 2-gráfico 67).

O segundo gráfico apresentado trata da autocorrelação e comparando os resultados concluímos que na subamostra 2 (Anexo 2-gráfico 73) a autocorrelação é mais elevada, o que é comprovado também através dos gráficos da autocorrelação parcial (Anexo 2-gráfico 74), e consecutivamente o gráfico da autocorrelação da série de retornos após ser eliminada a autocorrelação inicial (Anexo 2-gráfico 76) comprova o mesmo.

Finalmente, relativamente aos gráficos dos preços da energia em questão temos que, na subamostra 1 (Anexo 2-gráfico 70) os preços têm uma tendência de subidas seguidas de descidas, com alguns picos, no entanto, na subamostra 2 (Anexo 2-gráfico 75) há uma tendência decrescente dos preços, sendo observadas três subidas e respetivas descidas que se destacam mais.

3.2.2 – Estimação dos modelos de volatilidade do tipo GARCH

Tabela 4 - Resultados da estimação dos modelos do tipo GARCH no Gás Natural

		Resultados da estimação dos modelos do tipo GARCH											
		mu	omega	alpha 1	beta 1	gamma 1	Modelo de volatilidade	Distribuição	Log-likelihood	AIC	BIC	SIC	HQIC
IN SAMPLE	Modelo 1	-0.005484 [0,020]	0.056821 [0,011]	0.153842 [0,012]	0.845158 [0,011]		S-GARCH	Normal	-8800.75	3.817	3.822	3.817	3.819
	Modelo 2	-0.008382 [0,02]	0.028412 [0,01]	0.000456 [0,023]	0.980321 [0,01]	0.284704 [0,023]	E-GARCH	Normal	-8773.89	3.805	3.812	3.805	3.808
	Modelo 3	-0.004787 [0,021]	0.056829 [0,011]	0.155007 [0,015]	0.845123 [0,011]	-0.002261 [0,017]	GJR-GARCH	Normal	-8800.74	3.817	3.824	3.817	3.819
	Modelo 4	-0.007405 [0,021]	0.051367 [0,011]	0.156057 [0,015]	0.849628 [0,011]	0.020335 [0,017]	T-GARCH	Normal	-8641.31	3.748	3.757	3.748	3.751
OUT OF SAMPLE	Modelo 1	-0.025341 [0,048]	0.403589 [0,109]	0.400844 [0,055]	0.558691 [0,052]		S-GARCH	Normal	-1551.44	3.968	3.992	3.968	3.977
	Modelo 2	0.052307 [0,049]	0.142432 [0,033]	0.07797 [0,038]	0.895742 [0,025]	0.57187 [0,057]	E-GARCH	Normal	-1543.61	3.951	3.980	3.950	3.962
	Modelo 3	0.0058 [0,053]	0.38367 [0,108]	0.45425 [0,073]	0.57832 [0,053]	-0.14413 [0,096]	GJR-GARCH	Normal	-1550.35	3.968	3.998	3.968	3.979
	Modelo 4	0.001086 [0,049]	0.149457 [0,071]	0.263351 [0,063]	0.725250 [0,0729]	-0.066022 [0,163]	T-GARCH	Normal	-1525.259	3.906	3.942	3.906	3.920
AMOSTRA COMPLETA	Modelo 1	-0.117140 [0,018]	0.086626 [0,016]	0.193629 [0,014]	0.805371 [0,014]		S-GARCH	Normal	-10378.67	3.847	3.852	3.847	3.849
	Modelo 2	0.00067 [0,019]	0.043195 [0,007]	0.014356 [0,01]	0.969845 [0,005]	0.339992 [0,019]	E-GARCH	Normal	-10344.71	3.835	3.841	3.835	3.837
	Modelo 3	-0.003112 [0,019]	0.085972 [0,016]	0.207519 [0,018]	0.806245 [0,014]	-0.029529 [0,019]	GJR-GARCH	Normal	-10377.43	3.847	3.853	3.847	3.849
	Modelo 4	-0.004866 [0,018]	0.063372 [0,017]	0.171638 [0,019]	0.832269 [0,022]	-0.001983 [0,061]	T-GARCH	Normal	-10173.64	3.772	3.779	3.772	3.774

(coeficiente entre parênteses é o erro padrão robusto)

Ao analisar a tabela 4, concluímos que todos os coeficientes são estatisticamente significativos a 1%.

Neste caso, podemos observar que o coeficiente um é sempre negativo no modelo S-GARCH, o que nos leva a concluir que não é tão impactante a existência de picos de volatilidade, ou seja, os clusters são menos abundantes no Gás Natural.

Na subamostra 1, na subamostra 2 (Anexo 2) e na amostra completa temos no modelo E-GARCH em gamma1 um valor positivo e em GJR-GARCH este mesmo coeficiente é negativo, o que nos permite concluir existência de efeitos assimétricos na volatilidade, ou seja, o efeito das más notícias é maior do que as boas.

Mais uma vez, os melhores resultados do Log-likelihood são os do modelo T-GARCH, em todos os três períodos de tempo a ser estudados. Consequentemente deparamo-nos com os valores mais baixos do AIC, BIC, SIC e HQIC também no modelo T-GARCH, daqui podemos então concluir que este é o mais indicado para estudar a volatilidade do Gás Natural, sendo a teoria fortalecida pelos gráficos apresentados a seguir e pelos gráficos do (Anexo 2-gráficos 77 a 80 e 81 a 84), onde vemos uma melhor performance do modelo T-GARCH.

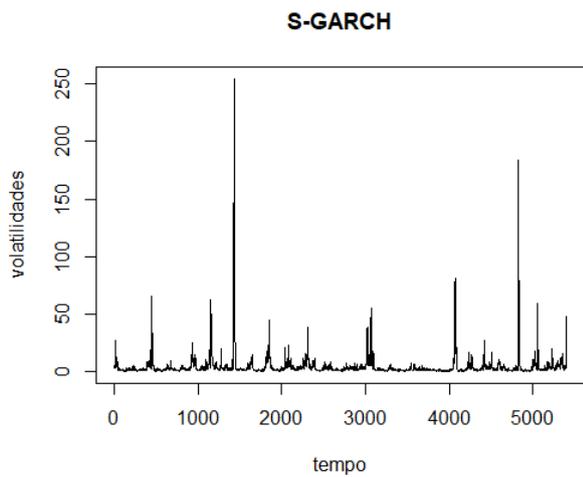


Gráfico 13 – Volatilidades do Gás Natural no modelo S-GARCH

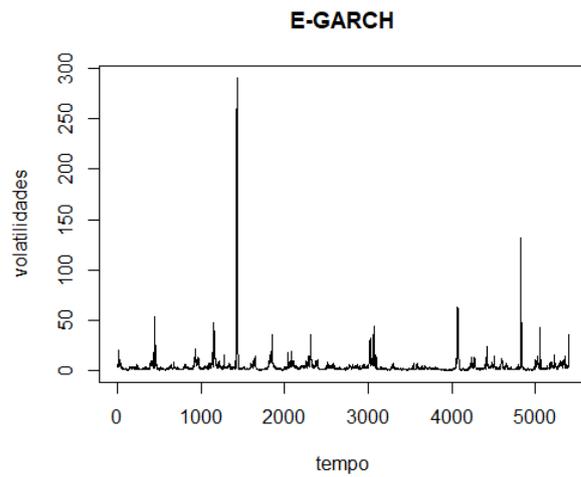


Gráfico 14 - Volatilidades do Gás Natural no modelo E-GARCH

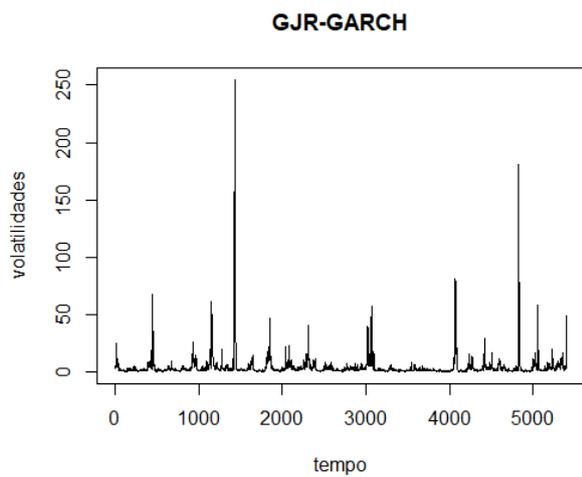


Gráfico 15 - Volatilidades do Gás Natural no modelo GJR-GARCH

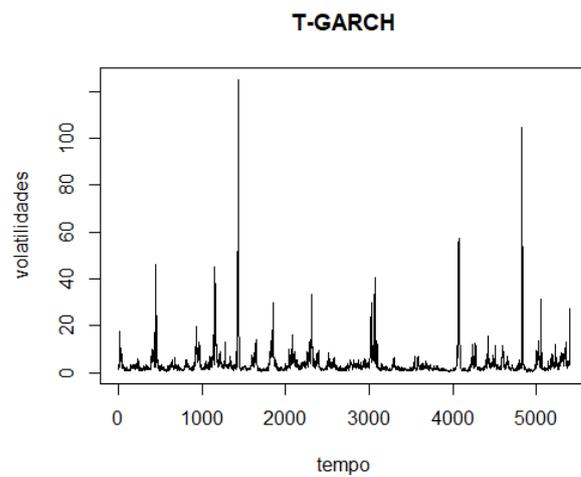


Gráfico 16 - Volatilidades do Gás Natural no modelo T-GARCH

3.3 – Análise das rendibilidades do Petróleo

3.3.1 – Estatísticas descritivas das rendibilidades do Petróleo

Tabela 5 – Petróleo - Amostra Total

AMOSTRA COMPLETA				
8271 observações desde 21 de Maio 1987, a 14 de Setembro 2020	Retornos-log		Retornos ao quadrado	
Média	0		1.26	
Mediana	0.04		0.27	
Desvio Padrão	1.12		10.57	
Mínimo	-27.96		0	
Máximo	17.89		781.51	
Curtose	71.69077		3740.936	
Assimetria	-1.828947		54.7869	
Testes de hipótese	Estatística de teste	p-value	Estatística de teste	p-value
Jarque Bera	1.63E+06	<2.2e-16	4.82E+09	<2.2e-16
ARCH(4)	1.06E+03	0.00E+00	2.20E+02	0.00E+00
ADF	-6.62E+01	<2.2e-16	-5.44E+01	<2.2e-16
Ljung Box (lag=10)	48.754	4.52E-07	1608.9	<2.2e-16
Ljung Box (lag=20)	126.27	<2.2e-16	2311	<2.2e-16
AR(1)				
Ljung Box (lag=10)	26.688	2.92E-03	473.48	<2.2e-16
Ljung Box (lag=20)	86.486	3.03E-10	774.16	<2.2e-16

Focando o estudo na tabela apresentada, acerca da média e mediana podemos concluir que, devido à proximidade dos valores, quase podemos afirmar que existe simetria. Os valores calculados do desvio padrão são baixos, o que sugere que estes são estáveis e existe regularidade relativamente à média. Os coeficientes de curtose são superiores a três, então são superiores ao da distribuição normal e acerca da simetria esta é comprovada pelos valores próximos de zero. Finalmente, tomando em consideração os testes Ljung-Box e principalmente os valores resultantes destes testes após a eliminação da autocorrelação, observamos descidas dos valores quase em metade, o que nos permite afirmar que temos assim um melhor ajustamento do modelo aplicado aos resíduos da série temporal financeira a ser estudada.

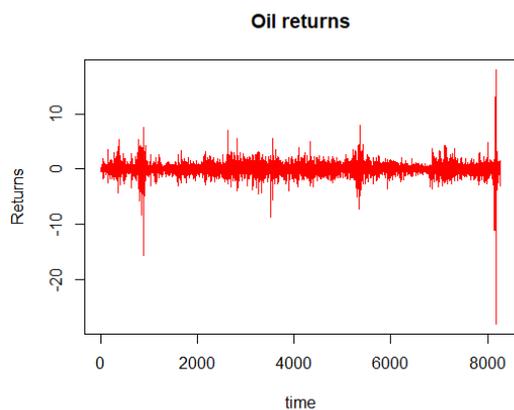


Gráfico 17 - Retornos do Petróleo entre 21 de maio de 1987 e 14 de setembro de 2020

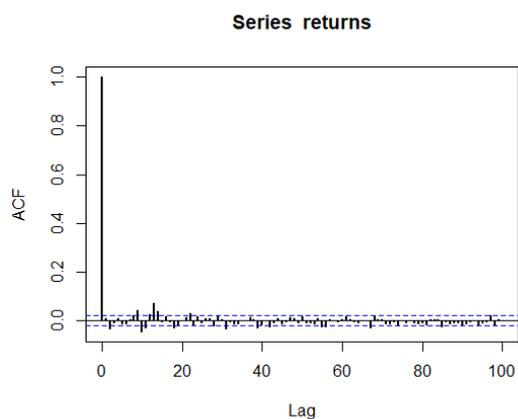


Gráfico 18 - Autocorrelação da série de retornos

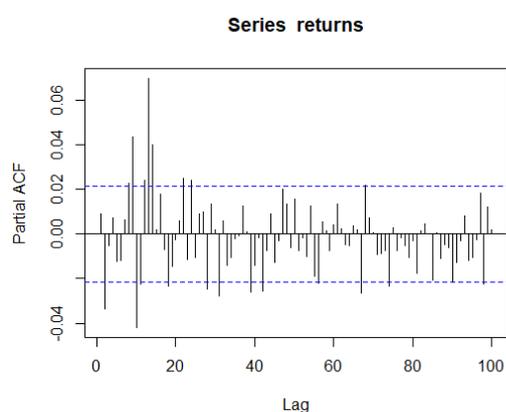


Gráfico 19 – Autocorrelação parcial da série de retornos

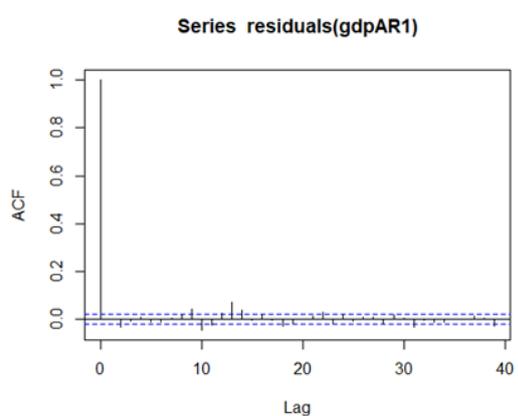


Gráfico 20 - Autocorrelação da série de retornos, pós eliminação de autocorrelação

Estamos agora perante o estudo do Petróleo e neste caso, relativamente aos retornos concluímos sem dúvida que na subamostra 1 (Anexo 3-gráfico 85) estes são muito mais abundantes e elevados, sendo que na subamostra 2 (Anexo 3-gráfico 90) apenas observamos um pico ao longo do tempo estudado.

Observando agora a autocorrelação já se passa o contrário, ou seja, esta é mais elevada na subamostra 2 (Anexo 3-gráfico 91), o que é provado também pelos gráficos da autocorrelação parcial (Anexo 3-gráfico 92) e conseqüentemente pelos gráficos que nos mostram a autocorrelação depois de termos eliminado o excesso de autocorrelação (Anexo 3-gráfico 94).

Finalmente, acerca da análise dos preços, podemos concluir que na subamostra 1 (Anexo 3-gráfico 88) temos uma subida gradual ainda que estejam evidentes dois picos de queda e conseqüente subida dos mesmos, na subamostra 2 (Anexo 3-gráfico 93) os preços mantêm-se quase constantes, sendo evidente duas quedas, uma delas mais acentuada, no entanto os preços voltaram a um valor próximo do que normalmente se observa.

3.3.2 – Estimação dos modelos de volatilidade do tipo GARCH

Tabela 6 - Resultados da estimação dos modelos do tipo GARCH no Petróleo

		Resultados da estimação dos modelos do tipo GARCH											
		mu	omega	alpha 1	beta 1	gamma 1	Modelo de volatilidade	Distribuição	Log-likelihood	AIC	BIC	SIC	HQIC
IN SAMPLE	Modelo 1	0.011288 [0,009]	0.006427 [0,002]	0.074226 [0,013]	0.922897 [0,007]		S-GARCH	Normal	-9525.49	2.596	2.600	2.596	2.598
	Modelo 2	0.000351 [0,009]	0.004138 [0,001]	-0.024423 [0,005]	0.990458 [0,001]	0.161816 [0,011]	E-GARCH	Normal	-9519.70	2.595	2.600	2.595	2.567
	Modelo 3	0.004599 [0,009]	0.006687 [0,001]	0.059491 [0,007]	0.922271 [0,007]	0.029963 [0,008]	GJR-GARCH	Normal	-9517.48	2.594	2.599	2.594	2.596
	Modelo 4	0.008504 [0,009]	0.006592 [0,003]	0.066185 [0,016]	0.942899 [0,016]	0.192943 [0,056]	T-GARCH	Normal	-9344.29	2.547	2.553	2.547	2.549
OUT OF SAMPLE	Modelo 1	0.040896 [0,027]	0.038512 [0,010]	0.152279 [0,021]	0.824821 [0,021]		S-GARCH	Normal	-1290.255	2.783	2.804	2.783	2.791
	Modelo 2	0.012589 [0,027]	0.008177 [0,006]	-0.114011 [0,019]	0.979524 [0,005]	0.196554 [0,034]	E-GARCH	Normal	-1281.24	2.766	2.792	2.766	2.776
	Modelo 3	-0.002625 [0,028]	0.047198 [0,009]	0.018244 [0,022]	0.839257 [0,021]	0.192234 [0,037]	GJR-GARCH	Normal	-1277.23	2.758	2.784	2.757	2.767
	Modelo 4	0.033086 [0,027]	0.027906 [0,006]	0.067016 [0,022]	0.920085 [0,018]	0.926542 [0,335]	T-GARCH	Normal	-1235.377	2.670	2.701	2.670	2.682
AMOSTRA COMPLETA	Modelo 1	0.015641 [0,009]	0.010635 [0,002]	0.093168 [0,006]	0.901475 [0,006]		S-GARCH	Normal	-10832.28	2.620	2.624	2.620	2.622
	Modelo 2	0.001232 [0,009]	0.005233 [0,001]	-0.036805 [0,005]	0.987684 [0,001]	0.184792 [0,011]	E-GARCH	Normal	-10814.19	2.616	2.620	2.616	2.618
	Modelo 3	0.006066 [0,011]	0.011377 [0,004]	0.068229 [0,011]	0.901721 [0,013]	0.046324 [0,015]	GJR-GARCH	Normal	-10816.65	2.617	2.621	2.617	2.618
	Modelo 4	0.012211 [0,008]	0.010875 [0,008]	0.079293 [0,033]	0.928634 [0,034]	0.232342 [0,042]	T-GARCH	Normal	-10596.43	2.564	2.569	2.564	2.566

(coeficiente entre parênteses é o erro padrão robusto)

Ao analisar a tabela 6, concluímos que todos os coeficientes são estatisticamente significativos a 1%.

Relativamente ao modelo S-GARCH, mais uma vez, estamos perante existência de períodos de volatilidade altos seguidos de períodos de volatilidade baixa, ou seja, os clusters de volatilidade, que são provados pelos valores sempre positivos deste modelo.

Na subamostra 1 temos que no alpha1 o modelo E-GARCH apresenta um valor negativo enquanto o modelo GJR-GARCH apresenta um valor positivo, daí tiramos que existem efeitos assimétricos na volatilidade, ou seja, as más notícias prevalecem às boas. Na subamostra 2 temos o mesmo acontecimento também em alpha1, tal como acontece na amostra completa.

Como tem acontecido, mais uma vez, temos que os valores mais baixos do Log-likelihood são os do modelo T-GARCH. Assim sendo, temos também valores de AIC, BIC, SIC e HQIC mais baixos neste modelo comparativamente com os outros. Concluímos então que este modelo é mais uma vez o mais indicado para estudar a energia em questão, Petróleo, tanto na subamostra 1, como na subamostra 2 e na amostra completa. Estas conclusões são complementadas com os dados dos gráficos apresentados seguidamente e no (Anexo 3-gráficos 95 a 98 e 99 a 102) que estudam a volatilidade dos preços do Petróleo nos diferentes modelos, onde podemos também observar uma melhor concordância no modelo T-GARCH.

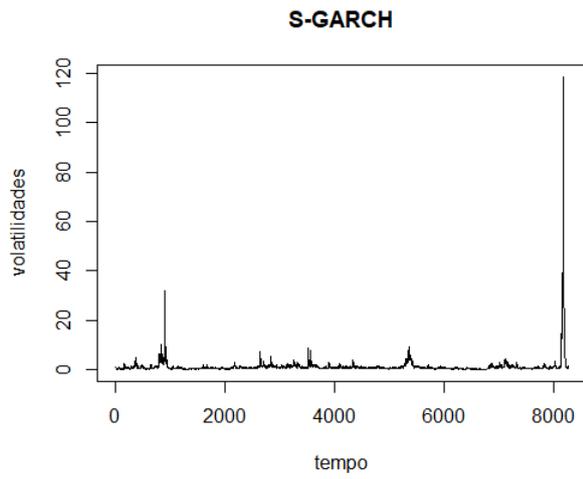


Gráfico 21 - Volatilidades do Petróleo no modelo S-GARCH

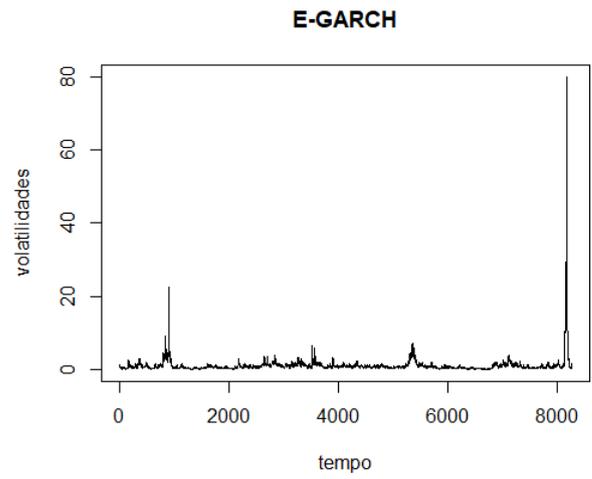


Gráfico 22 - Volatilidades do Petróleo no modelo E-GARCH

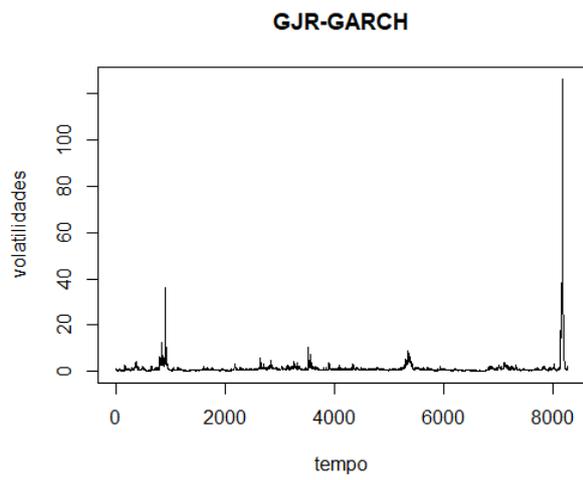


Gráfico 23 - Volatilidades do Petróleo no modelo GJR-GARCH

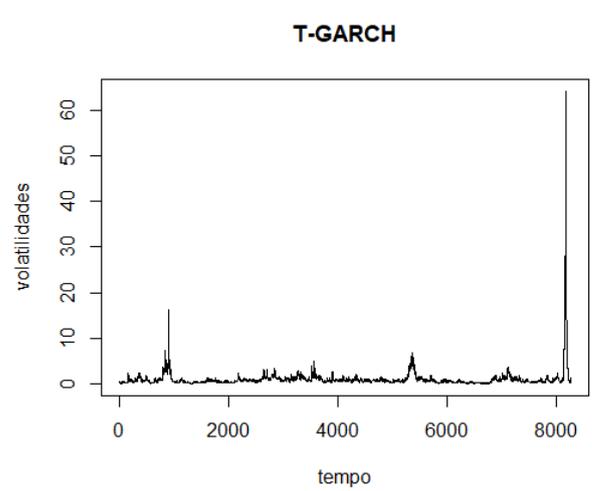


Gráfico 24 - Volatilidades do Petróleo no modelo T-GARCH

3.4 – Análise das rendibilidades do Petróleo de Aquecimento

3.4.1 – Estatísticas descritivas das rendibilidades do Petróleo de Aquecimento

Tabela 7 - Petróleo de Aquecimento - Amostra Completa

AMOSTRA COMPLETA				
8324 observações desde 3 de Junho 1986, a 14 de Setembro 2020	Retornos-log		Retornos ao quadrado	
Média	0		1.23	
Mediana	0.04		0.3	
Desvio Padrão	1.11		7.18	
Mínimo	-20.42		0	
Máximo	9.97		416.85	
Curtose	34.85		1955.6	
Assimetria	-1.37		39.53	
Testes de hipótese	Estatística de teste	p-value	Estatística de teste	p-value
Jarque Bera	3.54E+05	<2.2e-16	1.32E+09	<2.2e-16
ARCH(4)	1.28E+03	0.00E+00	5.54E+01	2.70E-11
ADF	-6.37E+01	<2.2e-16	-4.92E+01	<2.2e-16
Ljung Box (lag=10)	44.72	2.44E-06	2179.1	<2.2e-16
Ljung Box (lag=20)	51.75	0.0001238	2402.3	<2.2e-16
AR(1)				
Ljung Box (lag=10)	17.16	7.09E-02	2193	<2.2e-16
Ljung Box (lag=20)	24.776	2.10E-01	2437.4	<2.2e-16

Analisando as estatísticas descritivas e observando que os valores da média e mediana são próximos, concluímos que existe simetria, e com valores de desvio padrão baixos também afirmamos que estes são estáveis e estamos perante regularidade em relação à média. Temos também uma curtose superior à da distribuição normal e valores de assimetria relativamente próximos de zero, o que sugere alguma simetria. Os testes Ljung-Box, mais uma vez, permitem-nos observar o melhor ajustamento do modelo aplicado a resíduos da série temporal financeira em questão, pós eliminação da autocorrelação existente inicialmente.

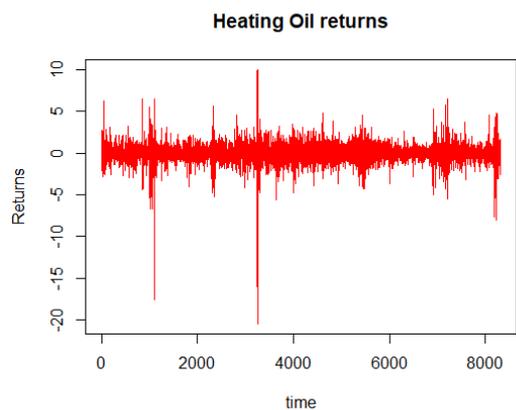


Gráfico 25 – Retornos do Petróleo de Aquecimento entre 3 de junho de 1986 e 14 de setembro de 2020

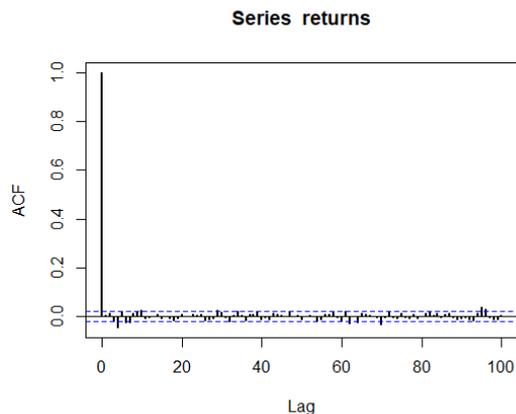


Gráfico 26 - Autocorrelação da série de retornos

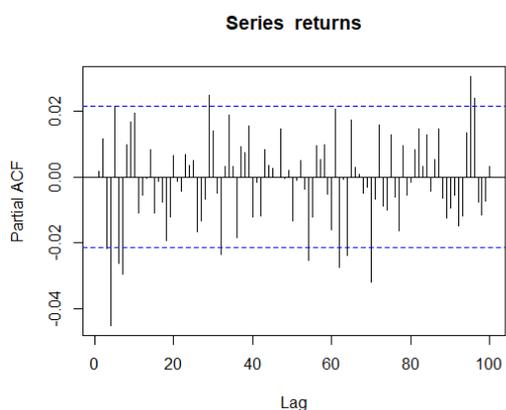


Gráfico 27 – Autocorrelação parcial da série de retornos

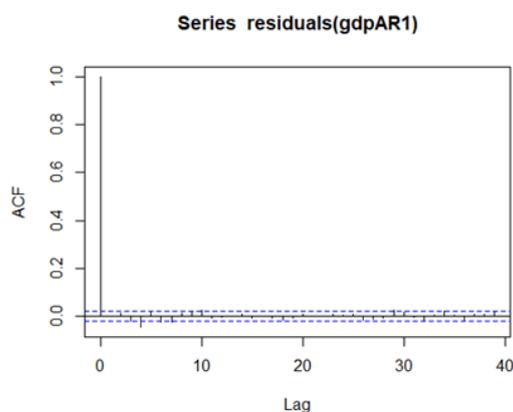


Gráfico 28 - Autocorrelação da série de retornos, pós eliminação de autocorrelação

Relativamente ao Petróleo de Aquecimento, e neste caso concluímos que relativamente aos retornos, estes são mais constantes na subamostra 1 (Anexo 4-gráfico 103) onde apenas temos dois picos, sendo que na subamostra 2 (Anexo 4-gráfico 108) observamos apenas um período de tempo em que os retornos aumentaram significativamente.

O mesmo se passa com a autocorrelação, esta é bastante mais evidente na subamostra 2 (Anexo 4-gráfico 109), podendo observar isso mais nitidamente nos gráficos da autocorrelação parcial (Anexo 4-gráfico 110), mas também no último, em que temos a autocorrelação depois de ter sido eliminada a autocorrelação existente inicialmente (Anexo 4-gráfico 112).

Por fim, acerca dos preços podemos concluir que na subamostra 1 (Anexo 4-gráfico 106) estes têm uma tendência de subida apesar das duas quedas evidenciadas, já na subamostra 2 (Anexo 4-gráfico 111) estes são mais constantes, observando apenas uma queda significativa que já foi seguida de um aumento novamente.

3.4.2 – Estimação dos modelos de volatilidade do tipo GARCH

Tabela 8 - Resultados da estimação dos modelos do tipo GARCH no Petróleo de Aquecimento

		Resultados da estimação dos modelos do tipo GARCH											
		mu	omega	alpha 1	beta 1	gamma 1	Modelo de volatilidade	Distribuição	Log-likelihood	AIC	BIC	SIC	HQIC
IN SAMPLE	Modelo 1	0.016083 [0,009]	0.015189 [0,003]	0.102440 [0,007]	0.888301 [0,007]		S-GARCH	Normal	-10040.02	2.709	2.713	2.709	2.710
	Modelo 2	0.018187 [0,009]	0.003578 [0,002]	0.019662 [0,007]	0.982453 [0,001]	0.215262 [0,012]	E-GARCH	Normal	-10038.46	2.709	2.713	2.709	2.710
	Modelo 3	0.022 [0,01]	0.015113 [0,003]	0.113422 [0,009]	0.890927 [0,007]	-0.027609 [0,010]	GJR-GARCH	Normal	-10036.10	2.708	2.713	2.708	2.710
	Modelo 4	0.014475 [0,009]	0.013147 [0,003]	0.092507 [0,010]	0.915385 [0,010]	-0.047513 [0,044]	T-GARCH	Normal	-9904.74	2.673	2.678	2.673	2.675
OUT OF SAMPLE	Modelo 1	0.008839 [0,025]	0.022804 [0,008]	0.109751 [0,020]	0.868069 [0,023]		S-GARCH	Normal	-1127.05	2.491	2.513	2.491	2.499
	Modelo 2	-0.00536 [0,024]	-0.001172 [0,005]	-0.094595 [0,019]	0.979675 [0,006]	0.139066 [0,029]	E-GARCH	Normal	-1115.53	2.468	2.495	2.468	2.478
	Modelo 3	-0.004865 [0,025]	0.023471 [0,007]	0.030548 [0,018]	0.886618 [0,021]	0.104835 [0,028]	GJR-GARCH	Normal	-1120.51	2.479	2.506	2.479	2.489
	Modelo 4	0.005840 [0,022]	0.017054 [0,005]	0.057537 [0,017]	0.936065 [0,016]	1.000000 [0,3323]	T-GARCH	Normal	-1074.729	2.381	2.412	2.380	2.393
AMOSTRA COMPLETA	Modelo 1	0.015019 [0,009]	0.015964 [0,002]	0.103226 [0,007]	0.886463 [0,007]		S-GARCH	Normal	-11167.7	2.684	2.688	2.684	2.685
	Modelo 2	0.014018 [0,007]	0.003959 [0,016]	0.009184 [0,006]	0.981801 [0,000]	0.21944 [0,000]	E-GARCH	Normal	-11168.45	2.685	2.689	2.685	2.686
	Modelo 3	0.018153 [0,009]	0.015975 [0,002]	0.110013 [0,008]	0.887216 [0,007]	-0.015167 [0,009]	GJR-GARCH	Normal	-11166.39	2.684	2.688	2.684	2.686
	Modelo 4	0.013495 [0,008]	0.014240 [0,003]	0.095315 [0,008]	0.912212 [0,008]	0.019750 [0,041]	T-GARCH	Normal	-10994.85	2.643	2.648	2.643	2.645

(coeficiente entre parênteses é o erro padrão robusto)

Ao analisar a tabela 8, concluímos que todos os coeficientes são estatisticamente significativos a 1%.

No modelo S-GARCH estamos perante valores somente positivos, na subamostra 1, subamostra 2 e na amostra completa, assim concluímos a existência de períodos de volatilidade altos que são seguidos de períodos de volatilidade baixa, ao que chamamos de clusters de volatilidade.

Tendo atenção aos modelos E-GARCH e GJR-GARCH, podemos aqui afirmar que na subamostra 1 E-GARCH apresenta um gamma1 positivo e GJR-GARCH tem gamma1 negativo; na subamostra 2 deparamo-nos com valor negativo em alpha1 no modelo E-GARCH e valor positivo em GJR-GARCH; já na amostra completa podemos tomar em consideração os valores de gamma1, em que no modelo E-GARCH este é negativo e em GJR-GARCH positivo, assim sendo, estando perante valores positivos e negativos concluímos existência de efeitos assimétricos na volatilidade, ou seja o efeito das más notícias é maior do que o das boas.

Dos resultados do Log-likelihood, concluímos que os mais baixos são, nos três casos, os valores do modelo T-GARCH. Temos consequentemente valores de AIC, BIC, SIC e HQIC mais baixos também no modelo T-GARCH. Mais uma vez vamos considerar o modelo T-GARCH o mais indicado para estudar a volatilidade no Petróleo de Aquecimento. Pela análise dos gráficos de volatilidade apresentados a seguir e no (Anexo 4-gráficos 113 a 116 e 117 a 120), temos como confirmada a teoria de que o modelo T-GARCH é o mais indicado para o estudo da volatilidade neste caso.

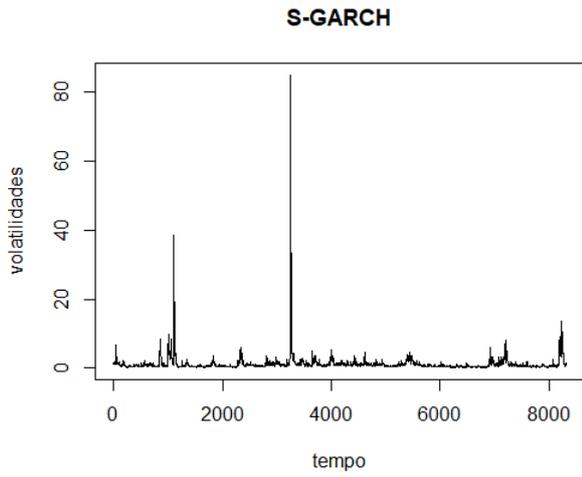


Gráfico 29 - Volatilidades do Petróleo de Aquecimento no modelo S-GARCH

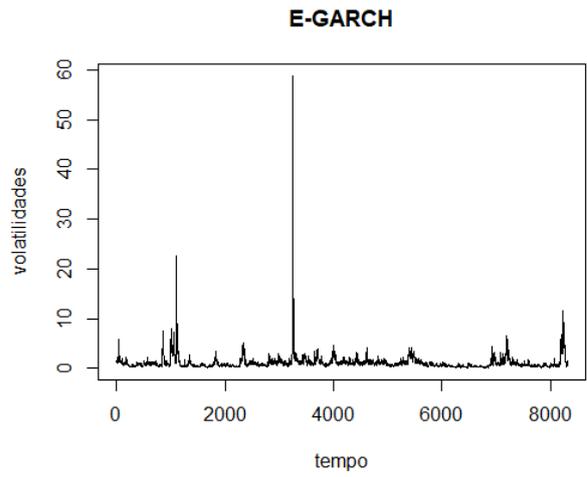


Gráfico 30 - Volatilidades do Petróleo de Aquecimento no modelo E-GARCH

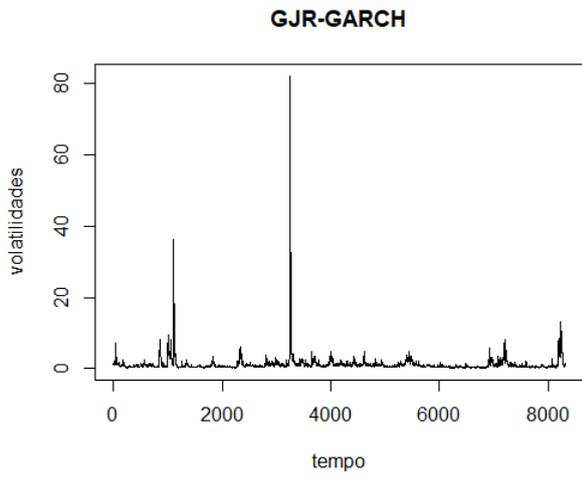


Gráfico 31 - Volatilidades do Petróleo de Aquecimento no modelo GJR-GARCH

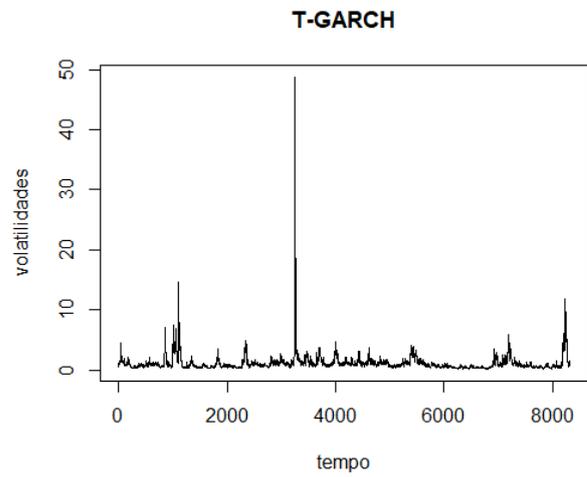


Gráfico 32 - Volatilidades do Petróleo de Aquecimento no modelo T-GARCH

3.5 – Análise das rendibilidades do Querosene

3.5.1 – Estatísticas descritivas das rendibilidades do Querosene

Tabela 9 - Querosene - Amostra Completa

OUT OF SAMPLE				
7451 observações desde 3 de Abril 1990, a 14 de Setembro 2020	Retornos-log		Retornos ao quadrado	
Média	0		1.32	
Mediana	0.03		0.32	
Desvio Padrão	1.15		5.65	
Mínimo	-16.4		0	
Máximo	14.18		268.88	
Curtose	19.42926		1018.939	
Assimetria	-0.5829231		26.69016	
Testes de hipótese	Estatística de teste	p-value	Estatística de teste	p-value
Jarque Bera	8.42E+04	<2.2e-16	3.21E+08	<2.2e-16
ARCH(4)	9.42E+02	0.00E+00	1.03E+02	0.00E+00
ADF	-6.27E+01	<2.2e-16	-4.44E+01	<2.2e-16
Ljung Box (lag=10)	30.738	6.48E-04	1253.9	<2.2e-16
Ljung Box (lag=20)	50.753	1.73E-04	1619.2	<2.2e-16
AR(1)				
Ljung Box (lag=10)	11.088	3.51E-01	1209.8	<2.2e-16
Ljung Box (lag=20)	20.866	4.05E-01	1563.2	<2.2e-16

Acerca das informações da tabela podemos concluir simetria dos dados, visto que os valores da média e mediana são próximos. Já o desvio padrão confere, pelos valores baixos, estabilidade e regularidade relativamente aos valores da média. Curtose acima de três é sinónimo de valores superiores ao da distribuição normal e os valores da assimetria confirmam a simetria falada acima, por serem próximos de zero. Já dos testes Ljung-Box, podemos mais uma vez concluir a necessidade da eliminação da autocorrelação inicial, visto que, em AR(1) os valores deste teste são bastante mais baixos do que anteriormente à eliminação da autocorrelação, assim sendo, temos no fim um melhor ajustamento do modelo aplicado a resíduos da série temporal financeira a ser estudada.

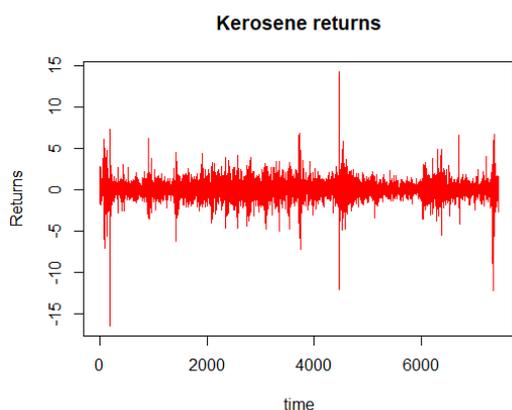


Gráfico 33 – Retornos do Querosene entre 3 de abril de 1990 e 14 de setembro de 2020

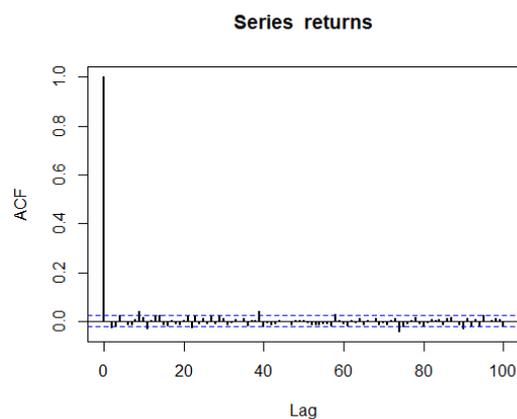


Gráfico 34 - Autocorrelação da série de retornos

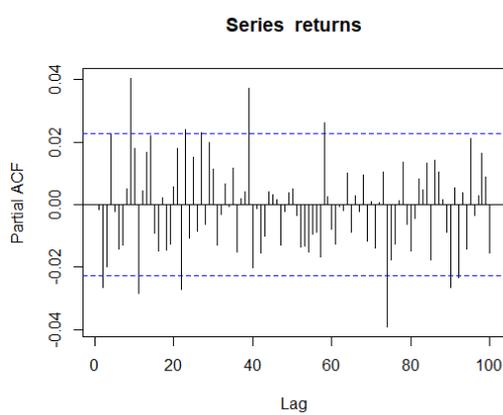


Gráfico 36 – Autocorrelação parcial da série de retornos

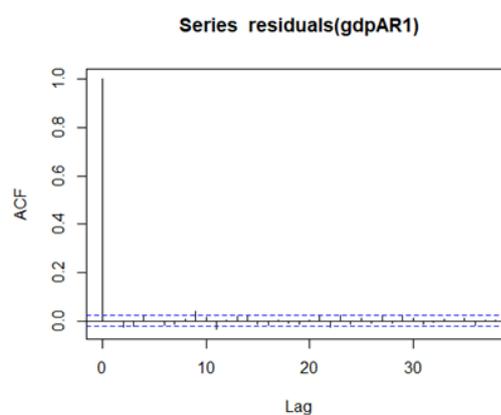


Gráfico 35 - Autocorrelação da série de retornos, pós eliminação de autocorrelação

No estudo do Querosene e acerca dos retornos dos resíduos podemos desde já afirmar que estes são mais abundantes e constantes na subamostra 1 (Anexo 5-gráfico 121), sendo que na subamostra 2 (Anexo 5-gráfico 126) observamos um período de tempo em que temos um aumento significativo dos valores.

No que toca à autocorrelação, esta é mais visível na subamostra 2 (Anexo 5-gráfico 127), o que é comprovado pelos gráficos relativos à autocorrelação parcial (Anexo 5-gráfico 128) e consequentemente pelo gráfico da autocorrelação após termos eliminado a autocorrelação inicial (Anexo 5-gráfico 130).

Observando agora os gráficos relativos aos preços, quase que podemos afirmar que são simétricos, visto que na subamostra 1 (Anexo 5-gráfico 124) estes têm tendência a subir sendo apenas observada uma queda mais brusca, já na subamostra 2 (Anexo 5-gráfico 129) os preços mantêm-se mais ou menos constantes observando uma queda brusca apenas, mas seguida de recuperação.

3.5.2 – Estimação dos modelos de volatilidade do tipo GARCH

Tabela 10 - Resultados da estimação dos modelos do tipo GARCH no Querosene

		Resultados da estimação dos modelos do tipo GARCH											
		mu	omega	alpha 1	beta 1	gamma 1	Modelo de volatilidade	Distribuição	Log-likelihood	AIC	BIC	SIC	HQIC
IN SAMPLE	Modelo 1	0.021819 [0,010]	0.010069 [0,002]	0.091180 [0,008]	0.906636 [0,008]		S-GARCH	Normal	-9095.36	2.782	2.786	2.782	2.783
	Modelo 2	0.015189 [0,009]	0.006023 [0,002]	-0.00553 [0,007]	0.987807 [0,001]	0.189358 [0,011]	E-GARCH	Normal	-9089.06	2.780	2.785	2.780	2.782
	Modelo 3	0.019672 [0,010]	0.010022 [0,002]	0.087271 [0,008]	0.906104 [0,008]	0.009142 [0,010]	GJR-GARCH	Normal	-9094.92	2.782	2.787	2.782	2.784
	Modelo 4	0.014215 [0,010]	0.009593 [0,003]	0.084629 [0,011]	0.925516 [0,010]	0.012754 [0,049]	T-GARCH	Normal	-8903.99	2.724	2.730	2.724	2.726
OUT OF SAMPLE	Modelo 1	0.008986 [0,025]	0.051873 [0,017]	0.185900 [0,040]	0.775277 [0,046]		S-GARCH	Normal	-1187.85	2.622	2.644	2.622	2.630
	Modelo 2	0.002194 [0,025]	0.007084 [0,006]	-0.046345 [0,019]	0.975647 [0,008]	0.251804 [0,040]	E-GARCH	Normal	-1182.58	2.613	2.639	2.613	2.623
	Modelo 3	-0.001195 [0,026]	0.046439 [0,015]	0.107955 [0,044]	0.809327 [0,043]	0.082448 [0,040]	GJR-GARCH	Normal	-1186.11	2.621	2.647	2.621	2.631
	Modelo 4	0.004333 [0,026]	0.020706 [0,006]	0.089513 [0,021]	0.908126 [0,021]	0.495253 [0,173]	T-GARCH	Normal	-1134.94	2.510	2.542	2.510	2.522
AMOSTRA COMPLETA	Modelo 1	0.020713 [0,010]	0.013572 [0,003]	0.101345 [0,008]	0.894147 [0,008]		S-GARCH	Normal	-10291.07	2.763	2.767	2.763	2.765
	Modelo 2	0.009776 [0,010]	0.006576 [0,002]	-0.01306 [0,006]	0.986225 [0,001]	0.201425 [0,010]	E-GARCH	Normal	-10275.10	2.759	2.764	2.759	2.761
	Modelo 3	0.016551 [0,010]	0.013419 [0,002]	0.09185 [0,009]	0.894243 [0,008]	0.018976 [0,010]	GJR-GARCH	Normal	-10289.19	2.763	2.768	2.763	2.765
	Modelo 4	0.012658 [0,009]	0.011294 [0,003]	0.090773 [0,009]	0.919115 [0,009]	0.074051 [0,564]	T-GARCH	Normal	-10047.70	2.699	2.704	2.699	2.701

(coeficiente entre parênteses é o erro padrão robusto)

Ao analisar a tabela 10, concluímos que todos os coeficientes são estatisticamente significativos a 1%.

No que toca ao modelo S-GARCH, podemos desde já concluir que como todos os coeficientes do modelo se revelam positivos, nos três casos, estamos perante a existência de clusters de volatilidade (períodos altos e baixos de volatilidade).

Tomando atenção aos resultados dos modelos E-GARCH e GJR-GARCH, na subamostra 1, subamostra 2 e na amostra completa, podemos afirmar que em alpha1 o modelo E-GARCH tem sempre valores negativos e o modelo GJR-GARCH valores positivos, ou seja, revelam a existência de feitos assimétricos na volatilidade, o que nos leva a concluir que o efeito das más notícias é maior do que o das boas.

Passando agora aos valores resultantes do Log-likelihood, concluímos que os mais baixos são, nos três casos, os valores do modelo T-GARCH. Assim sendo temos também que os valores de AIC, BIC, SIC e HQIC são também os menores neste modelo. Assim, estamos capazes de concluir que no caso do Querosene, o melhor modelo para estudar os efeitos da volatilidade dos preços no período de tempo a ser estudado, é o modelo T-GARCH. A teoria é confirmada pela análise dos gráficos apresentados a seguir e pelos gráficos no (Anexo 5-gráficos 131 a 134 e 135 a 138), que estudam a volatilidade do Querosene, nas três fases do estudo.

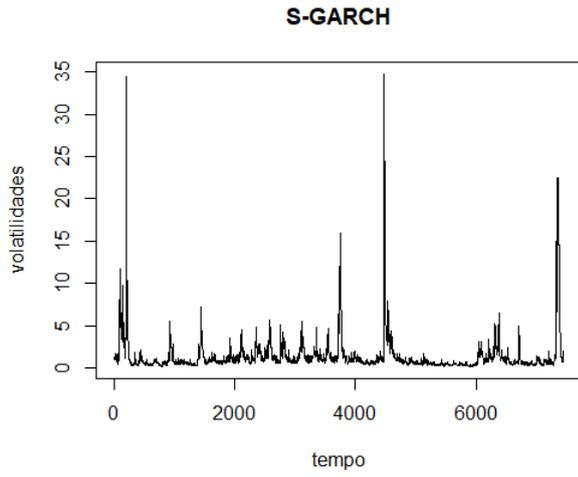


Gráfico 37 - Volatilidades do Querosene no modelo S-GARCH

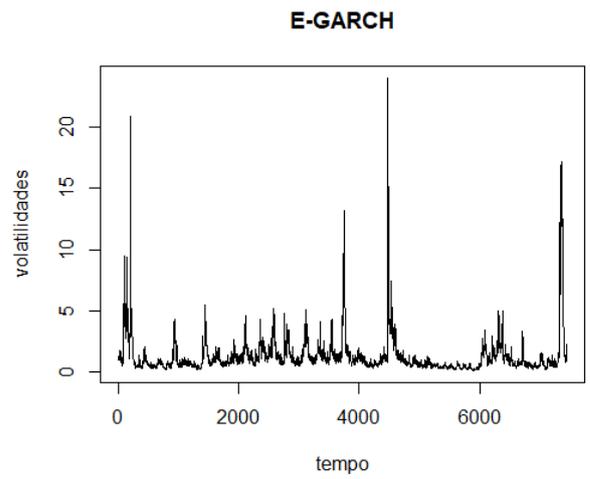


Gráfico 38 - Volatilidades do Querosene no modelo E-GARCH

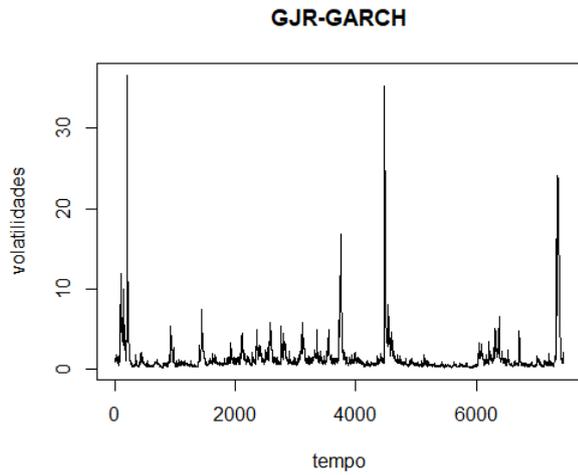


Gráfico 39 - Volatilidades do Querosene no modelo GJR-GARCH

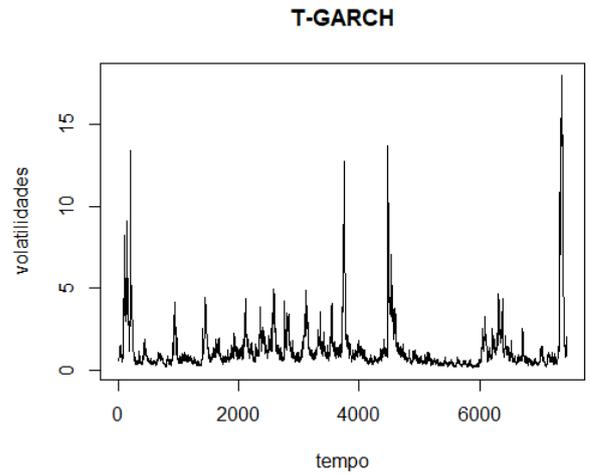


Gráfico 40 - Volatilidades do Querosene no modelo T-GARCH

3.6 – Análise das rendibilidades do Propano

3.6.1 – Estatísticas descritivas das rendibilidades do Propano

Tabela 11 - Propano – Amostra Completa

AMOSTRA COMPLETA				
6183 observações desde 10 de Julho 1992, a 14 de Setembro 2020	Retornos-log		Retornos ao quadrado	
Média	0		1.45	
Mediana	0.08		0.29	
Desvio Padrão	1.2		8.47	
Mínimo	-21.68		0	
Máximo	14.31		469.89	
Curtose	35.25082		1816.444	
Assimetria	-1.296569		37.44796	
Testes de hipótese	Estatística de teste	p-value	Estatística de teste	p-value
Jarque Bera	2.70E+05	<2.2e-16	8.49E+08	<2.2e-16
ARCH(4)	2.65E+02	0.00E+00	1.35E+00	8.53E-01
ADF	-5.33E+01	<2.2e-16	-4.57E+01	<2.2e-16
Ljung Box (lag=10)	33.084	2.64E-04	311.02	<2.2e-16
Ljung Box (lag=20)	63.243	2.22E-06	361.77	<2.2e-16
AR(1)				
Ljung Box (lag=10)	8.2981	6.00E-01	304.04	<2.2e-16
Ljung Box (lag=20)	32.503	3.82E-02	354.64	<2.2e-16

Nas estatísticas descritivas, mais uma vez, a partir da proximidade dos valores da média e mediana sugerem simetria dos dados. Os valores baixos do desvio padrão sugerem estabilidade e regularidade aos valores encontrados da média. Os valores da curtose são superiores aos da distribuição normal, acerca da assimetria e sendo esta relativamente próxima de zero é sinónimo do mencionado acima, os dados da energia em questão sugerem alguma simetria. Por fim, analisamos os testes Ljung-Box que também, mais uma vez, refletem um melhor ajustamento do modelo aplicado a resíduos da série temporal financeira em questão após eliminação da autocorrelação, ou seja, os outputs de AR(1).

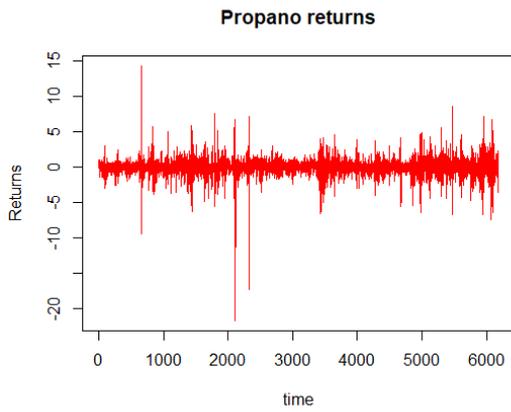


Gráfico 41 – Retornos do Propano entre 10 de julho de 1992 e 14 de setembro de 2020

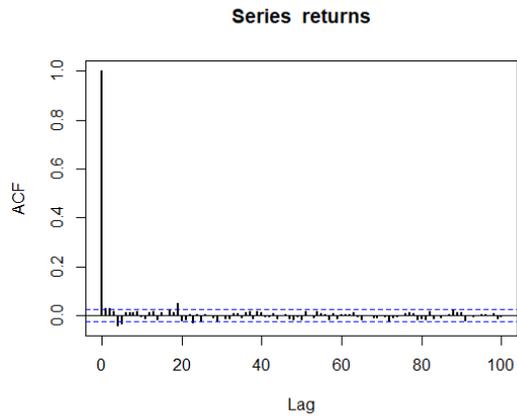


Gráfico 42 - Autocorrelação da série de retornos

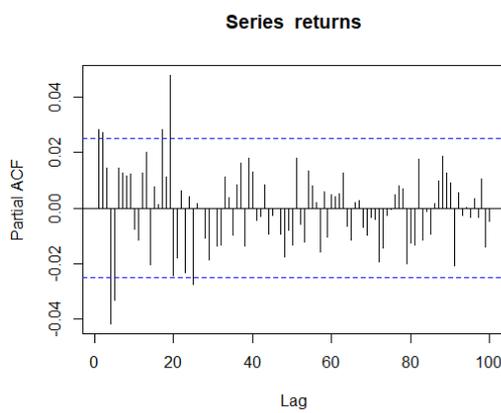


Gráfico 43 – Autocorrelação parcial da série de retornos

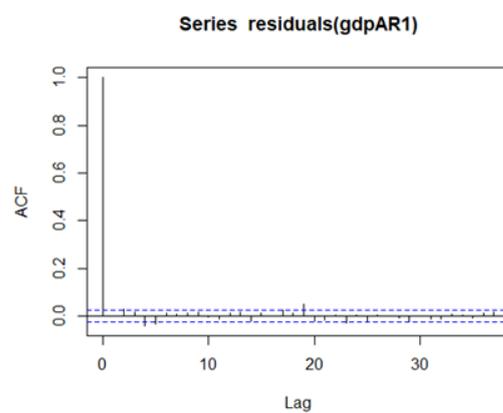


Gráfico 44 - Autocorrelação da série de retornos, pós eliminação de autocorrelação

A última energia a ser estudada é o Propano, e neste caso relativamente aos retornos é evidente que na subamostra 2 (Anexo 6-gráfico 144) estes são mais abundantes, o que é comprovado pelos gráficos que estudam a autocorrelação (Anexo 6-gráfico 145), onde podemos ver que esta é maior também na subamostra 2, teoria comprovada pela análise também do gráfico da autocorrelação parcial (Anexo 6-gráfico 146) e pelo gráfico da autocorrelação após eliminar a autocorrelação existente inicialmente (Anexo 6-gráfico 148).

Acerca da variação dos preços desta energia, podemos concluir que na subamostra 1 (Anexo 6-gráfico 142) estes tendem a aumentar gradualmente, apesar de que observamos algumas oscilações, já na subamostra 2 (Anexo 6-gráfico 147) os preços apresentam uma subida até certo momento em que se depara com uma queda dos preços.

3.6.2 – Estimação dos modelos de volatilidade do tipo GARCH

Tabela 12 - Resultados da estimação dos modelos do tipo GARCH no Propano

		Resultados da estimação dos modelos do tipo GARCH											
		mu	omega	alpha 1	beta 1	gamma 1	Modelo de volatilidade	Distribuição	Log-likelihood	AIC	BIC	SIC	HQIC
IN SAMPLE	Modelo 1	0.015294 [0,011]	0.046520 [0,006]	0.212335 [0,017]	0.771373 [0,016]		S-GARCH	Normal	-6807.18	2.665	2.670	2.685	2.667
	Modelo 2	0.015453 [0,011]	0.011924 [0,004]	0.023992 [0,009]	0.959646 [0,006]	0.322939 [0,022]	E-GARCH	Normal	-6781.88	2.655	2.662	2.655	2.658
	Modelo 3	0.02321 [0,011]	0.045419 [0,006]	0.253892 [0,023]	0.770491 [0,016]	-0.07326 [0,022]	GJR-GARCH	Normal	-6800.99	2.663	2.669	2.663	2.665
	Modelo 4	0.034720 [0,010]	0.036059 [0,006]	0.176184 [0,014]	0.830712 [0,038]	-0.049445 [0,397]	T-GARCH	Normal	-6487.93	2.541	2.548	2.541	2.543
OUT OF SAMPLE	Modelo 1	0.029647 [0,037]	0.114339 [0,030]	0.122034 [0,021]	0.823752 [0,029]		S-GARCH	Normal	-1814.49	3.396	3.415	3.396	3.403
	Modelo 2	-0.010444 [0,037]	0.038089 [0,012]	-0.100238 [0,018]	0.950204 [0,016]	0.202141 [0,039]	E-GARCH	Normal	-1806.81	3.383	3.407	3.383	3.392
	Modelo 3	-0.013054 [0,037]	0.074576 [0,016]	0.006232 [0,014]	0.886387 [0,019]	0.138861 [0,024]	GJR-GARCH	Normal	-1800.04	3.371	3.394	3.371	3.380
	Modelo 4	0.024786 [0,033]	0.059400 [0,021]	0.110353 [0,028]	0.873573 [0,031]	0.511849 [0,156]	T-GARCH	Normal	-1755.31	3.289	3.317	3.289	3.300
AMOSTRA COMPLETA	Modelo 1	0.016846 [0,011]	0.040167 [0,005]	0.183937 [0,013]	0.805620 [0,013]		S-GARCH	Normal	-8648.161	2.799	2.803	2.799	2.800
	Modelo 2	0.012266 [0,011]	0.017399 [0,003]	0.003097 [0,008]	0.963665 [0,005]	0.313586 [0,018]	E-GARCH	Normal	-8618.31	2.789	2.795	2.789	2.791
	Modelo 3	0.019888 [0,011]	0.040025 [0,005]	0.199446 [0,018]	0.804006 [0,013]	-0.025117 [0,017]	GJR-GARCH	Normal	-8647.02	2.799	2.804	2.799	2.801
	Modelo 4	0.033764 [0,009]	0.034820 [0,006]	0.171774 [0,013]	0.838448 [0,013]	0.011934 [0,035]	T-GARCH	Normal	-8260.43	2.674	2.681	2.674	2.676

(coeficiente entre parênteses é o erro padrão robusto)

Ao analisar a tabela 12, concluímos que todos os coeficientes são estatisticamente significativos a 1%.

Primeiramente, podemos observar que todos os coeficientes do modelo S-GARCH se revelam positivos, tanto na subamostra 1, como na subamostra 2 e na amostra completa, o que se traduz na existência de clusters de volatilidade, isto é, períodos de alta volatilidade que se sucedem a períodos de baixa volatilidade e assim sucessivamente.

Visto que, no caso dos modelos E-GARCH e GJR-GARCH o gamma1 num deles é positivo e no outro é negativo revelam a existência de feitos assimétricos na volatilidade, assim podemos concluir que o efeito das más notícias é maior do que o das boas notícias, isto acontece na subamostra 1 e na amostra completa. Sendo que o mesmo acontece com alpha1 na subamostra 2.

Assim sendo, tendo em consideração agora os valores de Log-likelihood, concluímos que os mais baixos são, nos três casos, os valores do modelo T-GARCH. O mesmo se passa com os valores referentes ao AIC, BIC, SIC e HQIC, o que finalmente nos permite concluir que na energia em questão, o Propano, o melhor modelo para estimar a volatilidade dos preços desta nos períodos de tempo em estudo é o modelo T-GARCH. O mesmo é confirmado pela análise dos gráficos que estudam a volatilidade do Propano, tanto na subamostra 1, como na subamostra 2 e na amostra completa, como se pode ver a seguir e no (Anexo 6-gráficos 149 a 152 e 153 a 156).

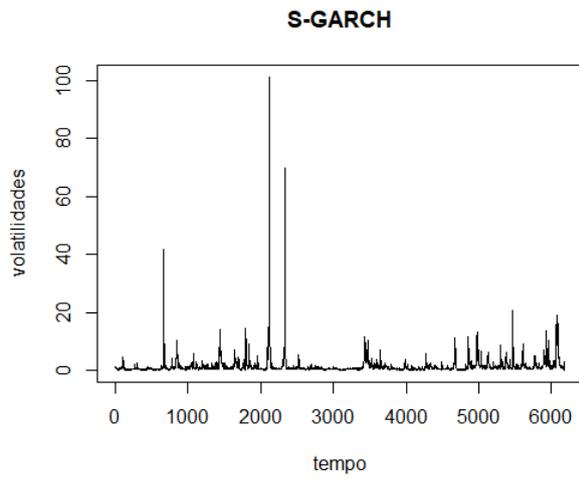


Gráfico 45 - Volatilidades do Propano no modelo S-GARCH

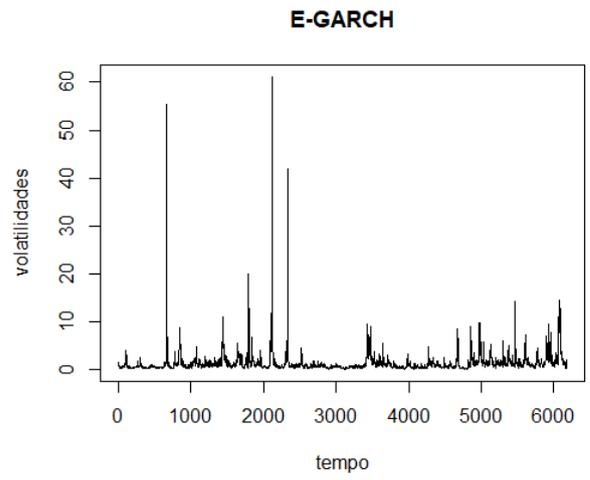


Gráfico 46 - Volatilidades do Propano no modelo E-GARCH

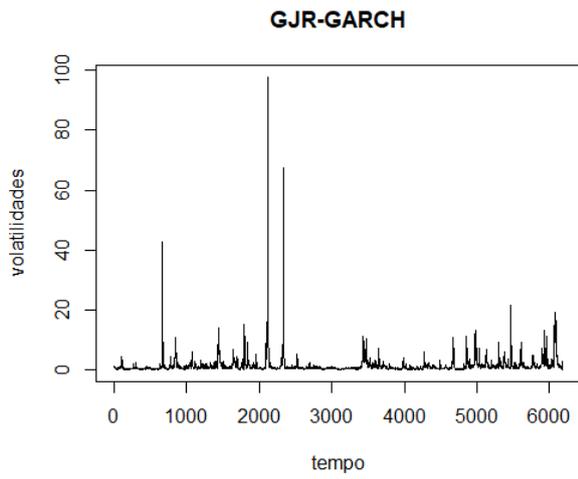


Gráfico 47 - Volatilidades do Propano no modelo GJR-GARCH

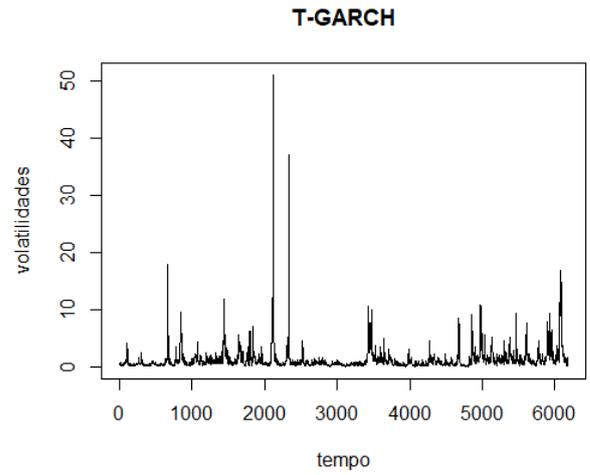


Gráfico 48 - Volatilidades do Propano no modelo T-GARCH

3.7 – Análise do Value at Risk

Os testes na subamostra 1, medem a qualidade de cada modelo no ajuste dos dados. Os testes na subamostra 2, atuando como backtest, comparam o retorno real com as previsões diárias do VaR ao longo do período da amostra, com o intuito de avaliar o desempenho de cada modelo na previsão de estimativas VaR. Na subamostra 1, os parâmetros são estimados pelo método da máxima verosimilhança usando dados da amostra como feito anteriormente estudando a volatilidade pelos modelos do tipo GARCH; agora na subamostra 2 (backtesting), os modelos são testados novamente para examinar quão bem os modelos preveem perdas extremas no futuro, avaliando assim o desempenho de cada modelo na previsão VaR. Para isto, foi testado no R os seguintes comandos:

```
#VaR
library(fGarch)
lambda1 <- 0.01
lambda5 <- 0.05
VaRS1 <- quantile(volS, lambda1)
VaRS1
VaRS5 <- quantile(volS, lambda5)
VaRS5

VaRE1 <- quantile(volE, lambda1)
VaRE1
VaRE5 <- quantile(volE, lambda5)
VaRE5

VaRGJR1 <- quantile(volGJR, lambda1)
VaRGJR1
VaRGJR5 <- quantile(volGJR, lambda5)
VaRGJR5

VaRT1 <- quantile(volT, lambda1)
VaRT1
VaRT5 <- quantile(volT, lambda5)
VaRT5

VaR1<-c(0.2888494,0.2192616,0.2863598,0.223046)*100
mybarcol <- "gray20"
barplot(VaR1, beside = TRUE,col = c("lightblue", "lavender",
    "mistyrose", "lightcyan"),
    legend = c("S-GARCH","E-GARCH","GJR-GARCH","T-GARCH"),
    main = "Value at Risk (VaR)", font.main = 4,sub = "Erro 1%",
    col.sub = mybarcol, ylab="% VaR",ylim= c(min(VaR1),max(VaR1)))

VaR5<-c(0.3457751,0.3158423,0.3442166,0.310018)*100
mybarcol <- "gray20"
barplot(VaR5, beside = TRUE,col = c("lightblue", "lavender",
    "mistyrose", "lightcyan"),
    legend = c("S-GARCH","E-GARCH","GJR-GARCH","T-GARCH"),
    main = "Value at Risk (VaR)", font.main = 4,sub = "Erro 5%",
    col.sub = mybarcol, ylab="% VaR",ylim= c(min(VaR5),max(VaR5)))
```

Figura 1 - Script do VaR

em que,

```
volS <- egarch.fitT@fit$var
```

```
plot(volS, type="l", xlab="tempo", ylab="volatilidades", main="S-GARCH"),
```

e assim da mesma forma para os restantes três modelos.

3.7.1 – Value at Risk das commodities em estudo

Sabendo que o Value at Risk (VaR) quantifica a perda máxima de um investimento, recorreremos a instrumentos estatísticos para estudar o erro associado, neste caso, aos preços das energias, sendo esta medida a mais utilizada para tratar os riscos nos mercados financeiros.

Relativamente ao estudo feito anteriormente a 99% e 95% de confiança, a partir da análise dos gráficos (em Anexo 7) e das respetivas tabelas, no que toca às energias gasolina, gás natural, petróleo e petróleo de aquecimento, concluímos que o modelo E-GARCH apresenta o menor VaR nos três períodos de tempo estudados, tanto a 1% como a 5%. Tomando como exemplo a gasolina na subamostra 1, num grau de confiança de 99% temos um valor VaR de 0.3117 que significa a perda em 99% dos dias, ou seja, no restante 1% o prejuízo pode ser superior a este valor.

Já no Querosene estamos perante uma situação semelhante às anteriores, no entanto o VaR do modelo T-GARCH na subamostra 2 com um nível de confiança de 95% é de 0.2883, o que nos mostra que nesta energia, T-GARCH é o modelo com o valor VaR mais baixo, logo em 95% dos dias a perda máxima é de 0.2883, o que implica que possa haver uma perda superior a esta nos restantes 5% dos dias.

Finalmente, o Propano apresenta valores do risco VaR mais baixos no modelo T-GARCH, nos três períodos de tempo em estudo, ou seja, no caso desta energia este é o modelo do tipo GARCH com menor risco associado.

Sendo o VaR uma medida de perda percentual de uma carteira sujeita aos riscos de mercado, neste caso aos riscos de flutuação dos preços das commodities, é possível com este cálculo obter o valor esperado da pior perda possível, num horizonte de tempo com um intervalo de confiança de 99% e 95%, no estudo em causa. Assim sendo e tendo em conta os dados obtidos anteriormente, podemos concluir que o modelo que apresenta menor risco no mercado das commodities é, geralmente, o modelo E-GARCH, com exceção do que acontece no Propano.

Tabela 13 - Dados do Value at Risk na Gasolina

VaR				
Subamostra 1				
	S-GARCH	E-GARCH	GJR-GARCH	T-GARCH
1%	0.3744	0.3117	0.3733	0.3316
5%	0.4452	0.4187	0.4448	0.4306
Subamostra 2				
	S-GARCH	E-GARCH	GJR-GARCH	T-GARCH
1%	0.4033	0.2799	0.3973	0.3621
5%	0.4485	0.3577	0.4422	0.4501
Amostra Completa				
	S-GARCH	E-GARCH	GJR-GARCH	T-GARCH
1%	0.3845	0.311	0.3843	0.3461
5%	0.4536	0.4146	0.4534	0.4414

Tabela 14 - Dados do Value at Risk no Gás Natural

VaR				
Subamostra 1				
	S-GARCH	E-GARCH	GJR-GARCH	T-GARCH
1%	0.7395	0.6586	0.7391	0.7531
5%	0.9307	0.8727	0.9302	0.945
Subamostra 2				
	S-GARCH	E-GARCH	GJR-GARCH	T-GARCH
1%	1.0351	0.6497	1.0319	0.7706
5%	1.2058	1.0053	1.2077	1.1192
Amostra Completa				
	S-GARCH	E-GARCH	GJR-GARCH	T-GARCH
1%	0.7696	0.6678	0.7704	0.7664
5%	0.9714	0.8975	0.9702	0.9695

Tabela 15 - Dados do Value at Risk no Petróleo

VaR				
Subamostra 1				
	S-GARCH	E-GARCH	GJR-GARCH	T-GARCH
1%	0.1862	0.1613	0.1869	0.1792
5%	0.2482	0.2372	0.2471	0.2517
Subamostra 2				
	S-GARCH	E-GARCH	GJR-GARCH	T-GARCH
1%	0.3472	0.2726	0.3608	0.3213
5%	0.4016	0.3091	0.3866	0.3663
Amostra Completa				
	S-GARCH	E-GARCH	GJR-GARCH	T-GARCH
1%	0.2052	0.1661	0.2095	0.1932
5%	0.2709	0.2502	0.2731	0.2754

Tabela 16 - Dados do Value at Risk no Petróleo de Aquecimento

VaR				
Subamostra 1				
	S-GARCH	E-GARCH	GJR-GARCH	T-GARCH
1%	0.2531	0.2112	0.2571	0.2318
5%	0.3169	0.2951	0.3194	0.3111
Subamostra 2				
	S-GARCH	E-GARCH	GJR-GARCH	T-GARCH
1%	0.2696	0.1951	0.2682	0.2075
5%	0.3014	0.2427	0.3109	0.2495
Amostra Completa				
	S-GARCH	E-GARCH	GJR-GARCH	T-GARCH
1%	0.2557	0.2114	0.2567	0.2326
5%	0.3155	0.2905	0.3164	0.3067

Tabela 17 - Dados do Value at Risk no Querosene

VaR				
Subamostra 1				
	S-GARCH	E-GARCH	GJR-GARCH	T-GARCH
1%	0.2292	0.1971	0.2277	0.2079
5%	0.3099	0.2989	0.308	0.3027
Subamostra 2				
	S-GARCH	E-GARCH	GJR-GARCH	T-GARCH
1%	0.3186	0.2192	0.3256	0.2317
5%	0.3558	0.2927	0.3582	0.2883
Amostra Completa				
	S-GARCH	E-GARCH	GJR-GARCH	T-GARCH
1%	0.2449	0.2031	0.2449	0.2178
5%	0.3267	0.3018	0.3239	0.3067

Tabela 18 - Dados do Value at Risk no Propano

VaR				
Subamostra 1				
	S-GARCH	E-GARCH	GJR-GARCH	T-GARCH
1%	0.2712	0.2001	0.2659	0.1979
5%	0.3229	0.2974	0.3182	0.2861
Subamostra 2				
	S-GARCH	E-GARCH	GJR-GARCH	T-GARCH
1%	0.7917	0.5655	0.7654	0.5521
5%	0.9006	0.7829	0.8391	0.7551
Amostra Completa				
	S-GARCH	E-GARCH	GJR-GARCH	T-GARCH
1%	0.2888	0.2193	0.2864	0.223
5%	0.3458	0.3158	0.3442	0.3101

Conclusão

A previsão do risco no mercado de commodities de energia é um assunto muito abordado ultimamente, e podemos enumerar alguns aspetos que contribuem para a necessidade de gerir e prever os riscos, sabendo que uma matéria-prima que seja considerada commodity, a partir desse momento o seu valor ou preço, passa a ser estipulado pela sua cotação no mercado, maioritariamente nas bolsas de valores, e não pelo preço de produção da mesma. Assim sendo, os mercados de commodities dependem da procura e da oferta, o que em mercados eficientes se reflete em quantidades de oferta e procura iguais.

A elaboração desta dissertação de mestrado visa expor as questões de investigação que se pretendem responder acerca do tema. O objetivo principal da minha dissertação de mestrado consiste em modelar e prever o risco de commodities no mercado de energia e, simultaneamente, efetuar um estudo comparativo da capacidade de previsão de diferentes modelos econométricos, tendo por base dados históricos do mercado em estudo, sendo estes analisados na subamostra 1, na subamostra 2 e também na amostra completa.

Inicialmente foi realizada a revisão da literatura. Seguidamente, foi utilizada uma metodologia econométrica com o intuito de estudar a previsão do risco, com modelos de avaliação de risco, para avaliar o risco no mercado das energias nomeadamente, de dados históricos diários das rendibilidades da gasolina, gás natural, petróleo, petróleo de aquecimento, querosene e propano. Os dados diários das seis energias em questão foram depois avaliados na subamostra 1, subamostra 2 e na amostra completa com o intuito principal da dissertação, estudar a volatilidade dos dados e para isso foram analisados os resultados de quatro modelos, sendo o S-GARCH, o E-GARCH, o GJR-GARCH e finalmente o T-GARCH. O standard inicialmente e posteriormente os três modelos do tipo GARCH referidos anteriormente. Com esta análise tivemos a possibilidade de, em cada caso, nomear o melhor modelo para estimar cada energia em certo período de tempo. Em conclusão podemos afirmar que, para o estudo das energias em questão, o modelo do tipo GARCH mais indicado para estudar a volatilidade dos preços diários destas, provou-se ser o T-GARCH. Por fim foi estudado o VaR (Value at Risk) dos modelos citados anteriormente para que nos fosse possível prever como os modelos irão lidar com perdas extremas no futuro, sendo que este teste é direcionado para o estudo out of sample.

Referências bibliográficas

- Ardia, D., Bluteau, K., Boudt, K., & Catania, L., (2018). "Forecasting risk with Markov-switching GARCH models: A large-scale performance study", *International Journal of Forecasting*, 34, 733-747.
- Bollerslev, T. P. (1986). "Generalized autoregressive conditional heteroscedasticity", *Journal of Econometrics*, 31, 309–328.
- Borensztein, E., & Reinhart, C. M. (1994). "The Macroeconomic Determinants of Commodity Prices", *IMF Staff Papers*, 41 (2), 236-261.
- Deaton, A., & Laroque, G. (1992). "On the Behaviour of Commodity Prices", *The Review of Economic Studies*, 59 (1), 1-23.
- Engle, R. F. (1982). "Autoregressive conditional heteroskedasticity with estimates of the variance of UK", *Econometrica*, 50, 987–1008.
- Frankel, J. A. (1986). "Expectations and commodity price dynamics: the overshooting model", *American Journal of Agricultural Economics*, 68 (2), 344.
- González-Pedraz, Moreno, Peña (2014). "Tail risk in energy portfolios", *Energy Economics*, 46, 422-434.
- Haas, M., S. Mittnik, & M. S. Paoletta. (2004b). "A New Approach to Markov Switching GARCH Models.", *Journal of Financial Econometrics*, 2 (4), 493-530.
- Hendricks, Darryl (1996). "Evaluation of value-at-risk models using historical data", *Economic Policy Review*, 2 (1), April 1996.
- Kuester, M., Mittnik, S., & Paoletta, M.S., (2006). "Value-at-Risk Prediction: A Comparison of Alternative Strategies", *Journal of Financial Econometrics*, 4 (1), 53-89.
- Makridakis, S. (1990). *Forecasting, planning and strategy for the 21st century*, New York: The Free Press.
- Samuel, Y.M.Z-t. (2008). "Value at risk and conditional extreme value theory via Markov regime switching models", *The Journal of Futures Markets*, 28 (2), 155-181.
- Taylor, S. (1986). *Modelling financial time series*, New York: John Wiley & Sons.
- Organismo oficial de Estatística do Departamento de Energia dos EUA conhecido por Energy Information Administration (EIA)

Anexos

Anexo 1 – Análise das rendibilidades da Gasolina

Tabela 19 - Gasolina – Subamostra 1

7472 observações desde 3 de Junho 1986, a 30 de Dezembro 2016	Retornos-log		Retornos ao quadrado	
Média	0.01		1.34	
Mediana	0.06		0.4	
Desvio Padrão	1.16		4.09	
Mínimo	-13.05		0	
Máximo	10.21		170.41	
Curtose	10.37683		612.8395	
Assimetria	-0.226048		19.74163	
Testes de hipótese	Estatística de teste	p-value	Estatística de teste	p-value
Jarque Bera	1.70E+04	<2.2e-16	1.16E+08	<2.2e-16
ARCH(4)	1.01E+03	0.00E+00	1.61E+02	0.00E+00
ADF	-6.08E+01	<2.2e-16	-4.52E+01	<2.2e-16
Ljung Box (lag=10)	48.973	4.12E-07	1153.1	<2.2e-16
Ljung Box (lag=20)	93.171	2.06E-11	1291.6	<2.2e-16
AR(1)				
Ljung Box (lag=10)	21.755	1.64E-02	1127	<2.2e-16
Ljung Box (lag=20)	63.361	2.12E-06	1281.3	<2.2e-16

Tabela 20 – Gasolina – Subamostra 2

912 observações desde 3 de Janeiro 2017, a 14 de Setembro 2020	Retornos-log		Retornos ao quadrado	
Média	-0.02		2.03	
Mediana	0.05		0.31	
Desvio Padrão	1.43		10.31	
Mínimo	-13.02		0	
Máximo	9.65		169.59	
Curtose	26.60497		164.4487	
Assimetria	-1.484774		11.78035	
Testes de hipótese	Estatística de teste	p-value	Estatística de teste	p-value
Jarque Bera	2.15E+04	<2.2e-16	1.01E+06	<2.2e-16
ARCH(4)	1.45E+02	0.00E+00	4.61E+01	2.34E-09
ADF	-2.06E+01	<2.2e-16	-1.35E+01	<2.2e-16
Ljung Box (lag=10)	46.244	1.30E-06	576.77	<2.2e-16
Ljung Box (lag=20)	88.385	1.42E-10	705.16	<2.2e-16
AR(1)				
Ljung Box (lag=10)	18.539	4.65E-02	473.48	<2.2e-16
Ljung Box (lag=20)	56.909	2.12E-05	774.16	<2.2e-16

Subamostra 1

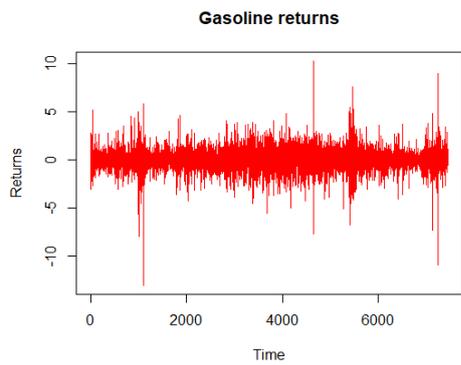


Gráfico 49 - Retornos da Gasolina entre 3 de junho de 1986 a 30 de dezembro de 2016

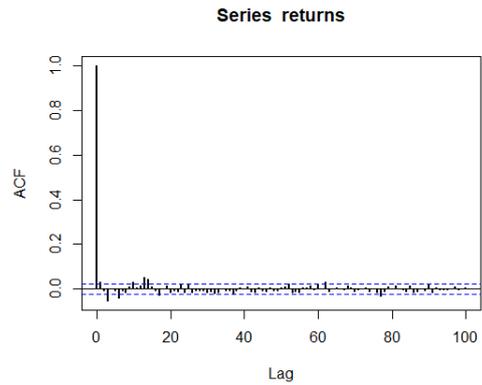


Gráfico 50 – Autocorrelação da série de retornos

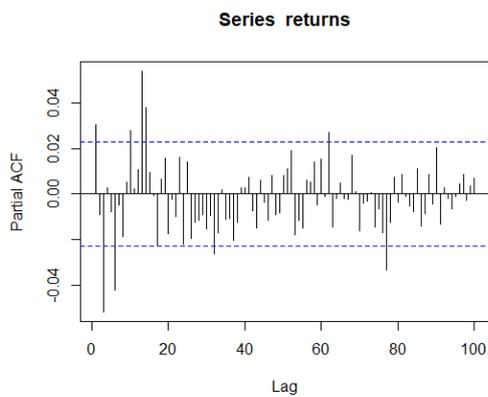


Gráfico 51 – Autocorrelação parcial da série de retornos

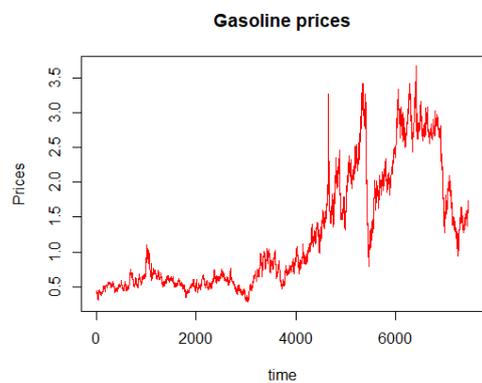


Gráfico 52 - Preços da Gasolina entre 3 de junho de 1986 a 30 de dezembro de 2016

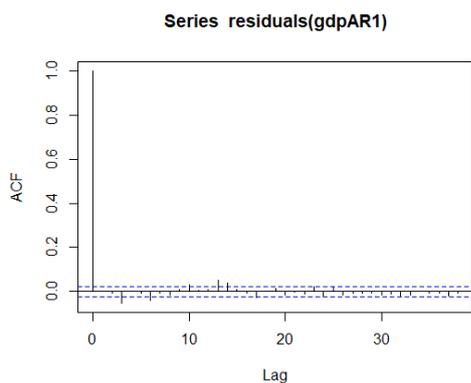


Gráfico 53 - Autocorrelação da série de retornos, pós eliminação de autocorrelação

Subamostra 2

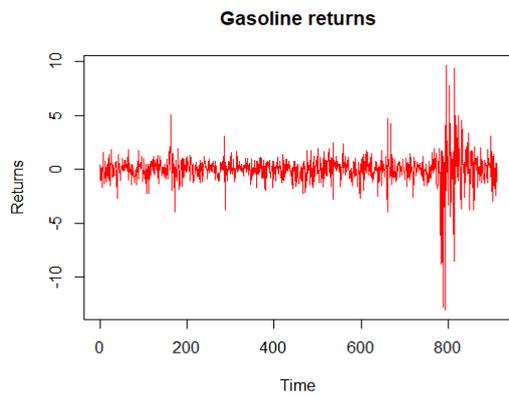


Gráfico 54 - Retornos da Gasolina entre 3 de janeiro de 2017 e 14 de setembro de 2020

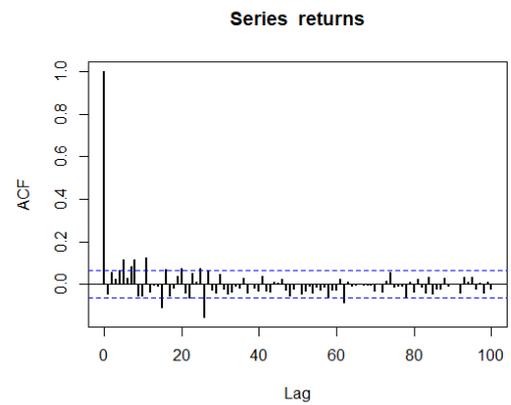


Gráfico 55 - Autocorrelação da série de retornos

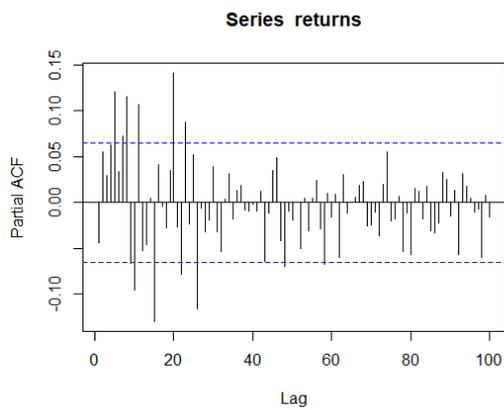


Gráfico 56 - Autocorrelação parcial da série de retornos

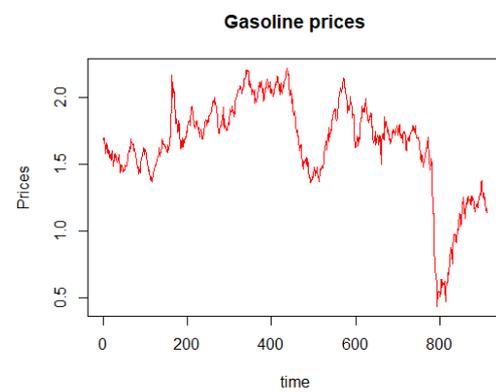


Gráfico 57 - Preços da Gasolina entre 3 de janeiro de 2017 e 14 de setembro de 2020

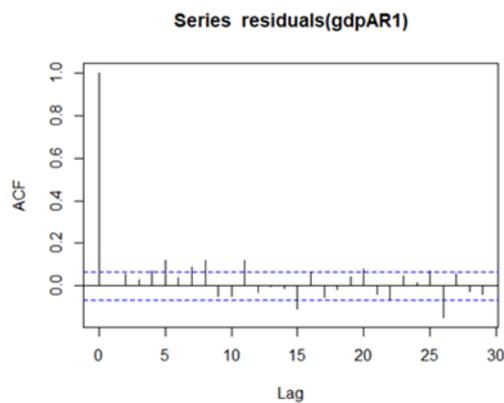


Gráfico 58 - Autocorrelação da série de retornos, pós eliminação de autocorrelação

Estudo da volatilidade da Gasolina na subamostra 1

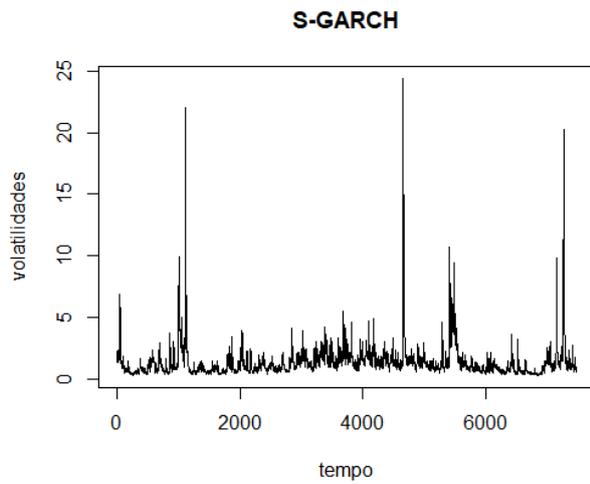


Gráfico 59 - Volatilidades da Gasolina no modelo S-GARCH

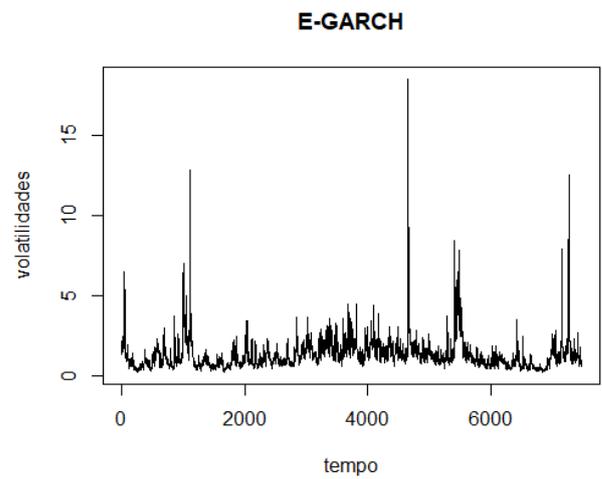


Gráfico 60 - Volatilidades da Gasolina no modelo E-GARCH

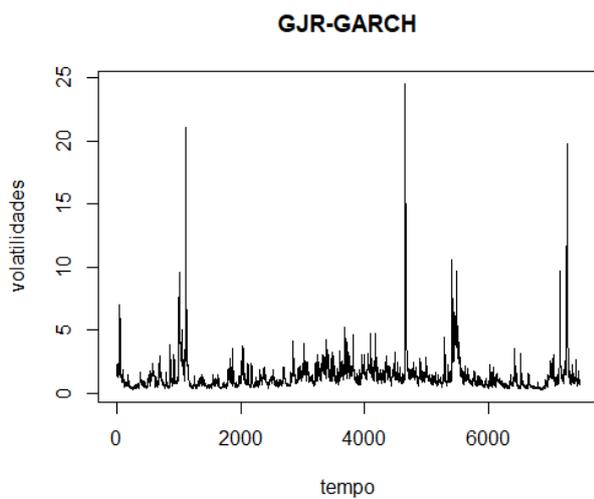


Gráfico 61 - Volatilidades da Gasolina no modelo GJR-GARCH

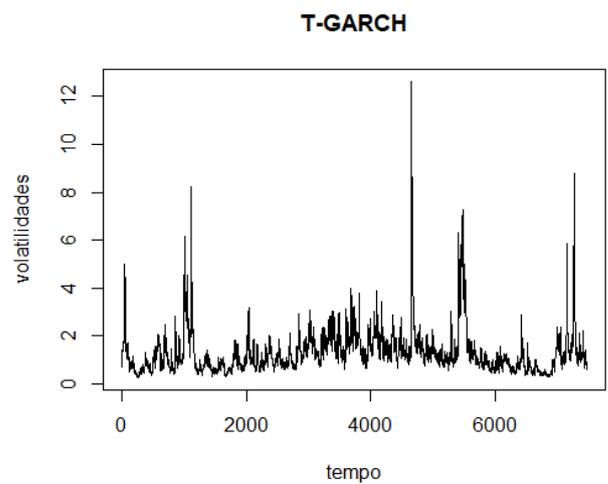


Gráfico 62 - Volatilidades da Gasolina no modelo T-GARCH

Estudo da volatilidade da Gasolina na subamostra 2

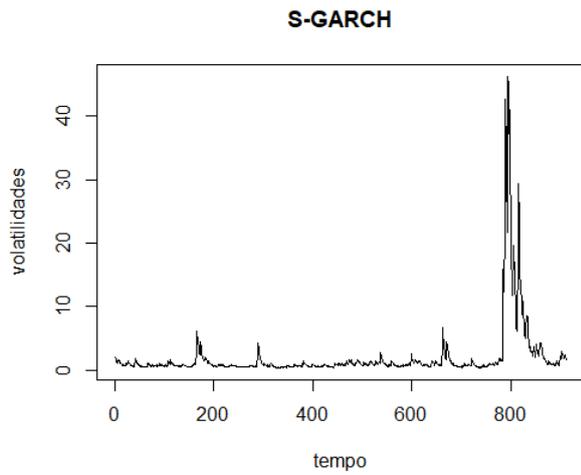


Gráfico 63 - Volatilidades da Gasolina no modelo S-GARCH

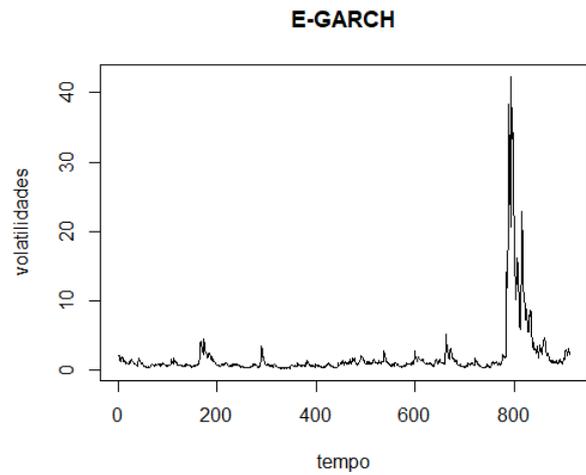


Gráfico 64 - Volatilidades da Gasolina no modelo E-GARCH

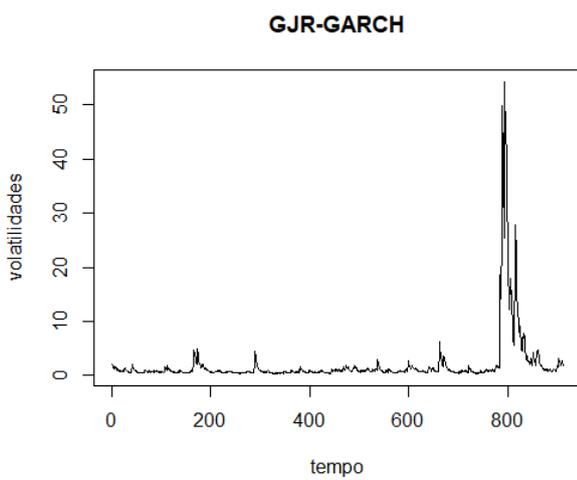


Gráfico 65 - Volatilidades da Gasolina no modelo GJR-GARCH

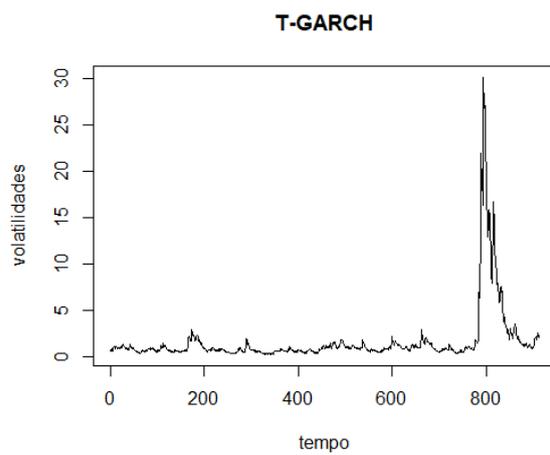


Gráfico 66 - Volatilidades da Gasolina no modelo T-GARCH

Anexo 2 – Análise das rendibilidades do Gás Natural

Tabela 21 – Gás Natural – Subamostra 1

784 observações desde 8 de Janeiro 1997, a 29 de Dezembro 2016	Retornos-log		Retornos ao quadrado	
Média	0		4.05	
Mediana	0.05		0.91	
Desvio Padrão	2.01		18.38	
Mínimo	-24.68		0	
Máximo	25.04		627.21	
Curtose	21.56		599.1	
Assimetria	0.58		20.72	
Testes de hipótese	Estatística de teste	p-value	Estatística de teste	p-value
Jarque Bera	6.65E+04	<2.2e-16	6.86E+07	<2.2e-16
ARCH(4)	2.02E+03	0.00E+00	1.48E+03	5.39E-10
ADF	-5.68E+01	<2.2e-16	-2.58E+01	<2.2e-16
Ljung Box (lag=10)	194.9	<2.2e-16	2122.4	<2.2e-16
Ljung Box (lag=20)	212.49	1.24E-14	2243.7	<2.2e-16
AR(1)				
Ljung Box (lag=10)	193.08	<2.2e-16	2042.1	<2.2e-16
Ljung Box (lag=20)	210.52	<2.2e-16	2160.1	<2.2e-16

Tabela 22 - Gás Natural – Subamostra 2

784 observações desde 3 de Janeiro 2017, a 15 de Setembro 2020	Retornos-log		Retornos ao quadrado	
Média	-0.03		5.9	
Mediana	-0.15		0.92	
Desvio Padrão	2.43		29.18	
Mínimo	-20.66		0.01	
Máximo	22.82		520.56	
Curtose	22.36		187.2561	
Assimetria	0.18		12.36594	
Testes de hipótese	Estatística de teste	p-value	Estatística de teste	p-value
Jarque Bera	1.64E+04	<2.2e-16	1.13E+06	<2.2e-16
ARCH(4)	3.35E+02	0.00E+00	1.77E+02	0.00+00
ADF	-2.47E+01	<2.2e-16	-1.08E+01	<2.2e-16
Ljung Box (lag=10)	107.11	<2.2e-16	458.69	<2.2e-16
Ljung Box (lag=20)	111.08	1.24E-14	459.21	<2.2e-16
AR(1)				
Ljung Box (lag=10)	6.5952	7.63E-01	150.44	<2.2e-16
Ljung Box (lag=20)	15.096	7.71E-01	151.04	<2.2e-16

Subamostra 1

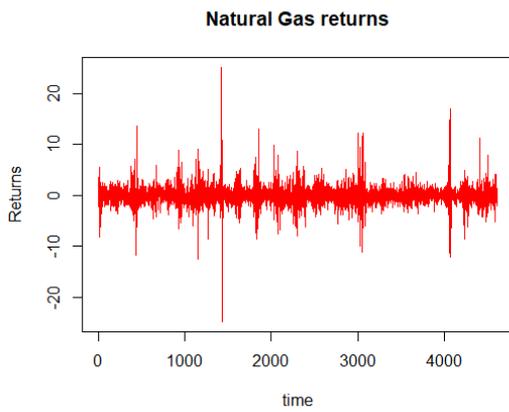


Gráfico 67 - Retornos do Gás Natural entre 8 de janeiro de 1997 e 29 de dezembro de 2016

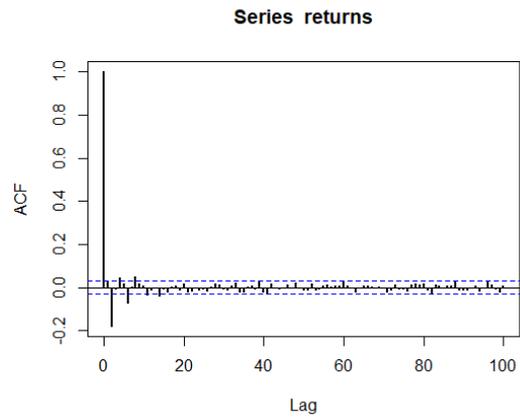


Gráfico 68 – Autocorrelação da série de retornos

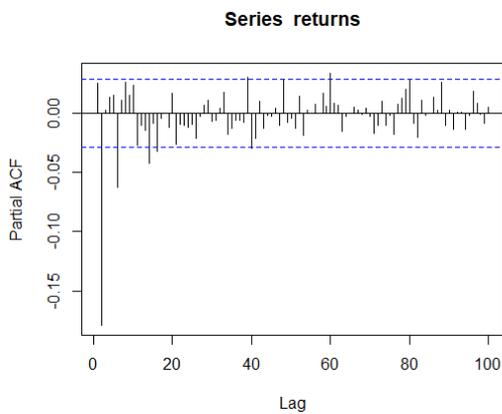


Gráfico 69 – Autocorrelação parcial da série de retornos

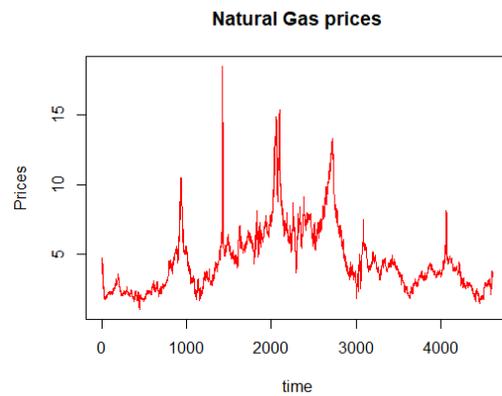


Gráfico 70 – Preços do Gás Natural entre 8 de janeiro de 1997 e 29 de dezembro de 2016

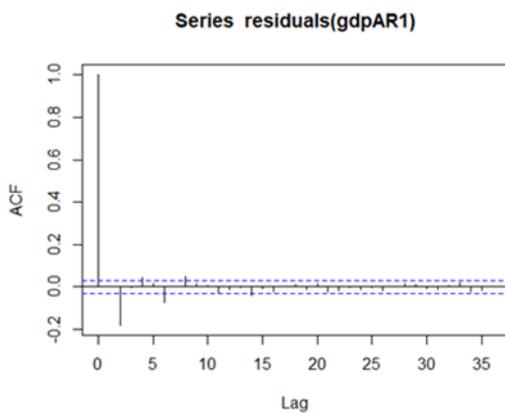


Gráfico 71 – Autocorrelação da série de retornos pós eliminação da autocorrelação

Subamostra 2

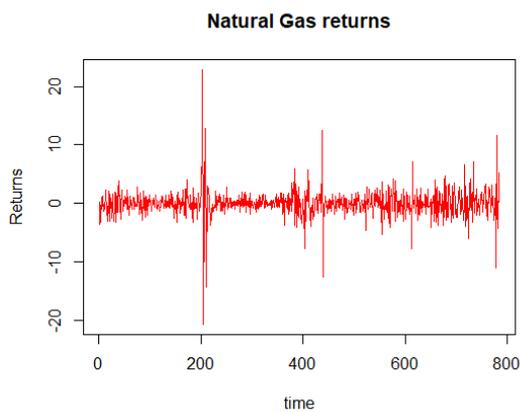


Gráfico 72 - Retornos do Gás Natural entre 3 de janeiro de 2017 e 15 de setembro de 2020

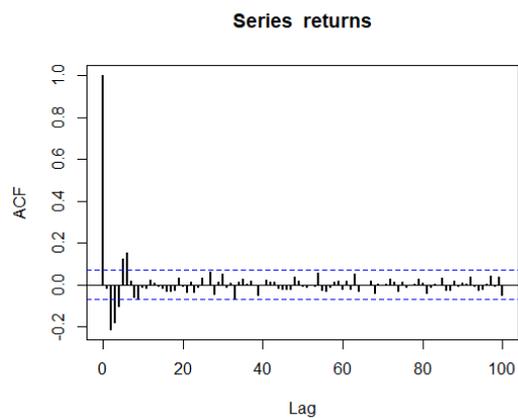


Gráfico 73 – Autocorrelação da série de retornos

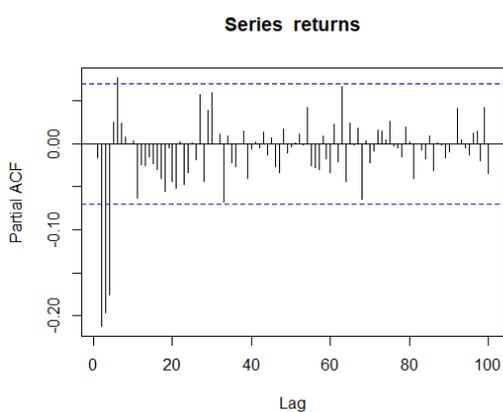


Gráfico 74 – Autocorrelação parcial da série de retornos

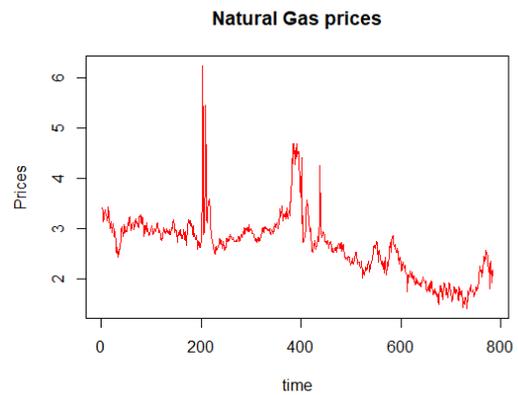


Gráfico 75 – Preços do Gás Natural entre 3 de janeiro de 2017 e 15 de setembro de 2020

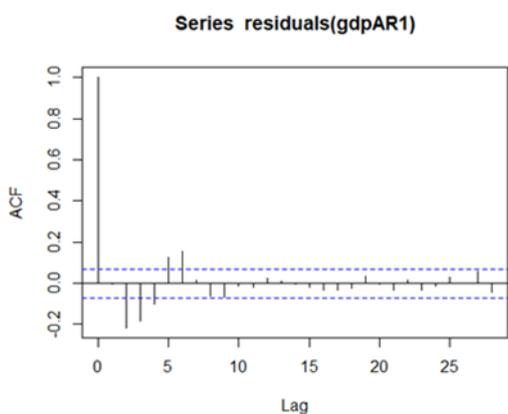


Gráfico 76 – Autocorrelação da série de retornos, pós eliminação de autocorrelação

Estudo da volatilidade do Gás Natural na subamostra 1

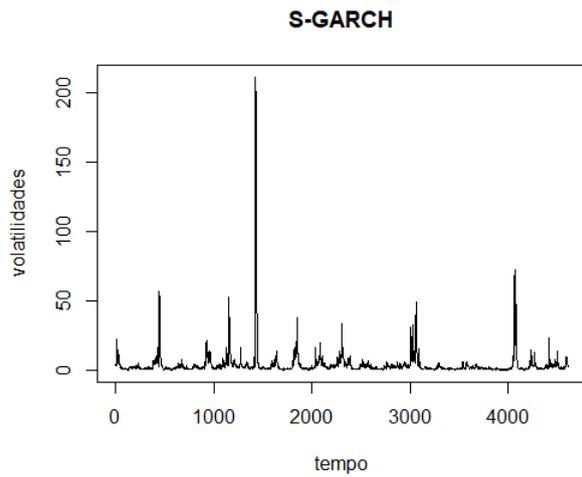


Gráfico 77 - Volatilidades do Gás Natural no modelo S-GARCH

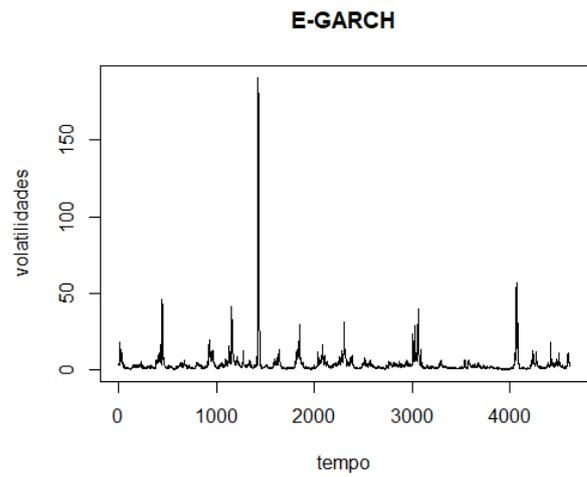


Gráfico 78 - Volatilidades do Gás Natural no modelo E-GARCH

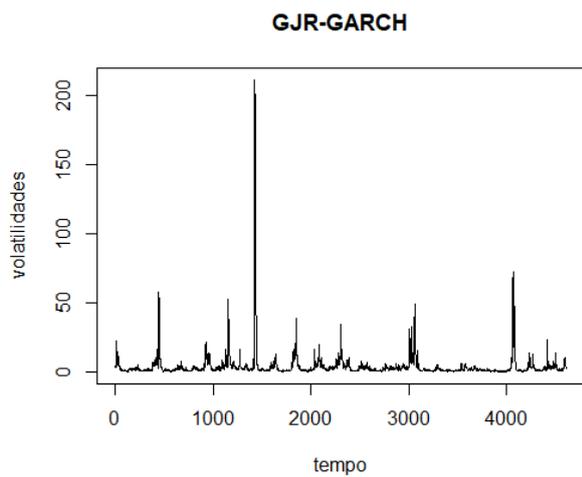


Gráfico 79 - Volatilidades do Gás Natural no modelo GJR-GARCH

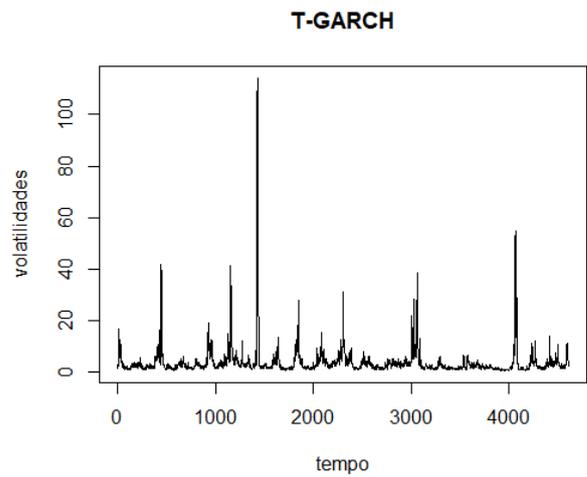


Gráfico 80 - Volatilidades do Gás Natural no modelo T-GARCH

Estudo da volatilidade do Gás Natural na subamostra 2

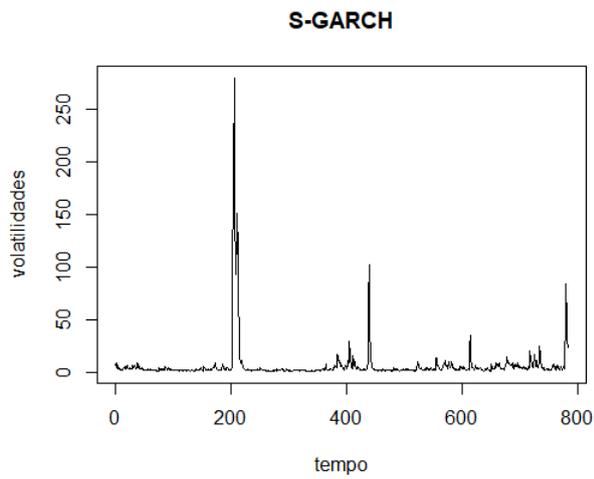


Gráfico 81 - Volatilidades do Gás Natural no modelo S-GARCH

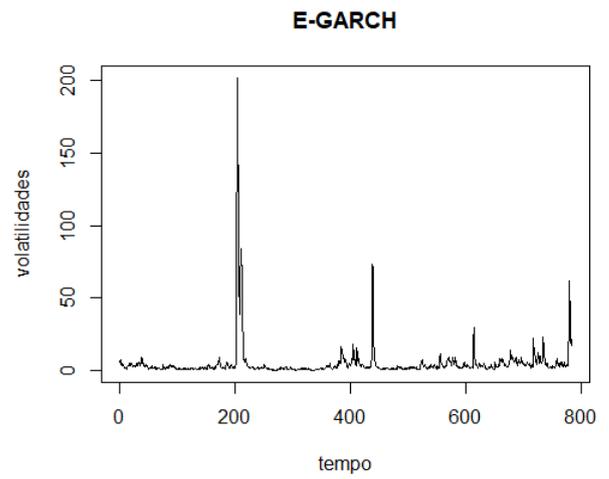


Gráfico 82 - Volatilidades do Gás Natural no modelo E-GARCH

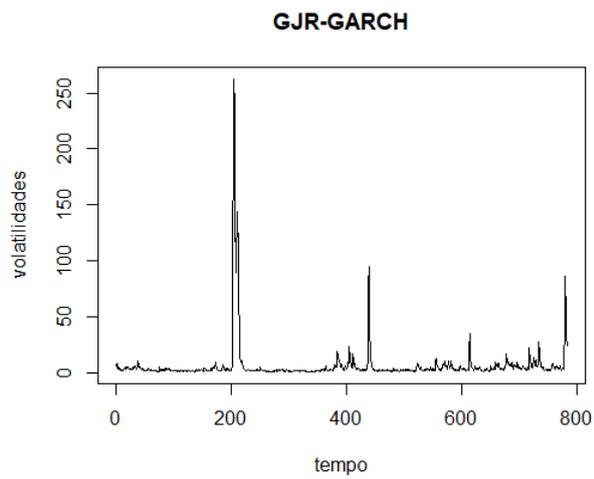


Gráfico 83 - Volatilidades do Gás Natural no modelo GJR-GARCH

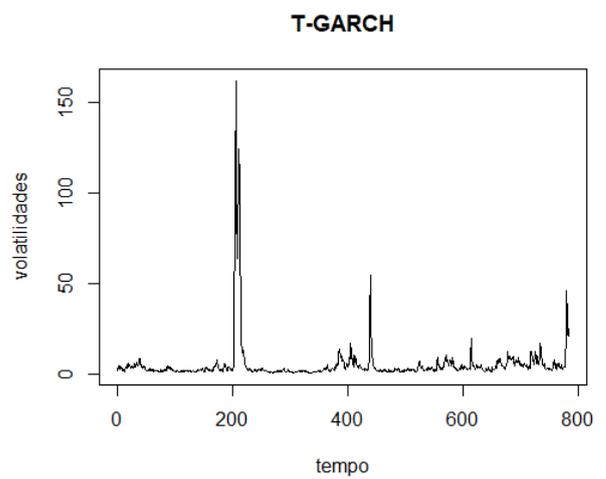


Gráfico 84 - Volatilidades do Gás Natural no modelo T-GARCH

Anexo 3 – Análise das rendibilidades do Petróleo

Tabela 23 - Petróleo – Subamostra 1

7341 observações desde 21 de Maio 1987, a 30 de Dezembro 2016	Retornos-log		Retornos ao quadrado	
Média	0.01		1.02	
Mediana	0.03		0.27	
Desvio Padrão	1.01		3.99	
Mínimo	-15.69		0	
Máximo	7.87		246.09	
Curtose	16.29227		1994.9	
Assimetria	-0.5364008		35.6337	
Testes de hipótese	Estatística de teste	p-value	Estatística de teste	p-value
Jarque Bera	5.44E+04	<2.2e-16	1.22E+09	<2.2e-16
ARCH(4)	4.02E+02	0.00E+00	2.69E+00	6.10E-01
ADF	-6.02E+01	<2.2e-16	-5.05E+01	<2.2e-16
Ljung Box (lag=10)	39.282	2.27E-05	787.06	<2.2e-16
Ljung Box (lag=20)	76.461	1.55E-08	931.69	<2.2e-16
AR(1)				
Ljung Box (lag=10)	26.463	3.16E-03	778.07	<2.2e-16
Ljung Box (lag=20)	60.966	5.04E-06	922.81	<2.2e-16

Tabela 24 - Petróleo – Subamostra 2

908 observações desde 3 de Janeiro 2017, a 14 de Setembro 2020	Retornos-log		Retornos ao quadrado	
Média	-0.02		3.13	
Mediana	0.05		0.25	
Desvio Padrão	1.77		29.41	
Mínimo	-27.96		0	
Máximo	17.89		781.51	
Curtose	89.20716		545.2963	
Assimetria	-3.333858		21.76238	
Testes de hipótese	Estatística de teste	p-value	Estatística de teste	p-value
Jarque Bera	2.90E+05	<2.2e-16	1.15E+07	<2.2e-16
ARCH(4)	1.37E+02	0.00E+00	2.48E+01	5.43E-05
ADF	-2.44E+01	<2.2e-16	-1.84E+01	<2.2e-16
Ljung Box (lag=10)	55.064	3.07E-08	200.36	<2.2e-16
Ljung Box (lag=20)	101.8	6.00E-13	289.11	<2.2e-16
AR(1)				
Ljung Box (lag=10)	29.772	9.33E-04	154.72	<2.2e-16
Ljung Box (lag=20)	61.276	4.51E-06	271.07	<2.2e-16

Subamostra 1

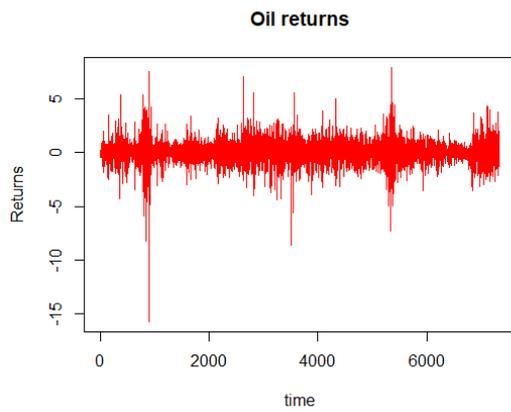


Gráfico 85 – Retornos do Petróleo entre 21 de maio de 1987 e 30 de dezembro de 2016

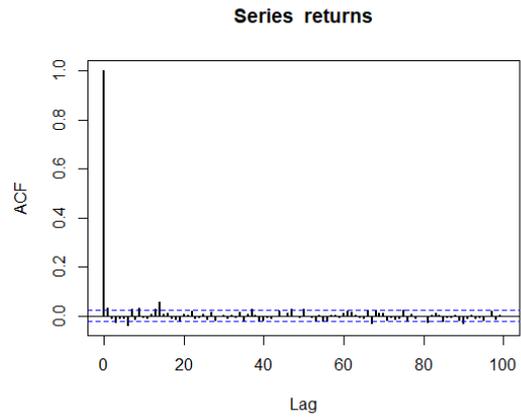


Gráfico 86 - Autocorrelação da série de retornos

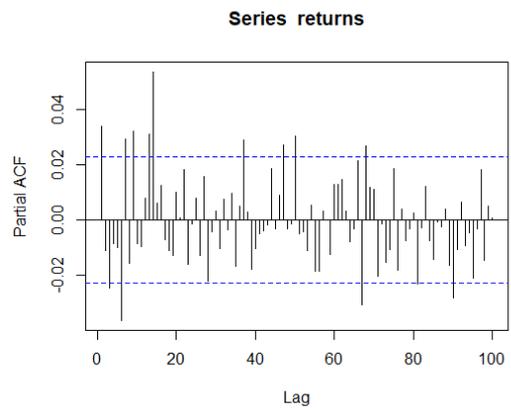


Gráfico 87 – Autocorrelação parcial da série de retornos

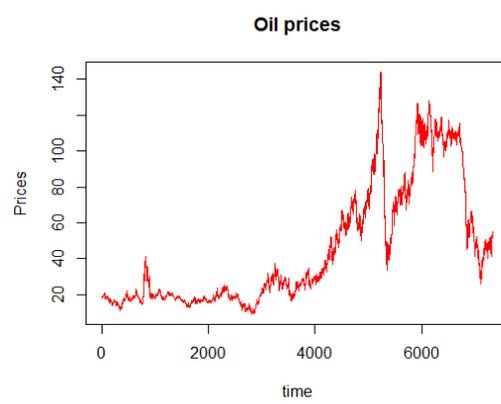


Gráfico 88 – Preços do Petróleo entre 21 de maio de 1987 e 30 de dezembro de 2016

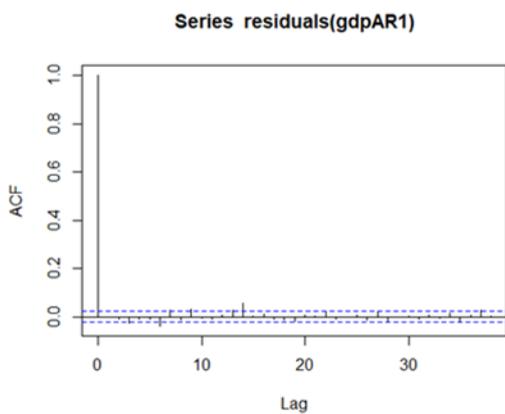


Gráfico 89 - Autocorrelação da série de retornos, pós eliminação de autocorrelação

Subamostra 2

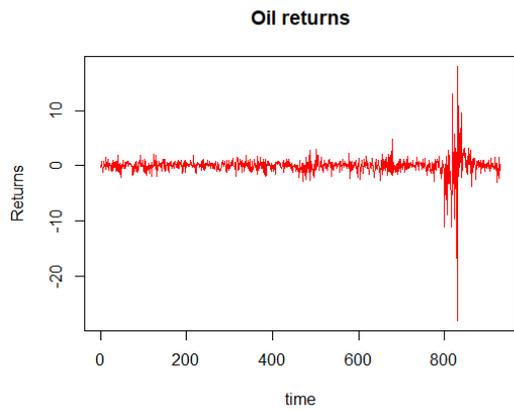


Gráfico 90 – Retornos do Petróleo entre 3 de janeiro de 2017 e 14 de setembro de 2020

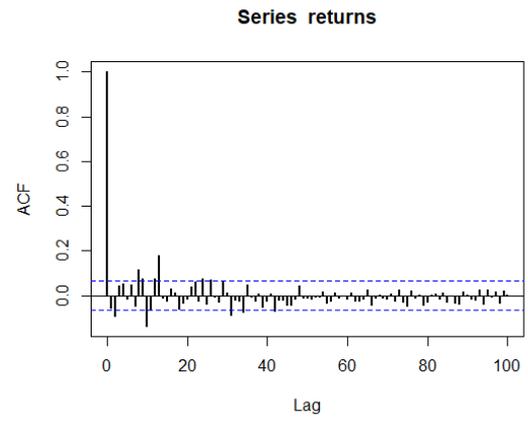


Gráfico 91 - Autocorrelação da série de retornos

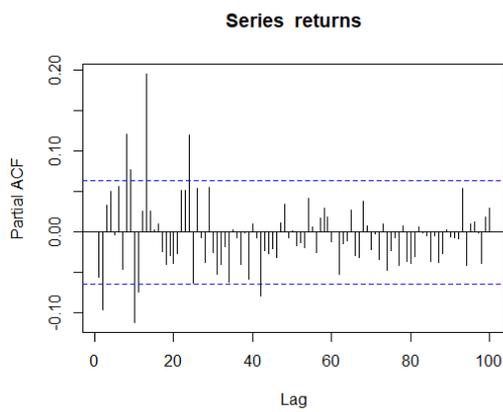


Gráfico 92 – Autocorrelação parcial da série de retornos

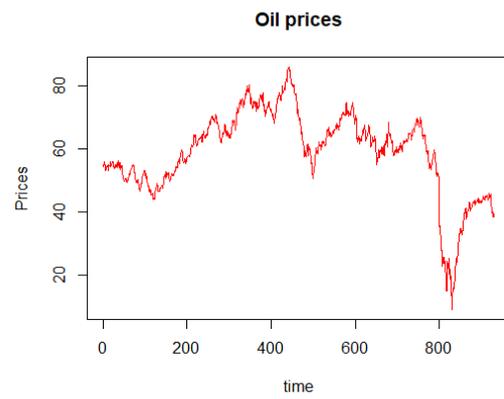


Gráfico 93 – Preços do Petróleo entre 3 de janeiro de 2017 e 14 de setembro de 2020

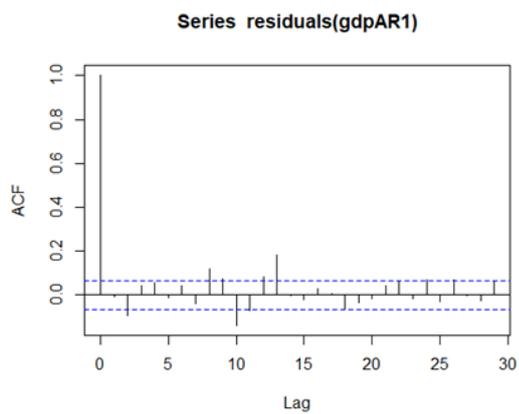


Gráfico 94 - Autocorrelação da série de retornos, pós eliminação de autocorrelação

Estudo da volatilidade do Petróleo na subamostra 1

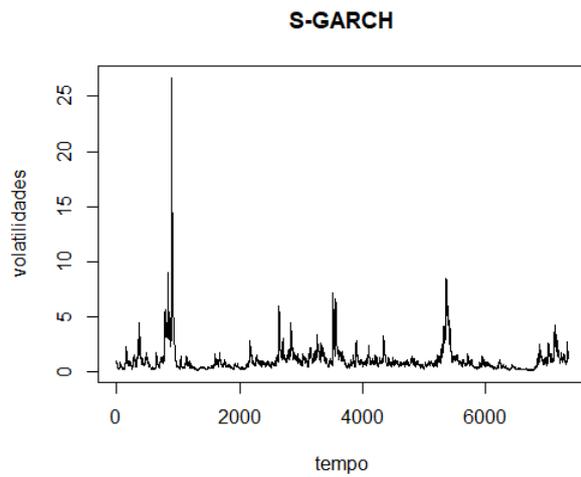


Gráfico 95 - Volatilidades do Petróleo no modelo S-GARCH

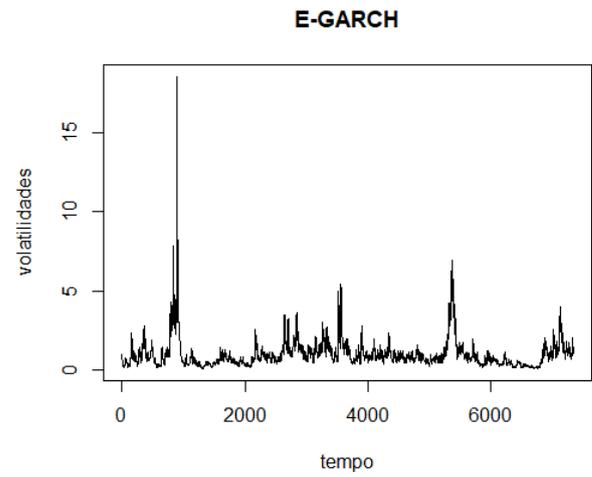


Gráfico 96 - Volatilidades do Petróleo no modelo E-GARCH

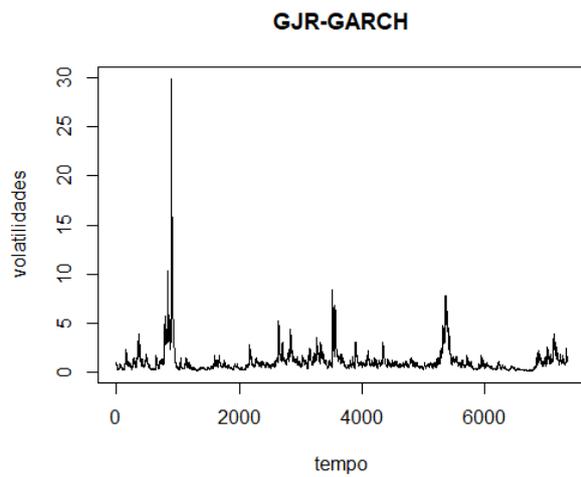


Gráfico 97 - Volatilidades do Petróleo no modelo GJR-GARCH

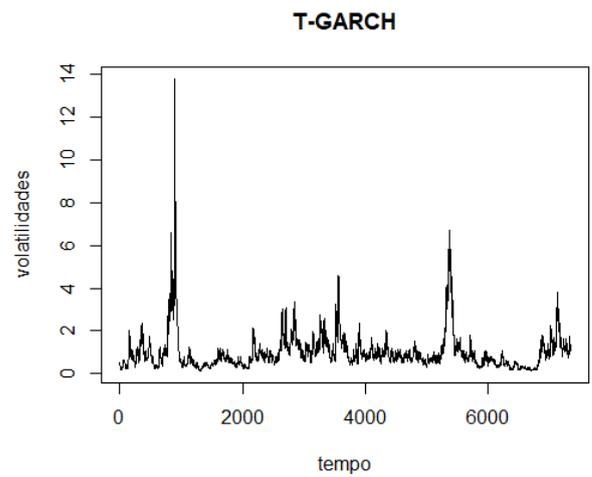


Gráfico 98 - Volatilidades do Petróleo no modelo T-GARCH

Estudo da volatilidade do Petróleo na subamostra 2

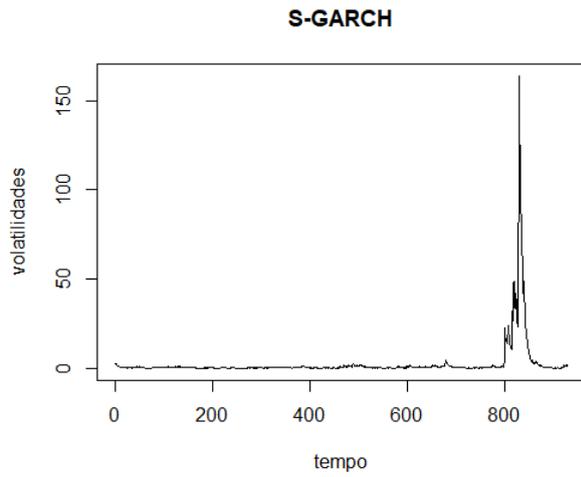


Gráfico 99 - Volatilidades do Petróleo no modelo S-GARCH

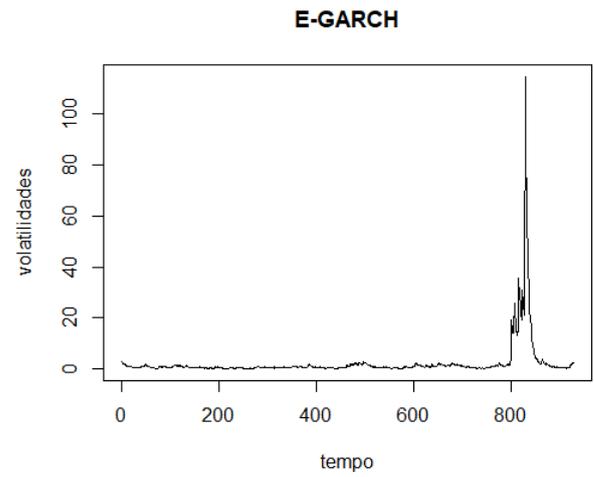


Gráfico 100 - Volatilidades do Petróleo no modelo E-GARCH

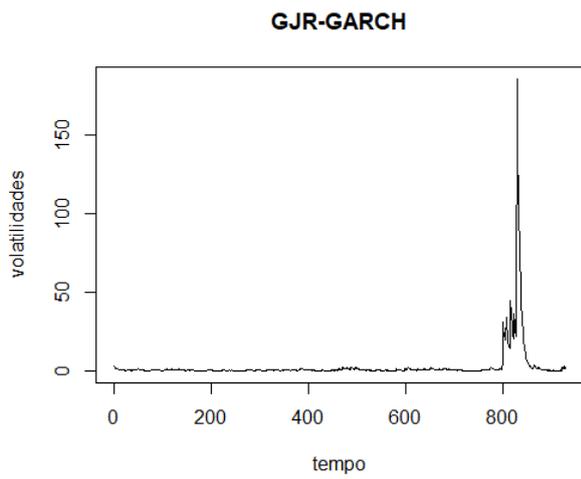


Gráfico 101 - Volatilidades do Petróleo no modelo GJR-GARCH

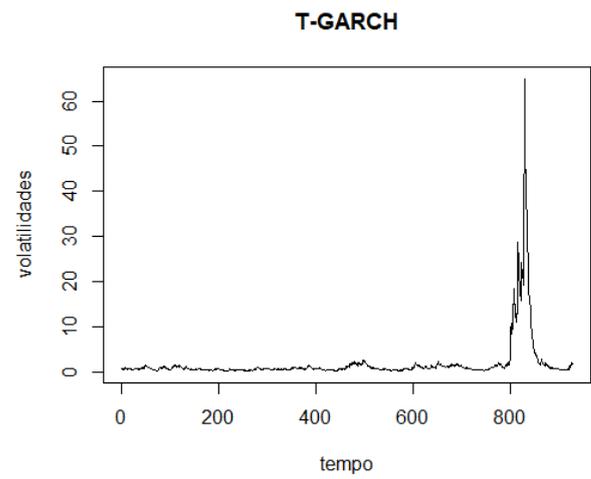


Gráfico 102 - Volatilidades do Petróleo no modelo T-GARCH

Anexo 4 – Análise das rendibilidades do Petróleo de Aquecimento

Tabela 25 - Petróleo de Aquecimento – Subamostra 1

7416 observações desde 3 de Junho 1986, a 30 de Dezembro 2016	Retornos-log		Retornos ao quadrado	
Média	0.01		1.25	
Mediana	0.04		0.32	
Desvio Padrão	1.12		7.46	
Mínimo	-20.42		0	
Máximo	9.97		416.85	
Curtose	36.87		1878.47	
Assimetria	-1.41		39.29	
Testes de hipótese	Estatística de teste	p-value	Estatística de teste	p-value
Jarque Bera	3.57E+05	<2.2e-16	1.09E+09	<2.2e-16
ARCH(4)	1.12E+06	0.00E+00	4.92E+01	5.39E-10
ADF	-6.00E+05	<2.2e-16	-4.66E+01	<2.2e-16
Ljung Box (lag=10)	47.73	6.95E-07	1902.4	<2.2e-16
Ljung Box (lag=20)	57.64	1.64E-05	2077.8	<2.2e-16
AR(1)				
Ljung Box (lag=10)	14.895	1.36E-01	1903.5	<2.2e-16
Ljung Box (lag=20)	26.106	1.62E-01	2098.9	<2.2e-16

Tabela 26 - Petróleo de Aquecimento – Subamostra 2

908 observações desde 3 de Janeiro 2017, a 14 de Setembro 2020	Retornos-log		Retornos ao quadrado	
Média	-0.02		1.13	
Mediana	0.05		0.22	
Desvio Padrão	0.04		0.14	
Mínimo	-8.02		0	
Máximo	4.86		64.27	
Curtose	11.61		117.1	
Assimetria	-1.02		9.71	
Testes de hipótese	Estatística de teste	p-value	Estatística de teste	p-value
Jarque Bera	5.28E+04	<2.2e-16	5.35E+05	<2.2e-16
ARCH(4)	2.32E+06	0.00E+00	5.70E+06	5.39E-10
ADF	-2.16E+05	<2.2e-16	-1.49E+05	<2.2e-16
Ljung Box (lag=10)	14.989	1.33E-01	463.77	<2.2e-16
Ljung Box (lag=20)	22.535	3.12E-01	761.97	<2.2e-16
AR(1)				
Ljung Box (lag=10)	11.637	3.10E-01	473.48	<2.2e-16
Ljung Box (lag=20)	18.689	5.42E-01	774.16	<2.2e-16

Subamostra 1

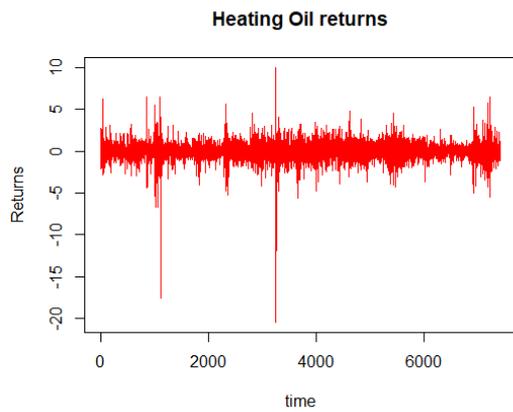


Gráfico 103 - Retornos do Petróleo de Aquecimento entre 3 de junho de 1986 e 30 de dezembro de 2016

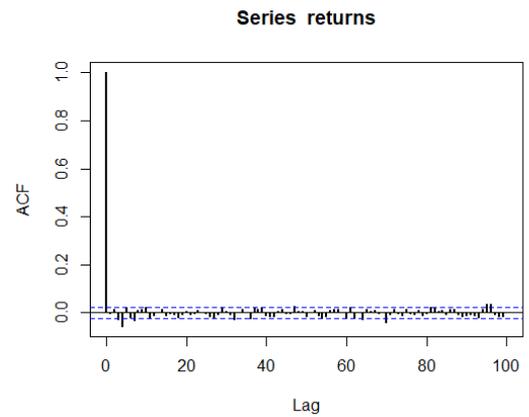


Gráfico 104 - Autocorrelação da série de retornos

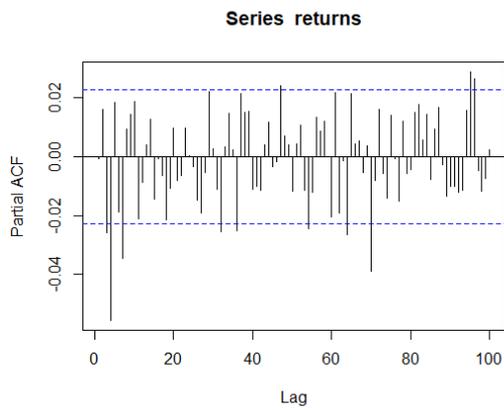


Gráfico 105 – Autocorrelação parcial da série de retornos

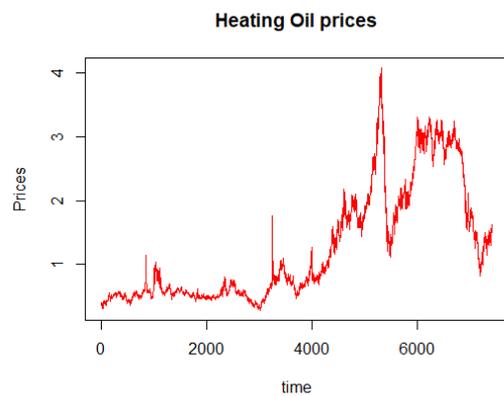


Gráfico 106 – Preços do Petróleo de Aquecimento entre 3 de junho de 1986 e 30 de dezembro de 2016

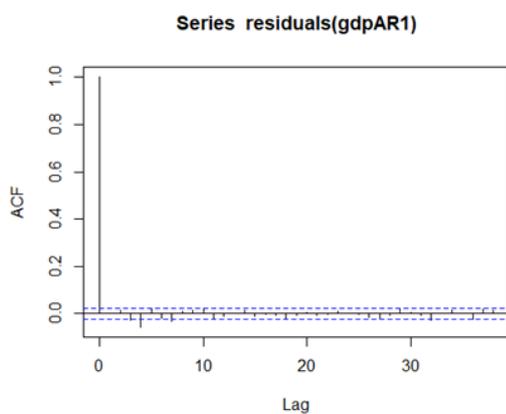


Gráfico 107 - Autocorrelação da série de retornos, pós eliminação de autocorrelação

Subamostra 2

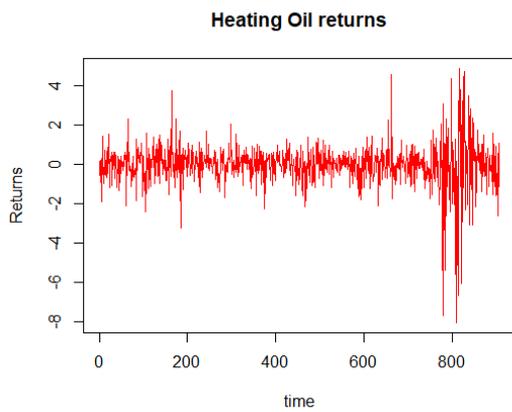


Gráfico 108 - Retornos do Petróleo de Aquecimento entre 3 de janeiro de 2017 e 14 de setembro de 2020

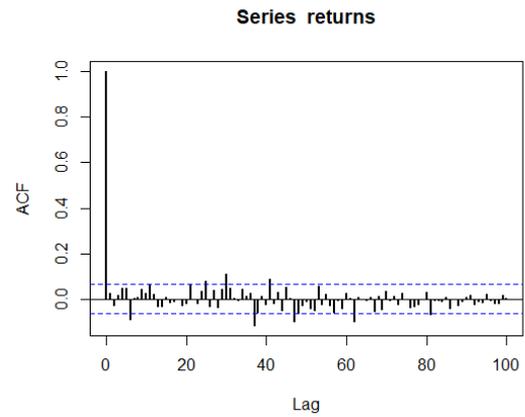


Gráfico 109 - Autocorrelação da série de retornos

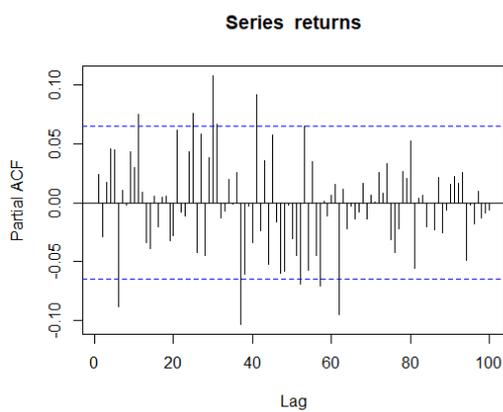


Gráfico 110 – Autocorrelação parcial da série de retornos

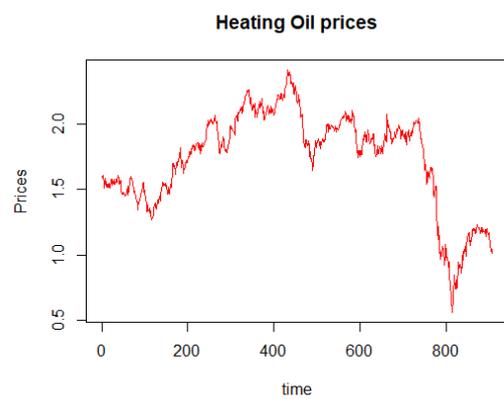


Gráfico 111 – Preços do Petróleo de Aquecimento entre 3 de janeiro de 2017 e 14 de setembro de 2020

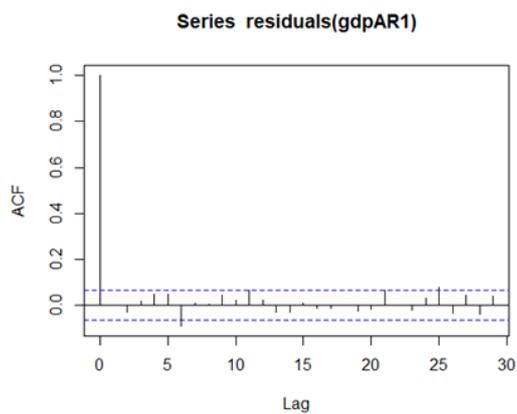


Gráfico 112 - Autocorrelação da série de retornos, pós eliminação de autocorrelação

Estudo da volatilidade do Petróleo de Aquecimento na subamostra 1

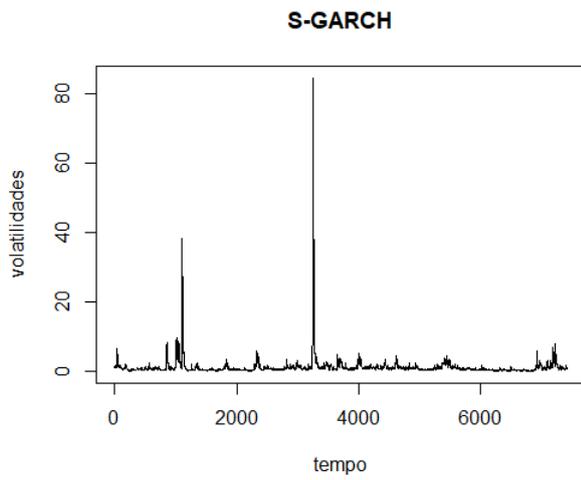


Gráfico 113 - Volatilidades do Petróleo de Aquecimento no modelo S-GARCH

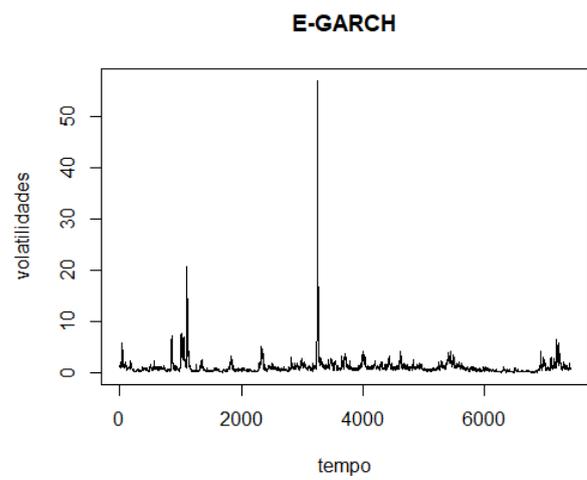


Gráfico 114 - Volatilidades do Petróleo de Aquecimento no modelo E-GARCH

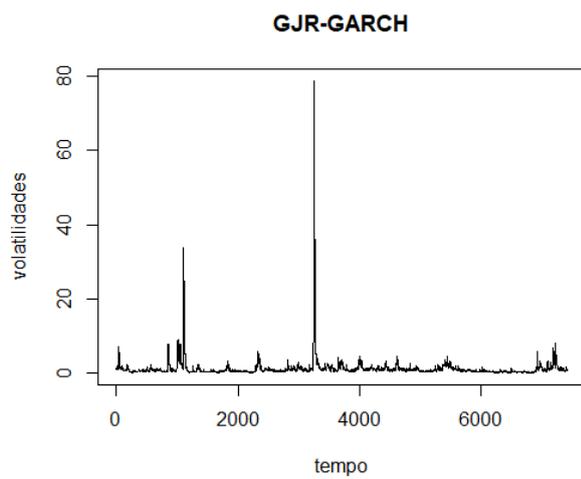


Gráfico 115 - Volatilidades do Petróleo de Aquecimento no modelo GJR-GARCH

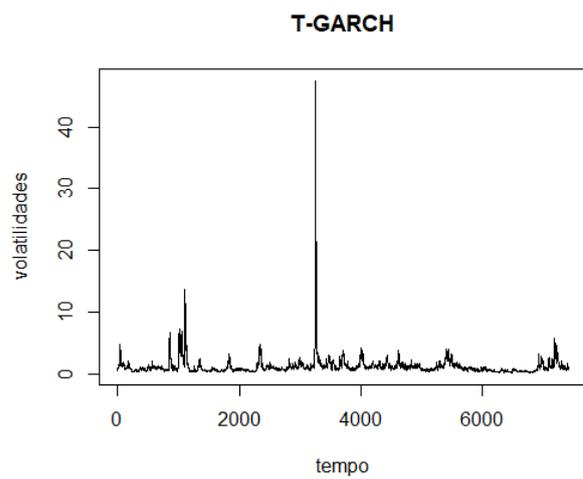


Gráfico 116 - Volatilidades do Petróleo de Aquecimento no modelo T-GARCH

Estudo da volatilidade do Petróleo de Aquecimento na subamostra 2

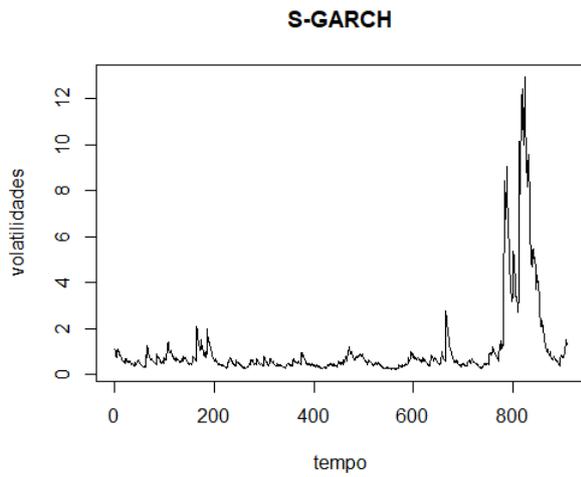


Gráfico 117 - Volatilidades do Petróleo de Aquecimento no modelo S-GARCH

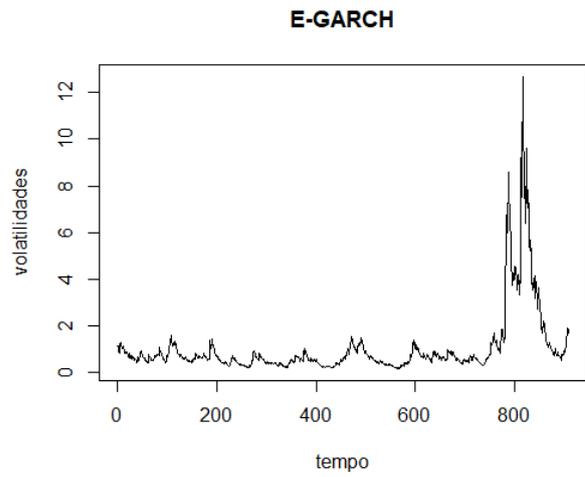


Gráfico 118 - Volatilidades do Petróleo de Aquecimento no modelo E-GARCH

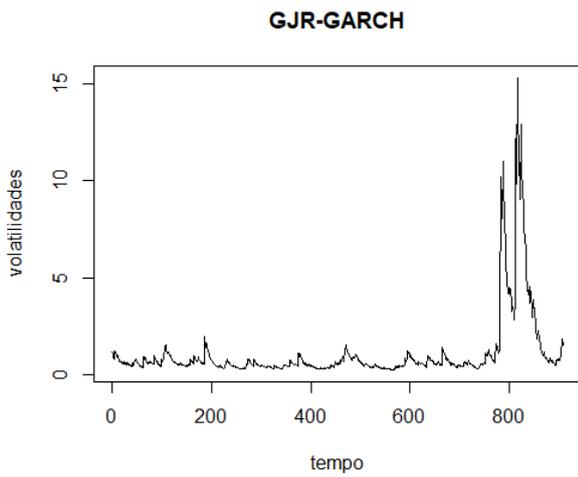


Gráfico 119 - Volatilidades do Petróleo de Aquecimento no modelo GJR-GARCH

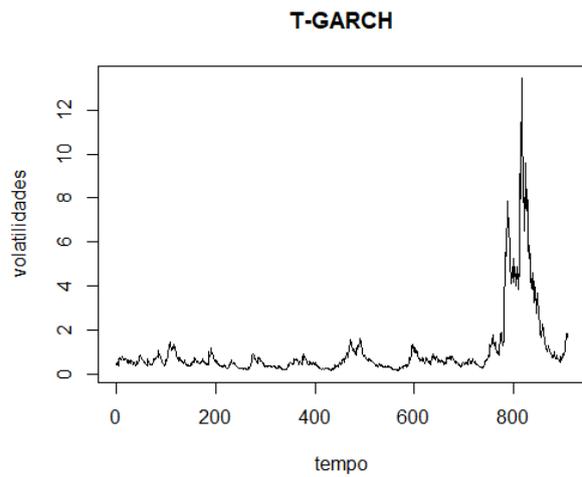


Gráfico 120 - Volatilidades do Petróleo de Aquecimento no modelo T-GARCH

Anexo 5 – Análise das rendibilidades do Querosene

Tabela 27 - Querosene – Subamostra 1

6542 observações desde 3 de Abril 1990, a 30 de Dezembro 2016	Retornos-log		Retornos ao quadrado	
Média	0.01		1.28	
Mediana	0.03		0.33	
Desvio Padrão	1.13		5.43	
Mínimo	-16.4		0	
Máximo	14.18		268.88	
Curtose	18.95251		1270.85	
Assimetria	-0.4689514		30.30151	
Testes de hipótese	Estatística de teste	p-value	Estatística de teste	p-value
Jarque Bera	6.96E+04	<2.2e-16	4.39E+08	<2.2e-16
ARCH(4)	7.49E+02	0.00E+00	1.01E+02	0.00E+00
ADF	-5.88E+01	<2.2e-16	-4.21E+01	<2.2e-16
Ljung Box (lag=10)	30.376	7.43E-04	875.12	<2.2e-16
Ljung Box (lag=20)	52.081	1.11E-04	1017.1	<2.2e-16
AR(1)				
Ljung Box (lag=10)	15.654	1.10E-01	845.2	<2.2e-16
Ljung Box (lag=20)	35.366	1.82E-02	995.73	<2.2e-16

Tabela 28 - Querosene – Subamostra 2

909 observações desde 3 de Janeiro 2017, a 14 de Setembro 2020	Retornos-log		Retornos ao quadrado	
Média	-0.02		1.57	
Mediana	0.03		0.25	
Desvio Padrão	1.25		7.05	
Mínimo	-12.21		0	
Máximo	6.66		148.97	
Curtose	21.09112		234.9079	
Assimetria	-1.170853		13.1248	
Testes de hipótese	Estatística de teste	p-value	Estatística de teste	p-value
Jarque Bera	1.26E+04	<2.2e-16	2.06E+06	<2.2e-16
ARCH(4)	1.83E+02	0.00E+00	2.66E+00	6.16E-01
ADF	-2.18E+01	<2.2e-16	-1.49E+01	<2.2e-16
Ljung Box (lag=10)	53.379	6.33E-08	413.2	<2.2e-16
Ljung Box (lag=20)	83.567	9.66E-10	699.01	<2.2e-16
AR(1)				
Ljung Box (lag=10)	11.103	3.50E-01	303.55	<2.2e-16
Ljung Box (lag=20)	41.357	3.35E-03	584.53	<2.2e-16

Subamostra 1

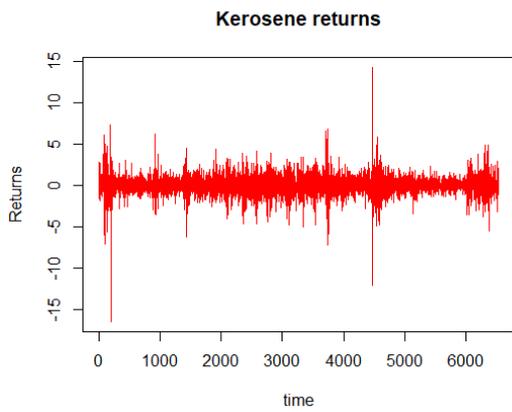


Gráfico 121 – Retornos do Querosene entre 3 de abril de 1990 e 30 de dezembro de 2016

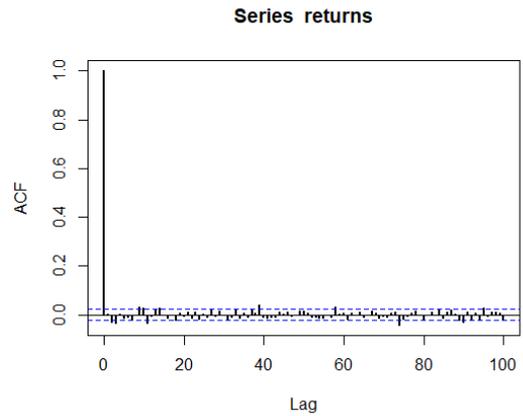


Gráfico 122 - Autocorrelação da série de retornos

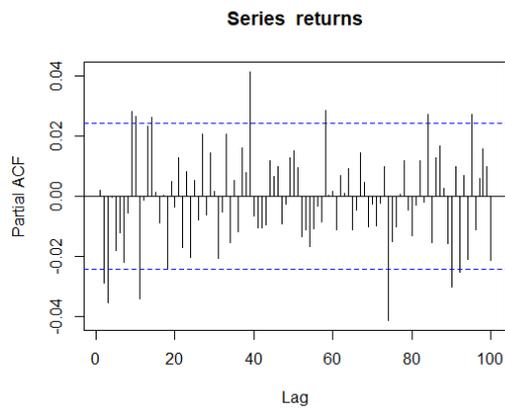


Gráfico 123 – Autocorrelação parcial da série de retornos

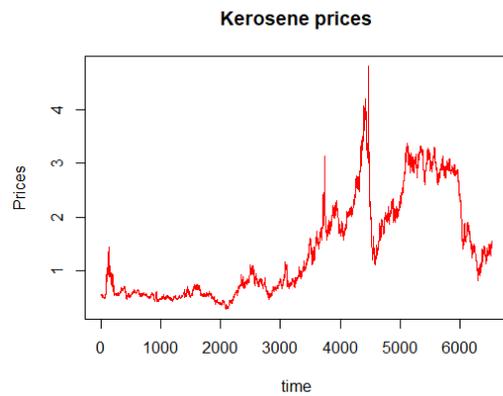


Gráfico 124 – Preços do Querosene entre 3 de abril de 1990 e 30 de dezembro de 2016

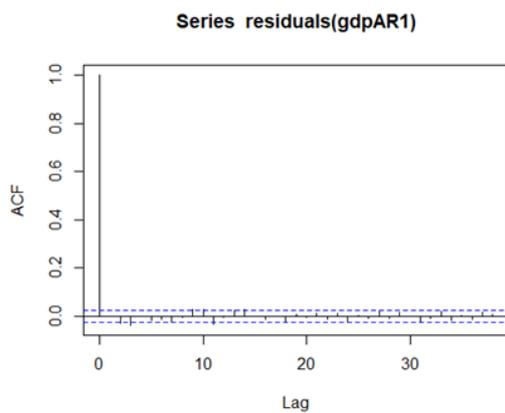


Gráfico 125 - Autocorrelação da série de retornos, pós eliminação de autocorrelação

Subamostra 2

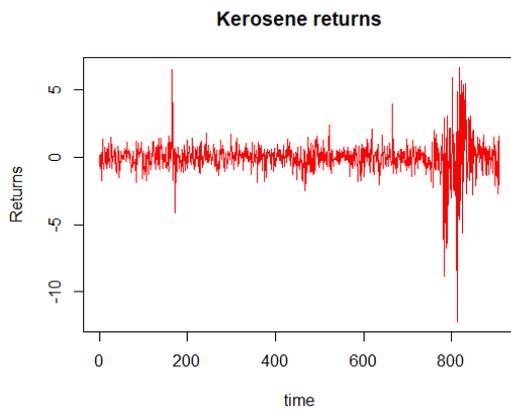


Gráfico 126 - Retornos do Querosene entre 3 de janeiro de 2017 e 14 de setembro de 2020

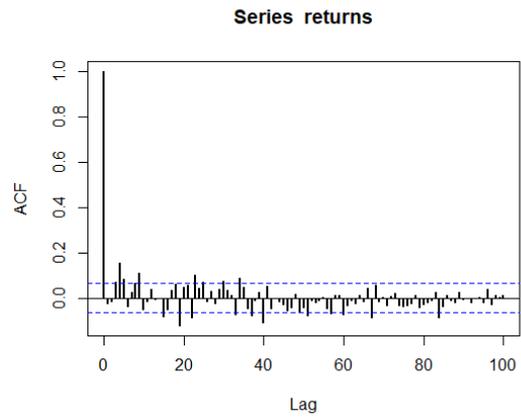


Gráfico 127 - Autocorrelação da série de retornos

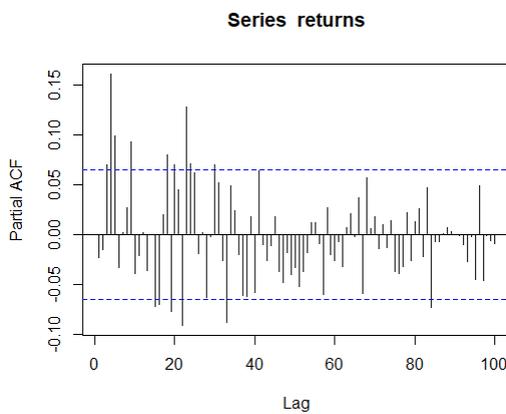


Gráfico 128 - Autocorrelação parcial da série de retornos

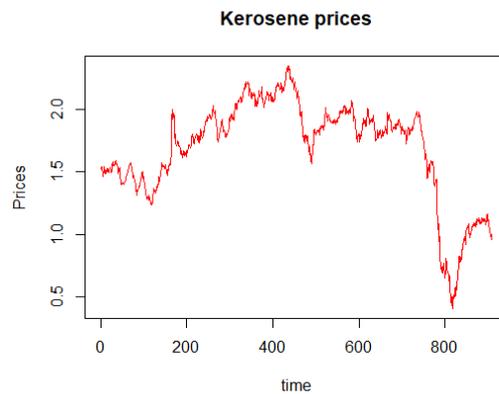


Gráfico 129 - Preços do Querosene entre 3 de janeiro de 2017 e 14 de setembro de 2020

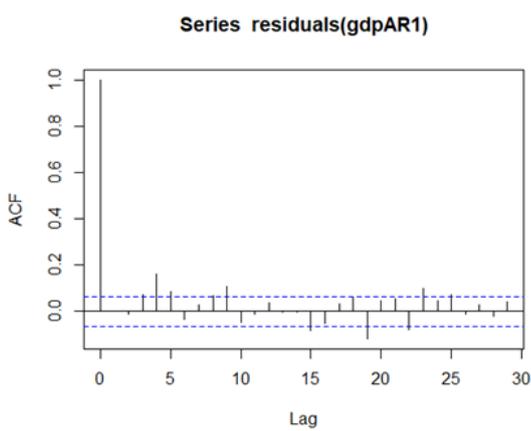


Gráfico 130 - Autocorrelação da série de retornos, pós eliminação de autocorrelação

Estudo da volatilidade do Querosene na subamostra 1

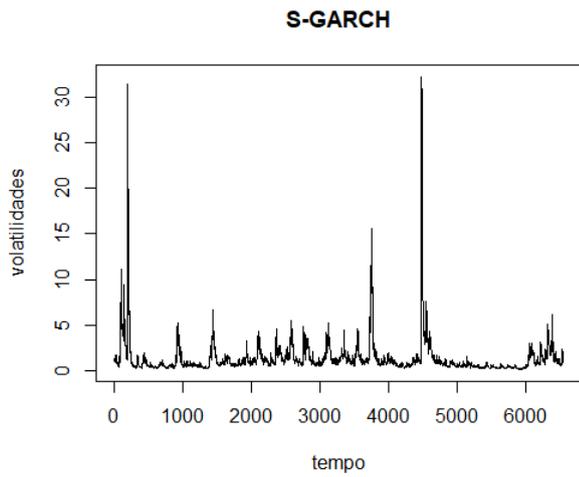


Gráfico 131 - Volatilidades do Querosene no modelo S-GARCH

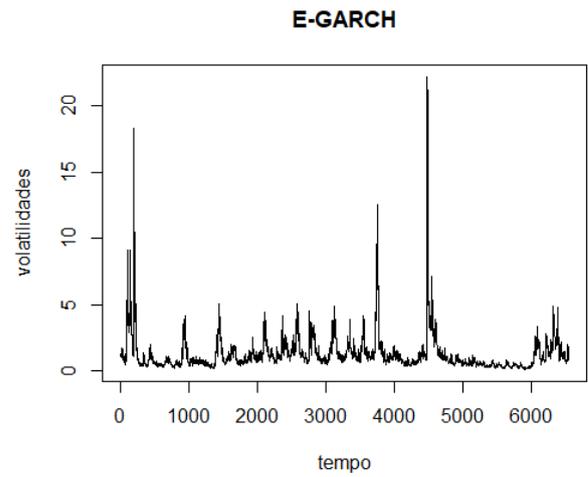


Gráfico 132 - Volatilidades do Querosene no modelo E-GARCH

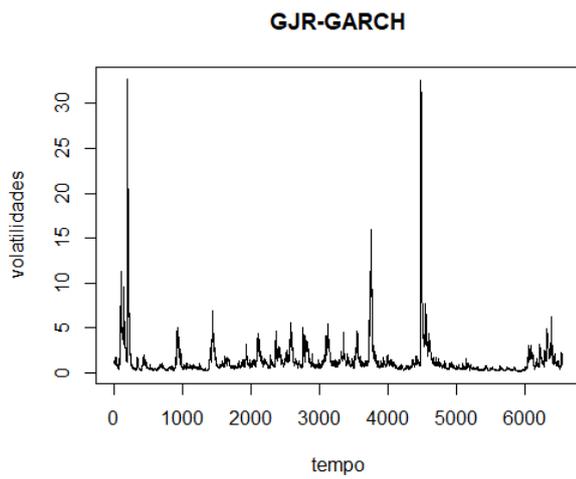


Gráfico 133 - Volatilidades do Querosene no modelo GJR-GARCH

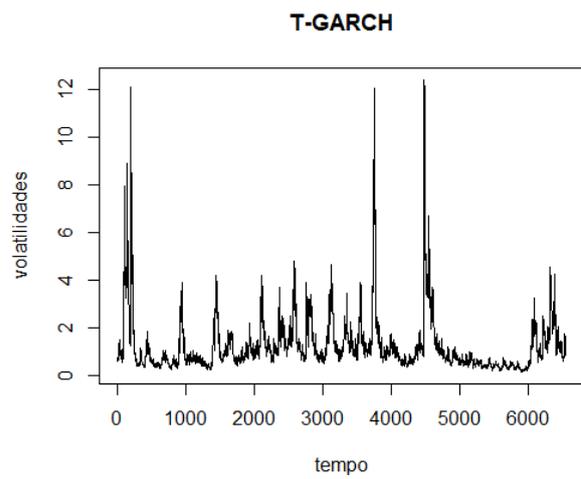


Gráfico 134 - Volatilidades do Querosene no modelo T-GARCH

Estudo da volatilidade do Querosene na subamostra 2

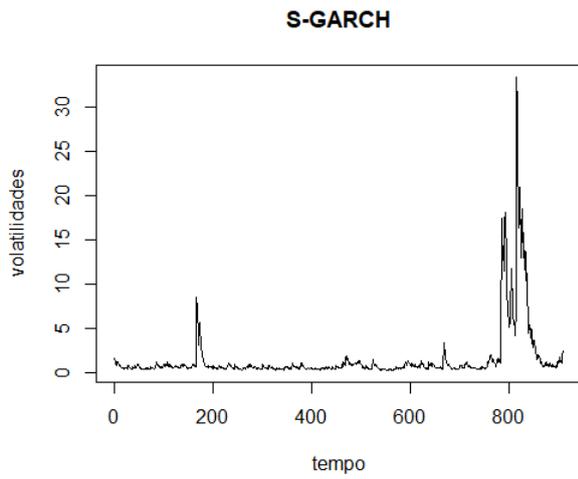


Gráfico 135 - Volatilidades do Querosene no modelo S-GARCH

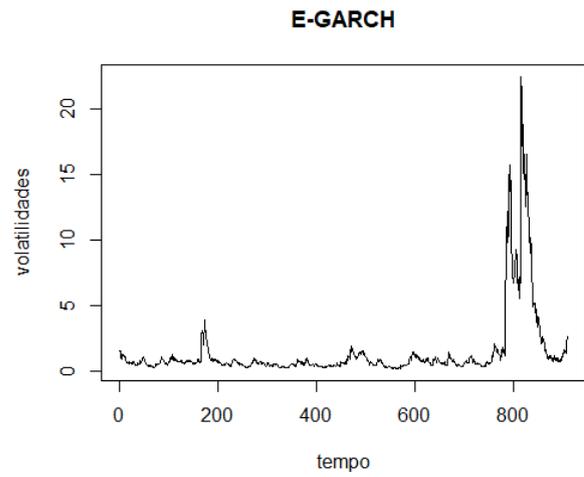


Gráfico 136 - Volatilidades do Querosene no modelo E-GARCH

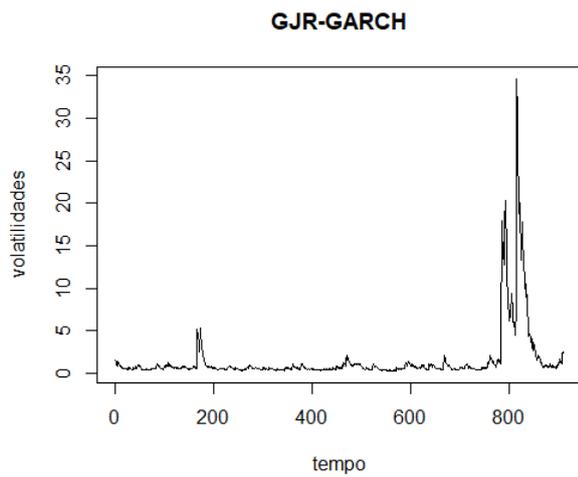


Gráfico 137 - Volatilidades do Querosene no modelo GJR-GARCH

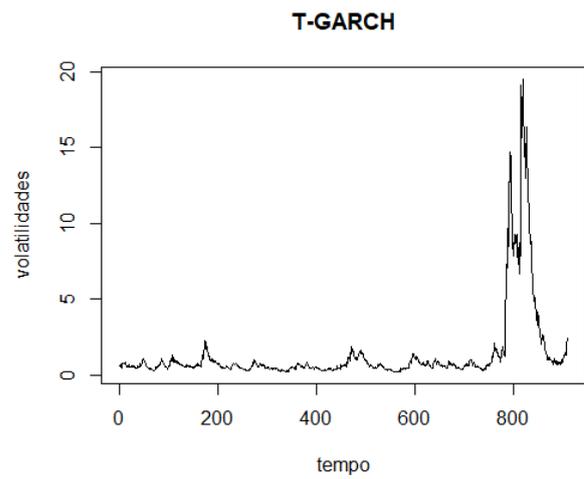


Gráfico 138 - Volatilidades do Querosene no modelo T-GARCH

Anexo 6 – Análise das rendibilidades do Propano

Tabela 29 - Propano – Subamostra 1

5112 observações desde 10 de Julho 1992, a 31 de Dezembro 2015		Retornos-log		Retornos ao quadrado	
Média		0		1.31	
Mediana		0.08		0.26	
Desvio Padrão		1.14		8.95	
Mínimo		-21.68		0	
Máximo		14.31		469.89	
Curtose		47.95565		1764.806	
Assimetria		-1.772572		38.10667	
Testes de hipótese		Estatística de teste	p-value	Estatística de teste	p-value
Jarque Bera		4.33E+05	<2.2e-16	6.62E+08	<2.2e-16
ARCH(4)		1.96E+02	0.00E+00	1.08E+00	8.97E-01
ADF		-4.76E+01	<2.2e-16	-4.22E+01	<2.2e-16
Ljung Box (lag=10)		40.129	1.61E-05	218.71	<2.2e-16
Ljung Box (lag=20)		81.211	2.44E-09	245.28	<2.2e-16
AR(1)					
Ljung Box (lag=10)		7.3893	6.88E-01	216.97	<2.2e-16
Ljung Box (lag=20)		33.079	3.31E-02	241.95	<2.2e-16

Tabela 30 - Propano – Subamostra 2

1071 observações desde 4 de Janeiro 2016, a 14 de Setembro 2020		Retornos-log		Retornos ao quadrado	
Média		0.01		2.12	
Mediana		0.09		0.53	
Desvio Padrão		1.46		5.62	
Mínimo		-7.37		0	
Máximo		8.68		75.29	
Curtose		7.991225		61.37262	
Assimetria		-0.136223		6.730905	
Testes de hipótese		Estatística de teste	p-value	Estatística de teste	p-value
Jarque Bera		1.12E+03	<2.2e-16	1.60E+05	<2.2e-16
ARCH(4)		1.21E+02	0.00E+00	4.68E+01	1.72E-09
ADF		-2.33E+01	<2.2e-16	-1.65E+01	<2.2e-16
Ljung Box (lag=10)		22.603	1.33E-01	225.59	<2.2e-16
Ljung Box (lag=20)		50.735	3.12E-01	323.08	<2.2e-16
AR(1)					
Ljung Box (lag=10)		11.257	3.10E-01	186.59	<2.2e-16
Ljung Box (lag=20)		30.133	5.42E-01	261.65	<2.2e-16

Subamostra 1

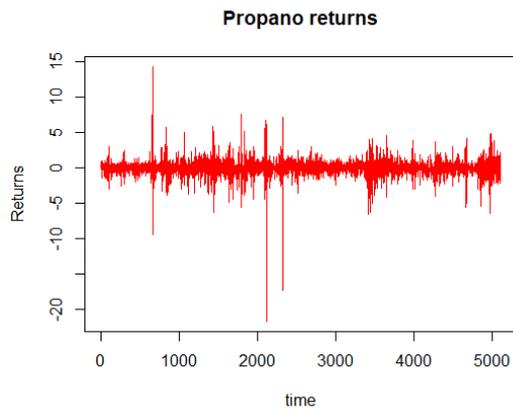


Gráfico 139 - Retornos do Propano entre 10 de julho de 1992 e 31 de dezembro de 2015

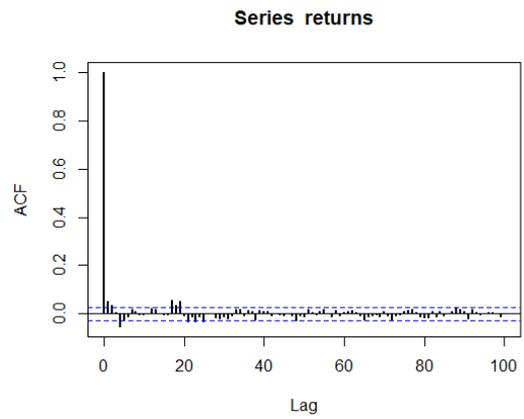


Gráfico 140 - Autocorrelação da série de retornos

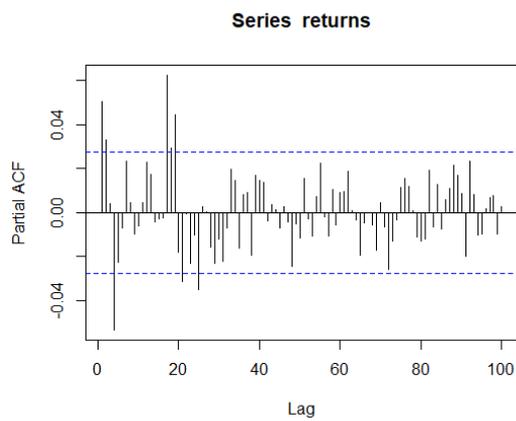


Gráfico 141 – Autocorrelação parcial da série de retornos

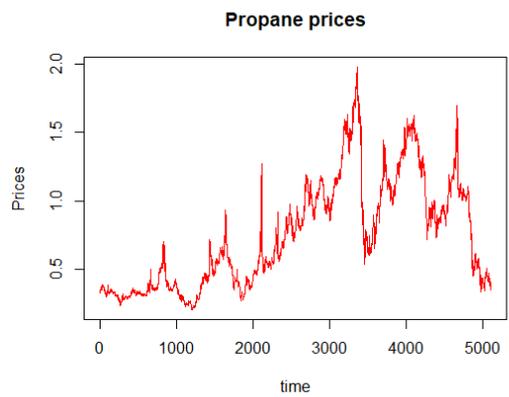


Gráfico 142 – Preços do Propano entre 10 de julho de 1992 e 31 de dezembro de 2015

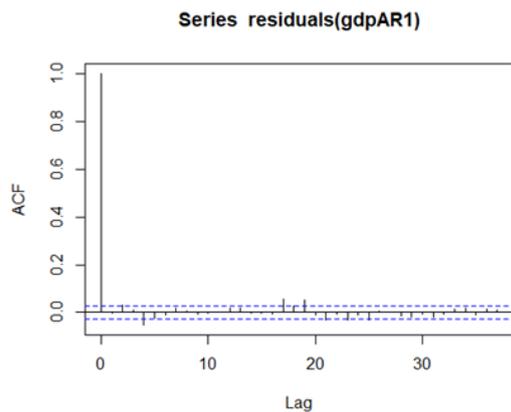


Gráfico 143 - Autocorrelação da série de retornos, pós eliminação de autocorrelação

Subamostra 2

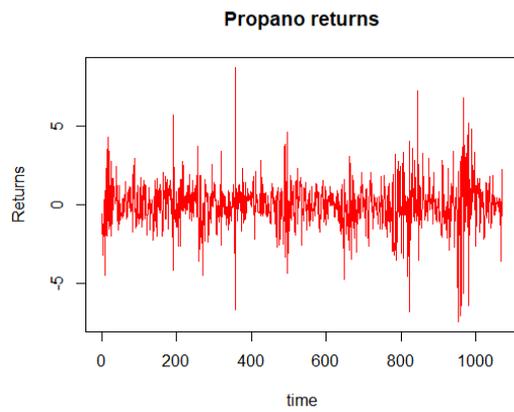


Gráfico 144 – Retornos do Propano entre 4 de janeiro de 2016 e 14 de setembro de 2020

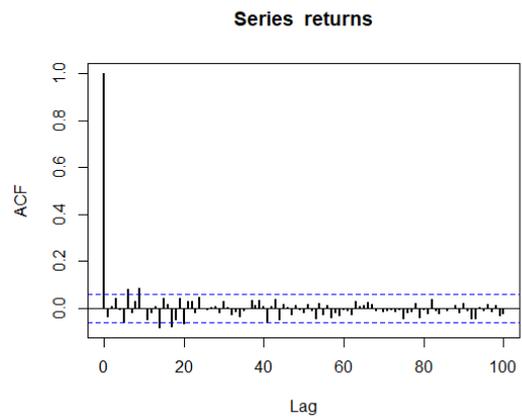


Gráfico 145 - Autocorrelação da série de retornos

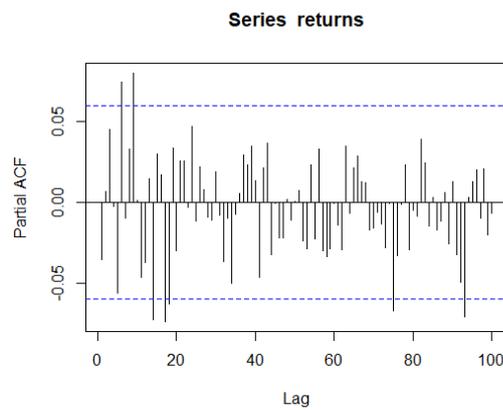


Gráfico 146 – Autocorrelação parcial da série de retornos

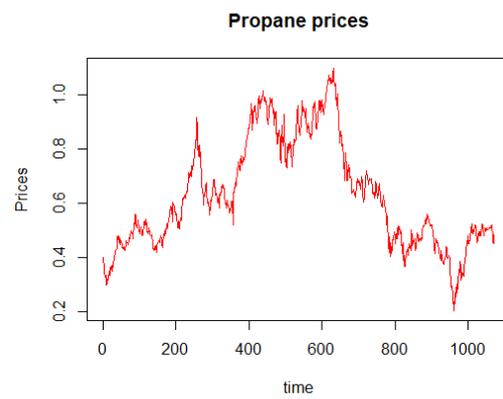


Gráfico 147 – Preços do Propano entre 4 de janeiro de 2016 e 14 de setembro de 2020

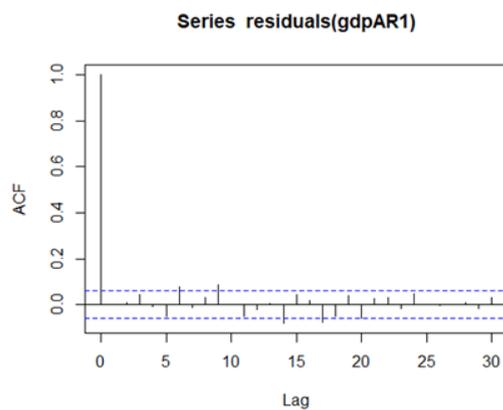


Gráfico 148 - Autocorrelação da série de retornos, pós eliminação de autocorrelação

Estudo da volatilidade do Propano na subamostra 1

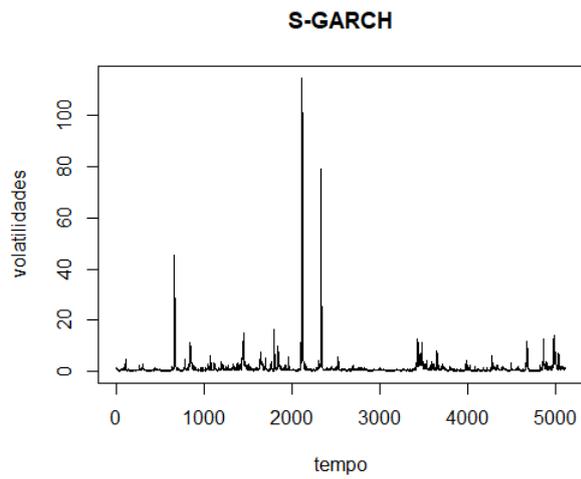


Gráfico 149 - Volatilidades do Propano no modelo S-GARCH

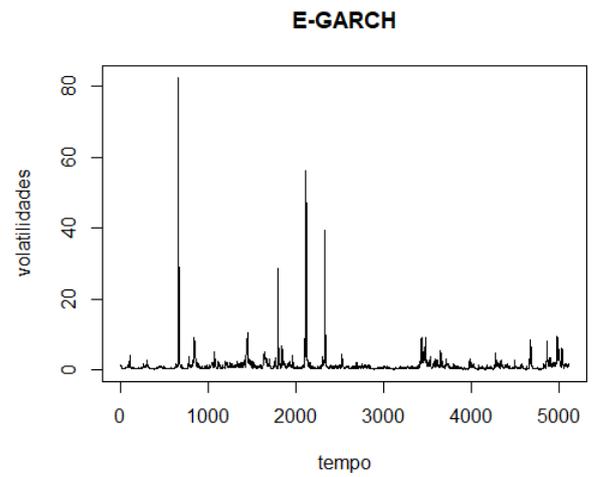


Gráfico 150 - Volatilidades do Propano no modelo E-GARCH

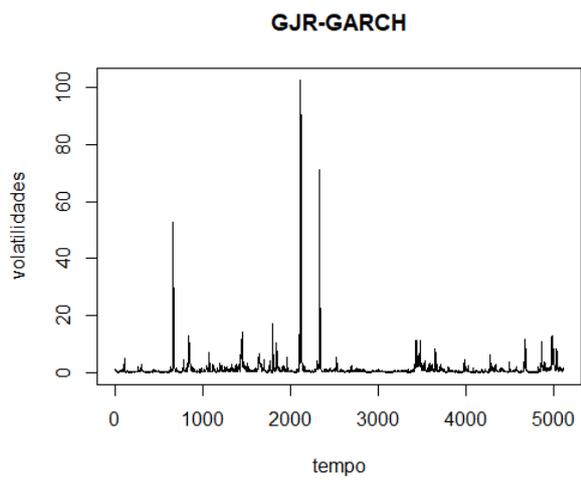


Gráfico 151 - Volatilidades do Propano no modelo GJR-GARCH

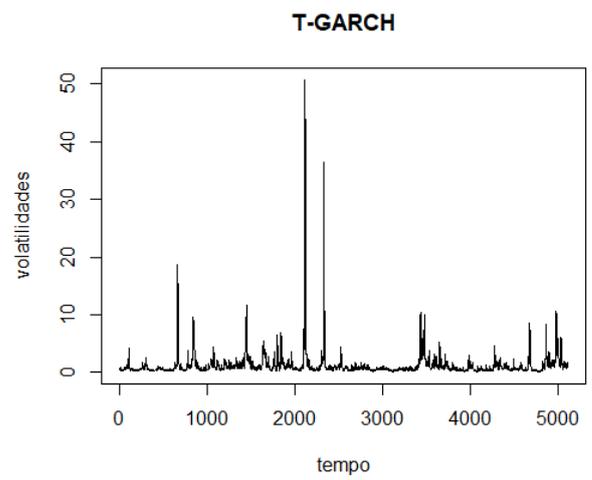


Gráfico 152 - Volatilidades do Propano no modelo T-GARCH

Estudo da volatilidade do Propano na subamostra 2

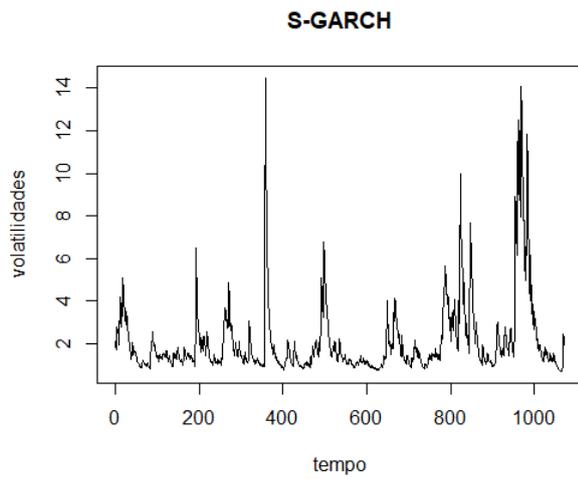


Gráfico 153 - Volatilidades do Propano no modelo S-GARCH

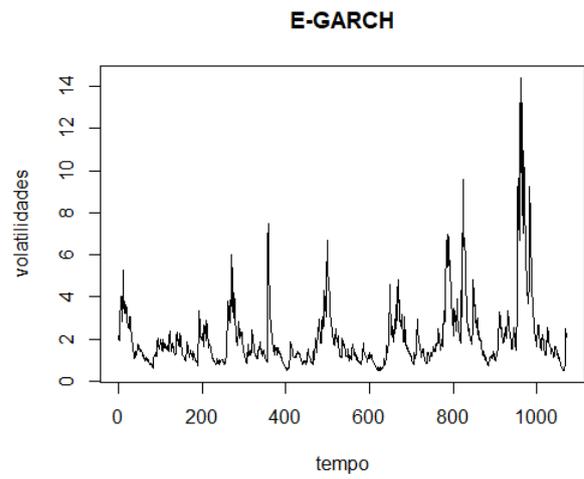


Gráfico 154 - Volatilidades do Propano no modelo E-GARCH

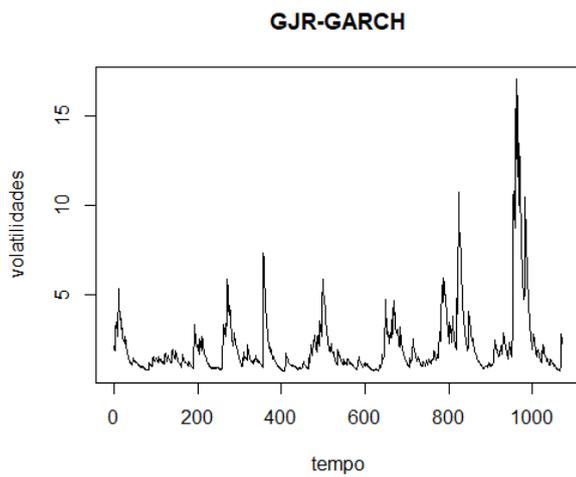


Gráfico 155 - Volatilidades do Propano no modelo GJR-GARCH

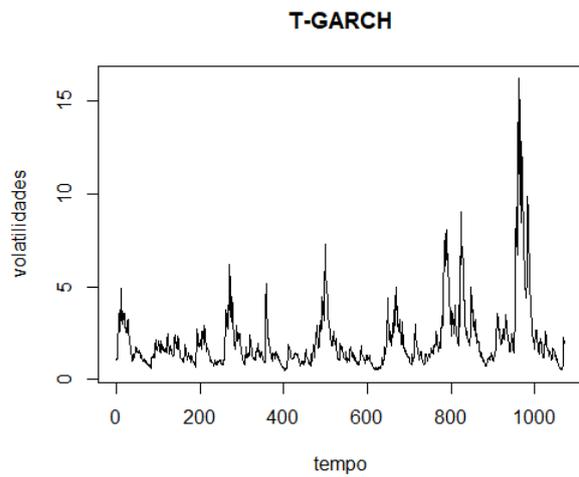


Gráfico 156 - Volatilidades do Propano no modelo T-GARCH

Anexo 7 – Estudo do Value at Risk Na Gasolina

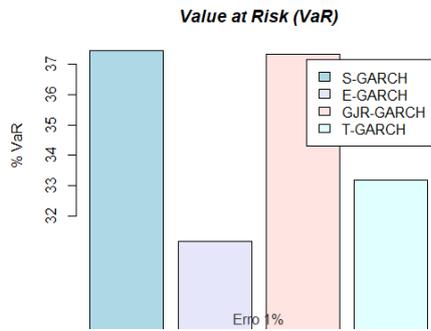


Gráfico 157 – Subamostra 1

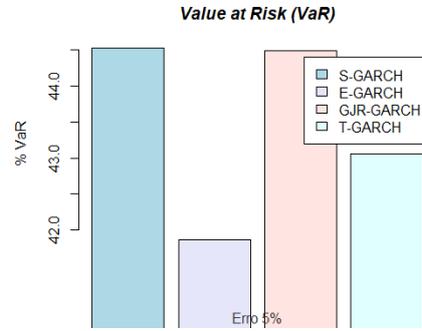


Gráfico 158 – Subamostra 1

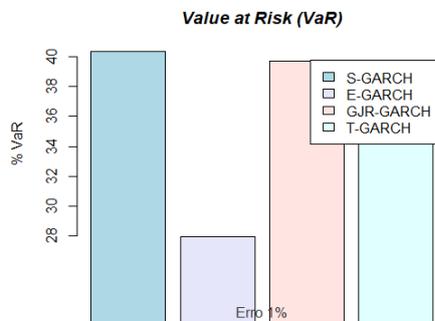


Gráfico 159 – Subamostra 2

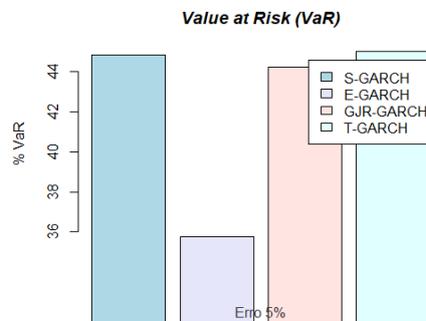


Gráfico 160 – Subamostra 2

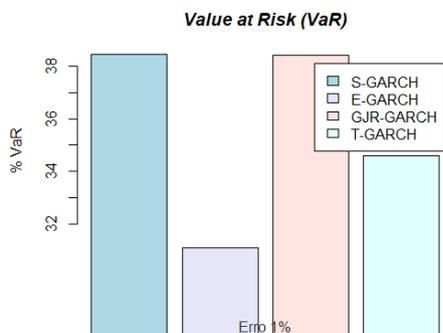


Gráfico 161 - Amostra Completa

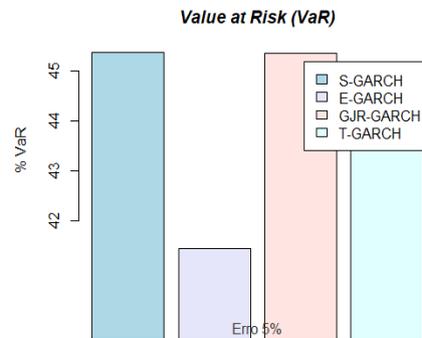


Gráfico 162 - Amostra Completa

No Gás Natural

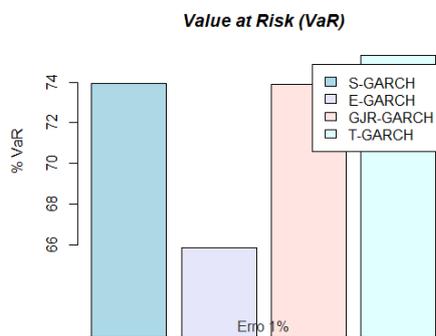


Gráfico 163 – Subamostra 1

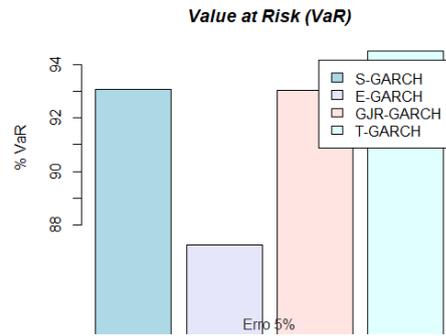


Gráfico 164 – Subamostra 1

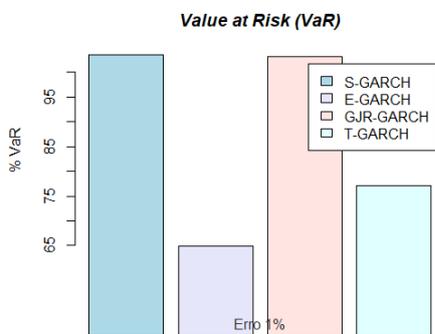


Gráfico 165 – Subamostra 2

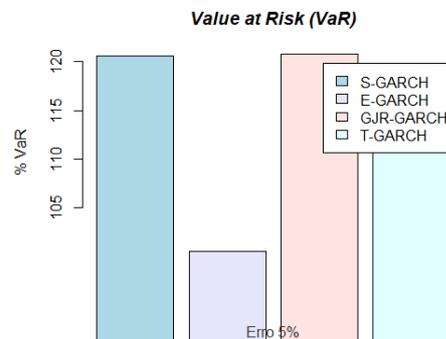


Gráfico 166 – Subamostra 2

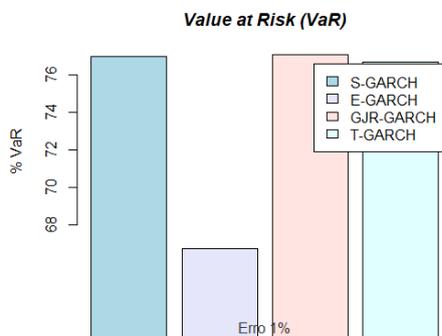


Gráfico 167 - Amostra Completa

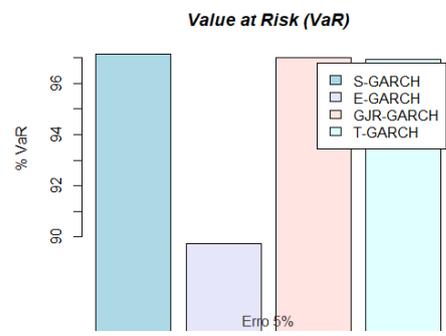


Gráfico 168 - Amostra Completa

No Petróleo

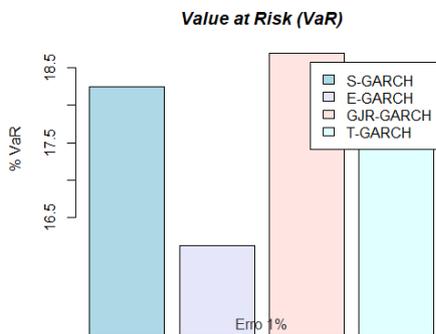


Gráfico 169 – Subamostra 1



Gráfico 170 – Subamostra 1

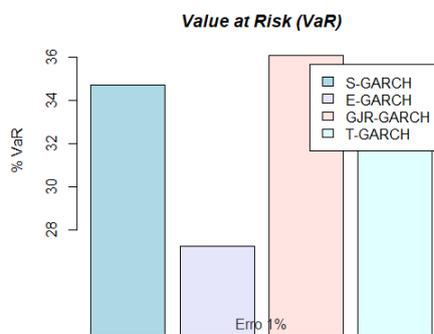


Gráfico 171 – Subamostra 2

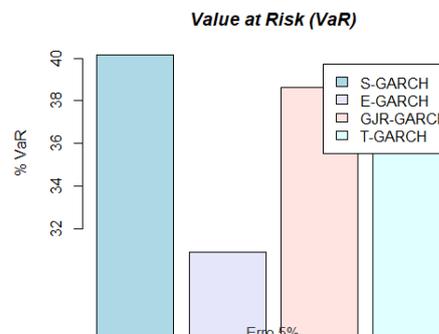


Gráfico 172 – Subamostra 2

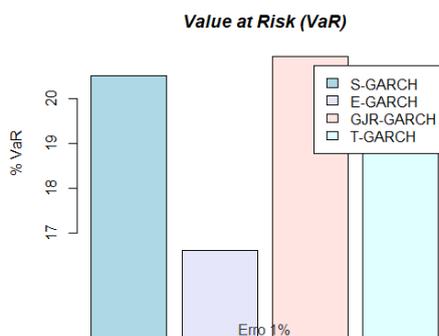


Gráfico 173 - Amostra Completa

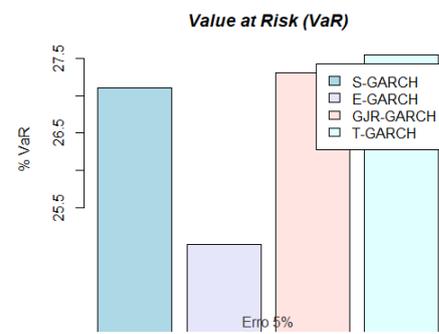


Gráfico 174 - Amostra Completa

No Petróleo de Aquecimento

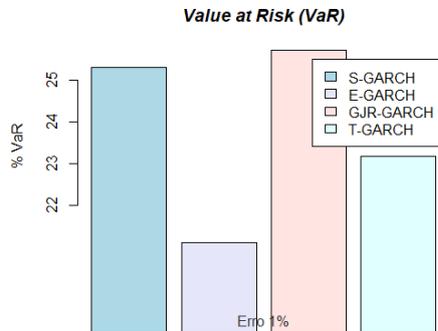


Gráfico 175 – Subamostra 1

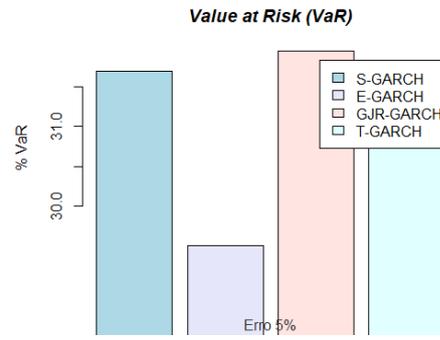


Gráfico 176 – Subamostra 1

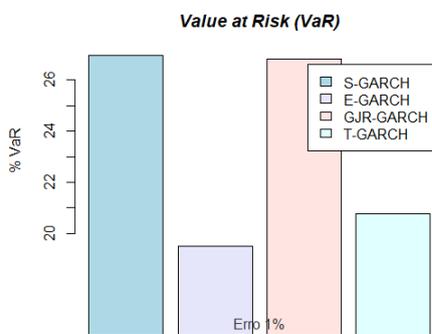


Gráfico 177 – Subamostra 2

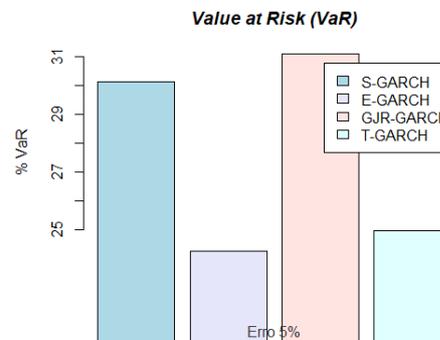


Gráfico 178 – Subamostra 2

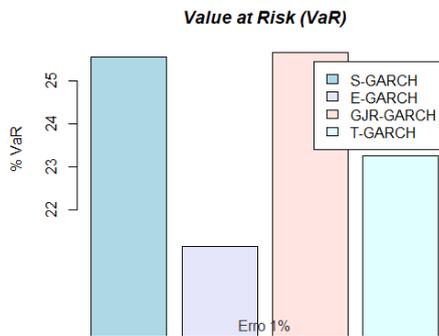


Gráfico 179 - Amostra Completa

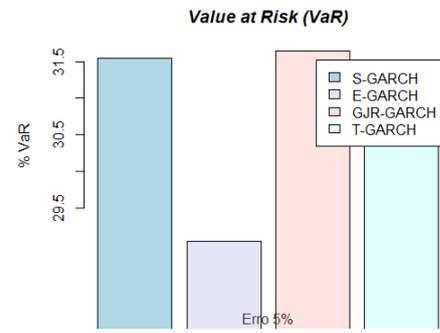


Gráfico 180 - Amostra Completa

No Querosene

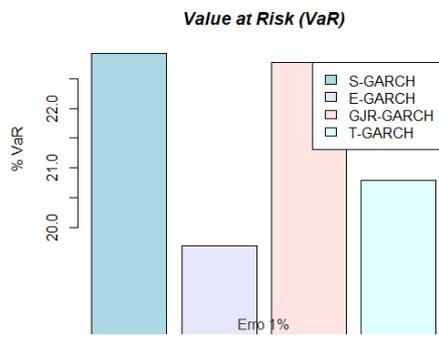


Gráfico 181 – Subamostra 1

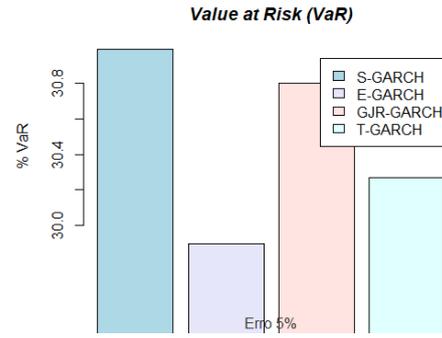


Gráfico 182 – Subamostra 1

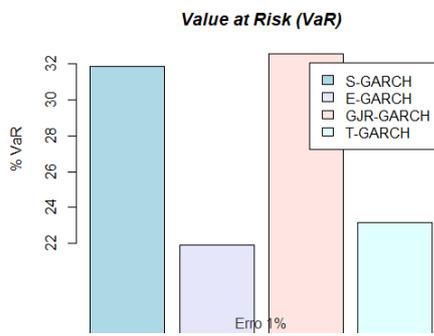


Gráfico 183 – Subamostra 2

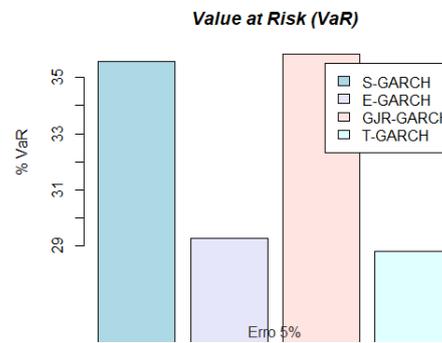


Gráfico 184 – Subamostra 2

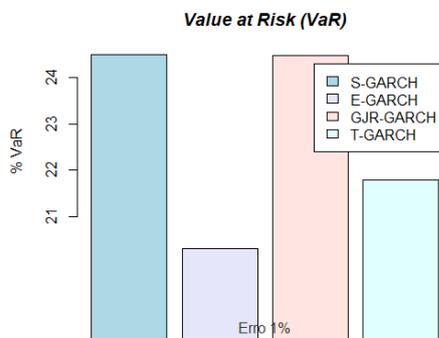


Gráfico 185 - Amostra Completa

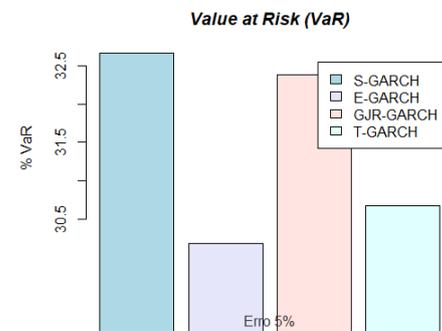


Gráfico 186 - Amostra Completa

No Propano

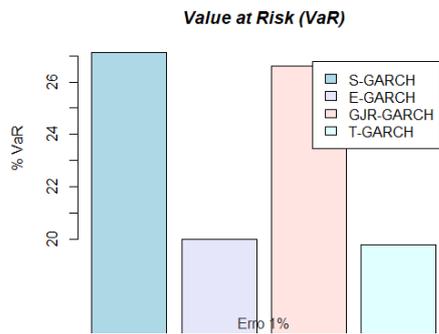


Gráfico 187 – Subamostra 1



Gráfico 188 – Subamostra 1

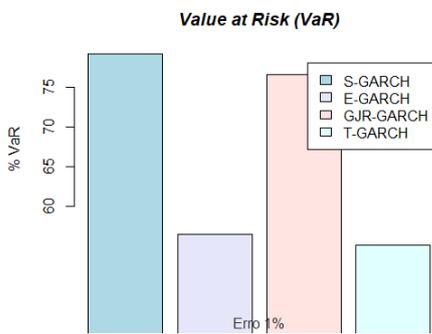


Gráfico 189 – Subamostra 2

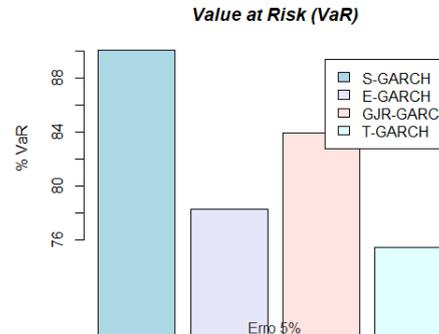


Gráfico 190 – Subamostra 2

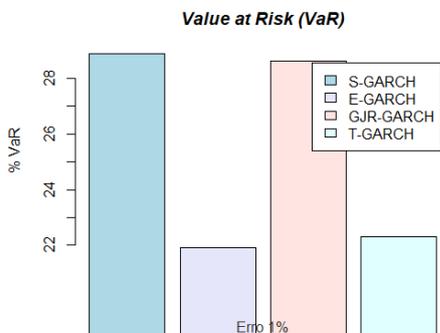


Gráfico 191 - Amostra Completa

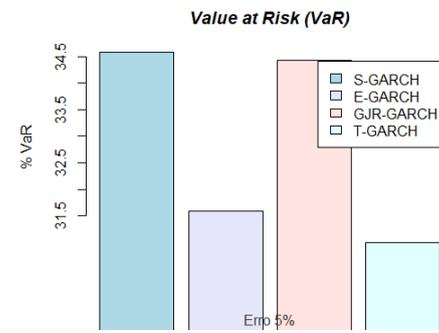


Gráfico 192 - Amostra Completa

Anexo 8 – Script do R

```
rm(list=ls()) #clean workspace
library(readxl)
library(car)
library(psych)

#Download the data
setwd("C:/Users/catar/OneDrive/Ambiente de Trabalho/InSampleRendibilidadesGasoline.xlsx")
gasoline <- read_excel("InSampleRendibilidadesGasoline.xlsx", 1)
date <- as.Date(gasoline$Date, format="%Y-%m-%d")
list(gasoline)

#Alternative 1
gasoline0 <- ts(gasoline$RENDIBILIDADES)
ts.plot(gasoline0,main="Gasoline returns",xlab="Time",ylab="Returns",
        col="red", lwd=1)

#Autocorrelation e partial autocorrelation functions
acf(returns, lag.max = 100, lwd=2)
pacf(returns, lag = 100)

#Summary statistics
library(moments)
summary(returns)
describe(returns)
skewness(returns)
kurtosis(returns)

#Jarque-Bera normality test
library(normtest)
jb.norm.test(returns, nrepl=2000)

#ARCH test
library(MTS)
archTest(returns, lag = 4)

#Augmented Dickey Fuller test
library(urca)
adf=ur.df(returns,type="none",lags=1)
summary(adf)

#Teste Ljung-Box
Box.test(returns, lag=10, type=c("Ljung-Box"))
Box.test(returns, lag=20, type=c("Ljung-Box"))

retsqs <- returns^2

Box.test(retsqs, lag=10, type=c("Ljung-Box"))
Box.test(retsqs, lag=20, type=c("Ljung-Box"))

#Para retornos ao quadrado
library(moments)
summary(retsqs)
describe(retsqs)
skewness(retsqs)
kurtosis(retsqs)

#Jarque-Bera normality test
library(normtest)
jb.norm.test(retsqs, nrepl=2000)

#ARCH test
library(MTS)
archTest(retsqs, lag = 4)

#Augmented Dickey Fuller test
library(urca)
adf=ur.df(retsqs,type="none",lags=1)
summary(adf)

#Gráfico Prices
gasoline0 <- ts(gasoline$GASOLINE)
ts.plot(gasoline0,main="Gasoline prices",xlab="time",ylab="Prices",
        col="red", lwd=1)

#ELIMINAR AUTOCORRELAÇÃO
library(forecast)
gdpAR1 <- arima(returns, order=c(1, 0, 0))
summary(gdpAR1)
tsdiag(gdpAR1)

acf(residuals(gdpAR1))

Box.test(residuals(gdpAR1), lag=10, type="Ljung-Box")
Box.test(residuals(gdpAR1), lag=20, type="Ljung-Box")

gdpAR1sq <- (residuals(gdpAR1))^2
Box.test(gdpAR1sq, lag=10, type="Ljung-Box")
Box.test(gdpAR1sq, lag=20, type="Ljung-Box")
```

```

#Estimação do modelo
library(fGarch)
m1 <- arima(returns, order = c(1, 0, 0))
m3 <- garchFit(~ arma(1, 0) + garch(1, 1), data = returns, include.mean=FALSE, trace = F)
summary(m3)

#S-GARCH
library(rugarch)
snps <- arima(returns, order = c(1,0,0))
egarch.specS <- ugarchspec (variance.model = list (model = "sGARCH",
                                                  garchOrder = c (1,1)), mean.model = list (armaOrder = c (0,0)))

egarch.fits = ugarchfit (egarch.specS, data=returns)
egarch.fits
coef (egarch.fits)
vols <- egarch.fits@fit$var
plot(vols, type="l", xlab="tempo", ylab="volatilidades", main="S-GARCH")

#E-GARCH
library(rugarch)
snpE <- arima(returns, order = c(1,0,0))
egarch.specE <- ugarchspec (variance.model = list (model = "eGARCH",
                                                  garchOrder = c (1,1)), mean.model = list (armaOrder = c (0,0)))

egarch.fitE = ugarchfit (egarch.specE, data=returns)
egarch.fitE
coef (egarch.fitE)
volE <- egarch.fitE@fit$var
plot(volE, type="l", xlab="tempo", ylab="volatilidades", main="E-GARCH")

#GJR-GARCH
library(rugarch)
snpGJR <- arima(returns, order = c(1,0,0))
egarch.specGJR <- ugarchspec (variance.model = list (model = "gjrgARCH",
                                                  garchOrder = c (1,1)), mean.model = list (armaOrder = c (0,0)))

egarch.fitGJR = ugarchfit (egarch.specGJR, data=returns)
egarch.fitGJR
coef (egarch.fitGJR)
volGJR <- egarch.fitGJR@fit$var
plot(volGJR, type="l", xlab="tempo", ylab="volatilidades", main="GJR-GARCH")

#T-GARCH
library(rugarch)
snpT <- arima(returns, order= c(1,0,0))
egarch.specT <- ugarchspec (variance.model = list (model="fGARCH",
                                                  garchOrder=c(1,1),
                                                  submodel="TGARCH"), mean.model = list(armaOrder=c(0,0)),
                             distribution.model = "std")
egarch.fitT <- ugarchfit (spec=egarch.specT, data=returns)
egarch.fitT
coef(egarch.fitT)
volT <- egarch.fitT@fit$var
plot(volT, type="l", xlab="tempo", ylab="volatilidades", main="T-GARCH")

#VaR
library(fGarch)
lambda1 <- 0.01
lambda5 <- 0.05
VaR1 <- quantile(vols, lambda1)
VaR5 <- quantile(vols, lambda5)
VaR1E <- quantile(volE, lambda1)
VaR5E <- quantile(volE, lambda5)
VaR1GJR <- quantile(volGJR, lambda1)
VaR5GJR <- quantile(volGJR, lambda5)
VaR1T <- quantile(volT, lambda1)
VaR5T <- quantile(volT, lambda5)
VaR1 <- c(0.3744303, 0.3116905, 0.3732879, 0.3316285)*100
mybarcol <- "gray20"
barplot(VaR1, beside = TRUE, col = c("lightblue", "lavender",
                                     "mistyrose", "lightcyan"),
        legend = c("S-GARCH", "E-GARCH", "GJR-GARCH", "T-GARCH"),
        main = "Value at Risk (VaR)", font.main = 4, sub = "Erro 1%",
        col.sub = mybarcol, ylab="% VaR", ylim= c(min(VaR1), max(VaR1)))

VaR5 <- c(0.4452226, 0.4187122, 0.4448325, 0.4306213)*100
mybarcol <- "gray20"
barplot(VaR5, beside = TRUE, col = c("lightblue", "lavender",
                                     "mistyrose", "lightcyan"),
        legend = c("S-GARCH", "E-GARCH", "GJR-GARCH", "T-GARCH"),
        main = "Value at Risk (VaR)", font.main = 4, sub = "Erro 5%",
        col.sub = mybarcol, ylab="% VaR", ylim= c(min(VaR5), max(VaR5)))

```

(o mesmo processo é realizado para todas as seis energias em estudo, na subamostra 1, subamostra 2 e amostra completa)