



Universidade Federal da Paraíba
Centro de Informática
Programa de Pós-Graduação em Modelagem Matemática e Computacional

VOLATILIDADE DOS RETORNOS DOS ÍNDICES DE ENERGIAS
RENOVÁVEIS E CHOQUES DE INCERTEZAS NOS ESTADOS UNIDOS E
UNIÃO EUROPEIA

Alexandre Gomes Souza

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Modelagem Matemática e Computacional, UFPB, da Universidade Federal da Paraíba, como parte dos requisitos necessários à obtenção do título de Mestre em Modelagem Matemática e Computacional.

Orientador: Bruno Ferreira Frascaroli

João Pessoa
Janeiro de 2021

Programa de Pós-Graduação em Modelagem Matemática e Computacional
Universidade Federal da Paraíba

Ata da Sessão Pública de Defesa de Dissertação de Mestrado de **ALEXANDRE GOMES SOUZA**, candidato ao título de Mestre em Matemática Computacional, na Área de Modelagem Matemática e Computacional, realizada no dia 29 de Janeiro de 2021.

Aos 29 dias do mês de JANEIRO do ano de dois mil e vinte e um, às 15 horas, via videoconferência, reuniram-se os membros da Banca Examinadora constituída para julgar o Trabalho Final do Sr. **ALEXANDRE GOMES SOUZA**, vinculado à Universidade Federal da Paraíba sob matrícula nº 20181021831, candidato ao grau de Mestre em “*Modelagem Matemática e Computacional*”, na linha de pesquisa “Modelagem e Simulação de Sistemas”, do Programa de Modelagem Matemática e Computacional. A comissão examinadora foi composta pelos professores Dr. BRUNO FERREIRA FRASCAROLI, Orientador e Presidente da Banca; Dra. TATIENE CORREIA DE SOUZA, Examinador Interno ao Programa; Dr. EDWARD MARTINS COSTA, Examinador Externo à Instituição. Dando início aos trabalhos, o Presidente da Banca cumprimentou os presentes, comunicou aos mesmos a finalidade da reunião e passou a palavra ao candidato para que o mesmo fizesse, oralmente, a exposição do trabalho de dissertação intitulado “**VOLATILIDADE DOS RETORNOS DOS ÍNDICES DE ENERGIAS RENOVÁVEIS E CHOQUES DE INCERTEZAS NOS ESTADOS UNIDOS E UNIÃO EUROPEIA**”. Concluída a exposição, o candidato foi arguido pela Banca Examinadora, que emitiu o parecer: “**aprovado**”. Do ocorrido, eu Hugo Leonardo Davi de Souza Cavalcante, Coordenador do Programa de Modelagem Matemática e Computacional (PPGMMC), lavrei a presente ata que vai assinada por mim e pelos membros da Banca Examinadora.

João Pessoa, 29 de janeiro de 2021.

Hugo Leonardo Davi de Souza Cavalcante
Coordenador do PPGMMC
SIAPE 1298679

Prof. Dr. Bruno Ferreira Frascaroli
Orientador (PPGMMC)



Prof. Dr. Tatiene Correia de Souza
Examinador Interno ao Programa (PPGMMC)



Prof. Dr. Edward Martins Costa
Examinador Externo à Instituição (UFC)



Catálogo na publicação
Seção de Catalogação e Classificação

S699v Souza, Alexandre Gomes.

Volatilidade dos retornos dos índices de energias renováveis e choques de incertezas nos Estados Unidos e União Europeia / Alexandre Gomes Souza. - João Pessoa, 2021.

71 f. : il.

Orientação: Bruno Ferreira Frascaroli.
Dissertação (Mestrado) - UFPB/CI.

1. Energia renovável. 2. Volatilidade. 3. Riscos. 4. Incerteza. 5. Choques. I. Frascaroli, Bruno Ferreira. II. Título.

UFPB/BC

CDU 502.21(043)

*A todos que me ajudaram e
apoiaram, diretamente ou
indiretamente.*

Agradecimentos

Primeiramente a Deus, pois sem fé tudo teria sido muito mais difícil.

Aos meus pais, Lourdes e Arnêlido, por me apoiarem a estudar e realizar meus objetivos sempre, e aos meus demais familiares.

A todos os professores do PPGMMC–UFPB que contribuiriam com minha formação.

Ao orientador Bruno Ferreira Frascaroli pela paciência comigo, e por todo aprendizado que foi adquirido.

Aos amigos, que ajudam e me aconselham, aos antigos e novos que fiz ao decorrer do mestrado, que menciono, Cristiane Brandão, Flávio Falcão, Davi Lopes, Rubens Sousa, Sabrina Abreu, Rebeca Maia, Mariana Maia e Mylenna Sá.

À Fundação PaqTcPB, pela contribuição financeira e pelas novas experiências como tutor, e ao orientador do CEEF, Bruno Ferreira Frascaroli.

Resumo da Dissertação apresentada ao PPGMMC/CI/UFPB como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc.)

VOLATILIDADE DOS RETORNOS DOS ÍNDICES DE ENERGIAS
RENOVÁVEIS E CHOQUES DE INCERTEZAS NOS ESTADOS UNIDOS E
UNIÃO EUROPEIA

Alexandre Gomes Souza

Janeiro/2021

Orientador: Bruno Ferreira Frascaroli

Programa: Modelagem Matemática e Computacional

O objetivo deste trabalho é estimar a volatilidade dos retornos e choques de incertezas sobre os índices relacionados ao desempenho do mercado de energias renováveis no âmbito dos EUA e Europa. Neste sentido, uma análise dos riscos associados aos índices European Renewable Energy e o Renewable Energy Generation pode revelar como os mesmos afetam o desempenho do setor. Primeiramente serão estimados testes de quebra estrutural sobre as trajetórias de retornos e verificar se a análise deve dividir entre regimes. Para estimar a volatilidade serão utilizados modelos heterocedásticos condicionais propostos na literatura, particularmente o modelo Dynamic conditional correlation multivariate GARCH (DCC-MGARCH). Os dados foram escolhidos tomando como base os índices Standard & Poor's 500, WilderHill, Arca Tech 100, West Texas Intermediate e Morgan Stanley Capital International, Thomson Reuters/CoreCommodity e U.S. Dollar. Além das estimativas de todos os parâmetros, serão obtidas matrizes de quase-correlação, quase covariância, e choques de incertezas sobre os índices estudados, por meio de funções de impulso respostas obtidas por um modelo de vetores autoregressivos (VAR).

Energias renováveis; Volatilidade; Riscos; Incertezas; Choques.

Abstract of Dissertation presented to PPGMMC/CI/UFPB as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

VOLATILITY OF RETURNS FROM RENEWABLE ENERGY INDICES AND
UNCERTAINTY SHOCKS IN THE UNITED STATES AND EUROPEAN
UNION

Alexandre Gomes Souza

January/2021

Advisor: Bruno Ferreira Frascaroli

Program: Computational Mathematical Modelling

The goal of this work is to estimate the volatility of returns and shocks of uncertainties on the indices related to the performance of the renewable energy market in the USA and Europe. In this sense, an analysis of the risks associated with the European Renewable Energy and Renewable Energy Generation indexes can reveal how they affect the sector's performance. First, structural break tests will be estimated on the return trajectories and check if the analysis should be divided between regimes. To estimate volatility, conditional heteroscedastic models proposed in the literature will be used, particularly the Dynamic conditional correlation multivariate GARCH (DCC-MGARCH). The data were chosen based on the Standard & Poor's 500, WilderHill, Arca Tech 100, West Texas Intermediate and Morgan Stanley Capital International, Thomson Reuters/ CoreCommodity and U.S. Dollar indices. In addition to the estimates of all parameters, quasi-correlation matrices, quasi covariance, and uncertainties shocks over the studied indices will be obtained through impulse response functions obtained by a VAR model.

Renewable energy; Volatility; Scratches; Uncertainties; Shocks.

Sumário

Lista de Figuras	ix
Lista de Tabelas	x
Lista de Símbolos	xii
Lista de Abreviaturas	xiii
1 Introdução	1
2 Literatura	4
3 Procedimentos Metodológicos	9
3.1 Representação Básica	10
3.2 Modelos de Heterocedasticidade Condicional Univariados	12
3.3 Modelos de Heterocedasticidade Condicional Multivariados	14
3.4 Representação dos Choques de Riscos e Incertezas	17
3.5 Suporte Computacional	17
4 Desenho Amostral e Tratamento dos Dados	19
5 Análise dos Resultados	25
6 Considerações Finais	31
Referências Bibliográficas	32
A Gráficos extras	36
B Tabelas extras	39
C Implementação em R	45

Lista de Figuras

2.1	Mapa global do potencial energético fotovoltaico	5
2.2	Mapa global do potencial da energia eólica	6
2.3	Potencial da energia hidráulica	6
2.4	Ilustração de sistemas de produção de energia, biomassa e geotérmica	7
2.5	Ilustração de sistemas de produção de energia, maremotriz e ondomotriz	7
4.1	Valores de fechamento das variáveis que representam a UE	21
4.2	Valores de fechamento das variáveis que representam os EUA.	21
4.3	Gráfico das séries temporais dos retorno dos valores de fechamento das variáveis que representam a UE.	21
4.4	Gráfico das séries temporais dos retorno dos valores de fechamento das variáveis que representam os EUA.	22
5.1	Estimativas DCC-MGARCH para os regimes UE (ERIX) e EUA (GRNREG)	27
5.2	Funções de impulso resposta para um choque de um desvio padrão no risco e incerteza sobre o índice ERIX	28
5.3	Funções de impulso resposta para um choque de um desvio padrão no risco e incerteza sobre o índice GRNREG	29
A.1	Covariâncias condicionais das variáveis usadas em todos os regimes, UE(ERIX) e EUA(GRNREG).	37
A.2	Correlações condicionais das variáveis usadas em todos os regimes, UE(ERIX) e EUA(GRNREG).	38

Lista de Tabelas

4.1	Estatísticas dos valores de fechamento da UE	22
4.2	Estatísticas dos valores de fechamento dos EUA	22
4.3	Estatísticas dos retornos da UE	23
4.4	Estatísticas dos retornos dos EUA	23
4.5	Resultados dos testes de raiz unitária dos retornos dos índices da UE	24
4.6	Resultados dos testes de raiz unitária dos retornos dos índices dos EUA	24
5.1	Testes de Chow	25
5.2	Resultados dos testes ARCH em ERIX e GRNREG para a UE e os EUA	26
5.3	Valores dos critérios de ajustes dos modelos	26
B.1	Valor dos critérios de informação e log-verossimilhança, obtidos das formas funcionais do modelos GARCH com parâmetros (1,1) e ARMA(1,2) no R, dados do regime 1 (UE).	39
B.2	Valor dos critérios de informação e log-verossimilhança, obtidos das formas funcionais do modelos GARCH com parâmetros (1,1) e ARMA(1,1) no R, dados do regime 2 (UE).	40
B.3	Valor dos critérios de informação e log-verossimilhança, obtidos das formas funcionais do modelos GARCH com parâmetros (1,1) e ARMA(2,2) no R, dados do regime 1 (EUA).	41
B.4	Valor dos critérios de informação e log-verossimilhança, obtidos das formas funcionais do modelos GARCH com parâmetros (1,1) e ARMA(1,1) no R, dados do regime 2 (EUA).	42
B.5	Valores dos parâmetros, error padrão, teste t e p-valor, estimados dos modelos univariados, ARCH(1,2)-EGARCH(1,1) e ARCH(1,1)- GJRGARCH(1,1) respectivamente, dos regimes I e II, das variáveis que representam a UE.	43

B.6 Valores dos parâmetros, error padrão, teste t e p-valor, estimados dos modelos univariados, ARCH(2,2)-EGARCH(1,1) e ARCH(1,1)-EGARCH(1,1) respectivamente dos regimes I e II, das variáveis que representam os EUA. 44

Lista de Símbolos

r_t	retornos de série temporal observada, p. 12
H_0	Hipótese nula do teste, p. 10
H_1	Hipótese alternativa do teste, p. 10
\hat{L}	Valor máximo da função de verossimilhança, p. 9
Σ	Somatório, p. 10–14 , 17
ε_t	Ruido, p. 10–12
h_t	Volatilidade no instante t , p. 12
k	Número de parâmetros estimados, p. 9
n	Número de observações, p. 9 , 10
p	Ordem do modelo AR, p. 10 , 11
q	Ordem do modelo MA, p. 11 , 12
x_t	valor da série temporal no instante t , p. 11

Lista de Abreviaturas

AIC	Critérios de informação Akaike, p. 9, 26
ARCH	Modelo de heterocedasticidade condicional autorregressiva, p. 12
ARIMA	Modelo autorregressivo integrado de médias móveis, p. 11
ARMA	Modelo autorregressivo de médias móveis, p. 10, 11
AR	Modelo autorregressivo, p. 10, 11
BIC	Critérios de informação Bayesian, p. 9
CA	corrente elétrica alternada, p. 5
CCC	Correlação Condicional Constante, p. 14
CC	corrente elétrica contínuas, p. 5
DCC-GARCH	Modelo generalizado de heterocedasticidade condicional autorregressiva de correlação condicional dinâmica, p. 9, 18
DCC	Correlação condicional dinâmica, p. 14, 18
DVCH	Diagonal VECH, p. 14
ECO	Índice WilderHill New Energy, p. 19
EGARCH	Modelo exponencial generalizado de heterocedasticidade condicional autorregressiva, p. 13
ERIX	European Renewable Energy, p. 20
EUA	Estados Unidos da América, p. 2, 9, 19
FV	Sistema de energia fotovoltaica, p. 1, 4
GARCH	Generalizado de heterocedasticidade condicional autorregressiva, p. 13

GARCH	Modelo generalizado de heterocedasticidade condicional autorregressiva, p. 2 , 18
GJR GARCH	Modelo Glosten-Jagannathan-Runkle generalizado de heterocedasticidade condicional autorregressiva, p. 13 , 14
GNU GPL	GNU General Public License da Free Software Foundation, p. 17
GRNREG	Renewable Energy Generation, p. 20
HQIC	Cr�terios de informa��o Hannan Quinn, p. 9 , 26
MA	Modelo de m�dias m�veis, p. 10 , 11
MGARCH	Modelo multivariado generalizado de heterocedasticidade condicional autorregressiva, p. 14
MSCI	Morgan Stanley Capital International, p. 20
PSE	NYSE Arca Tech 100 Index, p. 20
SBC	Cr�terios de informa��o Bayesiano de Schwartz, p. 26
SIC	Cr�terios de informa��o Shibata, p. 9 , 26
SQR	Soma dos quadrados dos res�duos, p. 10
S&P 500	Standard & Poor’s 500, p. 20
TGARCH	Modelo limiar generalizado de heterocedasticidade condicional autorregressiva, p. 13 , 14
TR/CRB	Thomson Reuters/CoreCommodity CRB Index, p. 20
UE	Uni�o Europeia, p. 2 , 19 , 21–23
USDX	U.S. Dollar Index, p. 20
VAR	Modelo vetor autoregressivo, p. 17 , 18
i.i.d.	Vari�vel aleat�ria independente e identicamente distribu�da, p. 12 , 15 , 17
iGARCH	Modelo integrado, generalizado de heterocedasticidade condicional autorregressiva, p. 13

Capítulo 1

Introdução

A energia é considerada um dos aspectos vitais da sociedade contemporânea. Tem-se usado energia de diferentes formas, a maior parte baseada em combustíveis fósseis. No entanto, o uso do petróleo, gás natural e o carvão mineral consumiu uma quantidade substancial das reservas conhecidas nos últimos 200 anos ([Amin *et al.*, 2017](#)). Desta forma, a energia limpa, sustentável e renovável tem se tornado cada vez mais importante, tendo em vista o reconhecimento de que o uso de combustíveis fósseis prejudica o meio ambiente. Neste sentido, as fontes alternativas de energia são cada vez mais reconhecidas como o caminho para a construção de matrizes energéticas mais sustentáveis ([Myers, 2012](#)).

Com o avanço das tecnologias e a busca por alternativas sustentáveis às convencionais fontes de produção de energia, as modalidades conhecidas como solar, eólica, ondulatória, biomassa, maré etc, passaram a ser viáveis economicamente ([Amin *et al.*, 2017](#)). A energia solar é usada pelos sistemas elétricos solares, como o sistema de energia fotovoltaica (FV), popularizado pelo uso nas habitações. Já a energia eólica é aquela obtida pela ação do vento, ou seja, através da utilização da energia cinética gerada pelas correntes atmosféricas. Obtida a partir da energia potencial de uma massa de água, a energia hidroelétrica utiliza fluxos de água, como rios e lagos e pode ser gerada por meio de um desnível ou queda d'água.

A definição de energia renovável é extensa e avança com as novas tecnologias. A energia geotérmica, maremotriz, ondo-motriz, de transformação de biomassa, entre outras, compõem esta lista. A produção de energia a partir de biomassa é a conversão de combustível sólido produzido a partir de materiais vegetais em eletricidade. Assim, os estudos sobre a produção de energias com esta característica vêm crescendo nos últimos anos, como mostrado nos depositários de artigos como o Science Direct, com mais de 200 mil resultados de publicações sobre o tema. Esse número passou de aproximadamente 5 mil publicações no ano de 2000, para mais de 32 mil resultados no ano de 2019, mostrando um aumento substancial de pesquisas neste campo.

Neste diapasão, uma análise dos riscos e incertezas associadas ao mercado de energias renováveis é de primeira necessidade, pois a partir disso pode-se identificar quais fatores podem afetar negativamente o desempenho do setor. A volatilidade, que consiste na "[...] variância condicional de uma variável" (Morettin, 2017, pg. 20), é uma das medidas que pode ser utilizada para esta finalidade. Ela pode revelar informações sobre as barreiras ao desenvolvimento do setor de energia renovável, uma vez associada às trajetórias de variáveis que representem o desempenho desse segmento. Para estimar a presença da volatilidade serão considerados modelos heterocedásticos condicionais, ou seja, aqueles em que a variância condicional não é constante.

Diversos modelos para estimação da volatilidade foram propostos na literatura, e no presente trabalho serão estimados modelos generalizados de heterocedasticidade condicional autorregressiva da família GARCH. Para representar o setor e produzir evidências empíricas sobre riscos e incertezas associados ao setor, serão adotados os dois principais índices que refletem o desempenho das empresas de capital aberto da União Europeia (UE) e dos Estados Unidos (EUA), como variáveis dependentes.

Sob a premissa de que os eventos estocásticos ocorrem simultaneamente e uma análise multivariada possa ser útil, serão capturados efeitos entre algumas variáveis potencialmente relevantes. As variáveis selecionadas foram o índice Standard & Poor's 500, (Frascaroli, 2020); Wilder Hill New Energy Global, Arca Tech 100, West Texas Intermediate e Morgan Stanley Capital International, (Inchauspe, Ripple, and Trück, 2015); Thomson Reuters/CoreCommodity e U.S. Dollar, (Han *et al.*, 2019); European Renewable Energy, (Xia *et al.*, 2019); Renewable Energy Generation (Vrinceanu *et al.*, 2020). Eles serão melhor detalhados no Capítulo 4.

O objetivo deste trabalho é estimar os riscos e incertezas dos retornos dos índices relacionados ao desempenho do mercado de energia renovável no âmbito dos EUA e UE, revelando como se dá a transmissão entre as variáveis. Serão construídos dois sistemas para comparação dos resultados provindos de cada mercado, americano e europeu. A ideia é que os *clusters* de volatilidade presente nas trajetórias das supracitadas variáveis sejam capazes de revelar informações sobre barreiras ao crescimento do setor e o contínuo melhoramento das matrizes energéticas dos países.

Os objetivos específicos consistem em primeiramente estimar a volatilidade univariada dos retornos dos índices de energia renovável dos EUA e UE empregando modelos da família GARCH. Logo após, serão estimados o Teste de Chow nas séries estudadas para identificar possíveis quebra estruturais nas trajetórias. A partir desse primeiro diagnóstico univariado das trajetórias, será possível estimar a matriz de quase-correlações e a matriz quase-covariância para identificar quais fatores estão mais diretamente ligados ao desempenho dos índices estudados.

Complementarmente às medidas de risco dadas pela volatilidades multivariadas,

também serão investigadas possíveis fontes de incertezas associadas ao setor. Para isso serão estimados choques de incertezas dos índices de energia renovável para verificar como elas afetam os índices americano e europeu. Para além desta breve introdução, o trabalho se divide em mais cinco capítulos. O Capítulo 2 caracteriza a energia renovável, abordando algumas de suas modalidades de acordo com a escolha feita para o estudo, mostrando características de tais modalidades, como produção e potencial enérgico.

No Capítulo 3 são descritos os detalhes técnicos dos procedimentos metodológicos da pesquisa, com as informações que foram importantes para as formulações dos modelos e testes a serem utilizados, especificando suas características e pacotes computacional do software livre R. O Capítulo 4 reporta como foi realizado o desenho amostral, com informações amostrais, características e tratamento de dados, bem como são apresentados os critérios usados para a escolha das formas funcionais, *lags* entre variáveis e aspectos fundamentais da construção das matrizes, etc. O Capítulo 5 expõe e analisa os resultados obtidos do trabalho. Por fim, o Capítulo 6 apresenta as considerações finais do trabalho, com sugestões para trabalhos futuros e continuação da pesquisa.

Capítulo 2

Literatura

Energia renovável é aquela que vem de recursos renováveis da natureza, como sol (energia solar), vento (energia eólica), chuva (energia hidroelétrica), entre outras. Contudo, nem todo recurso natural é renovável como, por exemplo, o urânio, carvão e petróleo, que existem em quantidades limitadas na natureza e geram resíduos significativos na sua transformação em energia. De acordo com [Stapleton and Neill \(2012\)](#) a energia é produzida por meio da conversão de luz solar em eletricidade, pelo efeito fotovoltaico. Este não deve ser confundido com os sistemas térmicos solares que usam a energia do sol para aquecer alguma substância, líquido, etc. Os sistemas fotovoltaico e térmico são muito diferentes em aparência e operação.

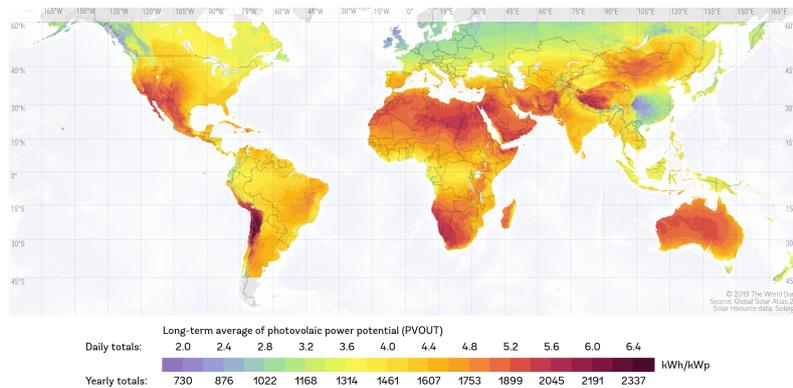
Os sistemas fotovoltaico e térmico têm como base energética o sol. No entanto, os mesmos guardam diferenças na geração de energia, sendo que fotovoltaico usa a luz solar e converte diretamente para energia elétrica. Na outra mão, o sistema térmico usa o calor do sol para obter energia térmica que depois poderá ser transformada em energia elétrica. Segundo [Myers \(2012\)](#) as tecnologias fotovoltaicas utilizam vários materiais semicondutores que liberam elétrons de sua estrutura atômica constituinte, e se tornam disponíveis para condução ou para a produção de corrente elétrica. Os elétrons são expulsos das bandas orbitais absorvendo fótons acima de um limiar de energia adequado.

Quando trata-se de sistemas FV, tem-se duas modalidades mais comuns de instalação, off-grid e on-grid. A principal diferença trata-se de quando a produção é maior que o consumo: na primeira, a energia sobressalente é enviada para a rede de distribuição, já a segunda, é armazenada utilizando baterias. Ambos os sistemas tendem a ser econômicos após um período de tempo tendo retorno. Mesmo considerando que o custo de manutenção e bateria seja alto para o off-grid e tenha manutenção e taxas do on-grid, ambos podem ser economicamente viáveis ([Vigneshwari et al., 2016](#)).

Um dos fatores empíricos da produção de energia solar é a radiação solar, que é a energia emitida pelo sol, propagada por ondas eletromagnéticas. A incidência de

radiação solar na superfície do planeta é uma contribuição fundamental para muitos aspectos da climatologia e outras ciências, além de ser um parâmetro importante nas aplicações de energia solar (Santamouris *et al.*, 1999). A Figura 2.1 mostra o potencial energético fotovoltaico a partir da radiação solar no ano de 2019.

Figura 2.1: Mapa global do potencial energético fotovoltaico

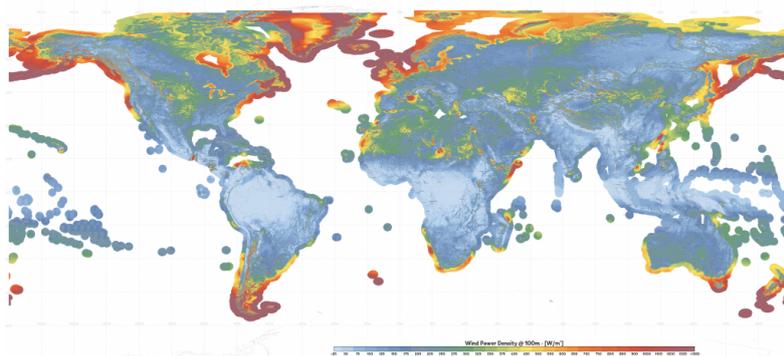


Fonte: Global Solar Atlas

A Energia Eólica é uma espécie de energia verde que também vem do sol, que aquece a superfície da Terra de forma não homogênea. Isso faz com que o ar se mova entre os locais de baixa pressão e locais de alta pressão, gerando ventos. A produção da energia eólica usa o movimento dos ventos para o deslocamento das turbinas acionando o gerador. Esse, por sua vez, converte energia cinética em elétrica, passando para o transformador que transforma CC (corrente elétrica contínua) em CA (corrente elétrica alternada), para que a energia possa ser usada na rede.

Um dos fatores mais importantes para a produção de energia eólica é o tipo de corrente de ventos, que é consiste na forma como se dá o movimento dos ventos. Logo, as turbinas eólicas devem ser instaladas nos melhores locais de ventos, que podem ser distantes a vários quilômetros de estradas e linhas da rede (Johnson, 1985), sendo esta questão logística extremamente importante. A Figura 2.2 mostra o potencial da energia eólica.

Figura 2.2: Mapa global do potencial da energia eólica

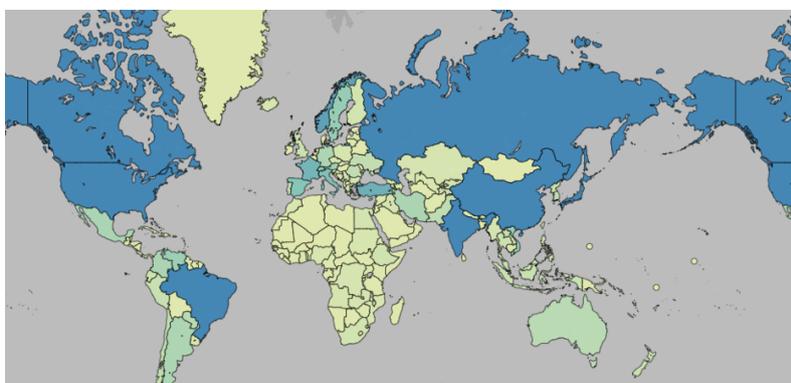


Fonte: Global Wind Atlas

A Energia Hidroelétrica, na outra mão, converte energia mecânica pela rotação de um eixo, por meio de turbinas hidráulicas, com a finalidade de prover energia elétrica para uso. A energia hidrelétrica também é caracterizada pela grande variedade de efeitos positivos e negativos que pode ter sobre o ecossistema. Tanto efeitos sociais quanto ambientais, que podem ser substanciais (Frey and Linke, 2002).

O International Hydropower Association, com um banco de dados de energia hidrelétrica, contém dados para mais de 8.000 estações hidrelétricas individuais acima de 1 MW de capacidade. Elas representando 89% da capacidade global, além de dados de empresas e nacionais, como mostra a Figura 2.3

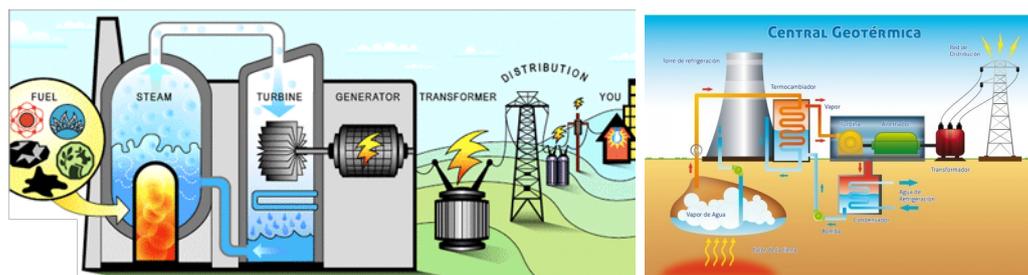
Figura 2.3: Potencial da energia hidráulica



Fonte: International Hydropower Association

Ao converter resíduos agrícolas, industriais e domésticos em combustível sólido, líquido e gasoso, a Biomassa gera energia a um custo econômico e ambiental muito mais baixo. A Energia Geotérmica, diferentemente, aproveita o calor natural abaixo da superfície da Terra. Ela se destaca em países como a Islândia, onde o calor geotérmico é muito mais disponível gratuitamente. Nas Figuras 2.4(a) e 2.4(b) nota-se a produção de energias por biomassa e geotérmica:

Figura 2.4: Ilustração de sistemas de produção de energia, biomassa e geotérmica



(a) Biomassa

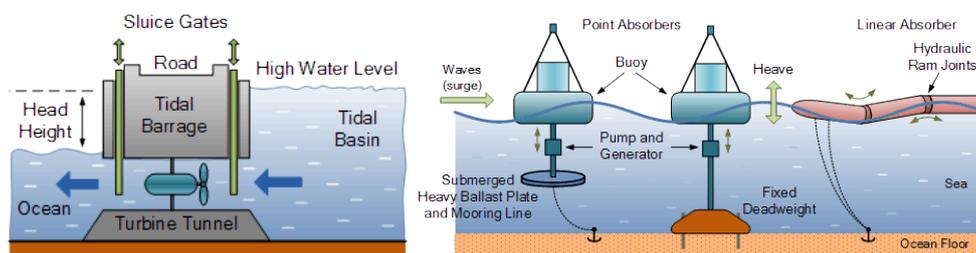
(b) Geotérmica

Fonte: Xcel Energy Inc. & Inpraind S.A

Algumas similaridades podem ser apontadas, pois em ambas o aquecimento de água em vapor gira turbinas que assim geram energia que pode ser convertida no consumo elétrico das redes e distribuidoras. A Maremotriz, por outro lado, é uma forma de energia hidráulica que usa correntes de maré duas vezes ao dia para acionar geradores de turbinas. Embora o fluxo das marés, diferentemente de outras fontes de energia hidráulica, não seja constante, é altamente previsível.

Por fim, a Ondomotriz como a maremotriz é hidráulica, mas aproveita os movimentos das ondas, como é possível observar nas Figuras 2.5(a) e 2.5(b):

Figura 2.5: Ilustração de sistemas de produção de energia, maremotriz e ondomotriz



(a) Maremotriz

(b) Ondomotriz

Fonte: Alternative Energy Tutorials May

À medida que o compromisso global com as energias renováveis aumenta em função da preocupação com o futuro da humanidade, é provável que mais atenção se concentre nas imensas reservas de energia no oceano, (Pelc and Fujita, 2002). Desta forma, os índices estudados podem revelar as ameaças ao desempenho desse segmento, sendo a compreensão da sua relação com demais indicadores mundiais de primeira importância. A partir de tal compreensão será possível desenhar políticas setoriais que minimizem os efeitos de distúrbios, *distress* e volatilidade sobre as empresas envolvidas em toda a cadeia de provisão, transmissão e distribuição de energias renováveis.

Para Inchauspe, Ripple, and Trück (2015) os retornos das empresas de alta tecnologia e energia renováveis parecem estar altamente correlacionados. O trabalho

também aponta que eles parecem ter uma influência fraca das mudanças no preço do petróleo. Assim índices como Arca Tech 100, que relaciona e as empresas de tecnologia e West Texas Intermediate, o valor futuro de petróleo mais líquido, também serão analisados. Os retornos de índices que se relacionam com o setor de energia renovável e seus respectivos mercados podem explicar como se comporta os riscos e as incertezas relacionadas ao aumento da participação dos mercados de energias renováveis nos EUA e UE. Tais aspectos podem enriquecer a análise e trazer mais evidências empíricas associadas a este setor.

Capítulo 3

Procedimentos Metodológicos

Conforme mencionado, para o propósito do presente trabalho foram utilizados os modelos da família GARCH. A partir das suas características e testes preliminares, foram escolhidas as formas funcionais do modelo univariado e, posteriormente, elencadas covariadas como entrada do sistema multivariado, particularmente o modelo DCC-GARCH. Esses modelos são utilizados com dados estacionários, condição atendida já que os dados dos retornos dos índices são estacionários por natureza, como pode-se verificar nas Tabelas 4.5 e 4.6.

Os critérios usados para a escolha da forma univariada são os critérios de informação Akaike (AIC), Bayesian (BIC), Hannan Quinn (HQIC) e Shibata (SIC) que permitem a seleção do modelo penalizando o sobreajuste (Ghalanos, 2013). Pode-se formular os critérios da seguinte forma:

$$\text{AIC} = \frac{-2 \ln(\hat{L})}{n} + \frac{2k}{n} \quad (3.1)$$

$$\text{BIC} = \frac{-2 \ln(\hat{L})}{n} + \frac{k \ln(n)}{n} \quad (3.2)$$

$$\text{SIC} = \frac{-2 \ln(\hat{L})}{n} + \ln\left(\frac{n+2k}{n}\right) \quad (3.3)$$

$$\text{HQIC} = \frac{-2 \ln(\hat{L})}{n} + \frac{2k \ln(\ln(n))}{n} \quad (3.4)$$

em que k é o número de parâmetros estimados no modelo, \hat{L} é o valor máximo da função de verossimilhança para o modelo e n é o número de observações.

Os dados representam a Europa e os EUA, utilizados para a construção de dois sistemas, permitindo a comparação dos resultados provindos de cada mercado. A partir do teste de Chow mostra-se a existência ou não de quebras estruturais nas variáveis dos sistemas, ou seja, mudança significativas nas trajetórias. Assim, é

possível decidir a partir de critérios estatísticos a melhor forma de construção de amostras para análises diferenciadas.

O teste de Chow, desenvolvido por [Chow \(1960\)](#), considera mudanças estruturais determinadas exogenamente para estimar pontos de possíveis quebras estruturais nas trajetórias dos retornos amostrados:

$$Q_q(y_i) = x'\lambda(q) \quad \text{para } n_1 \quad (3.5)$$

$$Q_q(y_i) = x'\gamma(q) \quad \text{para } n_2 \quad (3.6)$$

$$Q_q(y_i) = x'\beta(q) \quad \text{para } n = n_1 + n_2 \quad (3.7)$$

em que $\lambda(q)$, $\gamma(q)$ e $\beta(q)$ são os vetores de coeficientes estimados para n_1 , n_2 e $n = n_1 + n_2$, respectivamente. O teste de Chow usa a soma dos quadrados dos resíduos (SQR) dos diferentes modelos estimados.

A hipótese nula do teste (H_0) é que os parâmetros são estáveis, ou seja, não há alteração estrutural nas estimativas. Já a hipótese alternativa do teste (H_1) é que os parâmetros não são estáveis, ou seja, há alteração estrutural nas estimativas. A estatística F calculada a partir dos modelos com o valor crítico é comparado com $F_{(k, n_1+n_2-2\cdot k)}$.

3.1 Representação Básica

Para representação de séries temporais e obter estimativas do seu comportamento, utilizam-se modelos AR (*Autorregressive*), MA (*Moving Average*) e ARMA (*Autorregressive Moving Averages*). Tais formas permitem empregar técnicas de previsões de sistemas de energias renováveis como em [Espinhar et al. \(2010\)](#). Os modelos AR postulam que o valor de x no período t depende do seu valor no período anterior e de um termo aleatório. Em outras palavras, esse modelo informa que o valor previsto de x no período t é simplesmente alguma proporção mais um choque aleatório ou perturbação.

Os valores são expressos em torno dos seus valores médios ([Morettin, 2017](#)). Pode-se escrever, AR(p), como:

$$x_t = \sum_{i=1}^p \varphi_i x_{t-i} + \varepsilon_t \quad (3.8)$$

em que x_t é o valor da série temporal no tempo t , $\varphi = (\varphi_1 \cdots \varphi_p)$ é o vetor dos coeficientes do modelo e ε_t é o ruído.

Os modelos AR são base para modelos posteriores sendo sua forma funcional a

base para famílias de modelos mais complexos. Já os modelos MA , por outro lado, são um processo de média móvel, que consistem numa combinação linear de termos de erro do tipo *ruído branco*, (Morettin, 2017). Pode-se descrever um modelo de médias móveis de ordem m , $MA(q)$, como:

$$x_t = \sum_{j=0}^q \theta_j \varepsilon_{t-j} \quad (3.9)$$

em que x_t é o valor observado no instante t , $\theta = (\theta_1 \cdots \theta_q)$ é o vetor dos coeficientes do modelo, $\theta_0 = 1$ e ε_t é o ruído. O modelo $MA(1)$ é dado por:

$$x_t = \varepsilon_t + \theta_1 \varepsilon_{t-1}. \quad (3.10)$$

Uma combinação dos modelos AR da equação (3.8) e MA da equação (3.9) são os modelos ARMA , de ordem (p, q) . Nele, os termos autorregressivos p e termos de média móvel q possuem características tanto do modelo autoregressivo como do modelo de médias móveis, o $ARMA(p, q)$, que pode ser escrito por:

$$x_t = \sum_{i=1}^m \varphi_i x_{t-i} + \sum_{j=0}^n \theta_j \varepsilon_{t-j} \quad (3.11)$$

em que x_t é o valor da série temporal, no instante t . A combinação de AR da equação (3.8) e MA da equação (3.9), sendo φ_i, θ_j os coeficientes do modelo e ε_t é o ruído. O modelo $ARMA(1,1)$ é dado por:

$$x_t = \varphi_1 x_{t-1} + \varepsilon_t + \theta_1 \varepsilon_{t-1} \quad (3.12)$$

Os modelos de séries temporais mostrados, são baseados na suposição de que as trajetórias estudadas são (fracamente) estacionárias (Morettin, 2017). Se uma série temporal for integrada de ordem 1, suas primeiras diferenças são $I(0)$, isto é, estacionárias. Da mesma forma, se uma série temporal é $I(2)$, sua segunda diferença é $I(0)$. Em geral, se uma série temporal é $I(d)$, depois de diferenciá-la d vezes, obtemos uma série $I(0)$.

Por outro lado, os modelos ARIMA (*Autoregressive Integrated Moving Average*), de ordem (p, d, q) . Nele, d representa o número de vezes que se deve diferenciar uma série temporal, para torná-la estacionária, $ARIMA(p, d, q)$ pode ser escrito:

$$x_t = \sum_{i=1}^p \varphi_i S^d x_{t-i} + \sum_{j=0}^q \theta_j \varepsilon_{t-j} \quad (3.13)$$

A combinação das formas AR(3.8) e MA(3.9), é o modelo ARMA com a determi-

nação a ordem de integração $I(d)$, sendo φ_i, θ_j os coeficientes do modelo, ε_t o ruído, $S = 1 - q^{-1}$ e $\varphi_m(q)$ estacionários.

É possível escrever todos os modelos vistos anteriores utilizando a forma ARIMA, isto é:

$$ARIMA(p, 0, 0) = AR(p); \quad (3.14)$$

$$ARIMA(0, 0, q) = MA(q); \quad (3.15)$$

$$ARIMA(p, 0, q) = ARMA(p, q) \quad (3.16)$$

Em geral, a variância dos retornos dos ativos de risco dos mercados financeiros não é constante e, conseqüentemente é necessário representar esse fenômeno com a forma adequada (Navascués *et al.*, 2016). Para Engle (1982) uma classe de processos estocásticos chamados modelos de heterocedasticidade condicional autorregressiva (ARCH), em que a variância condicionada aos dados não é constante, são mais adequados para representar os modelos propostos no presente trabalho.

3.2 Modelos de Heterocedasticidade Condicional Univariados

Os modelos ARCH (*Autoregressive Conditional Heterocedasticity*) foram desenvolvidos para estimação da volatilidade pela primeira vez por Engle. Seja r_t a representação dos retornos da série temporal observada e h_t a volatilidade no instante t :

$$r_t = \sqrt{h_t} \varepsilon_t \quad (3.17)$$

em que ε_t é uma variável aleatória independente e identicamente distribuída (i.i.d.), com média zero ($\mu = 0$). Na prática, usualmente supõe-se que a série em tela segue distribuição normal ou t de *Student*. Para estimar a volatilidade h_t no instante t utilizando um modelo ARCH(q), tem-se:

$$h_t = \alpha_0 + \sum_{i=1}^q \alpha_i r_{t-i}^2 = \alpha_0 + \sum_{i=1}^q \alpha_i h_{t-i} \varepsilon_{t-i}^2$$

em que $\begin{cases} \alpha_0 > 0 \\ \alpha_i \geq 0, & i = 1, 2, \dots, q-1. \\ \alpha_q > 0 \end{cases}$ A condição de estacionariedade do modelo é $\sum_{i=1}^q \alpha_i < 1$.

O modelo ARCH(1) é dado por:

$$r_t = \varepsilon_t \sqrt{\alpha_0 + \alpha_1 r_{t-1}^2} \quad \text{onde } \alpha_0 + \alpha_1 < 1. \quad (3.18)$$

Com a generalização do modelo ARCH proposta por [Bollerslev \(1986\)](#), o modelo Generalizado de Heterocedasticidade Condicional Autorregressiva (GARCH) (*generalized ARCH*) estima a volatilidade h_t dos retornos (3.17) da série temporal observada no instante t . Ele pode ser escrito GARCH(p, q) conforme segue:

$$h_t = \alpha_0 + \sum_{i=1}^p \alpha_i r_{t-i}^2 + \sum_{j=1}^q \beta_j h_{t-j} \quad (3.19)$$

em que $\begin{cases} \alpha_0 > 0 \\ \alpha_i \geq 0 & i = 1, 2, \dots, p \\ \beta_j \geq 0 & j = 1, 2, \dots, q \end{cases}$, com a condição de estacionariedade

$$\sum_{i=1}^m (\alpha_i + \beta_i) < 1, \quad \text{onde } m = \max(p, q).$$

No caso em tela foram utilizadas algumas formas funcionais de GARCH. São elas o modelo Exponential GARCH (EGARCH), o modelo Integrated GARCH (IGARCH), o Threshold GARCH (TGARCH), e o Glosten-Jagannathan-Runkle GARCH (GJR GARCH). Os modelos EGARCH foram propostos por [Nelson \(1991\)](#). Estima-se a volatilidade h_t dos retornos (3.17) da série temporal observada no instante t pelo modelo EGARCH(p, q) da seguinte maneira:

$$\ln(h_t) = \alpha_0 + \sum_{i=1}^p \{ \alpha_i (|\varepsilon_{t-i}| - \mathbb{E}[|\varepsilon_{t-i}|]) + \gamma_i \varepsilon_{t-i} \} + \sum_{j=1}^q \beta_j \ln(h_{t-j}) \quad (3.20)$$

$$\ln(h_t) = \alpha_0 + \sum_{i=1}^p \left[\alpha_i \left(\frac{|r_{t-i}|}{\sqrt{h_{t-i}}} - \sqrt{\frac{2}{\pi}} \right) + \gamma_i \frac{r_{t-i}}{\sqrt{h_{t-i}}} \right] + \sum_{j=1}^q \beta_j \ln(h_{t-j}) \quad (3.21)$$

em que $\mathbb{E}[|\varepsilon_t|] = \mathbb{E}\left[\frac{|r_t|}{\sqrt{h_t}}\right] = \sqrt{\frac{2}{\pi}}$, $r_t = \sqrt{h_t} \varepsilon_t$ e $x_t = \mu + r_t$.

O modelo IGARCH proposto por [Engle and Bollerslev \(1986\)](#) trata de uma restrição ao modelo GARCH da equação (3.19), em que:

$$\sum_{j=1}^p \beta_j + \sum_{i=1}^q \alpha_i = 1 \quad (3.22)$$

com $1 > \beta_j > 0$.

O modelo TGARCH foi proposto por [Zakoian \(1994\)](#). Estima-se a volatilidade h_t dos retornos (3.17) da série temporal observada no instante t pelo modelo TGARCH(p, q) conforme a seguir:

$$h_t = \alpha_0 + \sum_{i=1}^p (\alpha_i + \gamma_i N_{t-i}) r_{t-i}^2 + \sum_{j=1}^q \beta_j h_{t-j} \quad (3.23)$$

em que $N = \begin{cases} 1 & \text{se } r_{t-1} < 0 \\ 0 & \text{se } r_{t-1} \geq 0 \end{cases}$ e α_i, γ_i e β_j são não-negativos.

Uma forma funcional equivalente ao TGARCH são os modelos GJR GARCH de [Glosten, Jagannathan, and Runkle \(1993\)](#). Estes ajustam choques positivos e negativos na variância condicional assimetricamente do valor de N :

$$\sigma_t^2 = \left(\alpha_0 + \sum_{j=1}^m \zeta_j v_{jt} \right) + \sum_{i=1}^p (\alpha_i + \gamma_i N_{t-i}) r_{t-i}^2 + \sum_{j=1}^q \beta_j h_{t-j}. \quad (3.24)$$

3.3 Modelos de Heterocedasticidade Condicional Multivariados

Uma especificação dinâmica do Modelo Multivariado Generalizado de Heterocedasticidade Condicional Autorregressiva (MGARCH) é usado para estimar a volatilidade condicional e identificar as covariadas de fenômenos por meio de suas quase-covariâncias e quase-correlações. Além de estimar mudanças estruturais que possivelmente afetaram a dinâmica dos retornos dos índices selecionados para este estudo, a estrutura multivariada utilizada fornece informações sobre outros processos estocásticos importantes para prever retornos e volatilidade.

Para análise multivariada, são utilizados quatro métodos de parametrização: o modelo Diagonal VEC (DVECH), o modelo de Correlação Condicional Constante (CCC), e o modelo de Correlação Condicional Dinâmica (DCC) ([Frascaroli, 2020](#)). Os modelos MGARCH foram propostos por [Bauwens, Laurent, and Rombouts \(2006\)](#). Desta forma, estima-se a matriz \mathbf{H}_t de covariadas, alternativamente à medida de volatilidade h_t dos retornos (3.17). Tem-se que:

$$y_t = \mathbf{C}x_t + \epsilon_t \quad (3.25)$$

$$\epsilon_t = \mathbf{H}_t^{1/2} v_t \quad (3.26)$$

em que y_t é um vetor de ordem $m \times 1$, \mathbf{C} é uma matriz de parâmetros de ordem $m \times k$,

x_{it} é um vetor de variáveis independentes que podem conter defasagens de y_t , $\mathbf{H}_t^{1/2}$ é o fator de Cholesky da matriz \mathbf{H}_t de covariância condicional variável no tempo, e v_t é um vetor de ordem $m \times 1$ com média zero e independente e identicamente distribuída (i.i.d.). No modelo geral \mathbf{H}_t é uma matriz GARCH univariada. Um MGARCH com um termo autoregressivo de heterocedasticidade condicional (ARCH) e um termo GARCH pode ser representado como segue:

$$\text{vech}(\mathbf{H}_t) = s + \mathbf{A} \text{vech}(\epsilon_{t-1} \epsilon'_{t-1}) - \mathbf{B} \text{vech}(\mathbf{H}_{t-1}), \quad (3.27)$$

em que a função $\text{vech}(\cdot)$ trata dos elementos acima ou abaixo da diagonal principal, s é um vetor de parâmetro; \mathbf{A} e \mathbf{B} são matrizes dos parâmetros. Uma vantagem deste modelo é que ele emprega a função vech para extrair e modelar elementos de \mathbf{H}_t , que deve ser definida positiva.

A equação (3.27) pode ser utilizada para mostrar que os parâmetros em s , \mathbf{A} e \mathbf{B} não são exclusivos. Portanto, para que o \mathbf{H}_t seja definida positiva, outras restrições devem ser incorporadas em s , \mathbf{A} e \mathbf{B} . [Bollerslev, Engle, and Wooldridge \(1988\)](#) exigem que \mathbf{A} e \mathbf{B} sejam diagonais para maior parcimônia e mais robustez ao estimar um pequeno número de processos temporais, uma vez que o número de parâmetros a serem estimados no modelo aumenta a uma taxa quadrática. DVECH (1,1) é formulado em que cada elemento de \mathbf{H}_t é dado da seguinte forma:

$$h_{ij,t} = s_{ij} + a_{ij} \epsilon_{i,t-1} \epsilon_{j,t-1} + b_{ij} h_{ij,t-1}. \quad (3.28)$$

O modelo MGARCH CCC permite representar um conjunto não linear de processos univariados GARCH para estimar variações condicionais. A matriz de correlação condicional é definida positiva para construir uma estrutura que facilite a estimativa de parâmetros. Nos modelos de correlação condicional do MGARCH \mathbf{H}_t é decomposto em uma matriz de correlação condicional \mathbf{R}_t e \mathbf{D}_t , uma matriz diagonal de variações condicionais, conforme a relação a seguir:

$$\mathbf{H}_t = \mathbf{D}_t^{1/2} \mathbf{R}_t \mathbf{D}_t^{1/2} \quad (3.29)$$

em que cada variação condicional segue GARCH univariado.

As parametrizações de \mathbf{R}_t tem-se:

$$h_{ij,t} = \rho_{ij,t} + \sigma_{i,t} \sigma_{j,t} \quad (3.30)$$

em que $\sigma_{i,t}$ é modelado por um GARCH univariado.

Já no modelo DCC-MGARCH desenvolvido por [Engle \(2002\)](#) os retornos \mathbf{R}_t seguem um GARCH (1,1). Os parâmetros de \mathbf{R}_t não são padronizados para terem correlações e são chamados quase-correlações. Este modelo é significativamente

mais flexível que o CCC e não introduz um número muito maior de parâmetros para o número de processos estocásticos. O DCC-MGARCH utiliza combinações não-lineares ponderadas de variações no tempo GARCH univariada. Os elementos diagonais de \mathbf{H}_t são modelados usando GARCH univariado. Os elementos restantes são modelados por funções não lineares com base nos termos resultantes da diagonal:

$$h_{ij,t} = \rho_{ij,t} + \sigma_{i,t}\sigma_{j,t}^{1/2} \quad (3.31)$$

em que os termos $h_{ii,t}$ e $h_{jj,t}$ caracterizam o processo GARCH e $\rho_{ij,t}$, t representa o processo dinâmico (Engle, 2002). O DCC-MGARCH pode ser escrito usando a Equação (3.29) da seguinte maneira:

$$\mathbf{R}_t = \text{diag } \mathbf{Q}_t^{-1/2} \mathbf{Q}_t \text{diag } \mathbf{Q}_t^{-1/2} \quad (3.32)$$

$$\mathbf{Q}_t = (1 - \lambda_1 - \lambda_2) \mathbf{R} + \lambda_1 \tilde{\epsilon}_{t-1} \tilde{\epsilon}'_{t-1} + \lambda_2 \mathbf{Q}_{t-1} \quad (3.33)$$

em que $\tilde{\epsilon}_{t-1}$ é um vetor $m \times 1$ de resíduos padronizados, $\tilde{\epsilon}'_t$, λ_1 e λ_2 são parâmetros que conduzem a dinâmica de quase correlação, λ_1 e λ_2 são não-negativos e atender à condição $0 \leq (\lambda_1 + \lambda_2) < 1$. Quando \mathbf{Q}_t é estacionário, a matriz \mathbf{R} é a média ponderada da matriz de covariância dos resíduos padronizados $\tilde{\epsilon}_t$. É denotado por $\bar{\mathbf{R}}$ e a média incondicional de \mathbf{Q}_t , denotado por $\bar{\mathbf{Q}}_t$. Como $\mathbf{Q}_t \neq \mathbf{R}_t$, R não representa a matriz de correlação ou a média incondicional de \mathbf{Q}_t .

\mathbf{B} é matriz de parâmetros dada por:

$$B = \begin{bmatrix} \sigma_{1,2}^2 & 0 & \dots & 0 \\ 0 & \sigma_{1,2}^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sigma_{1,2}^2 \end{bmatrix}$$

em que cada $\sigma_{i,t}^2$ correspondendo a um GARCH univariado, conforme a seguir:

$$\sigma_{i,t}^2 = s + \sum_{j=1}^p \alpha_j \epsilon_{i,t-j}^2 + \sum_{j=1}^q \beta_j \sigma_{i,t-j}^2 \quad (3.34)$$

ou quando o termo constante é adicionado:

$$\sigma_{i,t}^2 = \exp(\gamma_i z_{i,t}) + \sum_{j=1}^p \alpha_j \epsilon_{i,t-j}^2 + \sum_{j=1}^q \beta_j \sigma_{i,t-j}^2 \quad (3.35)$$

em que γ_i é um vetor $1 \times p$ de parâmetros, z_i é um vetor $p \times 1$ de variáveis independentes, incluindo um termo constante, α_j são os parâmetros ARCH e β_j são os parâmetros GARCH. A matriz de quase-correlação condicional é:

$$R_t = \begin{bmatrix} 1 & \rho_{12,t} & \dots & \rho_{1m,t} \\ \rho_{12,t} & 1 & \dots & \rho_{2m,t} \\ \vdots & \vdots & \ddots & \vdots \\ \rho_{1m,t} & \rho_{2m,t} & \dots & 1 \end{bmatrix} \quad (3.36)$$

3.4 Representação dos Choques de Riscos e Incertezas

Para simular os choques de riscos e incertezas sobre os índices de energias renováveis americano e europeu usou-se a volatilidade condicional dos retornos, as quase-correlações condicionais e os resíduos estimados como variáveis de entrada em um modelo de Vetores Autoregressivos (VAR). Esta é uma adaptação de (Jurado, Ludvigson, and Ng, 2015 e Scotti 2016), usando um modelo VAR padrão irrestrito, cuja forma mais simples é descrita em termos de variáveis defasadas:

$$y_t = \sum_{l=1}^p \Phi_l y_{t-l} + \epsilon_t \quad (3.37)$$

com Φ_l matriz $k \times k$ para $t = 1 \dots p$ dos parâmetros covariáveis da energia renovável e ϵ_t é o vetor de erros i.i.d.. A partir do modelo VAR foram estimadas funções impulso resposta (IRF) para verificar como um choque no risco e na incerteza das variáveis estudadas respondem.

3.5 Suporte Computacional

O *software R Statistics* é uma linguagem computacional com ambientes gráficos e estatísticos. O [R Core Team \(2019\)](#) fornece uma ampla variedade de técnicas estatísticas e gráficas e é altamente extensível. O mesmo está disponível como *software* livre (*open source*) sob os termos da GNU General Public License da Free Software Foundation (GNU GPL) no formato de código-fonte. Além da linguagem R ser muito popular, ela possui atualmente mais de 15 mil pacotes em seu depositário oficial CRAN¹.

Ele ainda conta com pacotes não oficiais depositados na plataforma de hospedagem de código-fonte no Github². Pacotes como `tseries` (Trapletti and Hornik, 2019), `xts` (Ryan and Ulrich, 2020), `fBasics` (Wuertz, Setz, and Chalabi, 2017), `strucchange` (Zeileis *et al.*, 2002), `rugarch` (Ghalanos, 2020), `rmgarch` (Ghalanos,

¹The Comprehensive R Archive Network

²GitHub Inc.

2019) e `vars` (Pfaff, 2008), possuem funções bastante úteis. As implementações dos códigos usados estão presentes no Apêndice C para que possa ser replicada ou tomada como ponto de partida para implementações futuras. Os pacotes usados `tseries`, `xts` criam objetos do tipo `"timeserie"`.

Para a construção da Tabela 4.1, Tabela 4.2, Tabela 4.3 e Tabela 4.4 foi utilizada a função `basicStats` do pacote `fBasics`. Ela recebe um objeto do tipo `"timeserie"` e retorna um `"data.frame"` com número de observações, número de não avaliações, valor máximo, 1º quartil, 3º quartil, média, mediana, soma total dos valores, erro quadrado médio, limite de controle inferior médio, limite de controle superior médio, variância, desvio padrão, coeficiente de assimetria e curtose.

As quebras estruturais foram estimadas com o uso do pacote `strucchange` utilizando a função `Fstats` que calcula a estatística F (estatística do teste Chow) para cada ponto possível. Ela gera um objeto da classe `"Fstats"`, aplicando esse objeto na função `breakpoints` e retorna as possíveis quebras estruturais, que posteriormente foram testadas com a função `sctest`. O pacote `rugarch` foi usado para testar qual forma funcional do modelo GARCH, com as funções `autoarfima` para qual modelo de média se ajusta melhor e `ugarchspec` para especificar qual forma funcional de GARCH será testada.

Ela gera um `"uGARCHspec"` que juntamente com os dados são inseridos em `ugarchfit` serve para testar os ajustamentos, tendo o retorno dos critérios AIC, BIC HQIC e SIC, entre outros parâmetros. Para o uso de modelos GARCH multivariados, recorreu-se ao pacote `rmgarch`, que disponibiliza a função `dccfit`, que recebe um `"data.frame"` com as variáveis, um objeto de saída da função `dccspec` que são as características do modelo DCC e um objeto de saída da função `multifit` que são as características do modelo GARCH.

O pacote oferece como saída vários objetos como matriz com os parâmetros estimados para o modelo DCC-GARCH e matrizes de correlação e covariância entre as variáveis, resíduos do modelo, variância estimada e outras estatísticas. Os choques de riscos e incertezas foram estimados com o pacote `vars`. Selecionou-se a função `VARselect` para a escolha da ordem de entrada das variáveis e em seguida a função `VAR` para estimar um modelo VAR (3.37).

Por fim, utilizou-se a função do impulso resposta `irf` tendo como dados de entrada os desvios-padrão estimados dos termos de erros, os desvios-padrão estimados dos erros da variável no modelo corresponde aos choques. As saídas das funções `irf` são empregadas na função `plot` para geração da Figura 5.2 e da Figura 5.3.

Capítulo 4

Desenho Amostral e Tratamento dos Dados

A escolha dos dados e o desenho amostral foi limitada pela inexistência de informações de outros países sobre o desempenho das energias renováveis. Além disso, buscou-se dados que poderiam fornecer respostas diante de variáveis endógenas que representassem riscos e incertezas ao setor. Por isso, foram afastados dados que teriam relação com variáveis potencialmente exógenas, como a irradiação solar, quantidade de vento, chuvas, etc., cujo fornecimento de evidências empíricas não seria de interesse analítico. Por esses motivos escolheu-se trabalhar com os índices, que refletem as maiores empresas americanas e europeias relacionados ao setor.

Conforme mencionado, os modelos heterocedásticos desse trabalho usam como dados de estudos séries temporais estacionárias. Assim, a variância dos erros será diferente para cada valor condicional da série, i.e., ela se desenvolve no tempo aleatoriamente ao redor de uma média constante. As amostras foram obtidas em [Inchauspe, Ripple, and Trück \(2015\)](#) e [Han *et al.* \(2019\)](#), principalmente pela não existência de dados da produção das matrizes enérgicas propriamente ditas. Logo, os dados dos retornos dos índices globais e de algumas commodities. Eles foram representados a UE e os EUA.

Algumas características das variáveis são apresentadas a seguir. O índice WilderHill New Energy (ECO) representa o setor de energia limpa: especificamente, empresas que podem se beneficiar de uma transição social em direção a uma energia e conservação mais limpas. As ações e os setores do índice baseiam-se em sua importância para energia limpa, influência tecnológica e relevância na prevenção da poluição em primeiro lugar, ([WilderHill, 2020](#)).

Já o West Texas Intermediate (WTI) é conhecido como petróleo doce leve do Texas, i.e., um tipo de óleo usado como referência nos preços do petróleo. Os contratos futuros de petróleo leve doce NYMEX WTI, o contrato de petróleo bruto mais líquido e negociado ativamente no mundo, são a maneira mais eficiente de negociar

os mercados globais de petróleo (CME, 2017). O índice Morgan Stanley Capital International (MSCI Inc.), por sua vez, refere-se à empresa financeira americana com sede na cidade de Nova York e que atua como fornecedora global de ações, renda fixa, índices do mercado de ações de fundos de hedge e ferramentas de análise de portfólio de múltiplos ativos. Publica os índices MSCI BRIC, MSCI World e MSCI EAFE (Inchauspe, Ripple, and Trück, 2015).

O índice NYSE Arca Tech 100 (PSE Index) foi projetado para fornecer uma referência para medir o desempenho de empresas relacionadas à tecnologia que operam em um amplo espectro de indústrias. A composição do índice e as ações corporativas, incluindo informações que podem ser acessadas a partir da NYSE Market Data, (Ryan, 2007). O índice Thomson Reuters/CoreCommodity CRB (TR/CRB Index) é um índice de preços futuros de commodities. O Commodity Research Bureau, Inc. fundado em 1957, compreende 19 commodities: alumínio, cacau, café, cobre, milho, algodão, petróleo bruto, ouro, óleo para aquecimento, porcos magros, gado vivo, gás natural, níquel, suco de laranja, prata, soja, açúcar, gás sem chumbo e trigo (Han *et al.*, 2019).

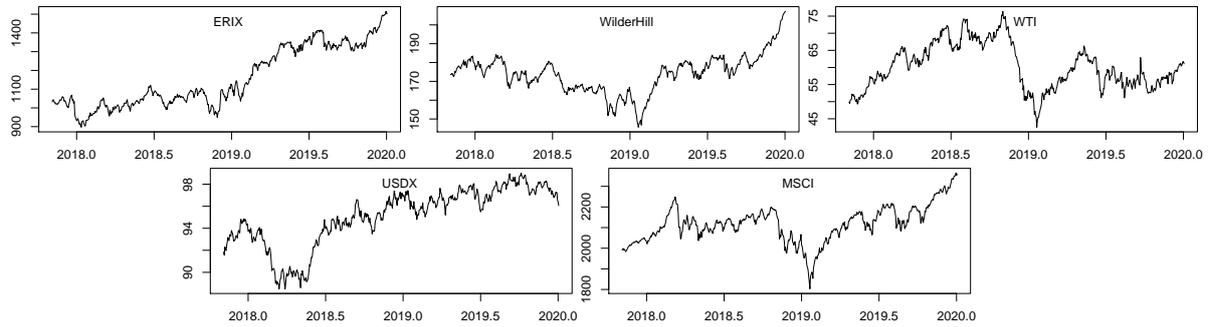
Outro índice que impacta o desempenho do setor de energia renováveis, o U.S. Dollar (USD Index), representa o impacto do valor do dólar dos EUA em relação a uma cesta de moedas estrangeiras, geralmente chamada de cesta de moedas dos parceiros comerciais. O índice sobe quando o dólar norte-americano torna-se mais competitivo quando comparado a outras moedas (Chen, 2020). O índice Standard & Poor's 500 (S&P 500 Index), na outra mão, é composto por quinhentos ativos cotados nas bolsas de NYSE/NASDAQ que juntas representam aproximadamente 80% da capitalização de mercado dos EUA, qualificados devido ao seu tamanho de mercado, sua liquidez e sua representação de grupo industrial (Frascaroli, 2020).

O índice European Renewable Energy (ERIX Index) acompanha o desempenho das empresas europeias de energia renovável que atuam em um, ou vários dos seis grupos de investimentos a seguir: biocombustíveis, geotérmica, marinho, solar, água e eólica (Xia *et al.*, 2019). O índice Renewable Energy Generation (GRNREG) representa o setor primário do índice de economia verde. Ele compreende empresas que produzem energia através de fontes renováveis, como células solares, eólicas, geotérmicas, de ondas, entre outros (Vrinceanu *et al.*, 2020).

O período analisado inicia-se em 19 de janeiro de 2011 (dezenove de janeiro de dois mil e onze) para os EUA, e 18 de setembro de 2017 (dezoito de setembro de dois mil e dezessete) para a UE, quando o índice foi criado. Ambos os períodos estudados encerram-se em 31 de dezembro de 2019 (trinta e um de dezembro de dois mil e dezenove), o que também foi delimitado devido à crise causada pela pandemia da Covid-19 em 2020. Na Figura 4.1 e na Figura 4.2 são apresentados os gráficos das séries temporais dos valores de fechamento das variáveis que compõem os sistemas

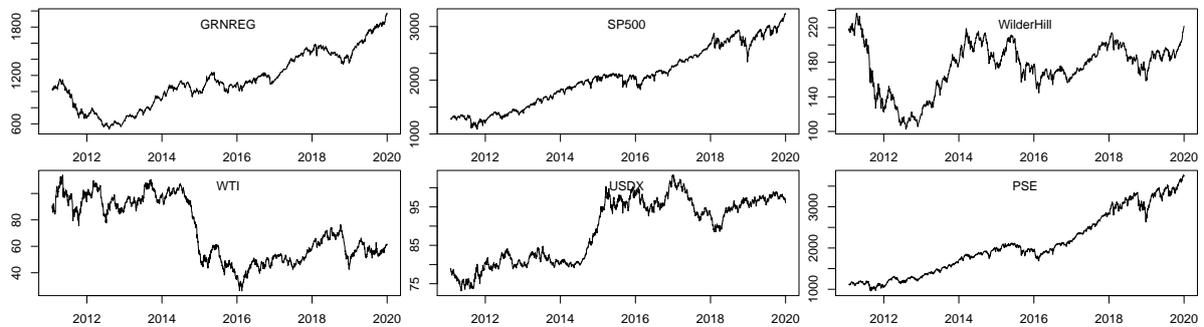
estimados. A Figura 4.3 e a Figura 4.4 exibem os gráficos das séries dos retornos.

Figura 4.1: Valores de fechamento das variáveis que representam a UE



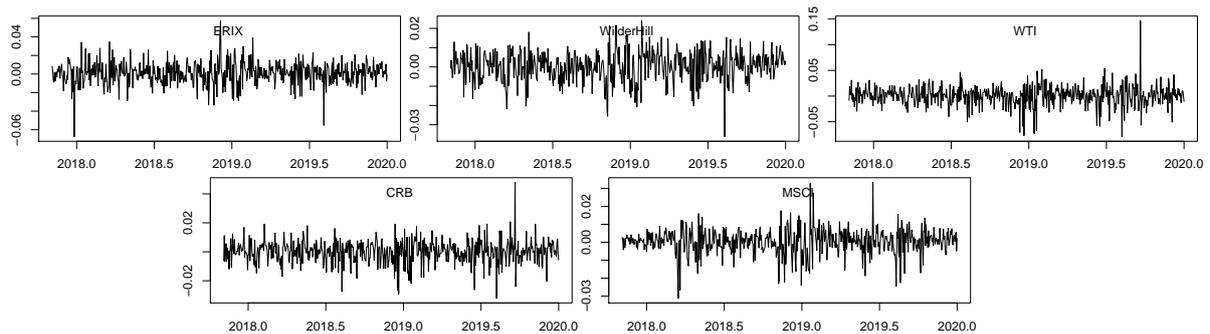
Fonte: Elaborado pelo autor com base em Investing.com

Figura 4.2: Valores de fechamento das variáveis que representam os EUA.



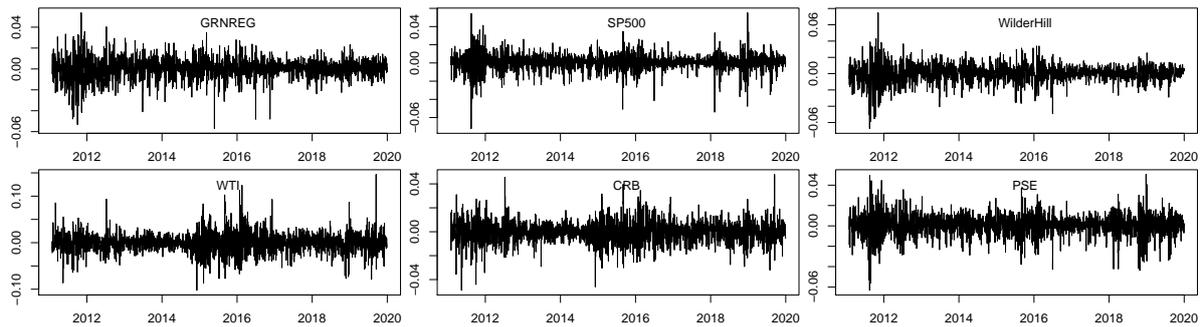
Fonte: Elaborado pelo autor com base em Investing.com

Figura 4.3: Gráfico das séries temporais dos retorno dos valores de fechamento das variáveis que representam a UE.



Fonte: Elaborado pelo autor com base em Investing.com

Figura 4.4: Gráfico das séries temporais dos retorno dos valores de fechamento das variáveis que representam os EUA.



Fonte: Elaborado pelo autor com base em Investing.com

Em termos da análise das estatísticas descritivas, são apresentados o número de observações (Obs.), os valores mínimo e máximo das variáveis estudadas, os valores do 1° quartil), do 3° quartil, assim como a média, a mediana (que equivale ao 2° quartil), o erro padrão médio (EPM), o desvio padrão (DP), a assimetria e a curtose. Tais valores encontram-se, na Tabela 4.1 e na Tabela 4.2. Eles referem-se aos valores de fechamento de mercado das variáveis e na Tabela 4.3 e na Tabela 4.4 referem-se aos retornos usados nas estimações.

Tabela 4.1: Estatísticas dos valores de fechamento da UE

	ERIX	WilderHill	WTI	USDX	MSCI
NObs.	563.00	563.00	563.00	563.00	563.00
Mínimo	896.83	145.62	42.53	88.50	1,802.95
Máximo	1,515.31	207.22	76.41	99.02	2,364.90
1° Quartil	1,027.30	167.13	55.34	93.58	2,063.61
3° Quartil	1,327.05	179.73	65.56	97.13	2,166.76
Média	1,158.10	173.92	60.24	95.05	2,116.68
Mediana	1,087.41	174.99	59.18	95.67	2,119.36
EPM	6.74	0.42	0.28	0.11	3.72
DP	159.97	10.04	6.69	2.62	88.22
Assimetria	0.40	0.05	0.21	-0.79	-0.09
Curtose	-1.29	0.95	-0.72	-0.27	0.70

Fonte: Elaborado pelo autor com base em Investing.com

Tabela 4.2: Estatísticas dos valores de fechamento dos EUA

	GRNREG	SP500	WilderHill	WTI	CRB	PSE
NObs.	2,250.00	2,250.00	2,250.00	2,250.00	2,250.00	2,250.00
Mínimo	531.80	1,086.25	102.40	26.21	155.01	958.37
Máximo	1,968.70	3,244.50	236.44	113.93	370.56	3,768.79
1° Quartil	900.03	1,564.94	160.67	51.07	184.62	1,406.49
3° Quartil	1,422.35	2,500.63	195.71	94.89	295.68	2,686.86
Média	1,130.51	2,054.66	174.78	71.62	239.24	2,077.30
Mediana	1,100.05	2,048.25	179.22	65.49	212.34	1,940.38
EPM	7.05	11.58	0.60	0.48	1.26	15.81
DP	334.34	549.22	28.58	22.92	59.60	749.70
Assimetria	0.26	0.16	-0.60	0.14	0.37	0.48
Curtose	-0.67	-1.05	-0.25	-1.49	-1.43	-0.91

Fonte: Elaborado pelo autor com base em Investing.com

Nas Tabelas 4.1, 4.3 a maioria, das médias ficaram próximas a mediana; os coeficientes de assimetria ficaram positivos que pode ser analisado que a cauda do lado direito da função densidade de probabilidade é maior que a do lado esquerdo e a curtose menor que 0 mostra uma curva da função de distribuição mais dispersa com um pico mais baixo do que a distribuição normal.

Tabela 4.3: Estatísticas dos retornos da UE

	ERIX	WilderHill	WTI	USDX	MSCI
NObs.	562.0000	562.0000	562.0000	562.0000	562.0000
Mínimo	-0.0674	-0.0362	-0.0790	-0.0137	-0.0313
Máximo	0.0574	0.0240	0.1468	0.0142	0.0334
1° Quartil	-0.0061	-0.0043	-0.0092	-0.0021	-0.0030
3° Quartil	0.0077	0.0056	0.0110	0.0022	0.0042
Média	0.0007	0.0003	0.0006	0.0001	0.0003
Mediana	0.0011	0.0010	0.0022	0.0000	0.0008
EPM	0.0005	0.0003	0.0008	0.0001	0.0003
DP	0.0121	0.0078	0.0197	0.0035	0.0071
Assimetria	-0.2548	-0.4684	0.0955	0.0460	-0.4024
Curtose	3.2661	0.8560	6.5932	0.6838	3.3668

Fonte: Elaborado pelo autor com base em Investing.com

Tabela 4.4: Estatísticas dos retornos dos EUA

	GRNREG	SP500	WilderHill	WTI	CRB	PSE
NObs.	2,249.0000	2,249.0000	2,249.0000	2,249.0000	2,249.0000	2,249.0000
Mínimo	-0.0572	-0.0722	-0.0675	-0.1023	-0.0490	-0.0633
Máximo	0.0538	0.0552	0.0748	0.1468	0.0479	0.0506
1° Quartil	-0.0047	-0.0034	-0.0056	-0.0109	-0.0054	-0.0045
3° Quartil	0.0057	0.0051	0.0059	0.0108	0.0049	0.0064
Média	0.0003	0.0005	0.0001	0.0000	-0.0002	0.0006
Mediana	0.0008	0.0006	0.0007	0.0006	0.0002	0.0010
EPM	0.0002	0.0002	0.0002	0.0004	0.0002	0.0002
DP	0.0099	0.0093	0.0108	0.0211	0.0090	0.0107
Assimetria	-0.4363	-0.5646	-0.3513	0.2563	-0.1294	-0.4136
Curtose	3.1070	5.9288	3.8561	3.8965	2.3751	3.0524

Fonte: Elaborado pelo autor com base em Investing.com

Na Tabela 4.3 e na Tabela 4.4 observa-se que a maioria das médias ficaram próximas a 0. Também nota-se que os coeficientes de assimetria ficaram negativos, e que a cauda do lado esquerdo da função densidade de probabilidade é maior que a do lado direito. A curtose maior que 0 (> 0) mostra uma curva da função de distribuição mais afunilada, com um pico mais alto do que a distribuição normal. O excesso de curtose caracteriza distribuições platicúrticas, comumente presentes em séries temporais financeiras, e isso fortalece o argumento para a escolha de um modelo multivariado (Frascaroli, 2020).

A Tabela 4.5 e a Tabela 4.5 correspondem aos testes de Augmented Dickey-Fuller (ADF), Phillips-Perron (PP) e Kwiatkowski-Phillips-Schmidt-Shin (KPSS), respectivamente. Os dois primeiros são testes de raiz unitária em séries temporais, em que

a hipótese nula do teste (H_0) é que existe raiz unitária, contra a hipótese alternativa (H_1), que propõe que não há raiz unitária. O terceiro teste possui a hipótese nula (H_0) de que a série temporal observável é estacionária, contra a alternativa (H_1) de que há presença de raiz unitária.

Tabela 4.5: Resultados dos testes de raiz unitária dos retornos dos índices da UE

	ERIX	WilderHill	WTI	USDX	MSCI
ADF	-8.79	-8.03	-7.89	-8.71	-8.09
PP	-564.28	-452.73	-617.33	-543.85	-493.30
KPSS	0.11	0.25	0.11	0.08	0.08

Fonte: Elaborado pelo autor com base em Investing.com

Tabela 4.6: Resultados dos testes de raiz unitária dos retornos dos índices dos EUA

	GRNREG	SP500	WilderHill	WTI	CRB	PSE
ADF	-11.94	-14.32	-12.17	-12.66	-12.69	-14.04
PP	-1,864.79	-2,223.39	-1,683.54	-2,469.67	-2,407.15	-2,122.14
KPSS	0.36	0.02	0.22	0.09	0.10	0.04

Fonte: Elaborado pelo autor com base em Investing.com

Desta forma, foram estimados os testes ADF, PP e KPSS para o caso do sistema de dados da UE e dos EUA, respectivamente, em que o p-valor para ADF e PP foram menor que 0,01 ($<0,01$). No caso do teste KPSS, verifica-se que o valor foi maior que os valores de referência usuais, assim todos os retornos são estacionários. Isto é, as hipóteses nulas são rejeitadas ao nível de significância de 1% para ADF e PP, enquanto para o KPSS não foi rejeitado. Concluída a etapa de análise dos dados, e obtidas algumas informações relevantes para o ajuste dos modelos, no próximo capítulo será realizada a análise dos resultados das estimações.

Capítulo 5

Análise dos Resultados

Os resultados dos testes de Chow estão na Tabela 5.1 mostra indícios de quebras estruturais. Por isso foi definido para o sistema que representa a UE o Regime I caracterizado durante o período de 18 de setembro de 2017 a 28 de janeiro de 2019, com 337 observações. O Regime II, por sua vez, abrange o período de 29 de janeiro de 2019 a 31 de dezembro de 2019, com 226 observações. No caso americano o Regime I predomina durante o período de 19 de janeiro de 2011 a 22 de fevereiro de 2017, com 1534 observações. Já o Regime II abrange o período de 23 de fevereiro de 2017 a 31 de dezembro de 2019, totalizando 716 observações.

Tabela 5.1: Testes de Chow

	UE	EUA
F =	1.55×10^2	2.82×10^2
p-value <	2.20×10^{-16}	2.20×10^{-16}

Fonte: Elaborado pelo autor com base em Investing.com

Na Tabela 5.1 é mostrado que o teste de Chow é rejeitado, ou seja, os parâmetros não são estáveis. Assim, há alteração estrutural nas estimativas, uma quebra estrutural. Na Tabela B.1, na Tabela B.2, na Tabela B.3 e na Tabela B.4, todas localizadas no Apêndice A, são apresentados os valores dos critérios de informação e da log-verossimilhança e das formas funcionais univariadas dos modelos GARCH para cada regime, respectivamente. Elas trazem informações do Regime I e Regime II referentes à UE, e Regime I e Regime II dos EUA.

As estimativas obtidas mostraram que as variáveis selecionadas para compor os sistemas foram significativas aos valores de 10% de significância. Assim, de certa forma a escolha desses *drivers* foram acertadas de acordo com certos níveis de significância menos rigorosos. Para o caso europeu, o Regime I foi melhor descrito pelo ARMA (1, 2) EGARCH (1, 1), enquanto o Regime II foi ajustado usando o ARMA (1, 1) GJRGARCH (1, 1). O Regime I americano foi melhor descrito pelo ARMA (2, 2) EGARCH (1, 1) e o Regime II foi ajustado usando o ARMA (1, 1) EGARCH

(1, 1).

Este resultado também foi confirmado pelo teste ARCH para ambos os regimes, em que a hipótese nula de ausência ARCH efeito foi rejeitado. A Tabela 5.2 mostra os resultados descritos, em que *Lag* são as defasagens testadas, χ^2 são os valores da estática da qui-quadrado no teste, *df* os graus de liberdade da qui-quadrado e, por fim, têm-se os p-valores para cada regime.

Tabela 5.2: Resultados dos testes ARCH em ERIX e GRNREG para a UE e os EUA

	Lag	χ^2	df	p-valor
Regime I (UE)	1-2	0.7211	2.0000	0.6973
	1-5	5.1754	5.0000	0.3949
Regime II (UE)	1-2	0.5133	2.0000	0.7737
	1-5	0.9404	5.0000	0.9672
Regime I (EUA)	1-2	1.7624	2.0000	0.4143
	1-5	2.9829	5.0000	0.7026
Regime II (EUA)	1-2	0.0284	2.0000	0.9859
	1-5	0.1524	5.0000	0.9995

Fonte: Elaborado pelo autor com base em Investing.com

Os parâmetros univariados estão resumidos na Tabela B.5 e na Tabela B.6, em que ω é uma constante, o parâmetro α é do modelo ARCH, o parâmetro β refere-se ao modelo GARCH, o parâmetro γ é estimado no modelo EGARCH e o parâmetro η é da especificação do modelo GJR, respectivamente. A volatilidade aumenta em resposta à inovação em ϵ_{t-1} , notada pelo parâmetro negativo α para os regimes I (UE), I (EUA) e II (EUA), respectivamente. Em contraste, diminui em consequência do parâmetro positivo α para o regime II (UE).

O parâmetro β indica alta volatilidade para todos os regimes, pois é próximo da unidade. Os parâmetros também revelam que choques positivos na volatilidade dos retornos de ERIX e GRNREG de longo prazo influenciam mais do que choques negativos para os regimes I (UE), I (EUA) e II (EUA). Este achado é apontado pelo parâmetro de assimetria γ , que é diferente de zero a um nível de confiança de 99%. Por outro lado, o parâmetro de assimetria η do regime II (UE) se mostra muito próximo da unidade a um nível de confiança de 99%.

A Tabela 5.3 mostra os critérios de adequação foram baseados no critério de informação de Akaike (AIC), no critério Bayesiano de Schwartz (SBC) e nas estatísticas de Shibata (SIC) e Hannan-Quinn (HQIC):

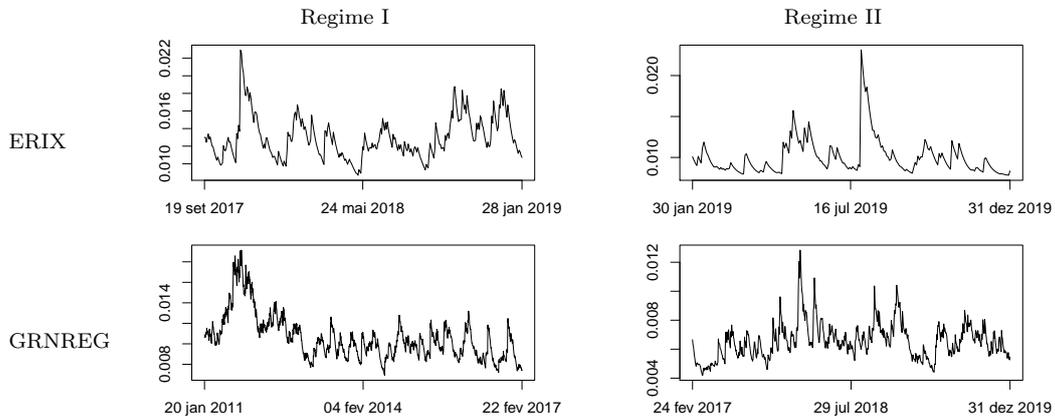
Tabela 5.3: Valores dos critérios de ajustes dos modelos

Regimes	AIC	SBC	SIC	HQIC
Regime I (UE)	-34.6594	-34.0119	-34.7066	-34.4013
Regime II (UE)	-35.1912	-34.4017	-35.2734	-34.8725
Regime I (EUA)	-42.6519	-42.4048	-42.6560	-42.5600
Regime II (EUA)	-44.3965	-44.0192	-44.4088	-44.2508

Fonte: Elaborado pelo autor com base em Investing.com

A Figura 5.1 mostra as estimativas DCC-MGARCH para a variância condicional de ERIX e GRNRES. Na Figura A.1 e na Figura A.2 são identificadas as covariâncias condicionais e correlações para UE (ERIX) com WilderHill, WTI, USDX e MSCI; e para EUA (GRNRES) com S&P500, WilderHill, WTI, CRB e PSE:

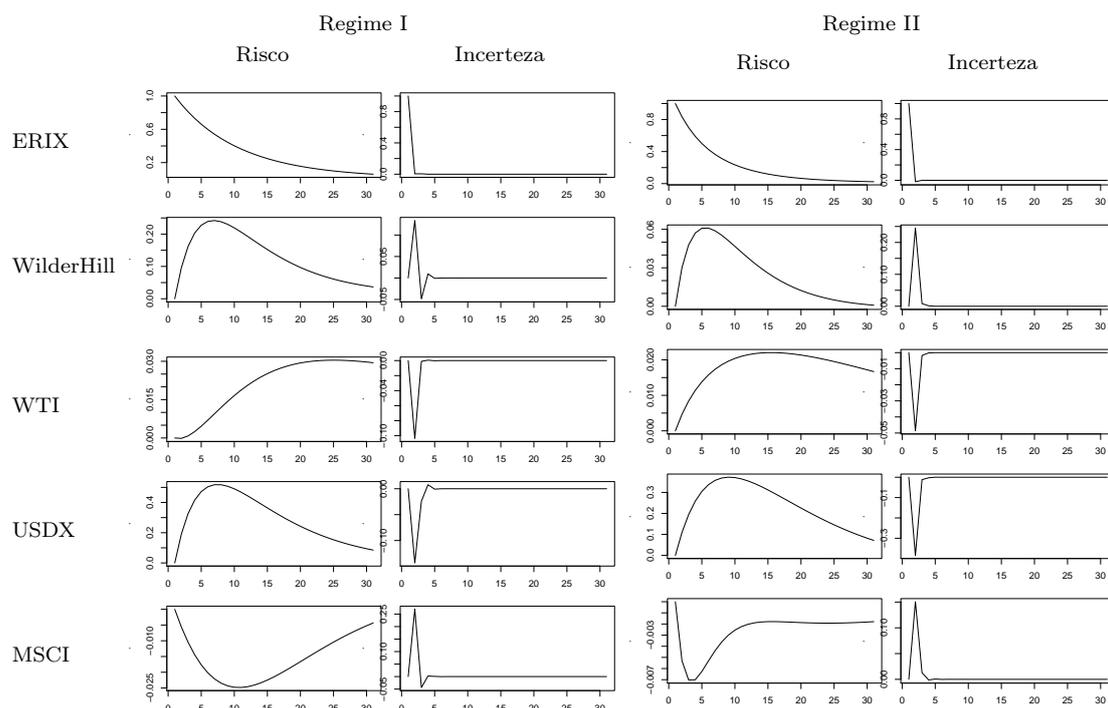
Figura 5.1: Estimativas DCC-MGARCH para os regimes UE (ERIX) e EUA (GRNREG)



Fonte: Elaborado pelo autor com base em Investing.com

Na Figura 5.2 e Figura 5.3, do lado esquerdo, estão as funções impulso resposta estimadas para o Regime I, ao passo que à direita estão as respostas para o Regime II. As respostas aos riscos representam os choques das variâncias condicionais de cada variável. A incerteza consiste em choques provenientes de fontes que não foram explicadas pelos sistemas de variáveis propostos para entrada dos modelos MGARCH. Todos os choques têm efeitos instantâneos, transitórios nos retornos de ERIX e GRNREG, cujas previsões são indicadas no eixo horizontal, que mede o número de períodos a frente, em número de dias:

Figura 5.2: Funções de impulso resposta para um choque de um desvio padrão no risco e incerteza sobre o índice ERIX



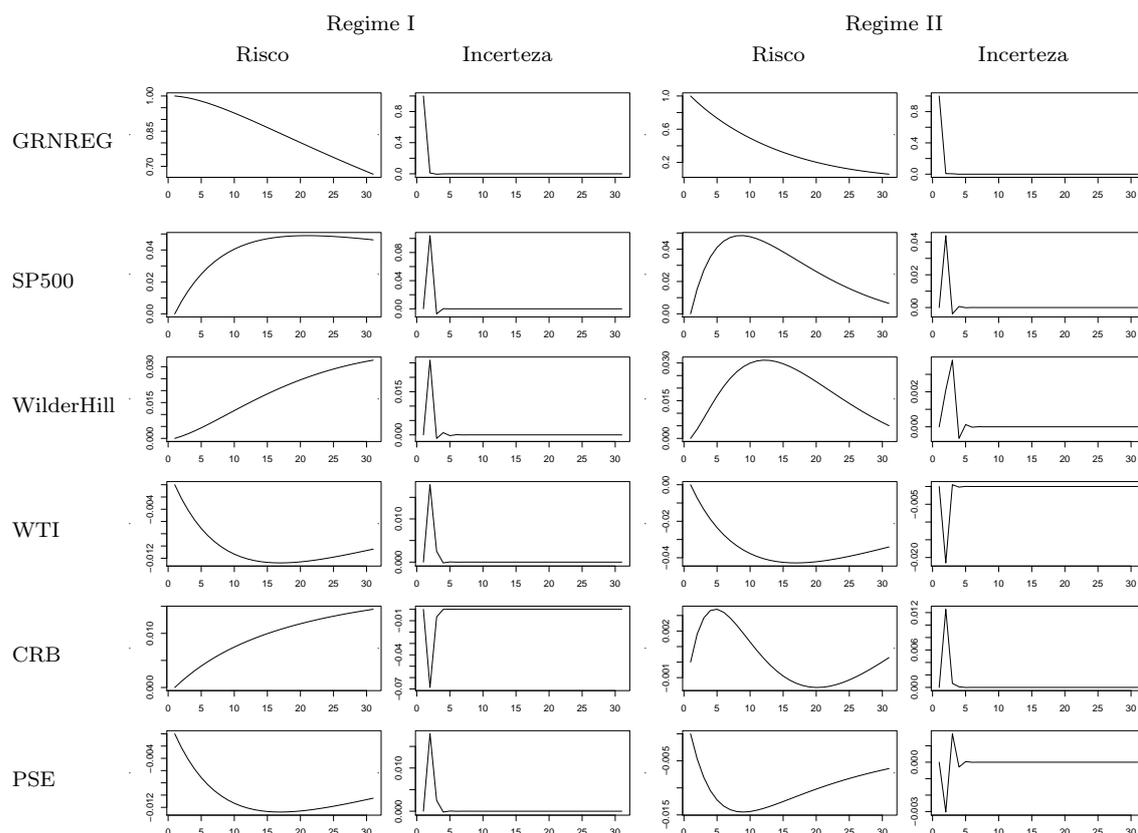
Fonte: Elaborado pelo autor com base em Investing.com

A Figura 5.2 reposta as funções impulso resposta de choques no risco e na incerteza sobre o índice ERIX provenientes das demais variáveis, WilldeHill, WTI, USDX e MSCI, no Regime I e Regime II. Os choques nos riscos em WilldeHill tanto no Regime I quanto no Regime II produzem um impacto positivo no ERIX, e esse efeito perdura poucos períodos (dias). Após isso, tendem a ser menores com o passar dos períodos.

Na variável WTI eles também são positivos, com impactos menores e mais duradouros, superiores a quinze dias, diminuindo posteriormente. Ou seja, a função impulso resposta retorna à zero possivelmente no segundo mês. Igualmente a variável WilldeHill, o USDX produz impactos positivos em ambos regimes, que perdura por alguns dias.

Diferentemente das demais variáveis o índice MSCI teve impactos negativos. Já em relação aos choques de incerteza, o índice WilldeHill no Regime I apresenta inicialmente um efeito positivo e em seguida uma queda, se estabilizando nos períodos a frente. Na outra mão, a variável WilldeHill no Regime II e MSCI em ambos regimes apresenta um efeito positivo seguido de uma dissipação. Os índices WTI e USDX no Regime I e no Regime II apresentaram um impacto positivo seguido de uma queda para zero em menos de 5 períodos (dias) a frente.

Figura 5.3: Funções de impulso resposta para um choque de um desvio padrão no risco e incerteza sobre o índice GRNREG



Fonte: Elaborado pelo autor com base em Investing.com

A Figura 5.3 ilustra as funções impulso resposta do GRNREG em respeito aos choques no risco e na incerteza. Nela percebe-se cada uma das outras variáveis SP500, WilldeHill, WTI, CRB e PSE, respectivamente, tanto para o Regime I quanto para o Regime II. Os choques no risco da variável SP500, apresentaram um impacto positivo em ambos os regimes sendo que no Regime I há uma duração maior da influência desse choque. No que se refere ao índice WilldeHill no Regime I, observa-se um impacto positivo pequeno de grande duração de períodos, se dissipando posteriormente, enquanto que no Regime II a dissipação é mais rápida.

Notou-se um impacto negativo em ambos os regimes quando observados os choques advindos da variável WTI, com uma duração bastante similar em ambos. No Regime II o efeito do choque é maior, com efeito relativamente próximo ao da variável WilldeHill no Regime I e da variável CRB no Regime I. Neste último verificou-se um efeito menos robusto, também mostrando um impacto positivo muito pequeno de grande duração de períodos. No Regime II, por sua vez, inicialmente é positiva tendo uma queda depois de próximos de cinco períodos (dias) até ter um efeito negativo e após vinte períodos (dias), quando tende a uma dissipação completa.

O índice SP500 apresentou um impacto negativo em ambos os regimes sendo que no Regime I nota-se uma duração maior desse choque. Em relação aos choques

de incerteza, o índice SP500, WilleHill em ambos regimes, WTI e PSE no Regime I, e CRB no Regime I, apresentam inicialmente um efeito positivo e em seguida uma queda, se estabilizando. A variável WTI no Regime II e CRB no Regime I apresentam efeito negativo, seguido de uma dissipação. O índice PSE no Regime II apresenta um efeito positivo seguido de um efeito negativo, para posteriormente se estabilizar.

Clusters de volatilidade e de *distress* nos mercados financeiros e na economia global provocados por fatores adversos são desfavoráveis ao crescimento da oferta de energias renováveis, conforme já exposto. Por esta razão, estimar a volatilidade e identificar o papel dos principais *drivers* do índices que representam os mercados dos EUA e UE é de fundamental importância. Comparando EUA e UE, é possível notar diferenças das magnitudes das funções de impulso resposta, sendo que nos EUA com -4% no WTI referente ao Regime II, o índice SP500 durante o Regime I chegou a quase 50%. Já na UE o valor apresentou-se negativo de -2,5% no que compreende o índice MSCI durante o Regime I, e o valor máximo do índice USDX com 50% no Regime I.

Sadorsky (2012) afirma que as correlações condicionais dinâmicas entre os preços das ações de energia limpa e de tecnologia são maiores do que as correlações condicionais dinâmicas entre os preços das ações de energia limpa e do petróleo. Resultados assim são importantes para estabelecer que as empresas de energia limpa possuem mais relação com empresas de tecnologia do que com as empresas dos mercados de petróleo. Ferrer *et al.* (2018) defende que o desempenho do mercado de ações de empresas de energia renovável provavelmente está mais relacionado aos fatores como inovação tecnológica, gastos de capital, legislação ou disponibilidade geográfica do que retornos excessivos.

Capítulo 6

Considerações Finais

O setor de energias renováveis é uma aposta para o futuro das matrizes energéticas dos países. Contudo, os desafios e as barreiras tanto tecnológicas de redução de custos, quanto advindas das turbulências dos mercados financeiros mundiais são notáveis. Neste trabalho foram revelados *clusters* de volatilidade e de *distress* nos mercados financeiros globais, que são desfavoráveis para o desenvolvimento de tais tecnologias.

O presente trabalho se voltou a estudar os dois índices mais importantes do setor, sendo segmentados de acordo com testes que indicaram quebras estruturais em suas trajetórias, originando mudanças de regimes. Foram estimados dois sistemas para representar o caso dos EUA e dois sistemas para representar a UE. Em geral, concluiu-se que o setor de energias renováveis americano e europeu possuem muitos desafios também no tocante ao controle de como a volatilidade os afeta.

As estimativas indicaram que esse setor possui elevada correlação com outros importantes segmentos da economia mundial, indicado pelas estimativas de correlações dos índices estudados com mercados de petróleo, monetário e outros. Sendo assim, recomenda-se o uso de derivativos, como as *commodities* do SP500 para os EUA, e do USDX para a UE para ajudar a diminuir a volatilidade nos retornos dos índices, ajudando a melhorar, portanto, o desempenho do setor. Tais resultados indicam que governos de países e territórios soberanos que almejem avançar na mudança para matrizes energéticas limpas, precisam também lidar com tais dificuldades.

Como continuação deste trabalho, sugere-se a inserção de outras variáveis sejam usadas como entrada dos modelos. Outra sugestão seria testar os efeitos dos mercados emergentes sobre os índices estudados, como aqueles referentes ao continente africano, asiático ou Latino-Americano, representados pelos índices representativos das bolsas de valores locais.

Referências Bibliográficas

- Amin, Nowshad; Shahahmadi, S Ahmad; Chelvanathan, Puvaneswaran; Rahman, Kazi Sajedur; Hossain, M Istiaque; Akhtaruzzaman, MD. Solar photovoltaic technologies: from inception toward the most reliable energy resource. *Encyclopedia of Sustainable Technologies*, p. 11–26, 2017.
- Bauwens, Luc; Laurent, Sébastien; Rombouts, Jeroen VK. Multivariate GARCH models: a survey. *Journal of applied econometrics*, v. 21, n. 1, p. 79–109, 2006.
- Bollerslev, Tim. Generalized autoregressive conditional heteroskedasticity. *Journal of econometrics*, v. 31, n. 3, p. 307–327, 1986.
- Bollerslev, Tim; Engle, Robert F; Wooldridge, Jeffrey M. A capital asset pricing model with time-varying covariances. *Journal of political Economy*, v. 96, n. 1, p. 116–131, 1988.
- Chen, James. U.S. Dollar Index - USDX Definition. 2020. URL <https://www.investopedia.com/terms/u/usdx.asp>. Acessado: 2020-03-30.
- Chow, Gregory C. Tests of equality between sets of coefficients in two linear regressions. *Econometrica: Journal of the Econometric Society*, p. 591–605, 1960.
- CME. Welcome to NYMEX WTI Light Sweet Crude Oil Futures. 2017. URL <https://www.cmegroup.com/trading/why-futures/welcome-to-nymex-wti-light-sweet-crude-oil-futures.html>. Acessado: 2020-03-30.
- Engle, Robert. Dynamic conditional correlation: A simple class of multivariate generalized autoregressive conditional heteroskedasticity models. *Journal of Business & Economic Statistics*, v. 20, n. 3, p. 339–350, 2002.
- Engle, Robert F. Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation. *Econometrica: Journal of the Econometric Society*, p. 987–1007, 1982.

- Engle, Robert F; Bollerslev, Tim. Modelling the persistence of conditional variances. *Econometric reviews*, v. 5, n. 1, p. 1–50, 1986.
- Espinar, Bella; Aznarte, José-Luis; Girard, Robin; Moussa, Alfred Mbairadjim; Kariniotakis, Georges. Photovoltaic Forecasting: A state of the art. *5th European PV-Hybrid and Mini-Grid Conference*, p. 50–255, 2010. URL <https://hal-mines-paristech.archives-ouvertes.fr/hal-00771465>.
- Ferrer, Román; Shahzad, Syed Jawad Hussain; López, Raquel; Jareño, Francisco. Time and frequency dynamics of connectedness between renewable energy stocks and crude oil prices. *Energy Economics*, v. 76, p. 1–20, 2018.
- Frascaroli, Bruno Ferreira. Bitcoin’s innovative aspects, return volatility and uncertainty shocks. *International Journal of Financial Markets and Derivatives*, v. 7, n. 3, p. 224–245, 2020.
- Frey, Gary W; Linke, Deborah M. Hydropower as a renewable and sustainable energy resource meeting global energy challenges in a reasonable way. *Energy policy*, v. 30, n. 14, p. 1261–1265, 2002.
- Ghalanos, Alexios. *Introduction to the rugarch package.(Version 1.0-11)*, 2013.
- Ghalanos, Alexios. *rmgarch: Multivariate GARCH models.*, 2019. R package version 1.3-7.
- Ghalanos, Alexios. *rugarch: Univariate GARCH models.*, 2020. R package version 1.4-2.
- Glosten, Lawrence R; Jagannathan, Ravi; Runkle, David E. On the relation between the expected value and the volatility of the nominal excess return on stocks. *The journal of finance*, v. 48, n. 5, p. 1779–1801, 1993.
- Han, Liyan; Jin, Jiayu; Wu, Lei; Zeng, Hongchao. The volatility linkage between energy and agricultural futures markets with external shocks. *International Review of Financial Analysis*, 2019.
- Inchauspe, Julian; Ripple, Ronald D; Trück, Stefan. The dynamics of returns on renewable energy companies: A state-space approach. *Energy Economics*, v. 48, p. 325–335, 2015.
- Johnson, Gary L. *Wind energy systems*. Citeseer, 1985.
- Jurado, Kyle; Ludvigson, Sydney C; Ng, Serena. Measuring uncertainty. *American Economic Review*, v. 105, n. 3, p. 1177–1216, 2015.

- Morettin, Pedro A. *Econometria financeira: um curso em séries temporais financeiras*. Editora Blucher, 2017.
- Myers, D. R. Chapter 1.12: Solar Radiation Resource Assessment for Renewable Energy Conversion. *Comprehensive Renewable Energy*, v. 1, p. 213–237, 2012.
- Navascués, MA; Sebastián, MV; Latorre, M; Campos, C; Ruiz, C; Iso, JM. Fractal Complexity of the Spanish Index IBEX 35. *International Work-Conference on Time Series Analysis*. Springer, 2016, p. 65–76.
- Nelson, Daniel B. Conditional heteroskedasticity in asset returns: A new approach. *Econometrica: Journal of the Econometric Society*, p. 347–370, 1991.
- Pelc, Robin; Fujita, Rod M. Renewable energy from the ocean. *Marine Policy*, v. 26, n. 6, p. 471–479, 2002.
- Pfaff, Bernhard. VAR, SVAR and SVEC Models: Implementation Within R Package vars. *Journal of Statistical Software*, v. 27, n. 4, 2008. URL <http://www.jstatsoft.org/v27/i04/>.
- R Core Team. *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing, Vienna, Austria, 2019. URL <https://www.R-project.org/>.
- Ryan, Eric. NYSE Arca Tech 100 ETF Lists on NYSE Arca. 2007. URL <https://www.businesswire.com/news/home/20070328005768/en/NYSE-Arca-Tech-100-ETF-Lists-NYSE>. Acessado: 2020-03-30.
- Ryan, Jeffrey A.; Ulrich, Joshua M. *xts: eXtensible Time Series*, 2020. URL <https://CRAN.R-project.org/package=xts>. R package version 0.12.1.
- Sadorsky, Perry. Correlations and volatility spillovers between oil prices and the stock prices of clean energy and technology companies. *Energy economics*, v. 34, n. 1, p. 248–255, 2012.
- Santamouris, M; Mihalakakou, G; Psiloglou, B; Eftaxias, G; Asimakopoulos, DN. Modeling the global solar radiation on the Earth’s surface using atmospheric deterministic and intelligent data-driven techniques. *Journal of climate*, v. 12, n. 10, p. 3105–3116, 1999.
- Scotti, Chiara. Surprise and uncertainty indexes: Real-time aggregation of real-activity macro-surprises. *Journal of Monetary Economics*, v. 82, p. 1–19, 2016.

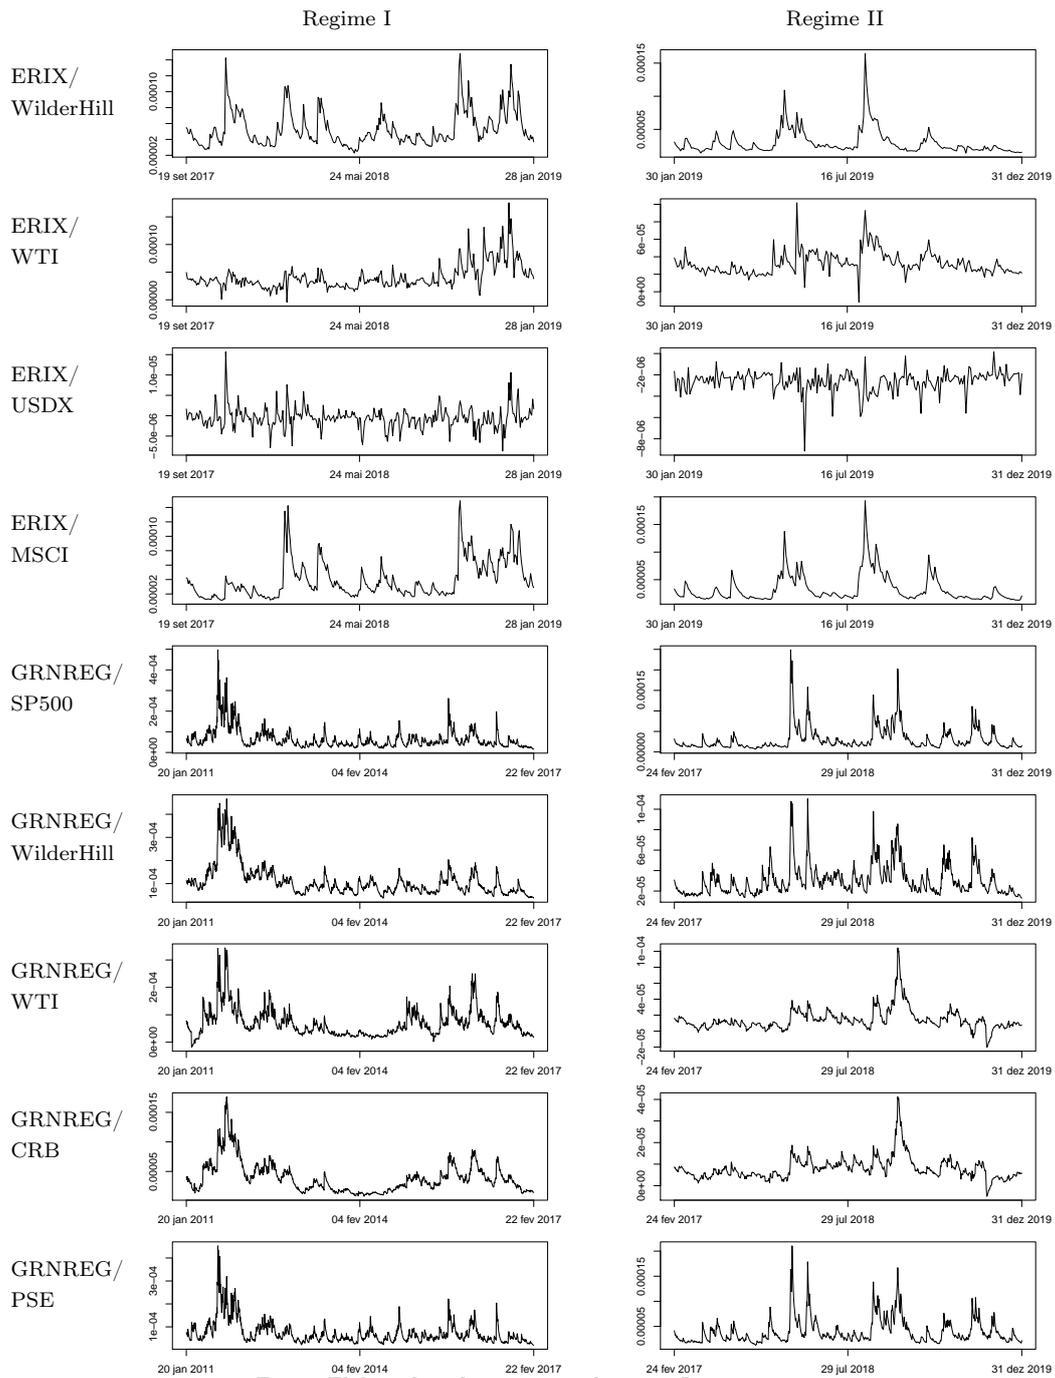
- Stapleton, Geoff; Neill, Susan. *Grid-connected solar electric systems: the earthscan expert handbook for planning, design and installation*. Routledge, 2012.
- Trapletti, Adrian; Hornik, Kurt. *tseries: Time Series Analysis and Computational Finance*, 2019. URL <https://CRAN.R-project.org/package=tseries>. R package version 0.10-47.
- Vigneshwari, C Aarthy; Velan, S Siva Sakthi; Venkateshwaran, M; Mydeen, M Adam; Kirubakaran, V. Performance and Economic Study of on-grid and off-grid Solar Photovoltaic System. *2016 International Conference on Energy Efficient Technologies for Sustainability (ICEETS)*. IEEE, 2016, p. 239–244.
- Vrînceanu, Georgiana; Horobet, Alexandra; Popescu, Consuela; Belaşcu, Lucian. The Influence of Oil Price on Renewable Energy Stock Prices: an Analysis for Entrepreneurs. *Studia Universitatis „Vasile Goldiș” Arad, Seria Științe Economice*, v. 30, n. 2, p. 24–35, 2020.
- WilderHill. The WilderHill New Energy Global Innovation Index. 2020. URL <https://nexindex.com/>. Acesoado: 2020-03-30.
- Wuertz, Diethelm; Setz, Tobias; Chalabi, Yohan. *fBasics: Rmetrics - Markets and Basic Statistics*, 2017. URL <https://CRAN.R-project.org/package=fBasics>. R package version 3042.89.
- Xia, Tongshui; Ji, Qiang; Zhang, Dayong; Han, Jinhong. Asymmetric and extreme influence of energy price changes on renewable energy stock performance. *Journal of Cleaner Production*, v. 241, p. 118338, 2019.
- Zakoian, Jean-Michel. Threshold heteroskedastic models. *Journal of Economic Dynamics and control*, v. 18, n. 5, p. 931–955, 1994.
- Zeileis, Achim; Leisch, Friedrich; Hornik, Kurt; Kleiber, Christian. strucchange: An R Package for Testing for Structural Change in Linear Regression Models. *Journal of Statistical Software*, v. 7, n. 2, p. 1–38, 2002. URL <http://www.jstatsoft.org/v07/i02/>.

Apêndice A

Gráficos extras

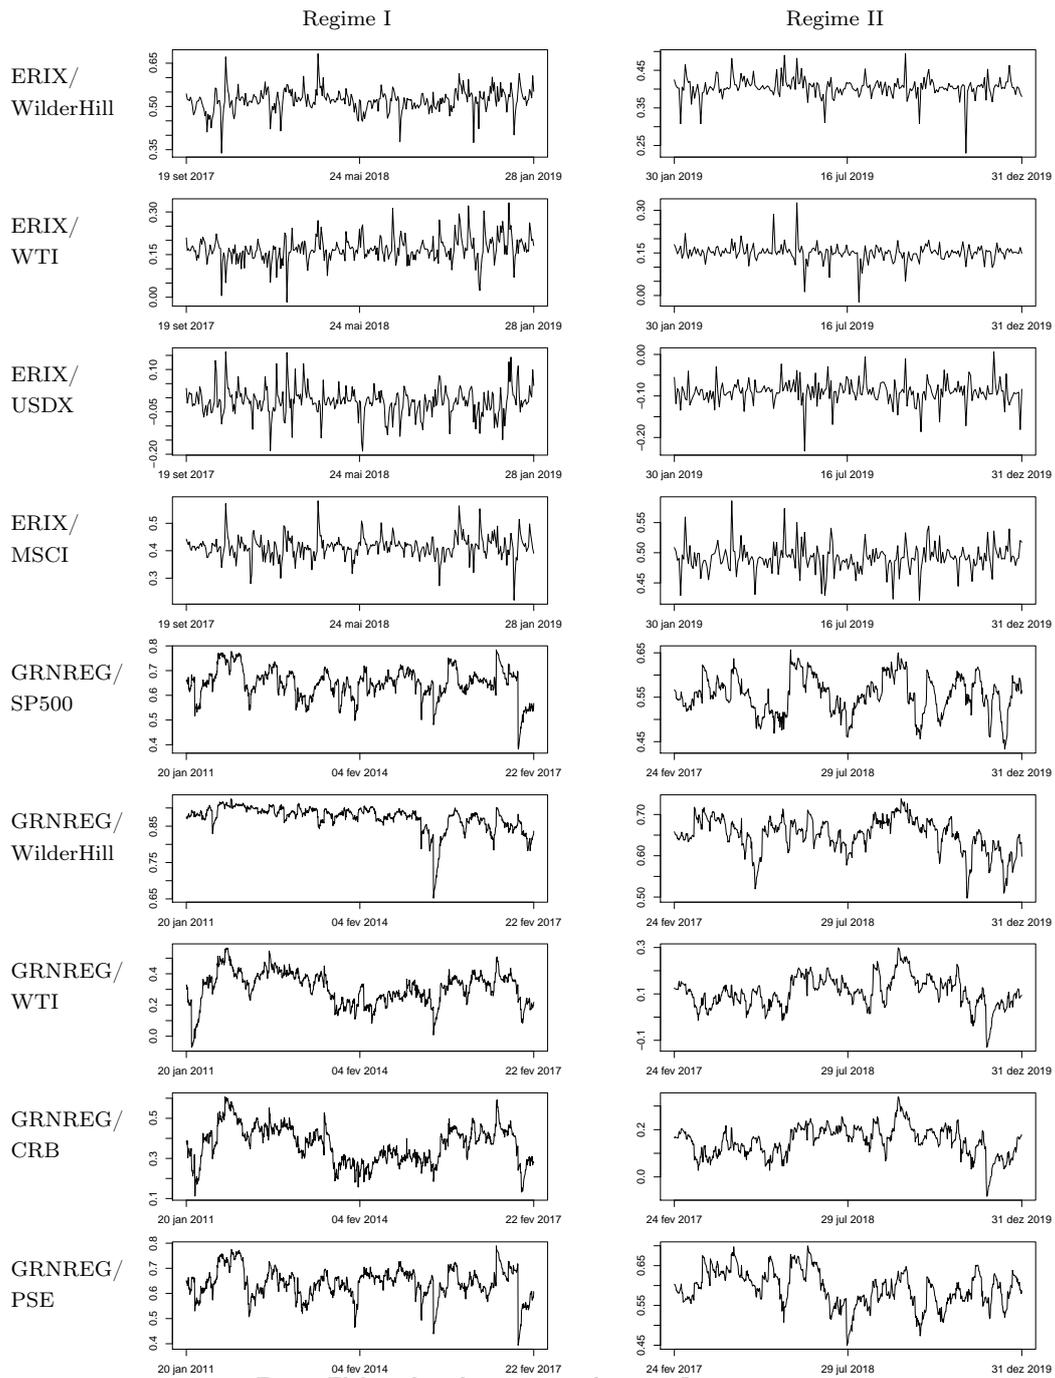
Nos gráficos na Figura [A.1](#) são apresentadas as covariâncias condicionais das variáveis usadas em todos os regimes, UE(ERIX) e EUA(GRNREG), já na Figura [A.2](#) são os gráficos das correlações condicionais das variáveis usadas em todos os regimes, UE(ERIX) e EUA(GRNREG).

Figura A.1: Covariâncias condicionais das variáveis usadas em todos os regimes, UE(ERIX) e EUA(GRNREG).



Fonte: Elaborado pelo autor com base em Investing.com

Figura A.2: Correlações condicionais das variáveis usadas em todos os regimes, UE(ERIX) e EUA(GRNREG).



Apêndice B

Tabelas extras

Nas Tabelas [B.1](#), [B.2](#), [B.3](#), [B.4](#) apresenta-se os valores dos critérios de informação e log-verossimilhança obtidas dos testes para a escolha de melhor forma funcional do GARCH, com ARMA que melhor se ajusta. Já nas Tabelas [B.5](#) e [B.6](#) valores dos parâmetros, error padrão, teste t e p-valor, estimados dos modelos univariados, para os regimes I e II, das variáveis que representam os UE e EUA, respectivamente.

Tabela B.1: Valor dos critérios de informação e log-verossimilhança, obtidos das formas funcionais do modelos GARCH com parâmetros (1,1) e ARMA(1,2) no R, dados do regime 1 (UE).

modelos	ERIX	WilderHill	WTI	USDX	MSCI
AIC					
GARCH	-5.8488	-6.9036	-5.2274	-8.2536	-7.2721
eGARCH	-5.8620	-6.9195	-5.2722	-8.2828	-7.3013
iGARCH	-5.8423	-6.8915	-5.2325	-8.2587	-7.2781
GJRGARCH	-5.8606	-6.9246	-5.2454	-8.2503	-7.3013
BIC					
GARCH	-5.7692	-6.8241	-5.1479	-8.1741	-7.1926
eGARCH	-5.7711	-6.8286	-5.1813	-8.1919	-7.2104
iGARCH	-5.7741	-6.8234	-5.1644	-8.1905	-7.2099
GJRGARCH	-5.7697	-6.8337	-5.1545	-8.1594	-7.2104
SIC					
GARCH	-5.8496	-6.9045	-5.2283	-8.2545	-7.2729
eGARCH	-5.8631	-6.9206	-5.2733	-8.2839	-7.3024
iGARCH	-5.8429	-6.8922	-5.2332	-8.2593	-7.2787
GJRGARCH	-5.8617	-6.9257	-5.2465	-8.2514	-7.3024
HQIC					
GARCH	-5.8171	-6.8719	-5.1957	-8.2219	-7.2404
eGARCH	-5.8257	-6.8833	-5.2360	-8.2465	-7.2650
iGARCH	-5.8151	-6.8644	-5.2054	-8.2315	-7.2509
GJRGARCH	-5.8244	-6.8884	-5.2091	-8.2141	-7.2651
LLH					
GARCH	989.5915	1,166.8068	885.2085	1,393.6122	1,228.7094
eGARCH	992.8108	1,170.4765	893.7339	1,399.5027	1,234.6132
iGARCH	987.5081	1,163.7772	885.0662	1,393.4610	1,228.7167
GJRGARCH	992.5812	1,171.3304	889.2201	1,394.0552	1,234.6158

Fonte: Elaborado pelo autor com base em Investing.com

Tabela B.2: Valor dos critérios de informação e log-verossimilhança, obtidos das formas funcionais do modelos GARCH com parâmetros (1,1) e ARMA(1,1) no R, dados do regime 2 (UE).

modelos	ERIX	WilderHill	WTI	USDX	MSCI
AIC					
GARCH	-6.3049	-7.0822	-4.8174	-8.7338	-7.3630
eGARCH	-6.3572	-7.1070	-4.8996	-8.7638	-7.4945
iGARCH	-6.3137	-7.0714	-4.8169	-8.7269	-7.3719
GJRGARCH	-6.2963	-7.1111	-4.8791	-8.7233	-7.4578
BIC					
GARCH	-6.2138	-6.9911	-4.7263	-8.6427	-7.2719
eGARCH	-6.2509	-7.0007	-4.7933	-8.6575	-7.3883
iGARCH	-6.2378	-6.9955	-4.7410	-8.6510	-7.2960
GJRGARCH	-6.1901	-7.0048	-4.7728	-8.6171	-7.3516
SIC					
GARCH	-6.3063	-7.0836	-4.8188	-8.7352	-7.3644
eGARCH	-6.3591	-7.1088	-4.9014	-8.7656	-7.4964
iGARCH	-6.3147	-7.0723	-4.8179	-8.7279	-7.3729
GJRGARCH	-6.2982	-7.1130	-4.8809	-8.7252	-7.4597
HQIC					
GARCH	-6.2682	-7.0455	-4.7806	-8.6970	-7.3263
eGARCH	-6.3143	-7.0641	-4.8567	-8.7209	-7.4516
iGARCH	-6.2831	-7.0407	-4.7863	-8.6963	-7.3413
GJRGARCH	-6.2535	-7.0682	-4.8362	-8.6805	-7.4149
LLH					
GARCH	715.3060	802.7509	547.9552	988.5542	834.3414
eGARCH	722.1855	806.5345	558.2024	992.9230	850.1354
iGARCH	715.2912	800.5289	546.9038	986.7770	834.3425
GJRGARCH	715.3393	807.0004	555.8933	988.3764	846.0065

Fonte: Elaborado pelo autor com base em Investing.com

Tabela B.3: Valor dos critérios de informação e log-verossimilhança, obtidos das formas funcionais do modelos GARCH com parâmetros (1,1) e ARMA(2,2) no R, dados do regime 1 (EUA).

modelos	GRNREG	SP500	WilderHill	WTI	CRB	PSE
AIC						
GARCH	-6.2739	-6.7497	-6.2171	-5.0818	-6.6236	-6.4176
eGARCH	-6.2859	-6.7949	-6.2328	-5.0998	-6.6364	-6.4711
iGARCH	-6.2626	-6.7392	-6.2124	-5.0810		-6.4130
GJRGARCH	-6.2766	-6.7809	-6.2331	-5.1148	-6.6286	-6.4562
BIC						
GARCH	-6.2461	-6.7219	-6.1893	-5.0540	-6.5957	-6.3897
eGARCH	-6.2546	-6.7636	-6.2014	-5.0684	-6.6051	-6.4398
iGARCH	-6.2383	-6.7149	-6.1881	-5.0567		-6.3886
GJRGARCH	-6.2453	-6.7495	-6.2017	-5.0835	-6.5973	-6.4248
SIC						
GARCH	-6.2740	-6.7498	-6.2172	-5.0819	-6.6236	-6.4176
eGARCH	-6.2860	-6.7950	-6.2328	-5.0998	-6.6364	-6.4712
iGARCH	-6.2627	-6.7393	-6.2125	-5.0811		-6.4130
GJRGARCH	-6.2767	-6.7809	-6.2331	-5.1149	-6.6287	-6.4562
HQIC						
GARCH	-6.2635	-6.7394	-6.2068	-5.0715	-6.6132	-6.4072
eGARCH	-6.2742	-6.7833	-6.2211	-5.0881	-6.6247	-6.4594
iGARCH	-6.2536	-6.7302	-6.2034	-5.0720		-6.4039
GJRGARCH	-6.2650	-6.7692	-6.2214	-5.1032	-6.6169	-6.4445
LLH						
GARCH	4,816.9490	5,181.6818	4,773.4408	3,903.2171	5,084.9535	4,927.0832
eGARCH	4,827.1450	5,217.3218	4,786.4093	3,917.9610	5,095.7857	4,969.0975
iGARCH	4,807.2994	5,172.6243	4,768.8296	3,901.6079		4,922.5552
GJRGARCH	4,820.0370	5,206.5219	4,786.6349	3,929.5047	5,089.8103	4,957.6526

Fonte: Elaborado pelo autor com base em Investing.com

Tabela B.4: Valor dos critérios de informação e log-verossimilhança, obtidos das formas funcionais do modelos GARCH com parâmetros (1,1) e ARMA(1,1) no R, dados do regime 2 (EUA).

modelos	GRNREG	SP500	WilderHill	WTI	CRB	PSE
AIC						
GARCH	-7.2294	-7.1072	-7.1724	-5.1051	-6.8987	
eGARCH	-7.2409	-7.1821	-7.2016	-5.1470	-6.9129	-6.5795
iGARCH	-7.2178	-7.1100	-7.1543	-5.0999	-6.8900	-6.5429
GJRGARCH	-7.2378	-7.1640	-7.2085	-5.1334	-6.9076	-6.5657
BIC						
GARCH	-7.1910	-7.0689	-7.1340	-5.0667	-6.8604	
eGARCH	-7.1962	-7.1374	-7.1568	-5.1023	-6.8681	-6.5347
iGARCH	-7.1858	-7.0780	-7.1223	-5.0679	-6.8580	-6.5109
GJRGARCH	-7.1930	-7.1192	-7.1637	-5.0886	-6.8629	-6.5210
SIC						
GARCH	-7.2295	-7.1074	-7.1725	-5.1052	-6.8989	
eGARCH	-7.2411	-7.1823	-7.2017	-5.1472	-6.9131	-6.5797
iGARCH	-7.2179	-7.1101	-7.1544	-5.1000	-6.8901	-6.5430
GJRGARCH	-7.2379	-7.1641	-7.2087	-5.1336	-6.9078	-6.5659
HQIC						
GARCH	-7.2146	-7.0924	-7.1576	-5.0903	-6.8839	
eGARCH	-7.2236	-7.1649	-7.1843	-5.1297	-6.8956	-6.5622
iGARCH	-7.2054	-7.0976	-7.1419	-5.0876	-6.8777	-6.5305
GJRGARCH	-7.2205	-7.1467	-7.1912	-5.1161	-6.8904	-6.5484
LLH						
GARCH	2,590.5012	2,546.8361	2,570.1227	1,831.0763	2,472.3023	
eGARCH	2,595.6316	2,574.6157	2,581.5575	1,847.0643	2,478.3571	2,359.1725
iGARCH	2,585.3602	2,546.8230	2,562.6533	1,828.2200	2,468.1831	2,344.0859
GJRGARCH	2,594.4982	2,568.1129	2,584.0258	1,842.1871	2,476.4839	2,354.2473

Fonte: Elaborado pelo autor com base em Investing.com

Tabela B.5: Valores dos parâmetros, error padrão, teste t e p-valor, estimados dos modelos univariados, ARCH(1,2)-EGARCH(1,1) e ARCH(1,1)-GJRARCH(1,1) respectivamente, dos regimes I e II, das variáveis que representam a UE.

Regime I					Regime II				
.	Estimativa	Erro	t	P-valor	.	Estimativa	Erro	t	P-valor
ERIX					ERIX				
AR(1)	0.2847	0.0227	12.5481	0.0000	AR(1)	0.5267	1.1863	0.4440	0.6570
MA(1)	-0.2252	0.0176	-12.7585	0.0000	MA(1)	-0.6239	1.0890	-0.5729	0.5667
MA(2)	0.0757	0.0466	1.6251	0.1041	ω	0.0000	0.0000	20.3846	0.0000
ω	-0.5232	0.1415	-3.6983	0.0002	α_1	0.0352	0.0147	2.3971	0.0165
α_1	-0.1165	0.0494	-2.3563	0.0185	β_1	0.8010	0.0454	17.6318	0.0000
β_1	0.9398	0.0164	57.3001	0.0000	η_{11}	1.0000	0.0221	45.3152	0.0000
γ_1	0.1153	0.0393	2.9328	0.0034	WillHill				
WillHill					AR(1)	-0.6552	0.1276	-5.1349	0.0000
AR(1)	0.5933	0.0288	20.5732	0.0000	MA(1)	0.8104	0.0956	8.4818	0.0000
MA(1)	-0.3985	0.0309	-12.8781	0.0000	ω	0.0000	0.0000	19.5064	0.0000
MA(2)	-0.0668	0.0169	-3.9482	0.0001	α_1	0.0629	0.0225	2.7909	0.0053
ω	-1.1446	0.0788	-14.5308	0.0000	β_1	0.7264	0.0452	16.0554	0.0000
α_1	-0.1463	0.0373	-3.9197	0.0001	η_{11}	1.0000	0.0354	28.2849	0.0000
β_1	0.8831	0.0080	110.8053	0.0000	WTI				
γ_1	0.1499	0.0432	3.4689	0.0005	AR(1)	0.8332	0.0688	12.1183	0.0000
WTI					MA(1)	-0.9081	0.0519	-17.4845	0.0000
AR(1)	-0.5444	0.0331	-16.4275	0.0000	ω	0.0000	0.0000	1.5208	0.1283
MA(1)	0.5084	0.0433	11.7285	0.0000	α_1	0.0155	0.0058	2.6690	0.0076
MA(2)	-0.0103	0.0560	-0.1840	0.8540	β_1	0.9503	0.0201	47.2377	0.0000
ω	-0.1530	0.0079	-19.2615	0.0000	η_{11}	0.9983	0.0376	26.5261	0.0000
α_1	-0.0992	0.0228	-4.3504	0.0000	USDX				
β_1	0.9819	0.0001	10,114.7201	0.0000	AR(1)	-0.8261	0.0677	-12.2014	0.0000
γ_1	-0.0359	0.0271	-1.3259	0.1849	MA(1)	0.8704	0.0560	15.5445	0.0000
USDX					ω	0.0000	0.0000	0.0122	0.9903
AR(1)	-0.9631	0.0237	-40.6957	0.0000	α_1	0.0064	0.0021	3.1249	0.0018
MA(1)	0.9343	0.0046	203.5644	0.0000	β_1	0.9876	0.0058	171.2270	0.0000
MA(2)	-0.0170	0.0065	-2.6237	0.0087	η_{11}	0.6875	0.5491	1.2521	0.2105
ω	-1.8215	0.0075	-242.5543	0.0000	MSCI				
α_1	-0.1016	0.0359	-2.8283	0.0047	AR(1)	0.9053	0.0358	25.2876	0.0000
β_1	0.8369	0.0005	1,640.5905	0.0000	MA(1)	-0.9410	0.0178	-52.9390	0.0000
γ_1	-0.1801	0.0352	-5.1107	0.0000	ω	0.0000	0.0000	2.2893	0.0221
MSCI					α_1	0.1047	0.0558	1.8765	0.0606
AR(1)	0.3095	0.0310	9.9935	0.0000	β_1	0.7172	0.0602	11.9187	0.0000
MA(1)	-0.1869	0.0403	-4.6360	0.0000	η_{11}	0.9982	0.2512	3.9741	0.0001
MA(2)	0.0399	0.0940	0.4244	0.6713					
ω	-0.4836	0.2033	-2.3791	0.0174					
α_1	-0.1559	0.0518	-3.0125	0.0026					
β_1	0.9533	0.0200	47.6327	0.0000					
γ_1	0.3120	0.0855	3.6484	0.0003					

Fonte: Elaborado pelo autor com base em Investing.com

Tabela B.6: Valores dos parâmetros, error padrão, teste t e p-valor, estimados dos modelos univariados, ARCH(2,2)-EGARCH(1,1) e ARCH(1,1)-EGARCH(1,1) respectivamente dos regimes I e II, das variáveis que representam os EUA.

Regime I					Regime II				
.	Estimativa	Erro	t	P-valor	.	Estimativa	Erro	t	P-valor
GRNREG					GRNREG				
AR(1)	0.8316	0.0371	22.4346	0.0000	AR(1)	-0.8726	0.1086	-8.0388	0.0000
AR(2)	-0.4972	0.2356	-2.1106	0.0348	MA(1)	0.9039	0.0912	9.9068	0.0000
MA(1)	-0.6898	0.0155	-44.4925	0.0000	ω	-0.6646	0.2026	-3.2803	0.0010
MA(2)	0.4142	0.2728	1.5183	0.1289	α_1	-0.0711	0.0288	-2.4703	0.0135
ω	-0.1949	0.0037	-52.8221	0.0000	β_1	0.9339	0.0200	46.7455	0.0000
α_1	-0.0329	0.0103	-3.1875	0.0014	γ_1	0.1582	0.0524	3.0169	0.0026
β_1	0.9784	0.0004	2,684.5642	0.0000	SP500				
γ_1	0.0769	0.0245	3.1343	0.0017	AR(1)	0.5025	0.1039	4.8359	0.0000
SP500					AR(2)	0.8579	0.0140	61.4208	0.0000
AR(1)	0.0980	0.0141	6.9599	0.0000	MA(1)	-0.1432	0.0017	-86.3323	0.0000
AR(2)	0.8579	0.0140	61.4208	0.0000	MA(2)	-0.8409	0.0000	-25,995.7317	0.0000
MA(1)	-0.1432	0.0017	-86.3323	0.0000	ω	-0.7037	0.0105	-67.1192	0.0000
MA(2)	-0.8409	0.0000	-25,995.7317	0.0000	α_1	-0.2301	0.0196	-11.7100	0.0000
ω	-0.7037	0.0105	-67.1192	0.0000	β_1	0.9265	0.0001	6,271.7314	0.0000
α_1	-0.2301	0.0196	-11.7100	0.0000	γ_1	0.1541	0.0177	8.7156	0.0000
β_1	0.9265	0.0001	6,271.7314	0.0000	WillHill				
γ_1	0.1541	0.0177	8.7156	0.0000	AR(1)	0.6347	0.0196	32.3006	0.0000
WillHill					AR(2)	-0.2007	0.0407	-4.9260	0.0000
AR(1)	0.6347	0.0196	32.3006	0.0000	MA(1)	-0.4037	0.0162	-24.9766	0.0000
AR(2)	-0.2007	0.0407	-4.9260	0.0000	MA(2)	0.0993	0.0501	1.9830	0.0474
MA(1)	-0.4037	0.0162	-24.9766	0.0000	ω	-0.2200	0.0097	-22.7068	0.0000
MA(2)	0.0993	0.0501	1.9830	0.0474	α_1	-0.0678	0.0143	-4.7331	0.0000
ω	-0.2200	0.0097	-22.7068	0.0000	β_1	0.9755	0.0012	787.9671	0.0000
α_1	-0.0678	0.0143	-4.7331	0.0000	γ_1	0.1279	0.0291	4.3931	0.0000
β_1	0.9755	0.0012	787.9671	0.0000	WTI				
γ_1	0.1279	0.0291	4.3931	0.0000	AR(1)	-0.6890	0.0011	-631.9949	0.0000
WTI					AR(2)	0.3070	0.0003	948.2753	0.0000
AR(1)	-0.6890	0.0011	-631.9949	0.0000	MA(1)	0.6400	0.0001	6,340.7478	0.0000
AR(2)	0.3070	0.0003	948.2753	0.0000	MA(2)	-0.3675	0.0002	-1,855.7713	0.0000
MA(1)	0.6400	0.0001	6,340.7478	0.0000	ω	-0.4379	0.2614	-1.6750	0.0939
MA(2)	-0.3675	0.0002	-1,855.7713	0.0000	α_1	-0.1114	0.0271	-4.1101	0.0000
ω	-0.4379	0.2614	-1.6750	0.0939	β_1	0.9439	0.0338	27.9026	0.0000
α_1	-0.1114	0.0271	-4.1101	0.0000	γ_1	0.2586	0.1056	2.4495	0.0143
β_1	0.9439	0.0338	27.9026	0.0000	CRB				
γ_1	0.2586	0.1056	2.4495	0.0143	AR(1)	-0.4254	0.0060	-71.1330	0.0000
CRB					AR(2)	-0.9799	0.0058	-167.7499	0.0000
AR(1)	-0.4254	0.0060	-71.1330	0.0000	MA(1)	0.4081	0.0072	56.5766	0.0000
AR(2)	-0.9799	0.0058	-167.7499	0.0000	MA(2)	0.9822	0.0004	2,295.5838	0.0000
MA(1)	0.4081	0.0072	56.5766	0.0000	ω	-0.0717	0.0028	-25.5220	0.0000
MA(2)	0.9822	0.0004	2,295.5838	0.0000	α_1	-0.0451	0.0112	-4.0144	0.0001
ω	-0.0717	0.0028	-25.5220	0.0000	β_1	0.9923	0.0002	6,445.2768	0.0000
α_1	-0.0451	0.0112	-4.0144	0.0001	γ_1	0.0829	0.0093	8.9474	0.0000
β_1	0.9923	0.0002	6,445.2768	0.0000	PSE				
γ_1	0.0829	0.0093	8.9474	0.0000	AR(1)	-1.5375	0.0174	-88.3015	0.0000
PSE					AR(2)	-0.5806	0.0179	-32.5146	0.0000
AR(1)	-1.5375	0.0174	-88.3015	0.0000	MA(1)	1.5398	0.0001	21,388.0206	0.0000
AR(2)	-0.5806	0.0179	-32.5146	0.0000	MA(2)	0.5933	0.0034	176.7988	0.0000
MA(1)	1.5398	0.0001	21,388.0206	0.0000	ω	-0.5319	0.0081	-65.4062	0.0000
MA(2)	0.5933	0.0034	176.7988	0.0000	α_1	-0.1993	0.0172	-11.5597	0.0000
ω	-0.5319	0.0081	-65.4062	0.0000	β_1	0.9426	0.0003	3,048.9390	0.0000
α_1	-0.1993	0.0172	-11.5597	0.0000	γ_1	0.1496	0.0165	9.0612	0.0000
β_1	0.9426	0.0003	3,048.9390	0.0000	GRNREG				
γ_1	0.1496	0.0165	9.0612	0.0000	AR(1)	-0.8726	0.1086	-8.0388	0.0000
GRNREG					MA(1)	0.9039	0.0912	9.9068	0.0000
AR(1)	-0.8726	0.1086	-8.0388	0.0000	ω	-0.6646	0.2026	-3.2803	0.0010
MA(1)	0.9039	0.0912	9.9068	0.0000	α_1	-0.0711	0.0288	-2.4703	0.0135
ω	-0.6646	0.2026	-3.2803	0.0010	β_1	0.9339	0.0200	46.7455	0.0000
α_1	-0.0711	0.0288	-2.4703	0.0135	γ_1	0.1582	0.0524	3.0169	0.0026
β_1	0.9339	0.0200	46.7455	0.0000	SP500				
γ_1	0.1582	0.0524	3.0169	0.0026	AR(1)	0.5025	0.1039	4.8359	0.0000
SP500					AR(2)	0.8579	0.0140	61.4208	0.0000
AR(1)	0.5025	0.1039	4.8359	0.0000	MA(1)	-0.5827	0.1278	-4.5578	0.0000
AR(2)	0.8579	0.0140	61.4208	0.0000	MA(2)	-0.8409	0.0000	-25,995.7317	0.0000
MA(1)	-0.5827	0.1278	-4.5578	0.0000	ω	-0.7037	0.0105	-67.1192	0.0000
MA(2)	-0.8409	0.0000	-25,995.7317	0.0000	α_1	-0.2301	0.0196	-11.7100	0.0000
ω	-0.7037	0.0105	-67.1192	0.0000	β_1	0.9265	0.0001	6,271.7314	0.0000
α_1	-0.2301	0.0196	-11.7100	0.0000	γ_1	0.1541	0.0177	8.7156	0.0000
β_1	0.9265	0.0001	6,271.7314	0.0000	WillHill				
γ_1	0.1541	0.0177	8.7156	0.0000	AR(1)	0.6347	0.0196	32.3006	0.0000
WillHill					AR(2)	-0.2007	0.0407	-4.9260	0.0000
AR(1)	0.6347	0.0196	32.3006	0.0000	MA(1)	-0.4037	0.0162	-24.9766	0.0000
AR(2)	-0.2007	0.0407	-4.9260	0.0000	MA(2)	0.0993	0.0501	1.9830	0.0474
MA(1)	-0.4037	0.0162	-24.9766	0.0000	ω	-0.2200	0.0097	-22.7068	0.0000
MA(2)	0.0993	0.0501	1.9830	0.0474	α_1	-0.0678	0.0143	-4.7331	0.0000
ω	-0.2200	0.0097	-22.7068	0.0000	β_1	0.9755	0.0012	787.9671	0.0000
α_1	-0.0678	0.0143	-4.7331	0.0000	γ_1	0.1279	0.0291	4.3931	0.0000
β_1	0.9755	0.0012	787.9671	0.0000	WTI				
γ_1	0.1279	0.0291	4.3931	0.0000	AR(1)	-0.6890	0.0011	-631.9949	0.0000
WTI					AR(2)	0.3070	0.0003	948.2753	0.0000
AR(1)	-0.6890	0.0011	-631.9949	0.0000	MA(1)	0.6400	0.0001	6,340.7478	0.0000
AR(2)	0.3070	0.0003	948.2753	0.0000	MA(2)	-0.3675	0.0002	-1,855.7713	0.0000
MA(1)	0.6400	0.0001	6,340.7478	0.0000	ω	-0.4379	0.2614	-1.6750	0.0939
MA(2)	-0.3675	0.0002	-1,855.7713	0.0000	α_1	-0.1114	0.0271	-4.1101	0.0000
ω	-0.4379	0.2614	-1.6750	0.0939	β_1	0.9439	0.0338	27.9026	0.0000
α_1	-0.1114	0.0271	-4.1101	0.0000	γ_1	0.2586	0.1056	2.4495	0.0143
β_1	0.9439	0.0338	27.9026	0.0000	CRB				
γ_1	0.2586	0.1056	2.4495	0.0143	AR(1)	-0.4254	0.0060	-71.1330	0.0000
CRB					AR(2)	-0.9799	0.0058	-167.7499	0.0000
AR(1)	-0.4254	0.0060	-71.1330	0.0000	MA(1)	0.4081	0.0072	56.5766	0.0000
AR(2)	-0.9799	0.0058	-167.7499	0.0000	MA(2)	0.9822	0.0004	2,295.5838	0.0000
MA(1)	0.4081	0.0072	56.5766	0.0000	ω	-0.0717	0.0028	-25.5220	0.0000
MA(2)	0.9822	0.0004	2,295.5838	0.0000	α_1	-0.0451	0.0112	-4.0144	0.0001
ω	-0.0717	0.0028	-25.5220	0.0000	β_1	0.9923	0.0002	6,445.2768	0.0000
α_1	-0.0451	0.0112	-4.0144	0.0001	γ_1	0.0829	0.0093	8.9474	0.0000
β_1	0.9923	0.0002	6,445.2768	0.0000	PSE				
γ_1	0.0829	0.0093	8.9474	0.0000	AR(1)	-1.5375	0.0174	-88.3015	0.0000
PSE					AR(2)	-0.5806	0.0179	-32.5146	0.0000
AR(1)	-1.5375	0.0174	-88.3015	0.0000	MA(1)	1.5398	0.0001	21,388.0206	0.0000
AR(2)	-0.5806	0.0179	-32.5146	0.0000	MA(2)	0.5933	0.0034	176.7988	0.0000
MA(1)	1.5398	0.0001	21,388.0206	0.0000	ω	-0.5319	0.0081	-65.4062	0.0000
MA(2)	0.5933	0.0034	176.7988	0.0000	α_1	-0.1993	0.0172	-11.5597	0.0000
ω	-0.5319	0.0081	-65.4062	0.0000	β_1	0.9426	0.0003	3,048.9390	0.0000
α_1	-0.1993	0.0172	-11.5597	0.0000	γ_1	0.1496			

Apêndice C

Implementação em R

```
1 library(magrittr); library(readr); library(tseries);
2 library(tibble); library(quantmod)
3 rm(list = ls())
4
5 retorno <- function(df) {
6   a <- xts(df[, -1], order.by=as.Date(df[[1]], "%Y-%m-%d"))
7   as.data.frame(diff(a, arithmetic = F) - 1)[-1,]
8 }
9
10
11 r_EU <- read_csv("Europa_(set2017-dez2019).csv",
12                 col_types = cols(Data = col_date(format = "%Y-%m-%d"))
13                 ) %>%
14   retorno()
15 r_US <- read_csv("USA_(jan2011-dez2019).csv",
16                 col_types = cols(Data = col_date(format = "%Y-%m-%d"))
17                 ) %>%
18   retorno()
19
20 tab_est <- function(mr=data.frame()) {
21   adf_ <- list(); pp_ <- list(); kpss_ <- list();
22   n <- length(mr)
23   for (i in 1:n){
24     adf_[[i]] <- adf.test(mr[[i]])[[1]] %>% round(., 4)
25     pp_[[i]] <- pp.test(mr[[i]])[[1]] %>% round(., 4)
26     kpss_[[i]] <- kpss.test(mr[[i]])[[1]] %>% round(., 4)
27   }
28   names(adf_) <- names(mr)
29   names(pp_) <- names(mr)
30   names(kpss_) <- names(mr)
31   rbind.data.frame(data.frame(adf_), data.frame(pp_),
32                   data.frame(kpss_)) %>%
33   cbind(data.frame('.', 'ADF', 'PP', 'KPSS')) , .)
```

```

32 }
33
34 write_csv(tab_est(r_EU), "estacionariedade_EU.csv")
35 write_csv(tab_est(r_US), "estacionariedade_USA.csv")

```

Listing C.1: Código fonte em R do teste de estacionariedade

```

1  library("fBasics");library(readr);library(magrittr);library(quantmod)
2
3  rm(list = ls())
4
5  df_EU <- read_csv("Europa_(set2017-dez2019).csv",
6                  col_types = cols(Data = col_date(format = "%Y-%m-%d")
7                  ))
8  be <- round(basicStats(df_EU[-1]),4)[-c(2,9,11,12,13),]
9  be <- c("NObs.", "Minimo", "Maximo", "1.\ tQuartil",
10         "3.\ tQuartil", "Media", "Mediana", "EQM",
11         "DP", "Assimetria", "Curtose") %>% cbind.data.frame(., be)
12 df_USA <- read_csv("USA_(jan2011-dez2019).csv",
13                  col_types = cols(Data = col_date(format = "%Y-%m-%d"
14                  )))
15 bu <- round(basicStats(df_USA[-1]),4)[-c(2,9,11,12,13),]
16 bu <- c("NObs.", "Minimo", "Maximo", "1.\ tQuartil",
17         "3.\ tQuartil", "Media", "Mediana", "EQM",
18         "DP", "Assimetria", "Curtose") %>% cbind.data.frame(., bu)
19
20 write_csv(be, "est_eu.csv", na = "")
21 write_csv(bu, "est_usa.csv", na = "")
22
23 r_EU <- retorno(df_EU)
24 r_USA <- retorno(df_USA)
25
26 ber <- round(basicStats(r_EU),4)[-c(2,9,11,12,13),]
27 ber <- c("NObs.", "Minimo", "Maximo", "1.\ tQuartil",
28         "3.\ tQuartil", "Media", "Mediana", "EQM",
29         "DP", "Assimetria", "Curtose") %>% cbind.data.frame(., ber)
30
31 bur <- round(basicStats(r_USA),4)[-c(2,9,11,12,13),]
32 bur <- c("NObs.", "Minimo", "Maximo", "1.\ tQuartil",
33         "3.\ tQuartil", "Media", "Mediana", "EQM",
34         "DP", "Assimetria", "Curtose") %>% cbind.data.frame(., bur)
35
36 write_csv(ber, "estR_eu.csv", na = "")
37 write_csv(bur, "estR_usa.csv", na = "")
38
39

```

```

40 nomes_e <- c("ERIX", "EUR", "WilderHill", 'WTI', 'USDX', 'CRB', 'MSCI')
41 nomes_u <- c("GRNREG", "SP500", "WilderHill", 'WTI', 'USDX', 'CRB', 'PSE')
42
43
44 pdf("plot_o_EU.pdf", width = 6, height = 3.5)
45 for (i in 2:8) {
46   ts.plot(ts(df_EU[[i]], start = c(2017,220), frequency = 260), xlab = '
47     ', ylab = "")
48   legend("top", legend=nomes_e[i-1], bty="n")
49 }
50 dev.off()
51
52 pdf("plot_r_EU.pdf", width = 6, height = 3.5)
53 for (i in 1:7) {
54   ts.plot(ts(r_EU[[i]], start = c(2017,220), frequency = 260), xlab = '
55     ', ylab = "")
56   legend("top", legend=nomes_e[i], bty="n")
57 }
58 dev.off()
59
60 pdf("plot_o_USA.pdf", width = 6, height = 3.5)
61 for (i in 2:8) {
62   ts.plot(ts(df_USA[[i]], start = c(2011,20), frequency = 252), xlab =
63     ', ylab = "")
64   legend("top", legend=nomes_u[i-1], bty="n", text.font=50)
65 }
66 dev.off()
67
68 pdf("plot_r_USA.pdf", width = 6, height = 3.5)
69 for (i in 1:7) {
70   ts.plot(ts(r_USA[[i]], start = c(2011,20), frequency = 252), xlab =
71     ', ylab = "")
72   legend("top", legend=nomes_u[i], bty="n")
73 }
74 dev.off()

```

Listing C.2: Código fonte em R das tabelas de estatísticas básicas

```

1 library(readr); library(strucchange); library(gap); library(magrittr)
2 rm(list = ls())
3
4
5 ##### amostra europeia#####
6 #set2017 a dez2019
7 a_EU <- read_csv("Europa_(set2017-dez2019).csv",
8   col_types = cols(Data = col_date(format = "%Y-%m-%d")
9   ))

```

```

10 ##### amostra americana#####
11 #jan2011 a dez2019
12 a_USA <- read_csv("USA_(jan2011-dez2019).csv",
13                 col_types = cols(Data = col_date(format = "%Y-%m-%d"
14                 )))
15 ##### Quebras estruturais #####
16
17 ###EU
18 stocks_e <- ts(a_EU[-1], start = c(2017,188), frequency = 250)
19
20 ## F statistics indicate one breakpoint
21 fs.test_e <- Fstats(ERIX~1, data = stocks_e); breakpoints(fs.test_e)
22
23 ts.plot(x = stocks_e[,1], ylab='', xlab='', main="breakpoint Europa")
24 lines(breakpoints(fs.test_e))
25 sc <- sctest(ERIX ~EUR+WilderHill+WTI+USDX+CRB+MSCI,
26 data = stocks_e, type = 'Chow', point = fs.test_e$breakpoint)
27
28
29 #####USA
30 stocks_u <- ts(a_USA[-1], start = c(2011,20), frequency = 250)
31
32 ## F statistics indicate one breakpoint
33 fs.test_u <- Fstats(GRNREG~1, data = stocks_u)
34 breakpoints(fs.test_u)
35
36 ts.plot(x = stocks_u[,1], ylab='', xlab='', main="breakpoint USA")
37 lines(breakpoints(fs.test_u))
38 sctest(GRNREG ~SP500+WilderHill+WTI+USDX+CRB+PSE,
39 data = stocks_u, type = 'Chow', point = fs.test_u$breakpoint)
40
41 ##### sub amostras #####
42 # set2017 a jan2019
43 sub1_e <- a1_EU[c(1:fs.test_e$breakpoint),]
44 # jan2019 a dez2019
45 sub2_e <- a1_EU[-c(1:fs.test_e$breakpoint),]
46
47 # jan2011 a fev2017
48 sub1_u <- a1_USA[c(1:fs.test_u$breakpoint),]
49 # fev2017 a dez2019
50 sub2_u <- a1_USA[-c(1:fs.test_u$breakpoint),]
51
52 ##### salvar
53
54 write_csv(sub1_e, "su1_e(set2017-jan2019).csv", na="")
55 write_csv(sub2_e, "su2_e(jan2019-dez2019).csv", na="")

```

```

56 write_csv(sub1_u, "su1_u(jan2011-fev2017).csv", na="")
57 write_csv(sub2_u, "su2_u(fev2017-dez2019).csv", na="")

```

Listing C.3: Código fonte em R do teste de quebra estrutural e criação de subamostras.

```

1 library(tibble); library(magrittr); library(rugarch)
2 library(readr); library(quantmod);
3 rm(list = ls())
4
5 #####funcoes auxiliares#####
6 qualgarch <- function(r_EU) {
7 #####ordem da media
8   m <- autoarfima(r_EU[[1]], method = 'partial', include.mean = 0)$
   rank.matrix[, 1:2]
9   p <- m[m[,1] > 0 & m[,2] > 0, ][1,]
10  #####Garch(1,1)#####
11   spec <- ugarchspec(variance.model=list(model="fGARCH",
   garchOrder=c(1,1),
12                                     submodel='GARCH'),
13                       mean.model=list(armaOrder=c(p), arfima=FALSE),
14                       distribution.model="norm")
15
16 garch11 <- list()
17 for (i in 1:7){
18   filibrary(tibble); library(magrittr); library(rugarch)
19   library(readr); library(quantmod);
20   rm(list = ls())
21
22   #####funcoes auxiliares#####
23   qualgarch <- function(r_EU) {
24     #####ordem da media
25     m <- autoarfima(r_EU[[1]], method = 'partial', include.mean = 0)$rank.
       matrix[, 1:2]
26     p <- m[m[,1] > 0 & m[,2] > 0, ][1,]
27     #####Garch(1,1)#####
28     spec <- ugarchspec(variance.model=list(model="fGARCH", garchOrder=c
       (1,1)
29     , submodel='GARCH'),
30                       mean.model=list(armaOrder=c(p), arfima=FALSE),
31                       distribution.model="norm")
32
33     garch11 <- list()
34     for (i in 1:7){
35       fitT <- ugarchfit(data=r_EU[[i]], spec=spec) # Ajuste do modelo
36       if (length(fitT@fit$LLH)==0){
37         garch11[[i]] <- NA
38       } else {garch11[[i]] <- c(Infocriteria(fitT), fitT@fit$LLH)}
39     }

```

```

40 names(garch11) <- names(r_EU)
41 garch11 <- data.frame(garch11)
42
43
44 #####GJRGarch(1,1)#####
45 spec <- ugarchspec(variance.model=list(model="fGARCH", garchOrder=c
46 (1,1),
47                                     submodel='GJRGARCH'),
48 mean.model=list(armaOrder=c(p), arfima=FALSE),
49 distribution.model="norm")
50
51 tgarch11 <- list()
52 for (i in c(1:7)){
53   fitT <- ugarchfit(data=r_EU[[i]], spec=spec) # Ajuste do modelo
54   if (length(fitT@fit$LLH)==0){
55     tgarch11[[i]] <-NA}
56   else{tgarch11[[i]] <-c(Infocriteria(fitT), fitT@fit$LLH)}
57 }
58 names(tgarch11) <- names(r_EU)
59 tgarch11 <- data.frame(tgarch11)
60
61 #####eGarch(1,1)#####
62 spec <- ugarchspec(variance.model=list(model="eGARCH", garchOrder=c
63 (1,1)),
64 mean.model=list(armaOrder=c(
65 p), arfima=F),
66 distribution.model="norm")
67
68 egarch11 <- list()
69 for (i in c(1:7)){
70   fitT <- ugarchfit(data=r_EU[[i]], spec=spec) # Ajuste do modelo
71   if (length(fitT@fit$LLH)==0){egarch11[[i]] <-NA
72 }else{egarch11[[i]] <-c(Infocriteria(fitT), fitT@fit$LLH)
73 }
74 }
75
76 names(egarch11) <- names(r_EU)
77 egarch11 <- data.frame(egarch11)
78
79 #####iGarch(1,1)#####
80 spec <- ugarchspec(variance.model=list(model="apARCH", garchOrder=c
81 (1,1)),
82 mean.model=list(armaOrder=c(
83 p), arfima=F),
84 distribution.model="norm")

```

```

82
83 igarch11 <- list()
84 for (i in 1:7){
85     fitT <- ugarchfit(data=r_EU[[i]], spec=spec) # Ajuste do modelo
86     if (length(fitT@fit$LLH)==0){igarch11[[i]] <-NA
87     }else{igarch11[[i]] <-c(infocriteria(fitT), fitT@fit$LLH)}
88 }
89 names(igarch11) <- names(r_EU)
90 igarch11 <- data.frame(igarch11)
91
92
93 ##### tabela com resultados #####
94
95 namecrit <- c('AIC', 'BIC', 'SIC', 'HQIC', 'LLH')
96
97 ae <- NULL
98 for (i in 1:5) {
99     ae <- rbind.data.frame(ae,
100     c(rep(NA_real_,7)),
101     garch11[i,],
102     egarch11[i,],
103     igarch11[i,],
104     tgarch11[i,])
105 }
106 ae <- round(ae,4)
107 ae <- cbind.data.frame(
108 modelos=rep(c('', 'GARCH', 'eGARCH', 'iGARCH', 'GJRGARCH'),5),
109 ae)
110 ae[seq(1,25,5),1] <- namecrit
111
112
113 'names<-'(list(ae)[], paste("ARMA",p[1],p[2], sep = '_'))}
114 retorno <- function(df) {
115     a <- xts(df[,-1], order.by=as.Date(df[[1]], "%Y-%m-%d"))
116     as.data.frame(diff(a, arithmetic = F)-1)[-1,]
117 }
118
119 #####tabelas garch#####
120 tab_su1_e <- read_csv("su1_e(set2017-jan2019).csv",
121     col_types = cols(Data = col_date(format = "%Y-%m
122     -%d")) %>%
123     retorno() %>% qualgarch()
124
125 tab_su2_e <- read_csv("su2_e(jan2019-dez2019).csv",
126     col_types = cols(Data = col_date(format = "%Y-%m
127     -%d")) %>%
128     retorno() %>% qualgarch()

```

```

127
128 tab_su1_u <- read_csv("su1_u(jan2011-fev2017).csv",
129                       col_types = cols(Data = col_date(format = "%Y-%m
130                                     -%d"))) %>%
131
132 retorno() %>% qualgarch()
133
134 tab_su2_u <- read_csv("su2_u(fev2017-dez2019).csv",
135                       col_types = cols(Data = col_date(format = "%Y-%m
136                                     -%d"))) %>%
137
138 retorno() %>% qualgarch()
139
140 ##### Salvar
141
142 save_image("~/Downloads/R/salve3/tabelasT.RData")
143 #load("~/Downloads/R/salve3/tabelas.RData")
144 write_csv(tab_su1_e$ARMA_1_2, "tUni_e1.csv", na="")
145 write_csv(tab_su2_e$ARMA_1_1, "tUni_e2.csv", na="")
146 write_csv(tab_su1_u$ARMA_2_2, "tUni_u1.csv", na="")
147 write_csv(tab_su2_u$ARMA_1_1, "tUni_u2.csv", na="")

```

Listing C.4: Código fonte em R para teste das formas funcionais do GARCH

```

1 library(readr); library(FinTS)
2 library(magrittr); library(xts)
3 library(rugarch)
4 rm(list = ls())
5
6 retorno <- function(df) {a <- xts(df[, -1], order.by=as.Date(df[[1]], "%
7   Y-%m-%d")); as.data.frame(diff(a, arithmetic = F)[-1][-1,]}
8
9 #####list_base#####
10 list_base <- list(suble = read_csv("su1_e(set2017-jan2019).csv",
11                                   col_types = cols(Data = col_date(format = "%Y-%m-%d"
12                                   ))) %>%
13                                   retorno() %>% .[1],
14                                   sub2e = read_csv("su2_e(jan2019-dez2019).csv",
15                                   col_types = cols(Data = col_date(format = "%Y-%m-%
16                                   d"))) %>%
17                                   retorno() %>% .[1],
18                                   sulu = read_csv("su1_u(jan2011-fev2017).csv",
19                                   col_types = cols(Data = col_date(format = "%Y-%m-%
20                                   d"))) %>%
21                                   retorno() %>% .[1],
22                                   su2u = read_csv("su2_u(fev2017-dez2019).csv",
23                                   col_types = cols(Data = col_date(format = "%Y-%m-%
24                                   d"))) %>%
25                                   retorno() %>% .[1]

```

```

21 )
22 #####list_aux#####
23
24 list_aux <- list()
25 spec <- list(
26 ugarchspec(variance.model=list(model="eGARCH", garchOrder=c(1,1)),
27           mean.model=list(armaOrder=c(1,2), arfima=FALSE),
28           distribution.model="ged"),
29 ugarchspec(variance.model=list(model="fGARCH", submodel="GJRGARCH",
30           garchOrder=c(1,1)),
31           mean.model=list(armaOrder=c(1,1), arfima=FALSE),
32           distribution.model="std"),
33 ugarchspec(variance.model=list(model="eGARCH", garchOrder=c(1,1)),
34           mean.model=list(armaOrder=c(2,2), arfima=FALSE),
35           distribution.model="norm"),
36 ugarchspec(variance.model=list(model="eGARCH", garchOrder=c(1,1)),
37           mean.model=list(armaOrder=c(1,1), arfima=FALSE),
38           distribution.model="norm")
39 )
40 for (i in 1:4) {
41   fitT <- ugarchfit(data=list_base[[i]], spec=spec[[i]]) # Ajuste do
42   modelo
43
44   z = residuals(fitT, standardize=TRUE)
45
46   list_aux[[i]] <- rbind(
47     unlist(ArchTest(x = z, lags = 2)[1:3]),
48     unlist(ArchTest(x = z, lags = 5)[1:3])
49   )
50 df1 <- cbind.data.frame(
51   "Modelo"=matrix(c("Regime 1", "(Europa)", "Regime 2", "(Europa)",
52   "Regime 1", "(USA)", "Regime 2", "(USA)")),
53   "Lag"=matrix(c("1-2", '1-5', "1-2", '1-5', "1-2", '1-5', "1-2", '1-5'), nc
54   =1),
55   rbind.data.frame(list_aux[[1]], list_aux[[2]], list_aux[[3]], list_aux
56   [[4]])
57 )
58 df1[3] <- round(df1[3], 4)
59 df1[5] <- round(df1[5], 4)
60
61 names(df1) <- c(".", "Lag", "Chi2", "df", "p-valor")
62
63 #####Salvar
64 write_csv(df1, "arch_test.csv", na="")

```

Listing C.5: Código fonte em R para este Arch

```
1 library(rmgarch);library(xts)
2 library(magrittr);library(readr)
3 rm(list = ls())
4
5 #####fun_aux#####
6 retorno <- function(df) {
7   a <- xts(df[, -1], order.by=as.Date(df[[1]], "%Y-%m-%d"))
8   as.data.frame(diff(a, arithmetic = F) - 1)[-1,]
9 }
10
11 qualdcc <- function(Dat, model="eGARCH", sub=F, dis.mo="norm") {
12 #numero de variaveis
13   r <- dim(Dat)[2]
14 #nome do modelo
15   model <- as.character(model)
16   dis.mo <- as.character(dis.mo)
17 #escolha da forma ARMA
18   m <- autoarfima(Dat[[1]], method = 'partial')$rank.matrix[, 1:2]
19   p <- m[m[,1] > 0 & m[,2] > 0,][1,]
20
21 if(!sub){var_model <- list(model=model, garchOrder=c(1,1))
22 }else{var_model <- list(model="fGARCH", garchOrder=c(1,1), submodel=
23   model)}
24
25 xspec = ugarchspec(variance.model=var_model,
26   mean.model=list(armaOrder=p, arfima=FALSE),
27   distribution.model=dis.mo)
28
29 uspec = multispec(replicate(r, xspec))
30 spec = dccspec(uspec = uspec, dccOrder = c(1, 1), distribution = 'mvnorm',
31   robust=T)
32
33 cl = makePSOCKcluster(3)
34 multf = multifit(uspec, Dat, cluster = cl)
35
36 fitdcc = dccfit(spec, data = Dat, fit.control = list(eval.se = TRUE),
37   fit = multf, cluster = cl)
38
39 stopCluster(cl)
40
41 fitdcc
42 }
43
44 #####datas#####
```

```

43
44 datas_e1 <- read_csv("su1_e(set2017-jan2019).csv",
45                      col_types = cols(Data = col_date(format = "%Y-%m
46                      -%d"))) %>%
47
48                      retorno()
49
50
51
52 datas_e2 <- read_csv("su2_e(jan2019-dez2019).csv",
53                      col_types = cols(Data = col_date(format = "%Y-%m
54                      -%d"))) %>%
55
56                      retorno()
57
58
59
60
61
62
63
64
65
66
67
68
69
70
71
72
73
74
75
76
77
78
79
80
81
82
83
84
85

```

```

##### dccgarch #####
fitdcc_e1 <- qualdcc(Dat = datas_e1[-c(2,6)], dis.mo = 'ged')
fitdcc_e2 <- qualdcc(Dat = datas_e2[-c(2,6)], model = 'GJRGARCH',
                    sub = T, dis.mo = 'std')
fitdcc_u1 <- qualdcc(datas_u1[-5])
fitdcc_u2 <- qualdcc(datas_u2[-5])

a <- cbind(data.frame(Regimes=c("Regime I (Europa)",
                              "Regime II (Europa)",
                              "Regime I (USA)",
                              "Regime II (USA)")),
           t(cbind(
               infocriteria(fitdcc_e1),
               infocriteria(fitdcc_e2),
               infocriteria(fitdcc_u1),
               infocriteria(fitdcc_u2))))

##### Salvando criterios
write_csv(a, "crit_dos_regimes.csv", na="")

##### extraindo correlacao e covariancia

##### e1 #####
cov = rcov(fitdcc_e1) # extracts the covariance matrix
cor = rcor(fitdcc_e1) # extracts the correlation matrix

```

```

86
87 pdf("cor_e1.pdf", width = 7, height = 3.5)
88 dat <- format(c(min(as.Date(names(cor[1,1,]))),mean(as.Date(names(cor
      [1,1,])))),
89 max(as.Date(names(cor[1,1,]))), "%d %b %Y")
90 for (i in 2:dim(cor)[2]) {
91   plot(cor[1,i,], ylab='', xlab='', xaxt='n', t='l')
92   axis(1, c(1,dim(cor)[3]/2,dim(cor)[3]), dat)
93 }
94 dev.off()
95
96 pdf("cov_e1.pdf", width = 7, height = 3.5)
97 dat <- format(c(min(as.Date(names(cov[1,1,]))),mean(as.Date(names(cov
      [1,1,])))),
98 max(as.Date(names(cov[1,1,]))), "%d %b %Y")
99 for (i in 2:dim(cov)[2]) {
100   plot(cov[1,i,], ylab='', xlab='', xaxt='n', t='l')
101   axis(1, c(1,dim(cov)[3]/2,dim(cov)[3]), dat)
102 }
103 dev.off()
104
105 #####e2#####
106 cov = rcov(fitdcc_e2) # extracts the covariance matrix
107 cor = rcor(fitdcc_e2) # extracts the correlation matrix
108
109 pdf("cor_e2.pdf", width = 7, height = 3.5)
110 dat <- format(c(min(as.Date(names(cor[1,1,]))),mean(as.Date(names(cor
      [1,1,])))),
111 max(as.Date(names(cor[1,1,]))), "%d %b %Y")
112 for (i in 2:dim(cor)[2]) {
113   plot(cor[1,i,], ylab='', xlab='', xaxt='n', t='l')
114   axis(1, c(1,dim(cor)[3]/2,dim(cor)[3]), dat)
115 }
116 dev.off()
117
118 pdf("cov_e2.pdf", width = 7, height = 3.5)
119 dat <- format(c(min(as.Date(names(cov[1,1,]))),mean(as.Date(names(cov
      [1,1,])))),
120 max(as.Date(names(cov[1,1,]))), "%d %b %Y")
121 for (i in 2:dim(cov)[2]) {
122   plot(cov[1,i,], ylab='', xlab='', xaxt='n', t='l')
123   axis(1, c(1,dim(cov)[3]/2,dim(cov)[3]), dat)
124 }
125 dev.off()
126
127 #####u1#####
128 cov = rcov(fitdcc_u1) # extracts the covariance matrix

```

```

129 cor = rcor(fitdcc_u1) # extracts the correlation matrix
130
131 pdf("cor_u1.pdf", width = 7, height = 3.5)
132 dat <- format(c(min(as.Date(names(cor[1,1,]))),mean(as.Date(names(cor
133 [1,1,]))),
134 max(as.Date(names(cor[1,1,]))), "%d %b %Y")
135 for (i in 2:dim(cor)[2]) {
136     plot(cor[1,i,], ylab='', xlab='', xaxt='n', t='l')
137     axis(1, c(1,dim(cor)[3]/2,dim(cor)[3]), dat)
138 }
139 dev.off()
140 pdf("cov_u1.pdf", width = 7, height = 3.5)
141 dat <- format(c(min(as.Date(names(cov[1,1,]))),mean(as.Date(names(cov
142 [1,1,]))),
143 max(as.Date(names(cov[1,1,]))), "%d %b %Y")
144 for (i in 2:dim(cov)[2]) {
145     plot(cov[1,i,], ylab='', xlab='', xaxt='n', t='l')
146     axis(1, c(1,dim(cov)[3]/2,dim(cov)[3]), dat)
147 }
148 dev.off()
149 #####u2#####
150 cov = rcov(fitdcc_u2) # extracts the covariance matrix
151 cor = rcor(fitdcc_u2) # extracts the correlation matrix
152
153 pdf("cor_u2.pdf", width = 7, height = 3.5)
154 dat <- format(c(min(as.Date(names(cor[1,1,]))),mean(as.Date(names(cor
155 [1,1,]))),
156 max(as.Date(names(cor[1,1,]))), "%d %b %Y")
157 for (i in 2:dim(cor)[2]) {
158     plot(cor[1,i,], ylab='', xlab='', xaxt='n', t='l')
159     axis(1, c(1,dim(cor)[3]/2,dim(cor)[3]), dat)
160 }
161 dev.off()
162 pdf("cov_u2.pdf", width = 7, height = 3.5)
163 dat <- format(c(min(as.Date(names(cov[1,1,]))),mean(as.Date(names(cov
164 [1,1,]))),
165 max(as.Date(names(cov[1,1,]))), "%d %b %Y")
166 for (i in 2:dim(cov)[2]) {
167     plot(cov[1,i,], ylab='', xlab='', xaxt='n', t='l')
168     axis(1, c(1,dim(cov)[3]/2,dim(cov)[3]), dat)
169 }
170 dev.off()
171 ####var

```

```

172
173 pdf_irf <- function(irfE, varE, data, nome=NULL){
174   n <- dim(data)[2]
175   nome <- paste(paste('irf', nome, sep = '_'), 'pdf', sep = '.')
176   pdf(nome, width = 5, height = 10/3)
177   for (i in 1:n) {
178     (irfE$irf[[i]]/summary(varE)$varresult[[i]]$sigma) %>% plot(t='1',
179       xlab='')
180   }
181   dev.off()
182 }
183 ##### var aplicado no residuo#####
184 #####e1#####
185 data <- residuals(fitdcc_e1)
186 v1 <- VAR(data, p=1); i1 <- irf(x = (v1), response = "ERIX", n.ahead = 30,
187   boot=F)
188 pdf_irf(i1, v1, data, 'res_e1')
189 #####e2#####
190 data <- residuals(fitdcc_e2)
191 v1 <- VAR(data, p=1); i1 <- irf(x = (v1), response = "ERIX", n.ahead = 30,
192   boot=F)
193 pdf_irf(i1, v1, data, 'res_e2')
194 #####u1#####
195 data <- residuals(fitdcc_u1)
196 v1 <- VAR(data, p=1); i1 <- irf(x = (v1), response = "GRNREG", n.ahead =
197   30, boot=F)
198 pdf_irf(i1, v1, data, 'res_u1')
199 #####u2#####
200 data <- residuals(fitdcc_u2)
201 v1 <- VAR(data, p=1); i1 <- irf(x = (v1), response = "GRNREG", n.ahead =
202   30, boot=F)
203 pdf_irf(i1, v1, data, 'res_u2')
204 #####var nos valores estimados #####
205 #####e1#####
206 data <- sigma(fitdcc_e1)
207 v1 <- VAR(data, p=1); i1 <- irf(x = (v1), response = "ERIX", n.ahead = 30,
208   boot=F)
209 pdf_irf(i1, v1, data, 'fit_e1')
210 #####e2#####
211 data <- sigma(fitdcc_e2)
212 v1 <- VAR(data, p=1); i1 <- irf(x = (v1), response = "ERIX", n.ahead = 30,

```

```

boot=F)
213
214 pdf_irf(i1 ,v1 ,data , 'fit_e2')
215
216 #####u1#####
217 data <- sigma(fitdcc_u1)
218 v1 <- VAR(data ,p=1); i1 <- irf(x = (v1) , response = "GRNREG" ,n.ahead =
30 ,boot=F)
219 pdf_irf(i1 ,v1 ,data , 'fit_u1')
220
221 #####u2#####
222 data <- sigma(fitdcc_u2)
223 v1 <- VAR(data ,p=1); i1 <- irf(x = (v1) , response = "GRNREG" ,n.ahead =
30 ,boot=F)
224 pdf_irf(i1 ,v1 ,data , 'fit_u2')

```

Listing C.6: Código fonte em R para dccGarch e var