UM ESTUDO DA RELAÇÃO ENTRE OS PREÇOS DO PETRÓLEO E DAS COMMODITIES DE ALIMENTOS NO MERCADO INTERNACIONAL

Marta Labanca Haik Gramatico Novo
Natália Leite dos Reis

Projeto de Graduação apresentado ao Curso de Engenharia de Produção da Escola Politécnica, Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Engenheiro.

Orientador:
André Assis de Salles

Rio de Janeiro
Dezembro de 2020

UM ESTUDO DA RELAÇÃO ENTRE OS PREÇOS DO PETRÓLEO E DAS COMMODITIES DE ALIMENTOS NO MERCADO INTERNACIONAL

Marta Labanca Haik Gramatico Novo

Natália Leite dos Reis

PROJETO DE GRADUAÇÃO SUBMETIDO AO CORPO DOCENTE DO CURSO DE ENGENHARIA DE PRODUÇÃO DA ESCOLA POLITÉCNICA DA UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE ENGENHEIRO DE PRODUÇÃO.

Examinado por:

Prof. André Assis de Salles, DSc.

Prof. Virgílio José Martins Ferreira Filho, DSc.

Prof. Rosemarie Broker Bone, DSc.

RIO DE JANEIRO, RJ - BRASIL

DEZEMBRO DE 2020

Novo, Marta Labanca Haik Gramatico

Reis, Natália Leite dos

Um estudo da relação entre os preços do petróleo e das commodities de alimentos no mercado internacional / Marta Labanca Haik Gramatico Novo e Natália Leite dos Reis – Rio de Janeiro: UFRJ / Escola Politécnica, 2020.

VI, 68 p.: il.; 29,7 cm

Orientador: André Assis de Salles

Projeto de Graduação – UFRJ/ Escola Politécnica/ Curso de Engenharia de Produção, 2020.

Referências Bibliográficas: p. 61-65.

1. Preços do Petróleo 2 Preços de Alimentos3. Modelos VAR

I. Salles, André Assis de. II. Universidade Federal do Rio de Janeiro, Escola Politécnica, Curso de Engenharia de Produção. III. Um estudo da relação entre os preços do petróleo e das commodities de alimentos no mercado internacional.

Agradecimentos

Marta Labanca Haik Gramatico Novo

Gostaria de agradecer aos meus amigos e familiares, os quais me apoiaram durante toda a jornada na universidade e foram fundamentais para que chegasse até aqui. Um agradecimento especial à minha mãe, meu pai, minha irmã e meu namorado, que me deram todo o suporte necessário para enfrentar os desafios durante uma longa jornada, mesmo nos momentos mais difíceis.

Também gostaria de citar todos os amigos que fiz durante minha caminhada na Escola Politécnica, os quais me ajudaram muito tanto nos momentos de estudo quanto nos momentos de maior descontração. Com certeza, algumas pessoas estarão entre os maiores legados que a Universidade Federal do Rio de Janeiro me proporcionou. Um agradecimento especial à minha dupla desse trabalho, Natália Reis, que esteve comigo desde o primeiro período letivo.

Por fim, agradeço a todos os professores que contribuíram para a minha excelente formação acadêmica e, em especial, ao meu orientador, André Salles, o qual esteve presente em grande parte da minha jornada acadêmica e me auxiliou no aprofundamento dos conhecimentos de estatística aplicada e econometria, além de ter confiado em mim para oportunidades de monitoria e iniciação científica, as quais foram muito motivadoras e me proporcionaram um grande aprendizado.

Agradecimentos

Natália Leite dos Reis

Agradeço em primeiro lugar a minha família, especialmente minha mãe, meu pai e meu irmão que desde sempre possibilitaram que eu pudesse conquistar e alcançar meus sonhos,

aos meus amigos e companheiro, cujo apoio nos estudos e na vida pessoal foi essencial para concluir essa jornada,

ao nosso orientador, aos professores e funcionários da UFRJ pela dedicação ao ensino e à Escola Politécnica

e, por fim, agradeço à minha dupla que esteve ao meu lado desde o primeiro dia até a defesa do nosso projeto de graduação.

Resumo do Projeto de Graduação apresentado à Escola Politécnica/ UFRJ como parte dos requisitos necessários para a obtenção do grau de Engenheiro de Produção.

UM ESTUDO DA RELAÇÃO ENTRE OS PREÇOS DO PETRÓLEO E DAS COMMODITIES DE ALIMENTOS NO MERCADO INTERNACIONAL

Marta Labanca Haik Gramatico Novo

Natália Leite dos Reis

Dezembro/2020

Orientador: André Assis de Salles

Curso: Engenharia de Produção

Estudar o comportamento dos preços dos alimentos consumidos no mundo é importante para os agentes econômicos devido ao problema da insegurança alimentar. A produção e os preços de alimentos estão relacionados com os preços de energia através, principalmente, da produção de fertilizantes e de biocombustíveis, que são produtos substitutos dos derivados de petróleo. O petróleo, por sua vez, é utilizado para a produção de fertilizantes e é uma das principais fontes de energia da matriz mundial. Nesse sentido, muitos estudos e pesquisas sobre a produção e os preços dos alimentos e do petróleo têm sido realizados. Este trabalho tem como objetivo examinar a relação dinâmica entre o preço do petróleo e os preços das *commodities* agrícolas arroz, trigo, milho e grãos de soja no mercado internacional. Foram estimados modelos vetoriais autorregressivos entre cada série temporal de preço e retorno dos grãos e o petróleo bruto do tipo Brent, além de se inferir a função de impulso resposta e a decomposição da variância. A amostra utilizada compreende dados semanais dos preços de fechamento em US$ entre junho de 2009 e novembro de 2019. Dessa forma, por não abranger as duas grandes crises do século, ou seja, a crise financeira da *subprime* e a crise sanitária da Pandemia de Covid-19, o período estudado não sofre variações anormais. Os resultados evidenciaram uma interação significativa entre os retornos dos preços do petróleo e os retornos dos preços dos grãos selecionados.

Palavras-chave: Petróleo Bruto, Alimentos, Mercados de Commodities, Modelos VAR.

Abstract of Undergraduate Project presented to POLI/UFRJ as a partial fulfillment of the requirements for the degree of Production Engineer.

STUDY OF THE RELATIONSHIP BETWEEN OIL PRICES AND FOOD COMMODITIES IN THE INTERNATIONAL MARKET

Marta Labanca Haik Gramatico Novo

Natália Leite dos Reis

December/2020

Advisor: André Assis de Salles

Course: Industrial Engineering

The production and price of food consumed in the world are directly or indirectly related to the production and prices of commodities in the grain sector. Thus, studying the prices behavior of the main commodities responsible for food security on the planet is important for economic agents, especially for those involved in macroeconomic policies decision making. Food production and prices are related to energy prices, mainly through the production of biofuels and fertilizers, which are substitute products for oil products. On the other hand, petroleum is used to produce fertilizers and is one of the main sources of energy in the world. Many studies and research on food and oil production and prices have been carried out relating energy and food, or oil price and the agricultural commodity prices. This work aims to examine the dynamic relationship between the oil price and grain commodity prices, namely rice, wheat, corn and soybeans as well as verify the cointegration and causality between each grain and Brent crude oil price return time series. Bivariate Autoregressive Vector Models were estimated to infer the impulse response function and the variance decomposition. The sample used cover the period between June 2009 and November 2019 that corresponds to the interval between the two major crises of the century, the subprime financial crisis and the Covid-19 Pandemic sanitary crisis. The results showed a significant interaction between oil price returns and selected grain price returns.

Keywords*:* Crude Oil Prices, Food Prices, VAR Models

SUMÁRIO

1. INTRODUÇÃO 11

2. REVISÃO BIBLIOGRÁFICA 17

3. METODOLOGIA APLICADA 23

3.1 Pressuposto de Normalidade 23

3.2 Pressuposto de Autocorrelação 24

3.3 Pressuposto de estacionariedade 25

3.4 Teste de Cointegração 28

3.5 Modelos Vetoriais Autorregressivos 30

3.6. Medidas de Performance e Critérios de Seleção de Modelos 32

4. AMOSTRA - DADOS UTILIZADOS 33

4.1. Dados Primários 33

4.2. Comportamento do Retorno dos Preços 38

4.3 Estacionariedade da Amostra 42

4.4 Autocorrelação da Amostra 43

5. ANÁLISE DOS RESULTADOS OBTIDOS 46

5.1. Teste de Cointegração 46

5.2. Resultados dos Modelos Vetoriais Autorregressivos 46

5.3. Resultado da Função Impulso Resposta 49

5.4 Resultado da Decomposição da Variância 53

6. COMENTÁRIOS FINAIS 59

REFERÊNCIAS BIBLIOGRÁFICAS 61

APÊNDICE A: Resultados Testes de Cointegração 65

A.1 Retorno do Brent e retorno do trigo 65

A.2 Retorno do Brent e retorno do arroz 66

A.3 Retorno do Brent e retorno da soja 67

A.4 Retorno do Brent e retorno do milho 68

APÊNDICE B: Tabelas Resultado da Decomposição da Variância 69

B.1 Retorno do Trigo 69

B.2 Retorno do Arroz 66

B.3 Retorno da Soja 67

B.4 Retorno do Milho 68

LISTA DE FIGURAS

Figura 1: Gráficos dos Preços do Petróleo e dos Grãos - escalas diferentes (US$) 34
Figura 2: Gráficos dos Preços do Arroz e do Petróleo - escalas diferentes (US$) 35
Figura 3: Gráficos dos Preços do Milho e do Petróleo - escalas diferentes (US$) 36
Figura 4: Gráficos dos Preços da Soja e do Petróleo - escalas diferentes (US$) 36
Figura 5: Gráficos dos Preços do Trigo e do Petróleo - escalas diferentes (US$) 37
Figura 6: Gráficos dos Retornos das Séries das *commodities* 39
Figura 7: Histogramas das Séries Temporais de Retorno 40
Figura 8A: Gráficos resultados das Funções Impulso Resposta 50
Figura 8B: Gráficos resultados das Funções Impulso Resposta 50
Figura 9A: Gráficos da Decomposição de Variância - 10 semanas 54
Figura 9B: Gráficos da Decomposição de Variância - 10 semanas 54
Figura 10A: Gráficos da Decomposição de Variância - 52 semanas 56
Figura 10B: Gráficos da Decomposição de Variância - 52 semanas 57

LISTA DE TABELAS

Tabela 1A: Resumo de artigos da revisão bibliográfica 19
Tabela 1B: Resumo de artigos da revisão bibliográfica 21
Tabela 2: Valores críticos para o teste Dickey-Fuller 28
Tabela 3: Resumo Estatístico das Séries Temporais de Preço 37
Tabela 4: Resumo Estatístico - Retornos 41
Tabela 5: Resultado ADF - Séries Temporais dos Preços 42
Tabela 6: Resultado ADF - Séries Temporais dos Retornos dos Preços 42
Tabela 7: Resultados do Teste de Autocorrelação - Preços 44
Tabela 8: Resultados do Teste de Autocorrelação - Retornos 45
Tabela 10: Resultado das Estimativas dos Parâmetros dos Modelos VECM 47
Tabela 11: Tabela Resultado da Função Impulso Resposta 52

1. INTRODUÇÃO

De acordo com a Organização das Nações Unidas para Alimentação e Agricultura (FAO) (2020), quase 690 milhões de pessoas passam fome no mundo, o que representa 8,9% da população mundial, e existe uma tendência de crescimento da quantidade de pessoas afetadas pelo problema da insegurança alimentar. Assim, o custo dos alimentos é de extrema importância para reduzir a fome mundial e minimizar o problema da insegurança alimentar, o qual sofre influência das políticas econômicas por meio das despesas públicas e dos investimentos governamentais. É interessante destacar que o Brasil saiu do Mapa Mundial da Fome em 2014 segundo o relatório "Estado da Insegurança Alimentar no Mundo" da Organização das Nações Unidas para Alimentação e Agricultura (FAO).

As *commodities* agrícolas, em especial grãos, são produtos necessários para a alimentação da população e possuem elevada relevância para a sobrevivência humana e para a redução da fome no mundo, o que reforça a necessidade de estudá-los e entender os fatores que podem afetar seus preços. São mercadorias que resultam da prática agropecuária, submetidas a um grau mínimo de industrialização, destarte a mecanização da agricultura. Em geral, são mercadorias homogêneas fundamentais para a sobrevivência da sociedade e fazem parte de um mercado de abrangência global (ver Capital Research, 2020). Comercializadas nas principais bolsas de valores e mercadorias do mundo, as *commodities* agrícolas possuem seus preços definidos a partir de cotações internacionais, com influência da oferta e da demanda (ver Politize, 2018). Segundo Paula *et al.* (2015), com a financeirização dos mercados de *commodities*, o envolvimento de agentes financeiros tem se tornado um determinante dos preços das *commodities* agrícolas.

De acordo com *Center For Advanced Medicine* (2020), três ingredientes são encontrados na maioria dos alimentos processados: trigo, milho e soja, os quais são chamados de "*Big Three*". Uma pessoa que segue a dieta americana padrão, geralmente ingere pelo menos um desses alimentos em suas refeições. Além disso, segundo Wright (2011), arroz, trigo e milho fornecem à população mundial a maior parte de sua energia alimentar. Assim, quando a oferta tem uma redução significativa, pode haver uma elevação abrupta dos preços e, em um mercado livre, consumidores de renda mais baixa podem ser forçados pelos altos preços a gastar boa parte de seus recursos em alimentos, o que reduz o consumo geral de outros bens. Nesse sentido, devido à elevada importância desses grãos para a população mundial, o foco desse trabalho são as *commodities* agrícolas arroz, trigo, milho e soja.

O arroz está entre os alimentos mais consumidos do mundo, sendo estratégico economicamente, e tem no Sudeste da Ásia os maiores produtores mundiais, segundo o *website* IFC Markets (2020). Cerca de 150 milhões de hectares de arroz são cultivados anualmente no mundo, produzindo 590 milhões de toneladas. É uma cultura que possui versatilidade, adaptando-se a diversas condições de solo e clima. O arroz fornece 20% da energia e 15% da proteína per capita necessária ao homem, com potencial para o combate da fome no mundo segundo o *website* Agrolink (2020). O trigo, por sua vez, é o segundo grão mais produzido no mundo e tem um papel muito importante na segurança alimentar, já que é o ingrediente fundamental do pão, alimento essencial para a nutrição da população mundial, presente em diversas culturas. O Departamento de Agricultura dos Estados Unidos (USDA) (2020) estima que a produção mundial de trigo 2020 / 2021 será de 768,49 milhões de toneladas (ver World Agricultural Production, 2020). Já o milho tem sua importância econômica caracterizada pelas diversas formas de sua utilização, que vão desde a alimentação animal até a indústria de alta tecnologia. O milho pode ser utilizado como fonte de energia na forma de biocombustíveis e está entre os principais componentes da ração de aves, bovinos e suínos, importantes fontes de proteína animal. É interessante destacar que o uso do milho em grão como alimentação animal representa a maior parte de seu consumo. Nos Estados Unidos representa cerca de 50%, enquanto no Brasil varia de 60 a 80%, dependendo da fonte da estimativa e de ano para ano, como verificado no *website* Agrolink (2020). Por fim, a soja, assim como o milho, pode ser utilizada como fonte de energia na forma de biocombustíveis e está entre os principais componentes da ração de aves, bovinos e suínos. Segundo Agromove (2019), a soja tem como principais países produtores os Estados Unidos e o Brasil e é utilizada na alimentação humana e na ração animal. A cultura da soja movimentou cerca de 31,7 bilhões de dólares somente em 2018. Portanto, somando o arroz aos "*Big Three*", denominação dada aos grãos trigo, milho e soja, tem-se os quatro alimentos responsáveis pela segurança alimentar do planeta.

É importante destacar que choques negativos de preços dos produtos agrícolas têm um impacto negativo ainda maior sobre o crescimento econômico, o que justifica o estudo da volatilidade dos preços desses produtos (Todsadee *et al.* 2014). Como observado em Politize (2018), em geral, países em desenvolvimento possuem maior dependência econômica da exportação de produtos primários, pois são produtores dessas *commodities* que têm participação importante na balança comercial. Porém, conforme comentado em Hespanhol *et al.* (2010), o aumento da produção de alimentos nos países exportadores de *commodities* agrícolas não

garante que os problemas da fome e da subnutrição sejam resolvidos nesses países devido à indisponibilidade de renda para adquiri-los.

Sabe-se que os preços das *commodities* de grãos podem ser afetados pelos preços de outras *commodities*, sejam elas também de grãos ou de outros grupos, como no segmento das *commodities* energéticas, em especial, o petróleo bruto. Isso ocorre porque, se por um lado, o petróleo influencia os preços de combustíveis, fertilizantes e transportes, por outro lado, a produção de grãos compete com a produção de biocombustível, um concorrente dos combustíveis fósseis. Pindyck e Rotemberg (1990) mostraram que há análises dos mercados futuros e de *commodities* feitas por analistas do mercado financeiro, nas quais são citadas o aumento dos preços de café ou do petróleo porque os preços das *commodities* em geral estão subindo. Assim, é como se os aumentos desses preços tivessem a mesma causa original que impactaria similarmente no aumento de outras *commodities* como o trigo, algodão e ouro. Como destacaram Dawson e White (2002), a semelhança entre os preços das *commodities* pode acontecer por 4 motivos gerais. O primeiro motivo está nas variáveis macroeconômicas, como demanda agregada, inflação e taxa de juros, que são determinantes comuns dos preços das *commodities*. Um segundo motivo da existência de associações entre os preços de *commodities* do mesmo grupo é devido à capacidade de substituir, ao menos parcialmente, uma *commodity* por outra, ou o fato de serem bens complementares, ou seja, bens que são consumidos ou utilizados geralmente em conjunto. Um terceiro motivo pode ser devido às correlações entre os preços futuros de todas as *commodities*, os quais podem ser causadas pelo comportamento dos especuladores. Para isso, Pindyck e Rotemberg (1990) forneceram duas explicações possíveis: (a) os mercados de capitais ineficientes impõem restrições de liquidez aos especuladores, de modo que uma queda em um preço futuro diminuirá outros, reduzindo a demanda por contratos futuros; (b) o comportamento "manada" surge quando uma proporção suficientemente grande de *traders* reage às notícias de maneira semelhante: estão otimistas ou pessimistas em todos os mercados sem razão econômica, mas por causa da psicologia do mercado, e isso pode ser agravado pela negociação automatizada. Por último, Dawson e White (2002) mencionam como o quarto fator o contexto de políticas governamentais em que podem surgir semelhanças quando são coordenadas como, por exemplo, da política agrícola comum da União Europeia, na qual os padrões dos preços de intervenção do trigo e da cevada são muito semelhantes. Salles *et al.* (2019) em trabalho sobre cobre mostra que a variação da renda, da produção industrial e da taxa de câmbio são variáveis relevantes que devem ser observadas. Segundo publicação no *website* da Escola de Economia de São Paulo (FVG / EESP) (2017), no caso brasileiro, os preços das

commodities em geral no mercado mundial são importantes, visto que esses produtos básicos correspondem à maior parte das exportações brasileiras. Em 2013, eles representavam 65% do valor de bens exportados pelo país, segundo levantamento da Conferência das Nações Unidas sobre Comércio e Desenvolvimento (UNCTAD).

Muitos trabalhos relacionam as *commodities* agrícolas e o preço de energia, principalmente devido à introdução dos biocombustíveis, que configuram como fontes energéticas de extrema relevância para a preservação do meio ambiente. Segundo definição disponível no *website* da Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP) (2020), "Biocombustíveis são derivados de biomassa renovável que podem substituir, parcial ou totalmente, combustíveis derivados de petróleo e gás natural em motores a combustão ou em outro tipo de geração de energia.". De acordo com *Nunez* (2019), o etanol é um dos biocombustíveis mais comuns, feito pela fermentação dos açúcares de plantas como milho ou a cana-de-açúcar, contém oxigênio que ajuda o motor de um carro a queimar o combustível com mais eficiência, reduzindo a poluição do ar. Nos EUA, a maior parte do etanol é derivado do milho. Já no Brasil, o segundo maior produtor de etanol depois dos EUA, a cana-de-açúcar é a principal matéria-prima. Nesse sentido, o preço do petróleo e o preço das *commodities* agrícolas são objetos de diversos estudos econométricos devido à sua influência na economia mundial e sua importância para suprir as necessidades alimentícias da população. Deve-se destacar que os preços das *commodities* agrícolas são afetados pelos preços da energia (petróleo) devido aos custos de produção e transporte. Além disso, o aumento da demanda por produtos agrícolas para produção de etanol gera discussões sobre uma relação mais forte entre os mercados agrícolas e de energia e o provável impacto do aumento dos preços dos combustíveis sobre a volatilidade dos preços dos alimentos. Portanto, compreender a fonte da volatilidade dos preços é importante para garantir a segurança e estabilidade alimentar do planeta, conforme observado por Todsadee *et al.* (2014).

O petróleo bruto, por sua vez, é uma das *commodities* mais procuradas no mundo. Sua ampla gama de usos varia desde a geração de energia até seu uso como matéria-prima para combustíveis e produtos petroquímicos, como plásticos, solventes e adesivos. Consequentemente, a indústria do petróleo é um dos ramos mais poderosos da economia mundial e as mudanças nos preços de referência do petróleo têm grandes implicações para a maioria dos setores manufatureiros e consumidores, como destaca Statista (2020). Além disso, as elevações dos preços do petróleo exercem impactos sobre diferentes indicadores macroeconômicos por meio do aumento dos custos de produção e dos custos operacionais. Ou

seja, um aumento no preço do petróleo se reflete em um maior custo de produção, reduzindo a taxa de retorno do investimento e aumentando a incerteza. Por conseguinte, o aumento do preço do petróleo afeta o consumo, pois a alteração do custo de produção afeta o preço do produto e, consequentemente, sua demanda, como destaca Rafiq *et al.* (2009). Além disso, Guo e Kliesen (2005) acrescentaram que a volatilidade nos preços do petróleo pode reduzir a produção agregada temporariamente, uma vez que atrasa o investimento empresarial, aumentando a incerteza ou induzindo uma dispendiosa realocação de recursos setoriais. Conforme observou Salles (2019), os preços do petróleo bruto são influenciados por diversos eventos aleatórios, como por exemplo: o clima, a disponibilidade de estoques de petróleo, o crescimento econômico, as variações da produção industrial, aspectos políticos ou geopolíticos e movimentos cambiais. Salles (2019) também destaca que como as variações bruscas dos preços do petróleo bruto influenciam diretamente os mercados financeiros internacionais, essas variações trazem mudanças no comércio exterior, nos investimentos e nas atividades produtivas, entre outras. Assim, pode-se inferir que existe uma relação significativa entre os preços do petróleo e as *commodities* agrícolas, em particular, as do setor de grãos responsáveis, como observado, pela segurança alimentar do planeta.

Este trabalho tem como objetivo examinar a interação entre os preços das *commodities* agrícolas de grãos arroz, trigo, milho e soja e o preço do petróleo bruto tipo Brent no mercado internacional, através de modelos estocásticos bivariados, a saber: modelos vetoriais autorregressivos (VAR) e modelos vetoriais autorregressivos com correção de erros (VECM), procurando entender se os preços dos grãos influenciam o preço do petróleo e vice-versa, bem como analisar a intensidade e o período de tempo de maior influência. E, a partir daí, fazer inferências sobre as relações de causalidade e cointegração entre as séries estudadas. Também será verificado como o preço de cada grão responde a inovações ou choques no preço do petróleo e como o preço do petróleo responde a inovações ou choques nos preços de cada grão. Por fim, será analisada como a variabilidade de cada série de preço de *commodity* de grão interage com a variabilidade da série do preço do petróleo.

Esse trabalho está organizado da seguinte forma: no Capítulo 2, que trata da revisão bibliográfica, serão apresentados outros estudos já realizados sobre temas próximos ao relatado anteriormente. Em seguida, o Capítulo 3, detalha a abordagem metodológica utilizada: os conceitos estatísticos básicos utilizados; os testes de normalidade, estacionariedade, autocorrelação e cointegração; os modelos vetoriais autorregressivos; a função impulso-resposta e a decomposição de variância. O capítulo 4 apresenta a amostra utilizada, as fontes

de coleta, o período, os resumos estatísticos e os resultados dos testes de normalidade, de estacionariedade e de autocorrelação. O Capítulo 5 mostra análise dos resultados obtidos, retrata os resultados das análises de cointegração, modelos vetoriais autorregressivos, função impulso resposta e decomposição de variância, com suas respectivas interpretações. Por fim, o Capítulo 6 apresenta as conclusões e os comentários finais do trabalho.

2. REVISÃO BIBLIOGRÁFICA

Historicamente, a especulação está presente nos mercados futuros de *commodities* energéticas e não energéticas. Além disso, o comportamento comum caracterizado por uma forte alta em torno do ano de 2008 seguido de uma queda acentuada durante a "grande recessão" reforçou a questão da ligação entre os dois mercados (Manera *et al.*, 2013b). Assim, diversos autores estudaram os fatores de impacto dos preços das *commodities* e como esses preços se relacionam entre si, principalmente os impactos econômicos das alterações do preço do petróleo e suas influências no preço de outros produtos, além dos fatores de influência sobre o preço das *commodities* agrícolas. Compreender as mudanças da volatilidade no tempo e os mecanismos de transmissão de volatilidade encontrados em diferentes tipos de mercados foi essencial para investidores internacionais e formuladores de políticas (Mensi *et al*., 2013).

O petróleo possui elevada importância para a economia mundial e seus preços podem impactar nos preços de outras *commodities* ou indicadores econômicos. Nesse sentido, a volatilidade do preço do petróleo já foi muito estudada, como fizeram Rafiq *et al.* (2009), analisando o impacto da volatilidade do preço do petróleo nos indicadores macroeconômicos da Tailândia e concluindo que a volatilidade tem impacto de curto prazo no investimento e na taxa de desemprego, o que pode ser explicado pelo fato da incerteza atrasar e reduzir os investimentos, impactando no desemprego devido à reestruturação setorial e à realocação de recursos.

Conforme observaram Harri e Hudson (2009), o uso de insumos químicos e derivados do petróleo na agricultura aumentou ao longo do tempo, havendo alteração dos preços desses insumos devido à alteração da oferta e, portanto, alteração dos preços das *commodities* que os utilizam. Além disso, as *commodities* agrícolas têm sido cada vez mais usadas para produzir energia. Nesse sentido, Harri e Hudson (2009) estudaram as dinâmicas de variação entre os preços das *commodities* agrícolas e preços do petróleo bruto, concluindo que a variação dos preços do petróleo possui relação de causalidade de Granger com a variação dos preços do milho. Motivados pelo crescimento da produção de etanol de milho e da produção de biodiesel de soja, Chen *et a*l. (2010) investigaram as relações entre o preço do petróleo bruto e os preços globais dos grãos de milho, soja e trigo. Os resultados mostraram que a variação no preço de cada grão é significativamente influenciada pelas mudanças no preço do petróleo bruto e outros preços de grãos durante o período de 2005 até 2008, o que implica que as *commodities* de grãos competem com a demanda derivada de biocombustíveis pelo uso de soja ou milho para produzir etanol ou biodiesel durante o período de alta dos preços do petróleo bruto naqueles anos.

Gardebroek e Hernandez (2013), porém, ao estudarem a transmissão da volatilidade nos preços do petróleo, etanol e milho nos Estados Unidos, não encontraram evidências de volatilidade nos mercados de energia estimulando a volatilidade dos preços no mercado de milho dos EUA. O retorno médio observado em um mercado é influenciado apenas pelo retorno defasado do mesmo mercado, mas não pelos retornos defasados de outros mercados.

Ainda buscando compreender os fatores sobre a volatilidade do mercado de *commodities*, Manera *et al.* (2013a) estudaram *commodities* energéticas e não energéticas, concluindo que a especulação afeta significativamente a volatilidade dos retornos: a especulação de curto prazo tem um impacto positivo e significativo na volatilidade, enquanto a especulação de longo prazo geralmente tem um efeito negativo. Em seguida, Manera *et al.* (2013b) estudaram os preços futuros de quatro *commodities* energéticas (petróleo bruto, óleo para aquecimento, gasolina e gás natural) e 5 *commodities* agrícolas (milho, aveia, óleo de soja, soja e trigo), concluindo que uma alta volatilidade nos mercados agrícolas corresponde a uma baixa volatilidade no mercado de energia e vice-versa. Bakhat e Würzburg (2013) também estudaram a transmissão de preços entre produtos alimentares e energéticos (petróleo), resultando em algumas evidências moderadas de que a produção de biocombustíveis aumentou a ligação entre os preços dos alimentos e os preços do petróleo. A maioria dessas relações de preços complexas foram encontradas nas matérias primas dos biocombustíveis (açúcar, soja, girassol, óleo de palma), porém, nenhuma relação de cointegração com os preços do petróleo bruto foi identificada para o milho, indicando que os resultados não foram inteiramente coerentes e unânimes.

Mensi *et al.* (2013) também estudaram a volatilidade de *commodities*, porém com uma abordagem mais voltada para o mercado de ações. Os autores investigaram as ligações de retorno e transmissão de volatilidade entre o S&P 500 e os índices de preços de *commodities* para energia, alimentos, ouro e bebidas durante o período turbulento de 2000-2011. Seus resultados corroboram os estudos anteriores sobre os efeitos significativos de volatilidade entre o preço do petróleo e os mercados de ações.

Com o objetivo de estudar a volatilidade dos preços das *commodities* alimentares no mercado agrícola dos Estados Unidos, Todsadee *et al.* (2014) notaram, entre outras observações, que as correlações entre soja e petróleo apresentaram valores baixos durante o período 2007-2013. Adicionalmente, Bin *et al.* (2014), ao examinarem o efeito do preço do petróleo bruto sobre os preços de outras *commodities*, observaram que o preço da soja reage excessivamente aos choques negativos em comparação com choques positivos de mudanças

nos preços do petróleo, enquanto os preços do milho reagem significativamente a choques positivos e negativos do preço do petróleo. Com foco no mercado brasileiro, Salles e Oliveira (2014) analisaram a correlação condicional entre os retornos dos preços do petróleo e os retornos dos preços das *commodities* agrícolas soja, café e açúcar, observando que parece haver uma correlação sólida entre os retornos dos preços internacionais do petróleo tipo Brent e os retornos dos preços de exportação do açúcar cristal brasileiro, havendo uma relação menos forte, mas também significativa, para os casos entre o petróleo bruto e o café e o petróleo bruto e a soja. Além disso, Ahumada e Cornejo (2016) tentaram prever o preço dos alimentos considerando a dependência cruzada entre eles, com foco em milho, soja e trigo, observando que há melhorias de previsão com o uso de modelos que incluem interações de preços.

Bernhardt (2017), motivado pela ideia de que o crescimento populacional, o aumento da riqueza e o uso de grãos como combustível influenciam os preços nos mercados agrícolas, estudou os efeitos de contágio de retorno e volatilidade dos mercados de *commodities* agrícolas (açúcar, trigo, soja e café), concluindo que a volatilidade e, portanto, o risco, desempenha um papel importante nos mercados à vista agrícolas no que diz respeito à média condicional e à volatilidade condicional. Nesse mesmo ano, Kumar (2017) analisou a transmissão da volatilidade do mercado de petróleo bruto para *commodities* agrícolas como trigo, milho, algodão e soja, encontrando que há transmissão de volatilidade do petróleo bruto para as *commodities* agrícolas, porém não é estável. Ainda com foco nesse tema, Herwartz e Saucedo (2020) concluíram que a volatilidade do petróleo bruto é um importante determinante das incertezas recebidas pelos mercados de matérias-primas após analisarem o papel do petróleo bruto na formação de incertezas de preços das *commodities* agrícolas. Por fim, com o objetivo de estimar a transmissão de volatilidade do preço do petróleo bruto e da taxa de câmbio com os preços de milho, arroz e soja em Gana e na Turquia, Damba *et al.* (2019) observaram transmissões de choque significativas entre os três preços dos produtos agrícolas com o preço do petróleo bruto e com a taxa de câmbio no curto prazo.

A seguir, as tabelas 1A e 1B apresentam um resumo da revisão bibliográfica realizada para esse trabalho.

Tabela 1A: Resumo de artigos da revisão bibliográfica

Título	Autores (Ano)	Variáveis Estudadas	Amostra	Metodologia	Resultados
Impact of crude oil price volatility on economic activities: An empirical investigation in the Thai economy	Rafiq *et al.* (2009)	Preço do petróleo, taxa de crescimento do PIB, investimentos, taxa de juros, inflação, taxa de desemprego, balança comercial e déficit orçamentário	Dados da Thailândia (1993-2006)	VAR, Causalidade de Granger, Impulso Resposta e Decomposição de Variância	A volatilidade do preço do petróleo tem impacto significativo nos indicadores macroeconômicos, como desemprego e investimento, no período de 1993T1 a 2006T4.
Mean and Variance Dynamics between Agricultural Commodity Prices and Crude Oil Prices	Harri e Hudson (2009)	Preço do petróleo, preço do milho, preço da soja, preço do óleo de soja, preço do algodão e preço do trigo	Dados internacionais (2003-2009)	VAR e modelos GARCH	A variação dos preços do petróleo possui relação de causalidade de Granger com a variação dos preços do milho.
Modeling the relationship between the oil price and global food prices	Chen *et al.* (2010)	Preço do petróleo, preço do milho, preço da soja e preço do trigo	Dados internacionais (2005-2008)	*Global Cropland Allocation Model*	A variação do preço de cada grão é significativamente influenciada pelas variações do preço do petróleo bruto e de outros preços dos grãos durante o período que vai da 3ª semana de 2005 à 20ª semana de 2008.
Do energy prices stimulate food price volatility? Examining volatility transmission between US oil, ethanol and corn markets	Gardebroek e Hernandez (2013)	Preço do petróleo, preço do álcool e preço do milho	Dados USA (1997-2011)	Modelo GARCH multivariado	Os resultados não fornecem evidências de volatilidade nos mercados de energia estimulando a volatilidade dos preços no mercado de milho dos EUA.
Futures price volatility in commodities markets: The role of short term vs long term speculation	Manera *et al.* (2013a)	- Índices: "Working's T" (participação de mercado de traders não comerciais), porcentagem de especuladores longos líquidos sobre o total de contratos em aberto no mercado futuro e "Scalping" (especulação de curto prazo) - Commodities de energia: petróleo leve doce, óleo para aquecimento, gasolina e gás natural - Commodities não energéticas: cacau, café, milho, aveia, óleo de soja, soja e trigo	Dados internacionais (1986-2010)	Modelos GARCH	A especulação de curto prazo tem um impacto positivo e significativo na volatilidade, enquanto a especulação de longo prazo geralmente tem um efeito negativo.
.Financial speculation in energy and agriculture futures markets: A multivariate GARCH approach	Manera *et al.* (2013b)	- Preços futuros das commodities energéticas: petróleo, óleo para aquecimento, gasolina e gás natural - Preços futuros da commodities agrícolas: milho, aveia, óleo de soja, soja e trigo	Dados internacionais (1986-2010)	Modelos GARCH multivariados	Uma alta volatilidade nos mercados agrícolas corresponde a uma baixa volatilidade no mercado de energia e vice-versa.
Correlations and volatility spillovers across commodity and stock markets: Linking energies, food, and gold	Mensi *et al.* (2013)	Índice S&P 500, preço do trigo, preço do ouro e preço do petróleo	Dados internacionais (2000-2011)	VAR, modelos GARCH	Efeitos significativos de volatilidade entre o preço do petróleo e os mercados de ações.
Price Relationships of Crude Oil and Food Commodities	Bakhat e Würzburg (2013)	Preço do petróleo, preço do milho, preço do óleo de soja, preço do óleo de girassol, preço do óleo de palma, preço do açúcar, preço do trigo, preço do arroz, preço da carne, preço da lã, preço da borracha e preço do café	Dados internacionais (2000-2011)	Cointegração, VECM e causalidade de Granger	Evidências moderadas de que a produção de biocombustíveis aumentou a ligação entre os preços dos alimentos e os preços do petróleo.

Tabela 1B: Resumo de artigos da revisão bibliográfica

Título	Autores (Ano)	Variáveis Estudadas	Amostra	Metodologia	Resultados
Price volatility of grains: Relationship with crude oil prices using CCC-GARCH model	Todsadee *et al.* (2014)	Preço do arroz, preço do milho, preço do trigo, preço da soja e preço do petróleo	Dados USA (2007-2013)	Modelos GARCH multivariados	As correlações entre soja e petróleo apresentaram valores baixos durante o período 2007-2013.
Asymmetric adjustment between crude oil and commodity Market: Evidence from corn, soybeans, palm oil, wheat and sugar	Bin *et al.* (2014)	Preço do petróleo, preço do milho, preço da soja, preço do óleo de palma, preço do trigo e preço do açúcar	Dados internacionais (1983-2013)	AECM: *Asymmetric Error Correction Model* (modelo de correção de erro assimétrico)	O preço da soja reage excessivamente aos choques negativos em comparação com choques positivos de mudanças nos preços do petróleo, enquanto os preços do milho reagem significativamente a choques positivos e negativos do preço do petróleo.
The Relationship between Oil and Brazilian Agricultural Commodities Prices	Salles e Oliveira (2014)	Preço do petróleo, preço da soja, preço do café e preço do açúcar	Dados do Brasil (2004-2012)	Modelos GARCH multivariados	Correlação sólida entre os retornos dos preços internacionais do petróleo tipo Brent e os retornos dos preços de exportação do açúcar cristal brasileiro, havendo uma relação menos forte, mas também significativa, para os casos entre o petróleo bruto e o café e o petróleo bruto e a soja.
Forecasting food prices: The case of corn, soybeans and wheat	Ahumada e Cornejo (2016)	Preço do milho, preço da soja e preço do trigo	Dados internacionais (2008-2014)	EqCMs: *equilibrium correction model* (modelo de correção de equilíbrio) e DVARs	Os resultados indicam melhorias de previsão com o uso de modelos que incluem interações de preços
On Volatility Transmission from Crude Oil to Agricultural Commodities	Kumar (2017)	Preço futuro do trigo, preço futuro do milho, preço futuro do algodão, preço futuro da soja e preço futuro do petróleo bruto	Dados internacionais (2006-2015)	HAR: *Heterogeneous Autoregressive Model* (modelo autoregressivo heterogêneo)	Há transmissão de volatilidade do petróleo bruto para as commodities agrícolas, porém não é estável.
Return and Volatility Spillover Effects in Agricultural Commodity Markets	Bernhardt (2017)	Preço do açúcar, preço do trigo, preço da soja e preço do café	Dados internacionais (2008-2016)	VAR e modelos GARCH	A volatilidade e, portanto, o risco, desempenha um papel importante nos mercados à vista agrícolas no que diz respeito à média condicional e à volatilidade condicional.
Volatility Transmission between Prices of Selected Agricultural Products with Crude Oil and Exchanges Rates in Ghana and Turkey	Damba *et al.* (2019)	Preço do petróleo, taxa de câmbio, preço do arroz, preço da soja e preço do milho	Dados de Gana e Turquia (2000-2015)	VAR e modelos GARCH	Há transmissões de choque significativas entre os três preços dos produtos agrícolas com o preço do petróleo bruto e com a taxa de câmbio no curto prazo.
Food–oil volatility spillovers and the impact of distinct biofuel policies on price uncertainties on feedstock markets	Herwartz e Saucedo (2020)	Preço do petróleo, preço do milho, preço do trigo, preço do açúcar, preço do óleo de soja, preço do óleo de palma e preço do óleo de canola	Dados internacionais (1995-2015)	Modelos GARCH	A volatilidade do petróleo bruto é um importante determinante das incertezas recebidas pelos mercados de matérias-primas.

Ao analisar-se as diferentes conclusões, nota-se que, em geral, os trabalhos apontam para a relação entre os preços de energia e de alimentos, bem como transmissão de volatilidade entre esses mercados. Entretanto, ambos os trabalhos com dados dos Estados Unidos (EUA), Gardebroek e Hernandez (2013) e Todsadee et al. (2014), apresentaram relação fraca entre os mercados de energia e de alimentos. No primeiro, não há evidências de volatilidade nos mercados de energia estimulando a volatilidade dos preços do milho e, no segundo, as correlações entre soja e petróleo apresentaram valores baixos.

3. METODOLOGIA APLICADA

Na metodologia aplicada nesse trabalho constam testes estatísticos de hipóteses de violação dos pressupostos fundamentais para a construção dos modelos vetoriais autorregressivos utilizados para se atingir os objetivos mencionados anteriormente. Os pressupostos são a normalidade, a autocorrelação e a estacionariedade das séries temporais utilizadas na estimação dos modelos VAR. Além disso, foram testados a cointegração entre as séries temporais de variações de preço ou retorno dos grãos e o retorno do preço das cotações do petróleo bruto. Assim, neste capítulo estão descritos e comentados os testes mencionados, os modelos estocásticos utilizados, as medidas de performance dos modelos estimados e os critérios de seleção de modelos.

3.1 Pressuposto de Normalidade

O primeiro pressuposto fundamental para a estimação de modelos estocásticos utilizados é o teste de normalidade que indica se as séries de dados se ajustam a uma distribuição de probabilidade normal e, assim, pode-se considerar que possuem esse comportamento que é considerado adequado para a estimação dos modelos nesse estudo. A normalidade das séries de dados foi verificada por meio do teste de Jarque-Bera (JB) que é um teste assintótico ou para amostra grande, conforme descrito em Gujarati e Porter (2011).

O teste estatístico de hipótese de normalidade JB que combina testes de assimetria e a curtose utiliza a seguinte estatística de teste:

$$JB = n\,[\frac{S^2}{6} + \frac{(K-3)^2}{24}]$$

onde: n = tamanho da amostra;

S = coeficiente de assimetria;

K = coeficiente de curtose.

Para uma variável distribuída normalmente, espera-se coeficiente de assimetria (S) igual a zero e coeficiente de curtose (K) igual a 3. O teste JB é um teste da hipótese conjunta em que S e K são 0 e 3, respectivamente e por conseguinte o valor da estatística JB deve ser próximo de zero para que a hipótese de normalidade seja aceita.

Também foram analisados os coeficientes de assimetria e curtose das amostras. Dada a relevância da distribuição normal para as estimações realizadas neste trabalho, a assimetria e

curtose são muito importantes para inferir o quanto a distribuição dos dados está próxima de uma distribuição normal. A primeira medida se refere a simetria da distribuição dos dados, enquanto a segunda mede o achatamento da curva de distribuição de probabilidade. Ambas indicam se o conjunto de dados está distribuído como uma distribuição normal. Quando a assimetria é igual a zero, os valores estão distribuídos simetricamente ao redor da média como acontece na distribuição normal. Se o coeficiente de assimetria for menor do que zero, a cauda do lado esquerdo da função densidade de probabilidade é maior, havendo maior concentração de valores abaixo da média. Se for maior do que zero, a cauda do lado direito é maior, havendo maior concentração de valores acima da média. A assimetria da distribuição normal possui valor igual a zero. Assim, quanto mais próxima de zero for a assimetria de uma série de dados, mais próxima do coeficiente de assimetria da distribuição normal ela será. Em relação à curtose, de acordo com Upton e Cook (2006), se o valor for igual a 3, tem-se uma distribuição Mesocúrtica, como uma distribuição normal. Valores menores que 3 indicam distribuições Platicúrticas, mais achatadas que a distribuição normal e valores maiores que 3 indicam distribuições Leptocúrticas, com um pico mais alto que a distribuição Normal.

3.2 Pressuposto de Autocorrelação

De acordo com Pickup (2014), a correlação entre os elementos de uma série de dados Yt e a mesma série com defasagem 1 (Y_{t-1}) é chamada de autocorrelação, a qual é dada pela covariância entre Y_t e Y_{t-1} dividida pela variância de $Y_{t.}$ A fórmula a seguir retrata o cálculo da autocorrelação, onde y_t é o valor da série no momento t e μ_y é a média dos valores da série.

$$\rho = Corr(y_t, y_{t-1}) = \frac{E((y_t - \mu_y)(y_{t-1} - \mu_y))}{E(y_t - \mu_y)^2}$$

A medição da autocorrelação das séries de dados será feita por meio do teste de Ljung Box, o qual representa uma versão melhorada do teste de Box Pierce. Segundo Murteira (1993), o teste de Box Pierce é um teste global para os *m lag*s considerados. É um teste da hipótese:

$$H_0: \rho_1(\hat{\epsilon}) = \rho_2(\hat{\epsilon}) = \cdots = \rho_m(\hat{\epsilon}) = 0$$

A não aceitação dessa hipótese sugere que o modelo estimado não é apropriado para descrever a sucessão cronológica em causa. Admite-se que o modelo estimado é ARIMA (*p*,*d*,*q*), ou seja,

um modelo que envolve um modelo autorregressivo e um modelo de médias móveis, onde *p* é a ordem do modelo autorregressivo, *q* é a ordem do modelo de médias móveis e *d* representa o número de vezes que a série temporal teve que ser integrada até se obter uma série estacionária. Dessa forma, Box e Pierce mostram que sob a hipótese H_0, a estatística a seguir tem distribuição assintótica do Qui-quadrado com *m-p-q* graus de liberdade, onde N é o tamanho da amostra e *m* é o número de *lags* (defasagens).

$$Q = n \sum_{k=1}^{m} \hat{\rho}^2{}_k(\hat{\epsilon}), \;\; n = N - d$$

Essa propriedade permite concluir uma má qualidade do ajustamento quando o valor o de Q exceder o nível de significância adotado. Posteriormente, Ljung e Box (1978), recomendaram um teste melhorado, baseado na estatística apresentada na expressão abaixo. Essa também converge para uma distribuição Qui-quadrado com *m-p-q* graus de liberdade, como observado em Pickup (2014), sendo mais conveniente quando a amostra não é muito grande.

$$\tilde{Q} = n(n+2) \sum_{k=1}^{m} \frac{1}{n-k} \hat{\rho}^2{}_k(\hat{\epsilon}), \;\; n = N - d$$

3.3 Pressuposto de estacionariedade

Outro pressuposto fundamental para essa pesquisa é o da estacionariedade. Como observado por Gujarati e Porter (2011), um processo estocástico é considerado estacionário se a média e a variância forem constantes ao longo do tempo e se o valor da covariância entre dois períodos depende apenas da distância, do intervalo ou da defasagem entre os dois períodos e não do tempo real em que a covariância é estimada. Em uma série temporal não estacionária, pode-se estudar seu comportamento apenas no período considerado, não permitindo influências fora da amostra utilizada. Como observado em Wooldridge (2014), "a estacionariedade da covariância enfatiza somente os primeiros dois momentos de um processo estocástico: a média e a variância do processo são constantes no decorrer do tempo e a covariância entre y_t e y_{t+h} depende somente da distância entre os dois termos, *h*, e não da localização do período de tempo inicial, *t*". Dessa forma, não é possível generalizá-lo para outros momentos ou períodos.

Segundo Gujarati e Porter (2011), a não-estacionariedade geralmente resulta em regressões espúrias ainda que realizadas com uma amostra grande. Como descreve Salles (2005), um dos possíveis testes para se verificar a estacionariedade de uma série temporal é o teste de raiz unitária. Sendo e_t o termo estocástico, ou ruído branco, com média zero e desvio padrão constante σ_e do modelo auto-regressivo de ordem 1, ou modelo AR (1), para a série temporal da variável de interesse Y como expresso a seguir:

$$Y_t = \rho Y_{t-1} + e_t$$

onde: $-1 \leq \rho \leq 1$. Na equação anterior, Y_t é o valor da série no momento *t*, ρ representa o coeficiente de correlação e e_t o termo estocástico. Sabe-se que, se $\rho = 1$, a série temporal representada por Y_t é uma série de passeio aleatório sem desvio, o qual é um processo estocástico não estacionário com raiz unitária pois, nesse caso, a variância de Y_t muda com o tempo de forma crescente caracterizando a não estacionariedade da série temporal. Por outro lado, se $|\rho| < 1$, ou se $\rho < 1$, então o processo estocástico AR (1) é estacionário. Dessa forma, a não estacionariedade pode ser testada da seguinte maneira:

Hipótese Nula: $H_0: \rho = 1$
Hipótese Alternativa: $H_1: \rho < 1$

Alternativamente, se estima Y_t sobre o seu valor defasado Y_{t-1} e se verifica a hipótese nula do parâmetro ser igual a 1 pode-se dessa forma testar a hipótese de estacionariedade, a partir do modelo AR (1) mencionado anteriormente:

$$Y_i - Y_{t-1} = \rho Y_{t-1} - Y_{t-1} + e_t$$
$$\Delta Y_i = (\rho - 1) Y_{t-1} + e_t$$
$$\Delta Y_i = \gamma Y_{t-1} + e_t$$

E as hipóteses relacionadas acima podem ser escritas da seguinte forma:

Hipótese Nula: $H_0: \gamma = 0$
Hipótese Alternativa: $H_1: \gamma < 0$

Testa-se a hipótese (nula) de que $\gamma = 0$. Se $\gamma = 0$, então $\rho = 1$, ou seja, tem-se uma raiz unitária, o que significa que as séries temporais em consideração não são estacionárias. Como e_t é um termo de erro de ruído branco e é estacionário, pode-se dizer que as primeiras diferenças de uma série temporal de passeio aleatório são estacionárias. Um processo é chamado de ruído puramente aleatório ou branco se tiver média zero, variância constante e for serialmente não correlacionado.

A variável ΔY_t é dita primeira diferença da série Y_t, e se Y_t segue um passeio aleatório então $\gamma = 0$. Se Y_t é uma série não estacionária que pode ser transformada em estacionária pela primeira diferença ΔY_tentão pode-se dizer que Y_t é uma série temporal integrada de ordem 1, designada por I(1). Enquanto as séries que precisam ser tomadas pela diferença *d*, ou diferenciadas *d* vezes, é designada por I(*d*) e dita integrada de ordem *d*, as séries estacionárias são indicadas por I(0), e ditas integradas de ordem zero. Ou seja, o teste consiste em fazer a regressão das primeiras diferenças de Yt com Y_{t-1} e ver se o coeficiente de inclinação estimado nesta regressão é zero ou não. Se for zero, conclui-se que Yt não é estacionário. Mas se for negativo, conclui-se que Yt é estacionário.

Outro teste de hipótese de estacionariedade é o teste de Dickey-Fuller (DF). Trata-se do teste da hipótese nula $\gamma = 0$, e os valores críticos do teste foram tabulados pelos autores do teste Dickey e Fuller (1979). O teste DF permite testar se uma série temporal representa:

- um passeio aleatório que pode ser expresso por um modelo na forma $\Delta Y_i = \gamma Y_{t-1} + e_t$;
- passeio aleatório com uma constante que pode ser expresso por um modelo na forma $\Delta Y_i = \alpha + \gamma Y_{t-1} + e_t$;
- um passeio aleatório com uma tendência não estocástico, ou temporal, expressa por um modelo na forma $\Delta Y_i = \alpha + \beta t + \gamma Y_{t-1} + e_t$;
- um passeio aleatório para modelos na forma quando o teste da hipótese Ho: $\gamma = 0$ passa a ser designado como teste DF aumentado, ou ADF.

$$\Delta Y_i = \alpha + \gamma Y_{t-1} + \sum_{i=1}^{m} \beta_i \, \Delta Y_{t-i} + e_t$$

Na Tabela 2 estão listados os valores críticos para o teste DF que variam de acordo com o tamanho da amostra segundo Hill (2003).

Tabela 2: Valores críticos para o teste Dickey-Fuller

Modelo	1 %	5 %	10 %
(i)	-2,56	-1,94	-1,62
(ii)	-3,43	-2,86	-2,57
(iii)	-3,96	-3,41	-3,13
Valores Críticos (padrão)	**-2,33**	**-1,65**	**-1,28**

No estudo em questão, foi utilizado o teste de Dickey-Fuller Aumentado (ADF). O teste explicado anteriormente assume que o termo de erro ε_t não é autocorrelacionado. Porém, caso ε_t seja autocorrelacionado, Dickey e Fuller desenvolveram um teste, conhecido como o Dickey-Fuller Aumentado (ADF). Este teste é realizado estimando a seguinte regressão:

$$\Delta Yt = \beta 1 + \beta 2t + \delta Y_{t-1} + \sum_{i=1}^{m} \alpha i \Delta Y_{t-1} + \varepsilon_t$$

onde: ε_t é um termo de erro de ruído branco puro e

$$\Delta Y_{t-1} = (Y_{t-1} - Y_{t-2}), \Delta Y_{t-2} = (Y_{t-2} - Y_{t-3}), \text{etc.}$$

O número de termos de diferença defasada, ou *lags*, são escolhidos de acordo com a periodicidade da série de tempo e é geralmente determinado empiricamente, com a ideia de incluir termos suficientes para que o termo de erro seja serialmente não autocorrelacionado. Como regra geral, se as informações da série são trimestrais são estimados quatro modelos (*lags* = 4), se as informações são mensais são estimados 12 modelos (*lags* = 12) e assim por diante. No ADF também é testado se δ = 0 e o teste ADF segue a mesma distribuição assintótica que a estatística DF (teste de raiz unitária), para que os mesmos valores críticos possam ser usados. A escolha do modelo para a realização do teste ADF, em geral, é feita a partir de critérios de informação utilizados para a seleção de modelos de regressão.

Dentre os critérios mais utilizados pode-se citar o critério de Akaike (AIC) e o critério de Schwarz (BIC), que serão descritos adiante no Item 3.6 “Medidas de Performance e Critérios de Seleção de Modelos”.

3.4 Teste de Cointegração

Outro teste estatístico de hipótese importante para este estudo é o teste de cointegração. Segundo Gujarati e Porter (2011), a cointegração se refere a existência de uma relação

estocástica de longo prazo, ou de equilíbrio, entre duas ou mais variáveis ou séries temporais, ou seja, se duas séries temporais forem cointegradas, pode-se dizer que há uma relação de longo prazo entre ambas.

Nesta pesquisa, será utilizado o teste de Johansen e Juselius (1990) para testar a existência de relação de longo prazo entre as séries temporais dos retornos dos preços das *commodities* de grãos e o retorno do preço do petróleo do tipo Brent. O Teste de Johansen e Juselius (1990) foi escolhido dado a sua adequação para a estimação de modelos vetoriais autorregressivos que serão construídos e apresentados adiante neste trabalho. A referência utilizada para a metodologia e procedimentos para a elaboração dos testes de cointegração foi o software estatístico EViews (2020). O modelo aplicado utilizando-se um VAR estimado de ordem *p*, ou VAR(p), pode ser descrito como segue:

$$y_t = A_1 y_{t-1} + \cdots + A_p y_{t-p} + Bx_t + \varepsilon_t$$

onde: y_t é um vetor de dimensão k de variáveis não estacionárias;

x_t é um vetor de dimensão d de variáveis determinísticas;

ε_t é um vetor de inovações.

É possível reescrever esse VAR como:

$$\Delta y_t = \Pi y_{t-1} + \sum_{i=1}^{p-1} \Gamma_i \Delta y_{t-1} \; Bx_t + \varepsilon_t$$

onde:

$$\Pi = \sum_{i=1}^{p} A_i - \mathrm{I}$$

$$\Gamma_i = -\sum_{j=i+1}^{p} A_j$$

Como observado em Salles e Oliveira (2013), o teorema da representação de Granger afirma que se o coeficiente da matriz Π tem posto completo reduzido $r < k$, então existe as matrizes α e β de dimensão $k \times r$, cada uma com posto completo r de modo que $\Pi = \alpha\beta'$ e

$\beta' y_t$ são estacionários. Sendo r o número de relações de cointegração (posto de cointegração) e cada coluna β é o vetor de cointegração. Os elementos de α são conhecidos como os parâmetros de ajuste no modelo vetorial autorregressivo com correção de erros (VECM) que será apresentado adiante neste trabalho. O método de Johansen estima a matriz Π a partir de um VAR sem restrição e testa se rejeita as restrições aplicadas pelo posto completo reduzido de Π. Porém, em Johansen (1991), os testes de hipóteses de razão de verossimilhança que verificam o número de raízes características estatisticamente diferentes de zero da matriz de coeficientes tiveram suas distribuições assintóticas derivadas e convergiram para duas estatísticas de teste: o traço da matriz e o autovalor máximo da matriz. Destes dois testes realizados, o primeiro considera a hipótese nula da existência de r relações de cointegração e testa contra a hipótese alternativa da existência de k relações de cointegração, onde k é o número de variáveis endógenas integradas de ordem 1, sendo r = 0, 1, ..., k – 1. Essa estatística de teste pode ser descrita da seguinte forma:

$$LR_{tracer}(r|k) = -T \sum_{i=r+1}^{k} log\ (1 - \lambda_i)$$

onde λ_i representa o maior autovalor da matriz de coeficientes Π e T é o número de observações das séries incluídas na análise. O segundo teste verifica a hipótese nula da existência de r relações de cointegração contra a hipótese alternativa da existência de r + 1 relações de cointegração. Desta forma, a estatística teste é denominada de autovalor máximo e pode ser representada pela expressão:

$$\begin{aligned} LR_{max}(r|r+1) &= -\mathrm{T}\log(1 - \lambda_{r+1}) \\ &= LR_{trace}(r|k) - LR_{trace}(r+1|k) \end{aligned}$$

para r = 0, 1, ..., k – 1.

3.5 Modelos Vetoriais Autorregressivos

O modelo Vetorial Autorregressivo (VAR) proposto por Sims (1980) é muito usado em trabalhos de macroeconomia para se verificar a evolução e as interdependências entre séries temporais econômicas. O modelo estocástico em questão é bivariado e foi desenvolvido a partir dos modelos vetoriais autorregressivos e não distingue variáveis endógenas e exógenas. Dessa

forma, permite estudar a relação entre duas ou mais variáveis estocásticas e inovações ou choques que uma variável inflige na outra além de verificar a relação de curto e longo prazo entre essas variáveis.

O Modelo Vetorial Autorregressivo com correção de erros (VECM) é um caso especial do modelo VAR e deve ser utilizado sempre que houver uma relação estocástica de longo prazo entre as séries temporais ou entre as variáveis de interesse. Esse modelo pode ser aplicado quando as variáveis são estacionárias, cointegradas e os resíduos são independentes. O modelo VAR pode ser descrito pelo seguinte sistema de equações, no caso particular de um modelo VAR de ordem 1, ou VAR(1):

$$Y_t = \beta_1 + \beta_2 Y_{t-1} + \beta_3 Z_{t-1} + \varepsilon_{1t}$$

$$Z_t = \beta_4 + \beta_5 Z_{t-1} + \beta_6 Y_{t-1} + \varepsilon_{2t}$$

onde as variáveis Y_t e Z_t são estacionárias, e $\mathcal{E}_{1t,}$ e $\mathcal{E}_{2t}$ têm valor esperado igual a zero e são ortogonais. Neste trabalho, *Y* representa a série de preço do petróleo do tipo Brent e *Zg* representa as séries de preço das variáveis de grãos e *g* pode ser 1,2,3 ou 4, que corresponde respectivamente a milho, arroz, soja e trigo. Em todos os modelos estimados as constantes β_1 e β_4 não foram significativas e por isso não foram incluídos nos modelos finais. Neste estudo todas as variáveis são consideradas endógenas e, uma vez sendo as variáveis cointegradas, utiliza-se o modelo VECM para:

a. testar se uma variável (preço do petróleo) é útil para prever outra (preço de cada uma das *commodities* de alimento) e vice-versa;
b. analisar a função resposta para entender se uma mudança inesperada, porém temporária, no preço do petróleo influencia as outras variáveis;
c. analisar a decomposição da variância da previsão dos resíduos.

Nos modelos econométricos em que a dependência de uma variável sobre outra nem sempre ocorre no mesmo instante, é possível que ocorra em períodos diferentes, isto é, uma variável pode influenciar na outra com uma defasagem de tempo. Esse atraso de tempo é comumente designado por defasagem ou *lag*. Escolher o número de *lag*s é um problema

intrínseco à estimação de modelos econométricos e, em geral, esse número é determinado de forma empírica.

3.6. Medidas de Performance e Critérios de Seleção de Modelos

A escolha do modelo é realizada através de critério de seleção. Como mencionado anteriormente, o critério de Akaike (AIC) e o critério de Schwarz (BIC) são os mais utilizados. Sendo *n* o número de observações, *k* o número de parâmetros estimados e SQR a soma dos quadrados dos resíduos, o modelo que minimizar o critério escolhido será o mais adequado. De acordo com Gujarati e Porter (2011), os critérios AIC e BIC podem ser descritos da seguinte forma, respectivamente:

- Critério de Informação de Akaike (AIC):

$$AIC = \left(\frac{SQR}{n}\right) exp\left(\frac{2k}{n}\right)$$

- Critério de informação Schwarz (BIC):

$$BIC = \left(\frac{SQR}{n}\right) n^{k/n}$$

Para estabelecer o *lag* utilizado neste trabalho, foi considerado aplicar o método de escolha do *lag* ótimo minimizando o critério de Akaike.

4. AMOSTRA - DADOS UTILIZADOS

4.1. Dados Primários

Os dados primários utilizados neste trabalho são das cotações das *commodities* de grãos e do petróleo no mercado internacional. Assim, foram coletados os preços de fechamento semanal das *commodities* arroz, trigo, milho e soja do mercado de grãos da Bolsa de Valores de Chicago. Os dados dos *commodities* de grãos se referem aos preços das cotações dos contratos futuros com o vencimento mais próximo ou, ainda, do primeiro contrato a vencer e do preço do petróleo bruto do tipo Brent. As séries de preço dos grãos selecionados foram coletadas de um terminal da Bloomberg, enquanto os preços do petróleo bruto do tipo Brent foram obtidos no *website* da Agência de Energia do Governo Americano (EIA) e se referem aos preços do mercado à vista. Todos os dados foram coletados em US$ para reduzir o impacto da inflação em diferentes moedas e pela aceitação internacional do dólar norte americano, a principal referência das trocas mundiais.

É importante destacar que há vários tipos de petróleo, cada um com diferentes características específicas dependendo do local de produção. As três principais referências no mercado mundial são o West Texas Intermediate (WTI), o Brent e o Dubai. O primeiro é produzido no West Texas e é negociado no mercado de Nova York sendo seu preço a principal referência no mercado norte americano. O Brent é produzido no Mar do Norte, na Europa, e é negociado em Londres, sendo referência para o mercado europeu e outros mercados ao redor do mundo, incluindo o Brasil. O petróleo Dubai é produzido no Oriente Médio, sendo o preço do petróleo do benchmark para o negociado na Ásia. Nesse estudo, optou-se por utilizar o petróleo do tipo Brent.

Os dados da amostra, compreendem o período de junho de 2009 até novembro de 2019, totalizando uma amostra com 547 observações das cotações de fechamento semanais. Esse período foi escolhido pois se situa entre duas grandes crises mundiais deste século: a crise financeira de 2008, conhecida como crise do *subprime*, e a crise sanitária de 2020, causada pela Pandemia de Covid-19. Dessa maneira, os dados não sofrem o impacto de variações anormais dos períodos de grandes crises.

Os gráficos apresentados na Figura 1 a seguir foram elaborados para facilitar a visualização de padrões de comportamento das séries temporais dos preços coletadas e de possíveis tendências. Se considerarmos todas as séries de dados em uma mesma escala, a ordem de grandeza do preço do petróleo bruto é muito superior às ordens de grandeza das séries de

grãos, dificultando a comparação através da visualização dos dados. Por isso, foram realizados gráficos que possibilitam comparar os preços sob escalas diferentes procurando, dessa forma, melhorar a visualização do comportamento de cada série temporal.

Figura 1: Gráficos dos Preços do Petróleo e dos Grãos - escalas diversas (US$)

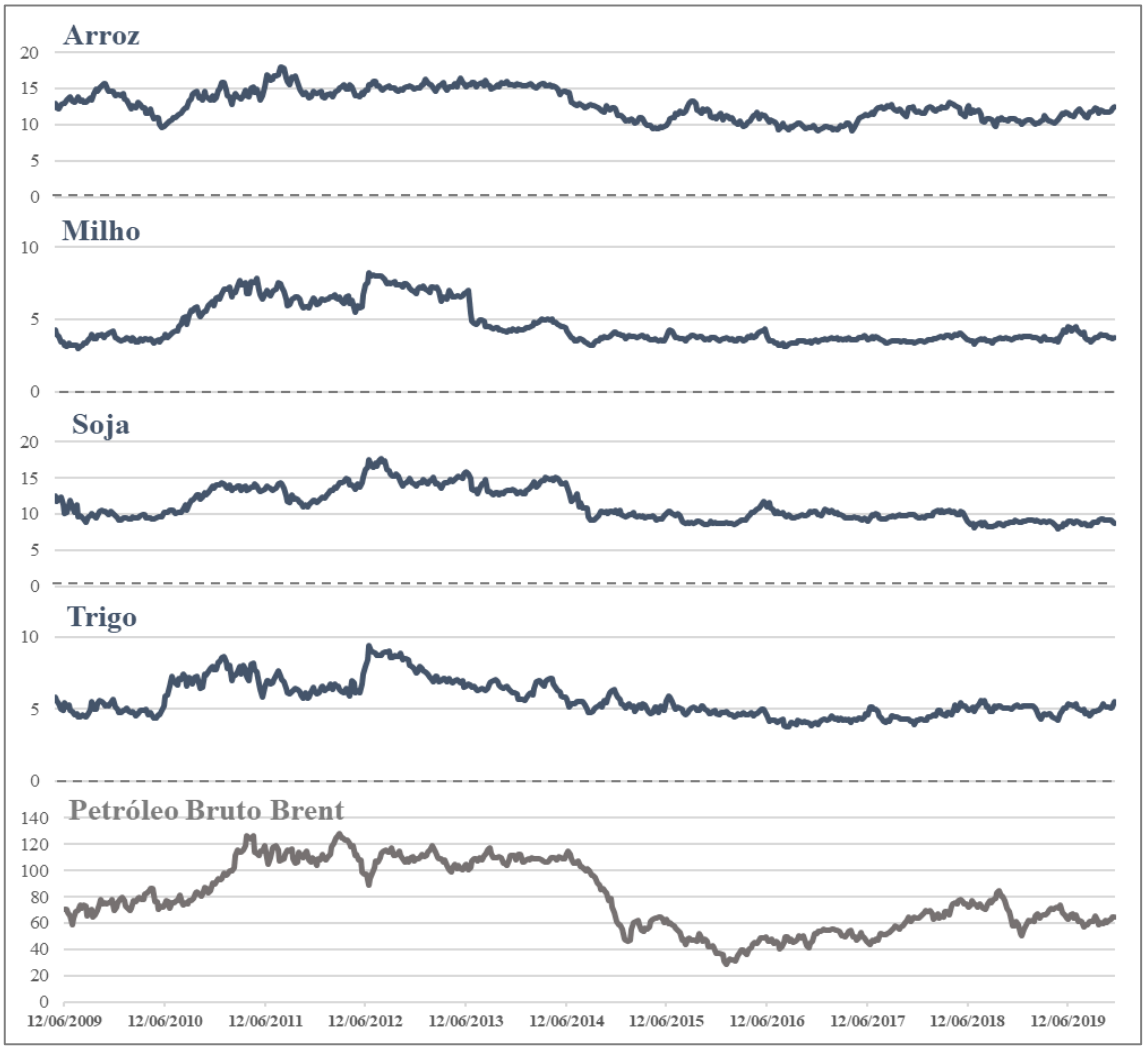

Em geral, as séries temporais possuem variações em direções semelhantes em determinados períodos e as séries de preço das commodities agrícolas aparentam seguir um padrão análogo. Os preços do Big Three, ou seja, do milho, trigo e soja possuem as séries mais semelhantes e é possível notar picos e vales equivalentes como acontece próximo de 12/06/2012 e 12/06/2014. O gráfico da série temporal de preço do Petróleo tipo Brent é o que mais destoa entre eles.

Foram elaborados, também, gráficos dos dados de cada *commodity* agrícola ao lado dos dados do petróleo, possibilitando comparar as variáveis do preço do óleo bruto com o preço de cada uma das *commodities* de grãos selecionados.

Na Figura 2 pode-se observar os gráficos para comparar as séries temporais de preço do arroz e do petróleo bruto do tipo Brent. Nota-se que há momentos em que variações significativas no preço de uma *commodity* não são notadas da mesma forma no preço da outra. Como exemplo, a partir do final de 2009 até meados de 2010, o preço do arroz tem uma queda constante, o que não ocorre com o preço do petróleo, no entanto, a partir de meados de 2010, as duas séries têm em uma tendência crescente. No início de 2012, o petróleo experimenta uma queda acentuada de preços, o que não ocorre com o arroz. O mesmo fenômeno é percebido no preço do petróleo no segundo semestre de 2014 que é acompanhado por uma queda de menor inclinação do preço de arroz.

Figura 2: Gráficos dos Preços do Arroz e do Petróleo - escalas diversas (US$)

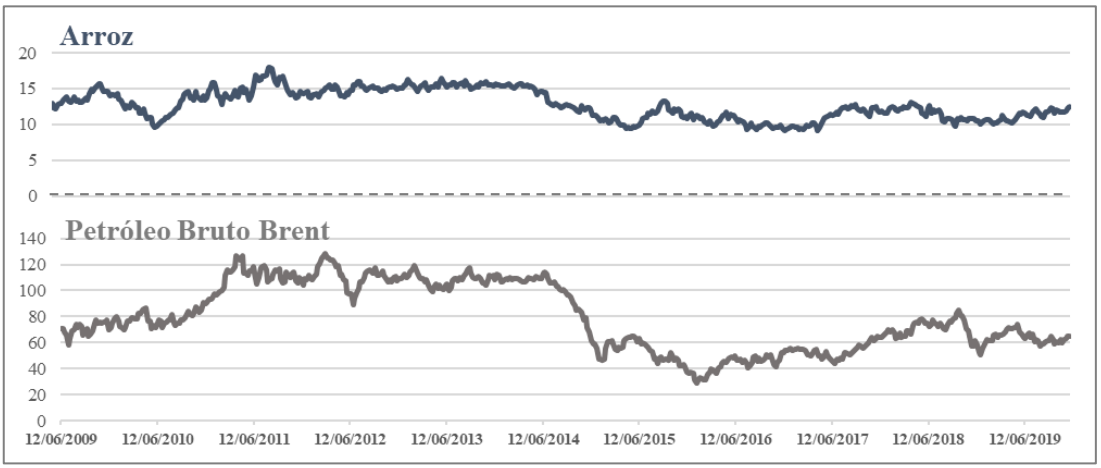

Ao se comparar as séries temporais dos preços do milho e do petróleo bruto do tipo Brent, observam-se momentos em que variações no preço de uma *commodity* são notadas da mesma forma no preço da outra. Pode-se ter, como exemplo, as variações entre os períodos de 2009 e 2011 quando ocorre um movimento de alta para ambos dados e no início de 2014 que ocorre um movimento de queda acentuado e longo para o preço do petróleo e não ocorre da mesma maneira no preço do milho, observado nos gráficos das séries temporais apresentadas na Figura 3.

Figura 3: Gráficos dos Preços do Milho e do Petróleo - escalas diversas (US$)

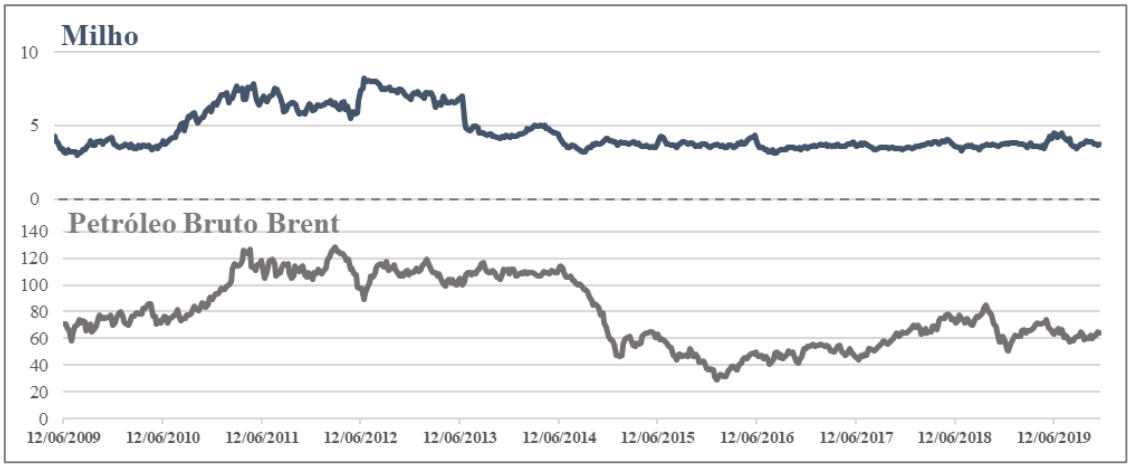

Na Figura 4, os gráficos apresentados possibilitam comparar as séries temporais dos preços da soja e do petróleo bruto do tipo Brent. Nesses gráficos observam-se movimentos análogos entre os anos de 2011 e 2013, há um movimento acentuado de queda no segundo semestre que é mais acentuado e mais longo no preço do petróleo de 2014 e um movimento de subida no primeiro semestre de 2016 nas duas séries temporais que é mais longo para o petróleo, enquanto o preço da soja logo se mantém constante.

Figura 4: Gráficos dos Preços da Soja e do Petróleo - escalas diversas (US$)

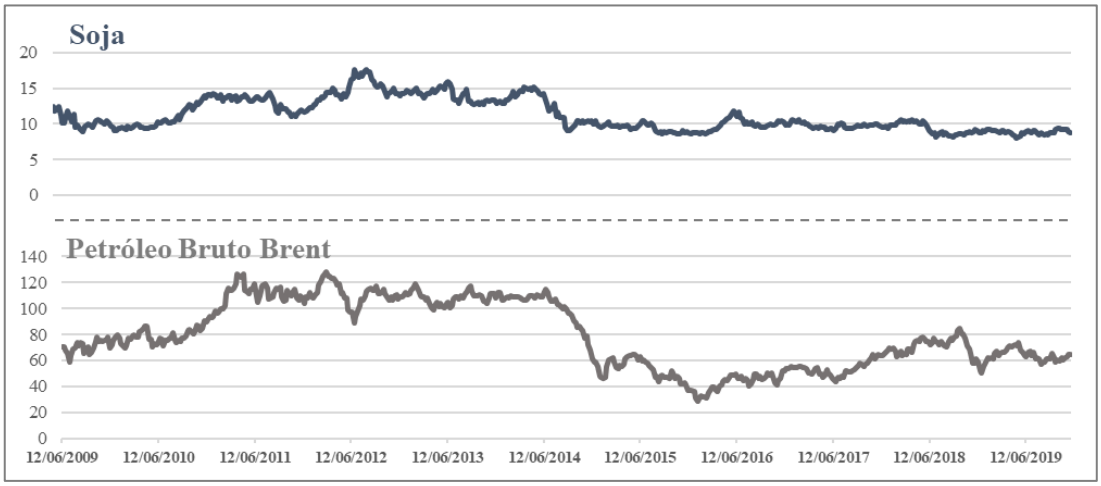

Ao se comparar as séries temporais dos preços do trigo e do petróleo bruto do tipo Brent, nota-se que há momentos em que as variações significativas no preço de uma *commodity* não são notadas da mesma forma no preço da outra. Pode-se observar uma queda acentuada do

preço do petróleo em 2014, a qual não é acompanhada pela série temporal do preço do trigo. A Figura 5 mostra os gráficos das séries temporais dos preços do trigo e do petróleo.

Figura 5: Gráficos dos Preços do Trigo e do Petróleo - escalas diversas (US$)

Os resultados do resumo estatístico das séries de dados estão representados na Tabela 3 a seguir.

Tabela 3: Resumo Estatístico das Séries Temporais de Preço

Medidas Estatísticas	Brent	Milho	Arroz	Soja	Trigo
Média	79,1545	4,5933	12,7825	11,1899	5,6547
Mediana	74,5800	3,8450	12,4150	10,2625	5,1950
Máximo	128,0800	8,2450	18,0600	17,6450	9,4325
Mínimo	28,8000	3,0050	9,1300	7,9700	3,7325
Desvio Padrão	25,5957	1,3930	2,0865	2,2675	1,2453
Assimetria	0,1417	1,0721	0,1601	0,7115	0,8242
Curtose	1,6994	2,6321	1,8592	2,3071	2,8436
Jarque-Bera	40,3852	107,8772	31,9958	57,0928	62,4809
Valor-p	0,0000	0,0000	0,0000	0,0000	0,0000
$\left\lvert \text{Desv. Pad.}/\text{Média} \right\rvert$	0,32	0,30	0,16	0,20	0,22

Ao se comparar os resultados das *commodities* na Tabela 3, pode-se observar que o petróleo bruto possui a maior média de preço seguido pelo arroz, que possui o maior valor dentre as *commodities* de grão, seguido da soja, do trigo e do milho. Essa mesma ordem se aplica para as medianas e para os valores máximos e mínimos o qual se refere a volatilidade ou a dispersão. No que se refere a volatilidade ou a dispersão, o petróleo bruto do tipo Brent possui

o maior valor geral de desvio padrão e a soja possui o maior desvio padrão dentre os grãos, seguida do arroz, do milho e do trigo. Como os dados possuem ordens de grandeza diferentes, o ideal é analisar a dispersão em termos relativos, utilizando o coeficiente de variação, dado pelo desvio padrão dividido pela média. O petróleo bruto do tipo Brent é a série temporal de preço que apresenta maior coeficiente de variação com valor maior que 30% que configura uma série de alta dispersão com dados heterogêneos e é a série com maior volatilidade dentre as séries estudadas. O milho é a variável que apresenta maior valor de coeficiente de variação dentre os grãos, seguido do trigo, da soja e do arroz. Dessa maneira, o milho é o grão cujo preço possui a maior volatilidade no período. A série de dados do arroz possui a distribuição mais homogênea dentre as séries estudadas, porém ainda é maior que 15%, configurando uma série de média dispersão. Além disso, todas as *commodities* possuem assimetria maior do que zero, indicando que a cauda direita da função densidade de probabilidade é maior, com maior concentração de valores acima da média. O petróleo possui o valor da assimetria mais próximo de zero, tendo o comportamento da assimetria mais próxima da distribuição de probabilidade normal. O arroz possui a menor assimetria dentre os grãos, com maior concentração de valores em torno da média. Ademais, todas possuem curtose menor do que 3, indicando que as distribuições são mais achatadas que a distribuição normal. O trigo e o milho são as variáveis com curtose mais próxima de 3, sendo as *commodities* com curtose mais próximas da distribuição normal. Por fim, o teste Jarque-Bera, o qual verifica se as séries se ajustam a uma distribuição normal dado um certo nível de significância e tem a normalidade como hipótese nula mostra que nenhuma das séries temporais de preços se ajustam a uma normal com 95% de confiança, porque possuem valor de teste "Valor-p" menor que 5%. Portanto, não tem aceitação da hipótese de normalidade com 95% de confiança para nenhuma das variáveis estudadas.

4.2. Comportamento do Retorno dos Preços

Neste trabalho, os dados utilizados para construção dos modelos e para inferências necessárias para se atingir os objetivos propostos serão as variações ou retorno dos preços das *commodities* apresentadas. Assim, as variações dos preços ou retornos dos preços para o período *t* designado por R_t foram calculadas da seguinte forma: $ln\ (\frac{Xt}{Xt-1})$ onde Xt é o preço de fechamento da semana no período *t* e X_{t-1} é o preço de fechamento da semana no período *t*-1. O logaritmo do retorno foi escolhido para que se possa trabalhar com a variação geométrica dos dados ou um retorno contínuo. Além disso, como será visto diante neste trabalho, os retornos das séries temporais são estacionários, um pressuposto essencial na construção dos modelos a

serem implementados. Os gráficos na Figura 6 retratam a evolução das séries de retornos dos preços de cada *commodity* selecionada para a realização deste trabalho, tornando possível observar as variações de cada *commodity* em um mesmo intervalo de tempo.

Figura 6: Gráficos dos Retornos das Séries das *commodities*

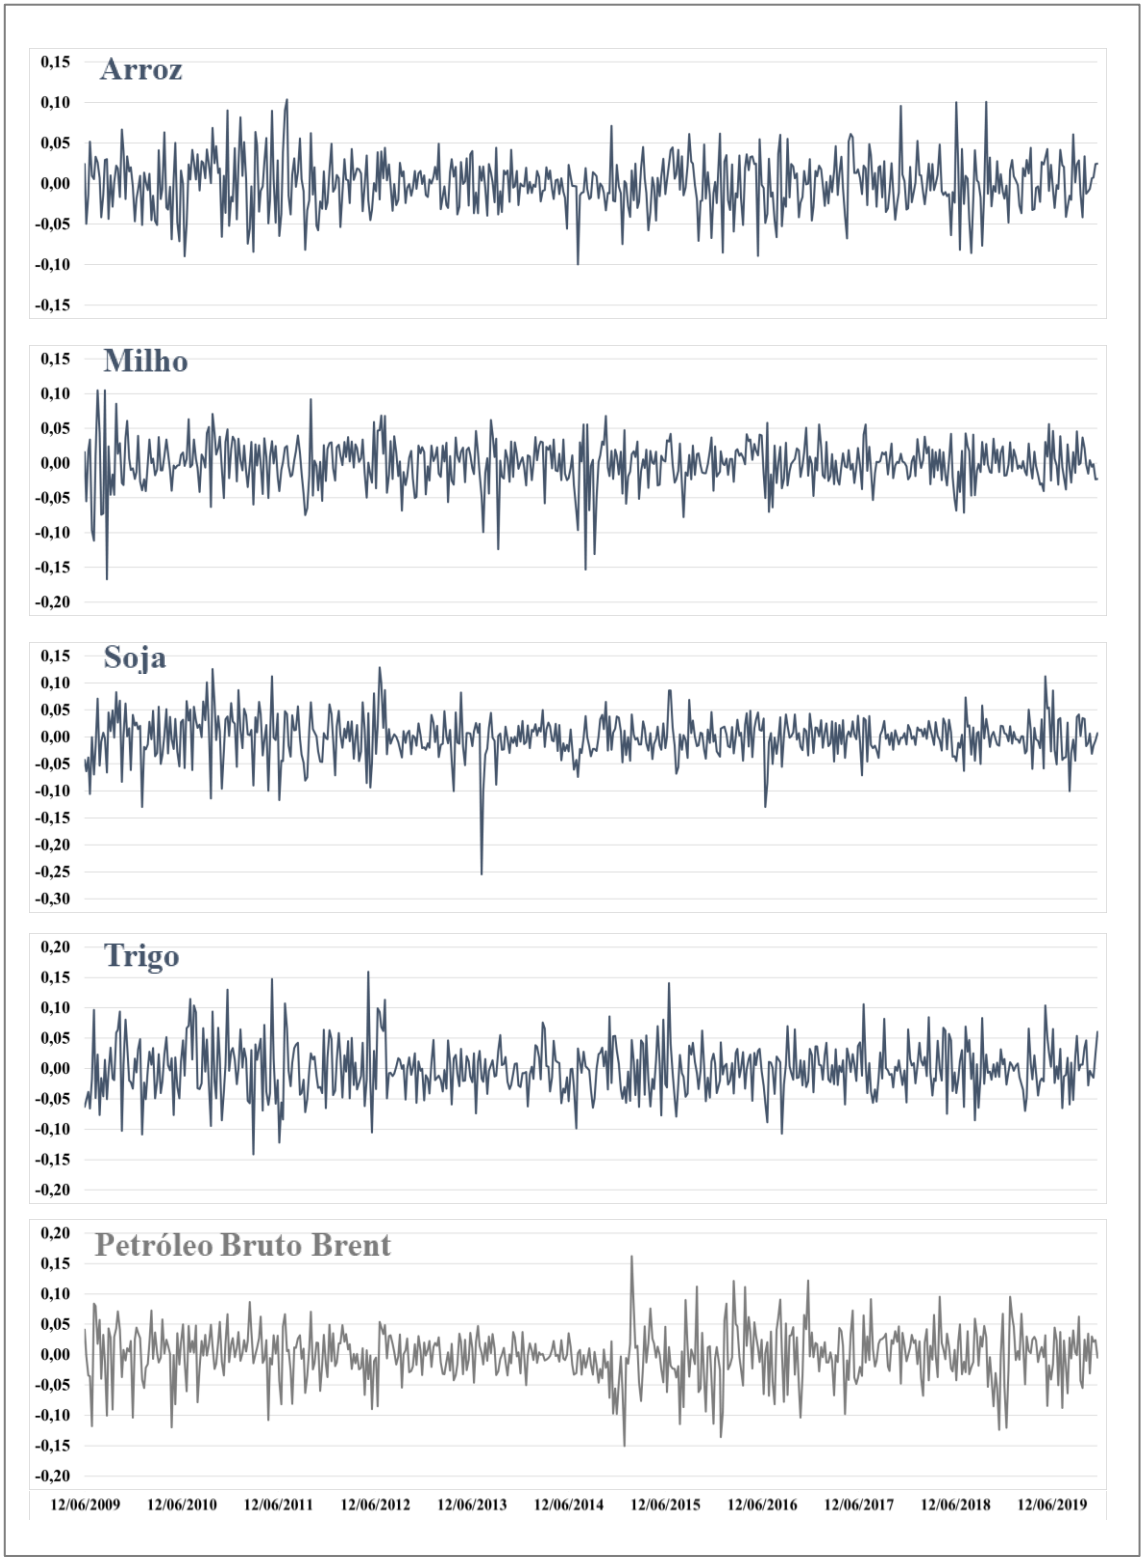

Na Figura 7 são apresentados os histogramas de frequência das séries temporais dos retornos, permitindo observar o formato da distribuição de probabilidade de cada uma dessas séries, ou seja, das séries temporais de retorno dos preços das *commodities* aqui estudadas.

Figura 7: Histogramas das Séries Temporais de Retornos

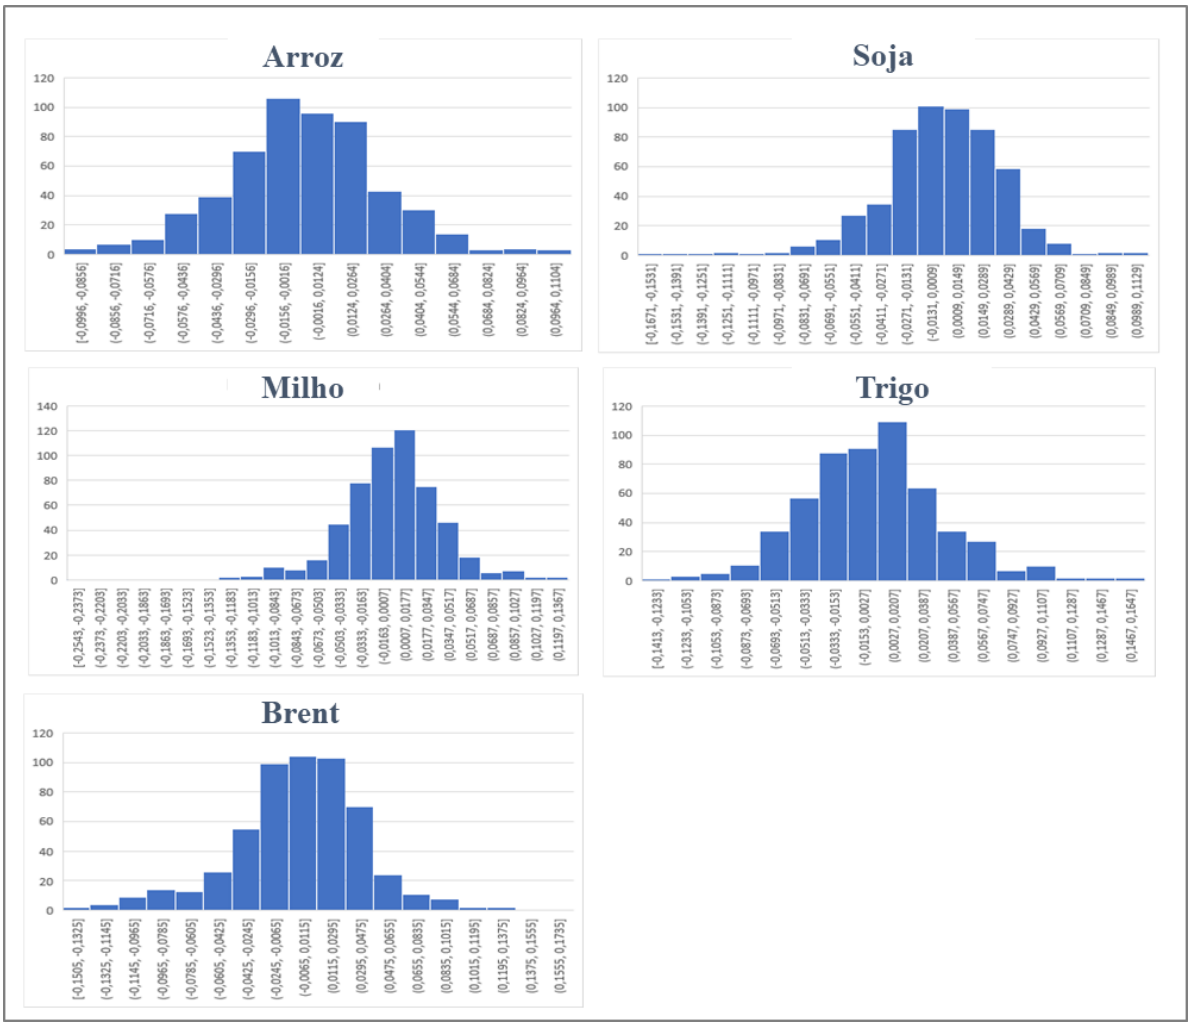

Além dos gráficos mostrados nas Figuras 5, 6 e 7, foram feitas descrições das séries temporais dos retornos utilizando-se medidas resumo de locação e escala, ou seja, de posição e dispersão comumente utilizadas para descrever um conjunto de dados. A seguir, é apresentada a Tabela 4, contendo as medidas resumo e os testes de normalidade de Jarque-Bera (JB) para cada uma das séries temporais utilizadas.

Tabela 4: Resumo Estatístico - Retornos

Medidas Estatísticas	R-Brent	R-Milho	R-Arroz	R-Soja	R-Trigo
Média	-0,0001	-0,0003	0,00002	-0,0006	-0,0002
Mediana	0,0017	0,0011	-0,0003	0,0010	-0,0016
Máximo	0,1621	0,1292	0,1038	0,1050	0,1595
Mínimo	-0,1506	-0,2543	-0,0996	-0,1671	-0,1413
Desvio Padrão	0,0415	0,0388	0,0322	0,0326	0,0420
Assimetria	-0,3130	-0,6076	0,0050	-0,7316	0,3146
Curtose	4,1845	6,9754	3,6248	5,7881	3,8849
Jarque-Bera	40,9060	393,8480	8,8993	225,9774	26,8696
Valor-p	0,0000	0,0000	0,0117	0,0000	0,0000
$\left\lvert \text{Desv. Pad.}/\text{Média} \right\rvert$	415	129	1703	54	21

No que se refere as séries temporais dos retornos dos preços, pode-se observar que o arroz é a única *commodity* com média de retorno positiva. No período, a *commodity* de menor média de retorno é a soja, seguida do milho e do trigo. O petróleo, o milho e a soja possuem medianas positivas, enquanto o arroz e o trigo possuem medianas negativas. Pode-se observar que o petróleo possui o maior valor máximo geral de retorno e o trigo possui o maior valor máximo dentre os grãos, ou seja, em algum momento da série temporal, foram as *commodities* com maior variação positiva de preço entre duas semanas. Por outro lado, o milho possui o menor valor mínimo de retorno. Em algum momento da série temporal, foi a série com maior variação negativa entre duas semanas. Outra observação importante é o fato de o trigo possuir o maior desvio padrão, ou seja, é a *commodity* cujos retornos dos preços possuem maior volatilidade semanal no período selecionado, seguido do petróleo, do milho, da soja e do arroz. O arroz é o item de menor desvio padrão, logo, é o item com menor variação semanal do retorno do preço no período selecionado. Ademais, o petróleo, o milho e a soja possuem assimetria do retorno negativa. Dessa maneira, ambos possuem a cauda à esquerda da função densidade de probabilidade maior, havendo maior concentração de valores abaixo da média. O arroz e trigo, porém, possuem assimetria positiva. Dessa forma, a cauda à direita da função densidade de probabilidade é maior, havendo maior concentração de valores acima da média. O arroz é o item com assimetria do retorno mais próxima de zero, indicando que é a série de retorno com assimetria mais próxima da distribuição normal, com maior concentração de valores de retorno em volta da média. Isso também é possível observar pelo fato do arroz ter o menor desvio padrão, mostrando menor volatidade.

Segundo Murteira (1993), o coeficiente de variação deve ser empregado apenas quando os valores dos dados possuem o mesmo sinal. Esse não é o caso das séries estudadas que, por serem dados das variações de preço, possuem valores acima e abaixo de zero, como é esperado nesse tipo de série temporal. Desse modo, o coeficiente de variação é muito alto visto que o valor do desvio padrão é muito maior que o da média, resultado em um valor de coeficiente de variação muito grande como é visto na Tabela 4. Ainda assim, nota-se que a variabilidade da série de retorno dos preços do arroz é a maior dentre as séries de retorno, seguida da série de retorno dos preços do petróleo, milho, soja e trigo. As séries temporais de retorno para todas as *commodities* possuem curtose maior do que três, indicando que as distribuições dos retornos dos preços das *commodities* são menos achatadas que a distribuição Normal. Por fim, o teste de Jarque-Bera indica que apenas a série temporal de retorno dos preços do arroz se ajusta a uma normal com 10% de confiança, porque possui valor de teste maior que 10% (Valor-p = 0,011683). Nas outras séries estudadas, não se aceita a hipótese de normalidade. É interessante notar que, apesar da aparência dos histogramas de frequências apresentados na Figura 7 possuírem semelhanças com uma distribuição normal, na maioria dos testes de normalidade apresentados não foi aceita a hipótese de normalidade.

4.3 Estacionariedade da Amostra

A Estacionariedade foi testada por meio do teste de raiz unitária (Dickey-Fuller Aumentado - ADF). A hipótese nula é a existência de uma raiz unitária na série. Os resultados obtidos estão representados nas tabelas a seguir. A Tabela 5 apresenta o resultado do teste ADF para as séries de preço das *commodities* e a Tabela 6 apresenta o resultado para os retornos das séries.

Tabela 5: Resultado ADF - Séries Temporais dos Preços

	Brent	**Milho**	**Arroz**	**Soja**	**Trigo**
Estatística t	-2,04	-2,63	-2,57	-2,34	-2,71
Valor p	0,5750	0,2671	0,2927	0,4116	0,2348

Tabela 6: Resultado ADF - Séries Temporais dos Retornos dos Preços

	R-Brent	**R-Milho**	**R-Arroz**	**R-Soja**	**R-Trigo**
Estatística t	-21,42	-10,42	-13,33	-25,01	-8,67
Valor p	0,0000	0,0000	0,0000	0,0000	0,0000

É possível observar que nenhuma das séries simples são estacionárias com 95% de confiança, pois possuem valor-p maior que 0,05. Por isso, não se rejeita a hipótese nula da

existência de uma raiz unitária (hipótese de não estacionariedade). Em relação às séries dos retornos, todas são estacionárias com 95% de confiança. Portanto, não se aceita a hipótese de existência de uma raiz unitária (não estacionariedade) com 95% de confiança, porque o valor p é menor do que 0,05.

4.4 Autocorrelação da Amostra

Para a medição da autocorrelação foi utilizado o teste de Ljung-Box. O cálculo foi realizado com número de *lags* igual a 36 para cada amostra. Para os casos (*lags*) em que o valor-p é menor que 0,01, há autocorrelação.

Em relação às séries de preço das *commodities*, os resultados encontrados para as séries do petróleo, do arroz, da soja, do trigo e do milho indicam que há autocorrelação em todos os *lags* de 1 a 36, pois todos os valores-p são menores que 0,01. A Tabela 7 a seguir apresenta o detalhamento dos resultados do teste de autocorrelação.

Ao se analisar a autocorrelação das séries de retorno dos preços, os resultados encontrados para os retornos dos preços do arroz, da soja e do trigo indicam que as séries não são autocorrelacionadas em todos os *lags* de 1 a 36. No caso do retorno do preço do milho, há autocorrelação para certas defasagens e para outras não. Apenas os *lags* 1, 2, 3, 4, 16, 18, 26, 32, 33, 34, 35 e 36 possuem valor-p maior que 0,01. Em relação aos retornos do preço do petróleo Brent, todos os valores-p são maiores que 0,01, indicando que não há autocorrelação em todos os *lags* de 1 a 36. A Tabela 8 apresenta o detalhamento dos resultados do teste de autocorrelação para as séries de retorno.

Tabela 7: Resultados do Teste de Autocorrelação - Preços

	Brent		Arroz		Soja		Trigo		Milho	
LAG	**Q-Stat**	**Prob**	**Q-Stat**	**Prob**	**Q-Stat**	**Prob**	**Q-Stat**	**Prob**	**Q-Stat**	**Prob**
1	542.29	0.000	528.77	0.000	533.14	0.000	528.10	0.000	538.29	0.000
2	1077.0	0.000	1035.9	0.000	1052.8	0.000	1034.6	0.000	1064.8	0.000
3	1604.2	0.000	1525.5	0.000	1558.5	0.000	1522.1	0.000	1580.4	0.000
4	2123.9	0.000	2000.3	0.000	2051.0	0.000	1990.3	0.000	2083.4	0.000
5	2636.3	0.000	2463.5	0.000	2531.6	0.000	2442.4	0.000	2576.9	0.000
6	3141.4	0.000	2916.9	0.000	3001.3	0.000	2882.1	0.000	3064.8	0.000
7	3638.2	0.000	3357.7	0.000	3459.3	0.000	3308.6	0.000	3544.9	0.000
8	4126.2	0.000	3786.3	0.000	3904.7	0.000	3721.0	0.000	4016.0	0.000
9	4605.3	0.000	4200.8	0.000	4335.8	0.000	4118.0	0.000	4477.1	0.000
10	5076.2	0.000	4598.3	0.000	4753.2	0.000	4499.3	0.000	4926.7	0.000
11	5540.4	0.000	4982.7	0.000	5157.2	0.000	4870.3	0.000	5365.8	0.000
12	5998.0	0.000	5354.2	0.000	5547.1	0.000	5232.5	0.000	5795.5	0.000
13	6449.4	0.000	5713.3	0.000	5925.2	0.000	5586.6	0.000	6217.3	0.000
14	6894.5	0.000	6061.8	0.000	6291.9	0.000	5932.3	0.000	6632.1	0.000
15	7333.3	0.000	6399.8	0.000	6647.1	0.000	6270.3	0.000	7038.7	0.000
16	7765.5	0.000	6724.9	0.000	6991.9	0.000	6601.9	0.000	7436.6	0.000
17	8192.5	0.000	7036.7	0.000	7327.0	0.000	6926.3	0.000	7826.3	0.000
18	8614.7	0.000	7334.7	0.000	7652.3	0.000	7240.6	0.000	8206.8	0.000
19	9031.7	0.000	7621.6	0.000	7967.7	0.000	7545.3	0.000	8578.6	0.000
20	9444.4	0.000	7899.6	0.000	8275.2	0.000	7844.3	0.000	8943.2	0.000
21	9852.7	0.000	8168.1	0.000	8574.6	0.000	8134.9	0.000	9300.3	0.000
22	10256.	0.000	8429.3	0.000	8866.2	0.000	8417.3	0.000	9649.4	0.000
23	10655.	0.000	8686.1	0.000	9150.6	0.000	8692.0	0.000	9990.8	0.000
24	11047.	0.000	8937.8	0.000	9428.6	0.000	8959.4	0.000	10324.	0.000
25	11434.	0.000	9183.6	0.000	9699.7	0.000	9218.4	0.000	10649.	0.000
26	11814.	0.000	9423.1	0.000	9964.0	0.000	9468.1	0.000	10967.	0.000
27	12188.	0.000	9655.9	0.000	10222.	0.000	9711.0	0.000	11279.	0.000
28	12557.	0.000	9883.2	0.000	10473.	0.000	9950.0	0.000	11585.	0.000
29	12920.	0.000	10105.	0.000	10716.	0.000	10183.	0.000	11884.	0.000
30	13277.	0.000	10322.	0.000	10953.	0.000	10407.	0.000	12175.	0.000
31	13628.	0.000	10535.	0.000	11184.	0.000	10622.	0.000	12457.	0.000
32	13974.	0.000	10744.	0.000	11410.	0.000	10828.	0.000	12730.	0.000
33	14313.	0.000	10948.	0.000	11631.	0.000	11024.	0.000	12994.	0.000
34	14648.	0.000	11147.	0.000	11848.	0.000	11215.	0.000	13251.	0.000
35	14977.	0.000	11346.	0.000	12060.	0.000	11401.	0.000	13502.	0.000
36	15301.	0.000	11543.	0.000	12268.	0.000	11583.	0.000	13746.	0.000

Tabela 8: Resultados do Teste de Autocorrelação - Retornos

	R-Brent		R-Arroz		R-Soja		R-Trigo		R-Milho	
LAG	**Q-Stat**	**Prob**	**Q-Stat**	**Prob**	**Q-Stat**	**Prob**	**Q-Stat**	**Prob**	**Q-Stat**	**Prob**
1	39.658	0.046	0.9369	0.333	27.578	0.097	0.2926	0.589	0.4645	0.496
2	44.055	0.110	63837	0.041	29.584	0.228	15.299	0.465	0.4750	0.789
3	45.045	0.212	78499	0.049	34.665	0.325	16.443	0.649	40.982	0.251
4	50.113	0.286	10198	0.037	35.240	0.474	39.893	0.407	69.558	0.138
5	54.255	0.366	10506	0.062	40.324	0.545	74.434	0.190	20.007	0.001
6	78.498	0.249	13511	0.036	43.588	0.628	81.644	0.226	22.997	0.001
7	80.419	0.329	13646	0.058	44.124	0.731	84.276	0.296	24.101	0.001
8	92.855	0.319	14647	0.066	52.046	0.736	91.205	0.332	24.665	0.002
9	10.479	0.313	18006	0.035	54.455	0.794	92.136	0.418	26.643	0.002
10	11.271	0.337	20081	0.028	57.722	0.834	18.013	0.055	26.767	0.003
11	11.271	0.421	20081	0.044	64.401	0.842	18.658	0.068	27.565	0.004
12	11.698	0.470	20387	0.060	86.065	0.736	18.662	0.097	30.460	0.002
13	12.138	0.516	21354	0.066	88.120	0.787	18.688	0.133	31.032	0.003
14	12.435	0.571	21559	0.088	88.122	0.843	19.160	0.159	31.153	0.005
15	12.474	0.643	24063	0.064	91.974	0.867	20.133	0.167	31.525	0.007
16	15.988	0.454	24211	0.085	92.006	0.905	20.176	0.212	31.603	0.011
17	16.974	0.456	25160	0.091	92.062	0.934	25.236	0.090	34.265	0.008
18	16.980	0.524	27318	0.073	92.903	0.953	25.725	0.106	34.600	0.011
19	18.872	0.465	29407	0.060	12.630	0.857	31.437	0.036	37.634	0.007
20	18.928	0.526	29608	0.076	12.715	0.889	35.084	0.020	39.749	0.005
21	19.090	0.579	31868	0.060	12.885	0.913	35.085	0.028	39.791	0.008
22	19.346	0.624	36655	0.026	13.091	0.931	35.350	0.036	40.659	0.009
23	23.604	0.426	36918	0.033	14.102	0.924	35.392	0.048	41.936	0.009
24	23.968	0.463	36957	0.044	14.864	0.925	36.268	0.052	43.520	0.009
25	23.981	0.520	37203	0.055	15.594	0.926	36.775	0.061	44.670	0.009
26	26.911	0.414	37738	0.064	15.614	0.945	38.174	0.058	44.743	0.013
27	27.167	0.455	38313	0.073	17.113	0.928	42.455	0.030	47.489	0.009
28	27.704	0.480	38479	0.090	17.228	0.944	43.838	0.029	49.152	0.008
29	27.954	0.520	38659	0.108	17.239	0.958	44.921	0.030	51.240	0.007
30	27.955	0.573	41407	0.080	18.576	0.948	45.600	0.034	51.280	0.009
31	28.289	0.606	41477	0.099	19.159	0.952	45.904	0.041	52.484	0.009
32	30.051	0.566	41698	0.117	19.711	0.956	46.602	0.046	52.789	0.012
33	30.204	0.607	42302	0.129	19.944	0.964	53.879	0.012	54.213	0.011
34	30.920	0.619	45196	0.095	20.343	0.969	54.915	0.013	54.373	0.015
35	30.967	0.663	45686	0.107	20.399	0.977	56.102	0.013	54.832	0.018
36	31.979	0.660	45696	0.129	20.837	0.980	56.304	0.017	54.832	0.023

5. ANÁLISE DOS RESULTADOS OBTIDOS

Neste capítulo são apresentados os resultados dos testes de cointegração da série de retorno do preço do petróleo bruto com as séries de retorno das *commodities* agrícolas, os modelos vetoriais autorregressivos estimados para esses conjuntos de dados e as análises das funções impulso resposta e das decomposições da variância desses modelos estimados.

5.1. Teste de Cointegração

A cointegração foi testada individualmente entre o retorno do preço de cada *commodity* agrícola e o retorno do preço do petróleo bruto do tipo Brent. Nos quatro casos analisados, pode-se concluir que há relação de cointegração entre as séries de dados com 5% de significância. Os resultados completos se encontram no Apêndice A. Ou seja, existe relação de cointegração do retorno do preço do petróleo com os retornos dos preços dos quatro grãos estudados, confirmando que existe relação de longo prazo entre elas.

5.2. Resultados dos Modelos Vetoriais Autorregressivos

Já que as séries estudadas são cointegradas, foram elaborados modelos autorregressivos com correção de erros. A Tabela 10 apresenta o resultado dos quatro modelos VECM. São apresentadas as estimativas dos parâmetros e seus respectivos testes de significância analisados individualmente. Serão analisados os resultados dos testes de significância antes e, em seguida, os efeitos das estimativas para cada um dos quatro casos. No primeiro momento, o *lag* ótimo foi estimado através do critério AIC porém, em todos os casos, pelo menos um dos parâmetros dos modelos estimados não foi significativo. Por isso, a fim de selecionar os modelos em que todas as variáveis fossem explicativas, foi decidido utilizar *lag* = 1, maximizando a estatística F dos modelos, minimizando a soma dos erros quadrados e obtendo quase todos os parâmetros significativos, como apresentado na Tabela 10.

A Tabela 10 apresenta os valores dos coeficientes das equações (escritas com mais detalhes a seguir) e o valor da estatística de teste, utilizada para medir se os parâmetros estimados são significativos. Cada coluna “Milho”, “Arroz, “Soja” e “Trigo” representa as estimações entre a respectiva *commodity* agrícola e o petróleo bruto do tipo Brent, sendo dividida em duas equações: uma tendo o petróleo como variável dependente e uma tendo o grão como variável dependente.

Tabela 9: Resultado das Estimativas dos Parâmetros dos Modelos VECM

		MILHO		ARROZ		SOJA		TRIGO	
		D(R-Brent)	D(R-Milho)	D(R-Brent)	D(R-Arroz)	D(R-Brent)	D(R-Soja)	D(R-Brent)	D(R-Trigo)
CointEq (ECM)	**Coeficiente**	**-0,3163**	**-0,4117**	**-0,0812**	**-0,1685**	**-0,1016**	**0,3426**	**-0,2339**	**-0,4156**
	t-statistic	[-8,9444]	[-13,2296]	[-5,3858]	[-17,0723]	[-3,0075]	[15,2107]	[-7,7695]	[-15,1490]
D(R-Brent(-1)	**Coeficiente**	**-0,2700**	**0,2527**	**-0,4044**	**0,1451**	**-0,3850**	**-0,1258**	**-0,3155**	**0,2781**
	t-statistic	[-6,6776]	[7,1028]	[-10,5802]	[5,7949]	[-9,0403]	[-4,4285]	[-7,9285]	[7,6680]
D(R-Grão(-1))	**Coeficiente**	**0,3581**	**-0,1818**	**0,2454**	**0,0537**	**-0,1257**	**-0,0624**	**0,3061**	**-0,0811**
	t-statistic	[7,9030]	[-4,5598]	[3,8090]	[1,2736]	[-1,9028]	[-1,4167]	[6,8462]	[-1,9905]
	R-squared	0,3084	0,4220	0,2328	0,4738	0,2052	0,5086	0,2805	0,4511
	F-statistic	**120,8414**	**197,8256**	**82,2482**	**243,9808**	**69,9699**	**280,5348**	**105,6621**	**222,7252**

Dessa forma, como visto na Tabela 10, os parâmetros dos modelos estimados indicam a influência, ou a relevância de uma variável sobre a outra em cada um dos modelos estimados. A primeira partição da Tabela 10 apresenta o coeficiente estimado do mecanismo de correção de erro ("CointEq"). A segunda partição da Tabela 10 mostra o coeficiente estimado da variável defasada (*t-1*) do retorno do preço do petróleo Brent ("D(R-Brent(-1))") que representa a influência dessa variável nas variáveis de Brent(t) e de cada uma das *commodities* de grão no período *t* nos modelos estimados. Na partição final da tabela ("D(R-Grão(-1))") tem-se o coeficiente estimado da variável defasada (*t-1*) de cada uma das *commodities* de grão ("D(R-Grão(-1))") que, por sua vez, representa a influência dessas variáveis nas variáveis de Brent(t) e de cada uma das *commodity* de grão no período *t* nos modelos estimados. Por exemplo, no modelo estimado do milho, um aumento de uma unidade no retorno do preço do petróleo Brent no período *t-1* representa uma variação de -0,27 no retorno do preço do preço do Brent no período *t*, enquanto o aumento de uma unidade no retorno do preço do petróleo Brent no período *t-1* representa uma variação de 0,25 no retorno do preço do preço do milho no período *t*.

A seguir são apresentadas as equações por extenso dos modelos VECM estimados, sendo Y_t o retorno do preço do petróleo Brent no período *t*, Z_{gt} o retorno do preço de cada *commodity* de grão no período *t* sendo *g* um valor de 1 a 4, que corresponde respectivamente a milho, arroz, soja e trigo e ECM é a correção de erro.

1. Modelo VECM - Petróleo e Milho:

$$Y_t = -0{,}32 \times (\text{ECM}) - 0{,}27 \times Y_{t-1} + 0{,}36 \times Z_{1,t-1}$$
$$Z_{1,t} = -0{,}41 \times (\text{ECM}) + 0{,}25 \times Y_{t-1} - 0{,}19 \times Z_{1,t-1}$$

2. Modelo VECM - Petróleo e Arroz:

$$Y_t = -0{,}08 \times (\text{ECM}) - 0{,}40 \times Y_{t-1} + 0{,}25 \times Z_{2,t-1}$$
$$Z_{2,t} = -0{,}16 \times (\text{ECM}) + 0{,}15 \times Y_{t-1} + 0{,}05 \times Z_{2,t-1}$$

3. Modelo VECM - Petróleo e Soja:

$$Y_t = -0{,}10 \times (\text{ECM}) - 0{,}39 \times Y_{t-1} - 0{,}13 \times Z_{3,t-1}$$
$$Z_{3,t} = -0{,}34 \times (\text{ECM}) + 0{,}13 \times Y_{t-1} - 0{,}06 \times Z_{3,t-1}$$

4. Modelo VECM - Petróleo e Trigo:

$$Y_t = -0{,}44 \times (\text{ECM}) + 0{,}31 \times Y_{t-1} - 0{,}32 \times Z_{4,t-1}$$
$$Z_{4,t} = -0{,}78 \times (\text{ECM}) + 0{,}08 \times Y_{t-1} + 0{,}28 \times Z_{4,t-1}$$

Como foi observado previamente, as variáveis de grão são cointegradas com o preço do petróleo, logo, compartilham as mesmas propriedades estocásticas ao longo prazo. Observa-se que quase todos os parâmetros estimados nos modelos são significativos com 95% de probabilidade visto que o módulo do valor t (apresentado no gráfico como *t-statistic*) é maior que 1,96 exceto nos seguintes casos: (1) parâmetro da regressão de soja para soja, cujo valor t é -1,41669, significativo com 80% de probabilidade; (2) parâmetro do retorno da soja em *t-1* para explicação do retorno do Brent, cujo valor é -1,9028, significativo com 90% de confiança e (3) parâmetro de arroz para arroz cujo valor t é 1,2735, não significativo com nível de confiança maior que 80%. Como pode-se observar na Tabela 10, as estatísticas F de todos os modelos possuem ordem de grandeza grande o suficiente para garantir que todos os parâmetros são conjuntamente diferentes de 0, o que aponta que os modelos são significativos. Como mostra Salles (2020), segundo o teste de causalidade de Granger, a aceitação da estatística F aponta para a não rejeição da causalidade bidimensional das variáveis nos modelos que

relacionam o retorno do preço do petróleo com o retorno do preço das commodities de milho, arroz, soja e trigo e, deste modo, infere-se que existe interação no curto e no longo prazo entre as variáveis estudadas.

Ainda sobre os modelos estimados, observa-se que o modelo de estimação do retorno no preço da soja ("D(R-Soja)") possui o maior $\overline{R^2}$ que indica que o modelo explica 50% do comportamento da série temporal estudada, enquanto o menor $\overline{R^2}$ é do modelo que explica o retorno do preço do petróleo a partir da soja, explicando cerca de 20% das variações da série. É interessante notar, também, que o $\overline{R^2}$ nos 4 Modelos VECM estimados é maior nos modelos que explicam a variação do preço dos *commodities* de grão ($42\% < \overline{R^2} < 51\%$) do que nos modelos que explicam a variação do preço do petróleo Brent ($20\% < \overline{R^2} < 29\%$).

No que se refere ao sinal dos coeficientes estimados, nota-se que no Modelo 1 a relação entre as variáveis de retorno do preço de petróleo e do milho é positiva enquanto o impacto entre as próprias variáveis e a sua defasagem é negativo. Isto é, quando o preço do petróleo sobe no período *t-1*, o preço do milho no período *t* também sobe e, por sua vez, o preço do petróleo diminui no período *t*. No Modelo 2, nota-se que existe a mesma relação de sinais entre as variáveis exceto na influência da defasagem do retorno do preço do arroz com ele mesmo que, nesse caso, é positivo. É interessante notar que a unidade de grandeza do coeficiente dessa relação (10^{-2}) é menor do que a dos demais parâmetros estimados (10^{-1}). Ou seja, uma variação positiva no preço do arroz no período *t-1* causa um aumento menor no preço do arroz no período *t*. O Modelo 3 se assemelha com o Modelo 2, inclusive na unidade de grandeza do coeficiente da influência da defasagem do retorno do preço da soja sobre ela mesmo no período vigente, porém, nesse caso, o retorno do preço da soja no período *t-1* impacta negativamente no retorno do preço do petróleo no período *t*. No Modelo 4, todas as variáveis se impactam de forma positiva exceto a defasagem do retorno do preço do trigo que impacta negativamente o retorno do preço do petróleo no período *t*.

5.3. Resultado da Função Impulso Resposta

As funções impulso resposta são performadas a fim de analisar como o choque de uma variável em um instante do tempo persistirá nos períodos futuros, ou seja, trata-se de um efeito não contemporâneo. Foi considerado o período de estimativa de 10 semanas e os resultados da estimação da função impulso resposta para cada uma das séries temporais do retorno (variação)

dos preços das *comodities* de grãos estudadas e o retorno (variação) do preço do petróleo Brent estão apresentados a seguir nas figuras 8A e 8B.

Figura 8A: Gráficos resultados das Funções Impulso Resposta

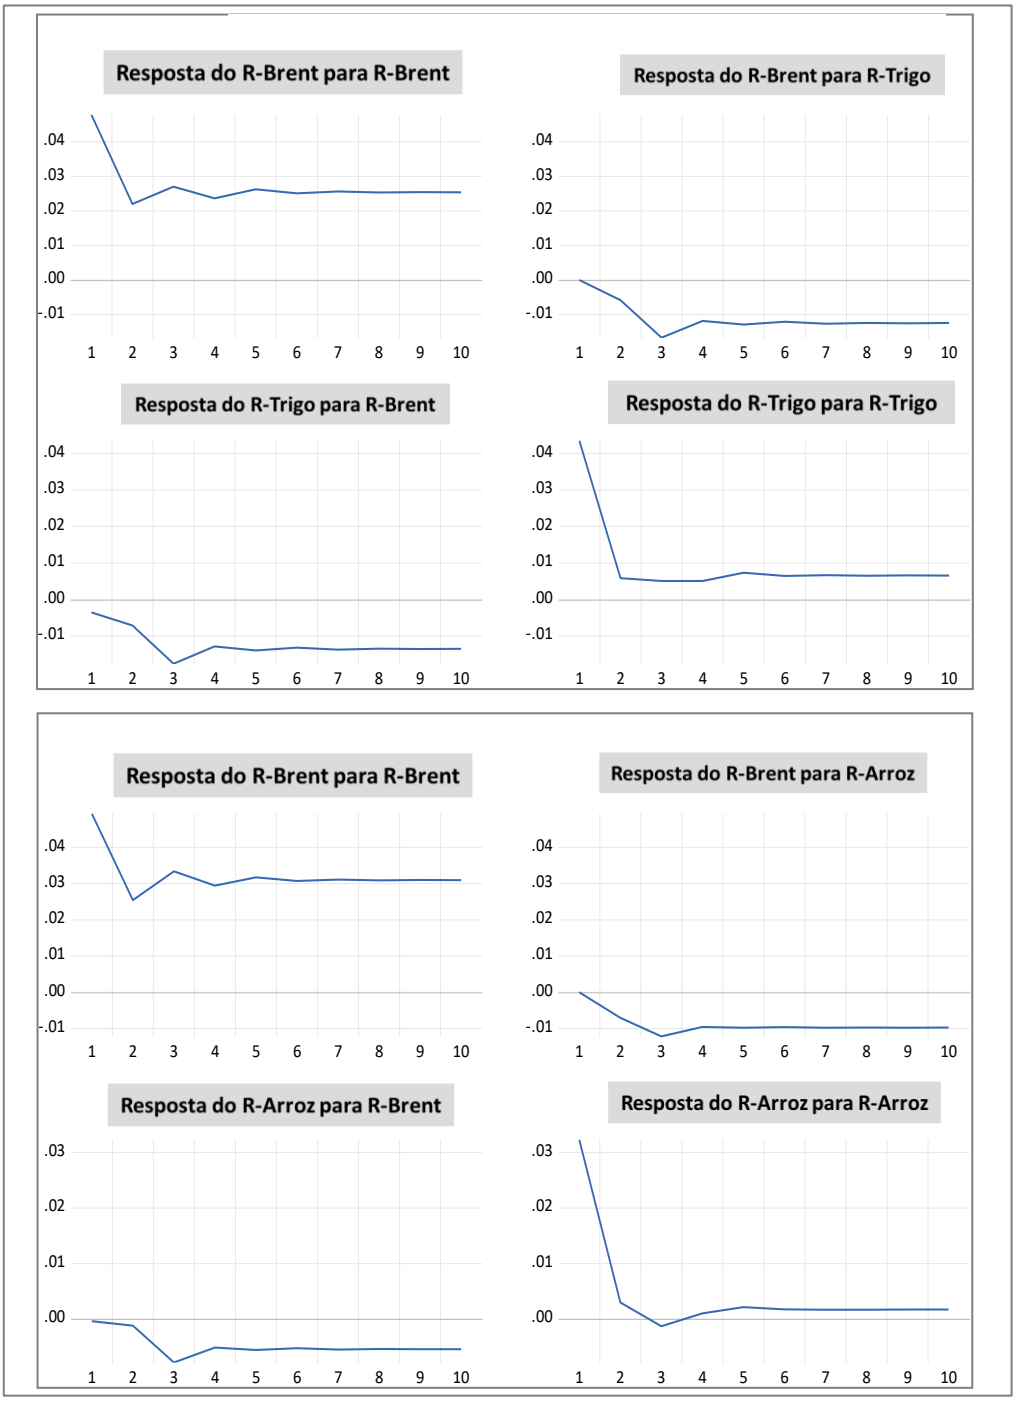

Figura 8B: Gráficos resultados das Funções Impulso Resposta

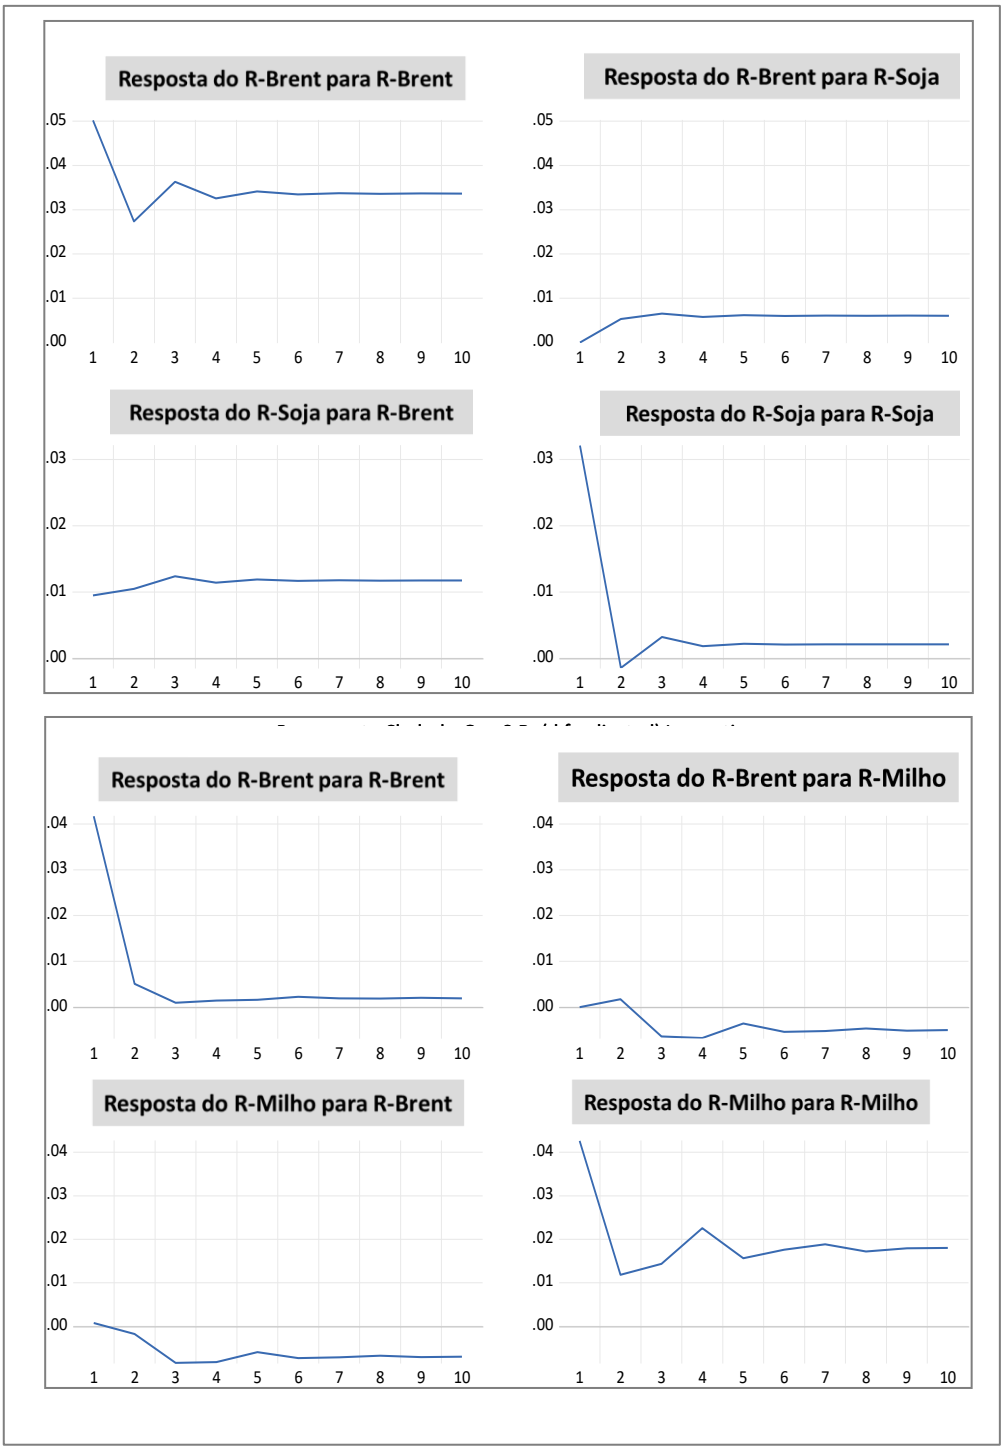

As tabelas dos resultados de impulso resposta para 10 semanas podem ser observadas na Tabela 11.

Tabela 10: Tabela Resultado da Função Impulso Resposta

	Modelo Petróleo e Trigo				Modelo Petróleo e Arroz			
	Resposta do R-Brent:		Resposta do R-Trigo:		Resposta do R-Brent:		Resposta do R-Arroz:	
Período	R-Brent	R-Trigo	R-Brent	R-Trigo	R-Brent	R-Arroz	R-Brent	R-Arroz
1	0,0478	0,0000	0,0035	0,0434	0,0493	0,0000	0,0004	0,0323
2	0,0220	-0,0059	0,0070	0,0059	0,0255	0,0070	0,0012	0,0030
3	0,0270	0,0167	0,0175	0,0051	0,0334	0,0122	0,0078	0,0013
4	0,0236	0,0119	-0,0128	0,0051	0,0295	0,0096	0,0051	0,0010
5	0,0263	0,0129	0,0139	0,0074	0,0317	-0,0098	0,0056	0,0022
6	0,0251	0,0121	0,0131	0,0065	0,0307	0,0096	0,0053	0,0018
7	0,0256	0,0126	0,0137	0,0067	0,0311	0,0098	0,0055	0,0017
8	0,0253	0,0124	0,0134	0,0065	0,0309	0,0097	-0,0054	0,0017
9	0,0255	0,0125	0,0135	0,0067	0,0310	0,0098	0,0054	0,0017
10	0,0254	0,0125	0,0135	0,0066	0,0310	0,0097	0,0054	0,0017

	Modelo Petróleo e Soja				Modelo Petróleo e Milho			
	Resposta do R-Brent:		Resposta do R-Soja:		Resposta do R-Brent:		Resposta do R-Milho:	
Período	R-Brent	R-Soja	R-Brent	R-Soja	R-Brent	R-Milho	R-Brent	R-Milho
1	0,0502	0,0000	0,0095	0,0321	0,0468	0,0000	0,0035	0,0411
2	0,0274	0,0053	0,0105	0,0014	0,0198	0,0051	0,0081	0,0079
3	0,0363	0,0065	0,0124	0,0032	0,0231	0,0178	0,0172	0,0098
4	0,0325	0,0058	0,0114	0,0019	0,0199	0,0127	0,0134	0,0074
5	0,0341	0,0062	0,0119	0,0022	0,0223	0,0145	0,0147	0,0097
6	0,0334	0,0060	0,0117	0,0021	0,0212	0,0133	0,0138	0,0087
7	0,0337	0,0061	0,0118	0,0021	0,0218	0,0140	-0,0143	0,0092
8	0,0336	0,0060	0,0117	0,0021	0,0215	0,0136	0,0141	0,0089
9	0,0337	0,0060	0,0117	0,0021	0,0216	0,0138	0,0142	0,0091
10	0,0336	0,0060	0,0117	0,0021	0,0215	-0,0137	0,0141	0,0090

Pode ser observado que a resposta dos retornos dos preços do petróleo (R-Brent) para impactos nas variáveis de *commodities* agrícolas em todos os casos é muito próximo a 0,01. A resposta do retorno do preço do petróleo em relação a esta própria série temporal, para todos os casos, é positiva e maior no primeiro período e decresce no segundo, mantendo-se constante em um valor positivo muito pequeno, exceto no modelo do retorno do preço do milho (R-Milho), no qual a resposta decresce para aproximadamente 0 a partir do terceiro momento. Para os retornos dos preços do milho, trigo (R-Trigo) e arroz (R-Trigo) a resposta das *commodities* agrícolas para o impacto do retorno do preço do Brent é muito similar sendo aproximadamente nula no primeiro período e ligeiramente negativa e constante a partir do segundo. Para o retorno

do preço da soja (R-Soja), a resposta é constantemente positiva em um valor muito pequeno (0,01). A resposta dos retornos das variáveis agrícolas em relação às suas próprias séries no caso do arroz e da soja é positiva e maior no primeiro período e reduz para próximo de zero a partir do segundo, mantendo-se constante a partir do quinto. Para o retorno do preço do trigo, o impacto é positivo e maior no primeiro período e reduz para um valor muito pequeno, mantendo-se constante. Para o retorno do preço do milho, o impacto é maior no primeiro período, e mantem-se constante aproximadamente a partir do quinto período.

5.4 Resultado da Decomposição da Variância

A metodologia de decomposição de variância sugerida por Pesaran e Shin (1998) é empregada para determinar a proporção da variância do erro de previsão de X períodos a frente de uma variável que é explicada pela sua própria defasagem como também pelas defasagens de outras variáveis explanatórias no sistema.

Notou-se que o resultado da decomposição da variância para as séries estudadas varia muito do curto para o longo prazo e, por isso, após observar a diferença dos gráficos de curto prazo e longo prazo, escolheu-se analisar o período de longo prazo equivalente a um ano, ou seja, 52 semanas. Os gráficos com os resultados de decomposição da variância do retorno dos preços das *commodities* de grãos relacionadas aos retornos dos preços do petróleo estão apresentados para o curto prazo (10 semanas) na Figura 9A e Figura 9B e para o longo prazo (52 semanas) na Figura 10A e Figura 10B com os resultados das decomposições da variância obtidos através da estimação dos quatro modelos VECM. Sendo A e B duas das variáveis estudadas, nos gráficos o valor percentual da variância de A devido a B são apresentados no eixo y enquanto o eixo x apresenta o número de períodos a frente. Ao escrever “Percentual do R-Brent devido ao R-Trigo”, por exemplo, o gráfico retrata o percentual da variância do retorno do Brent devido ao retorno do trigo.

As tabelas dos resultados da decomposição da variância para as 52 semanas podem ser observadas no Apêndice B.

Figura 9A: Gráficos da Decomposição de Variância - 10 semanas

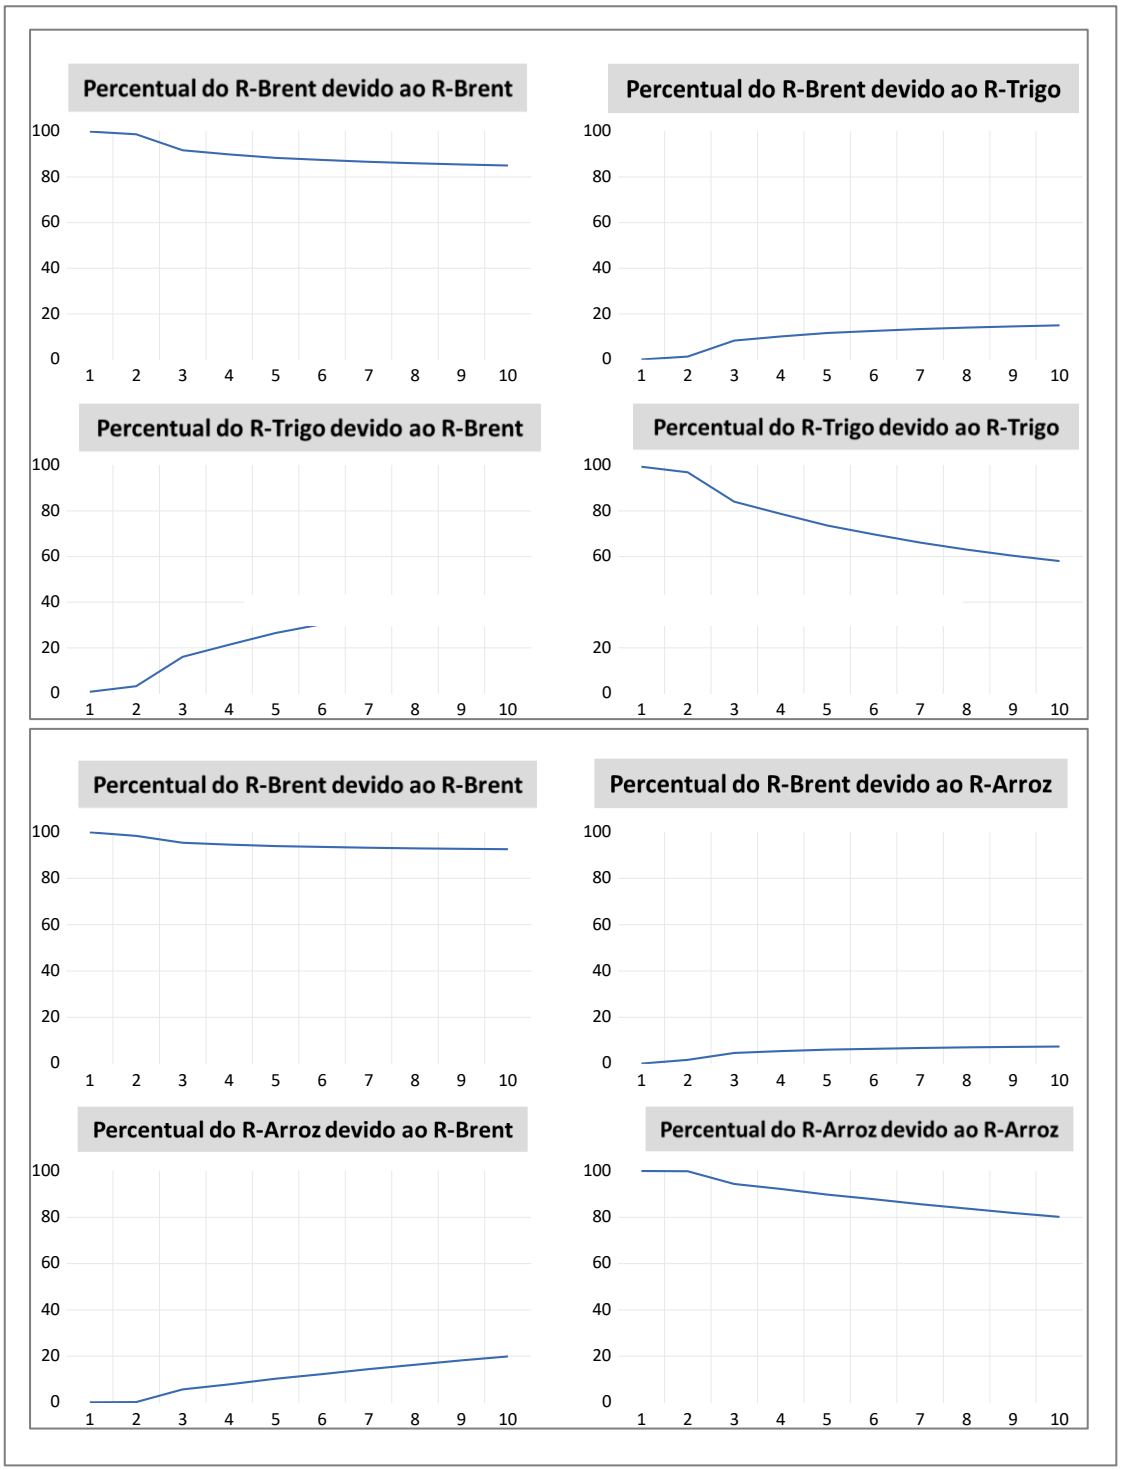

Figura 9B: Gráficos da Decomposição de Variância - 10 semanas

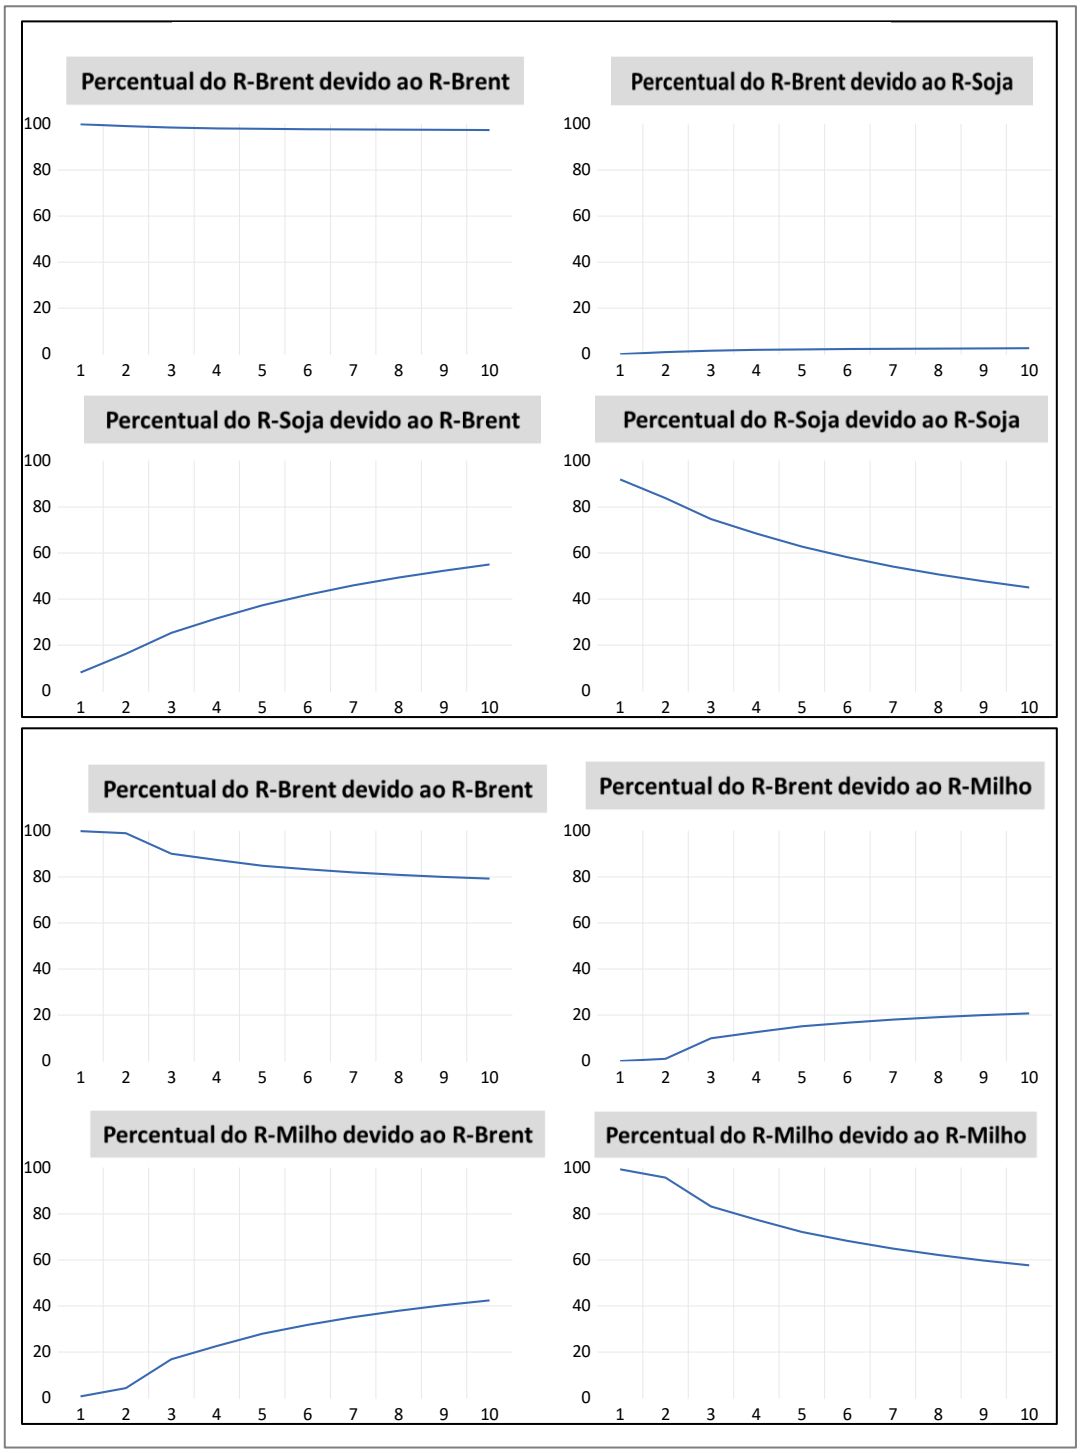

Figura 10A: Gráficos da Decomposição de Variância - 52 semanas

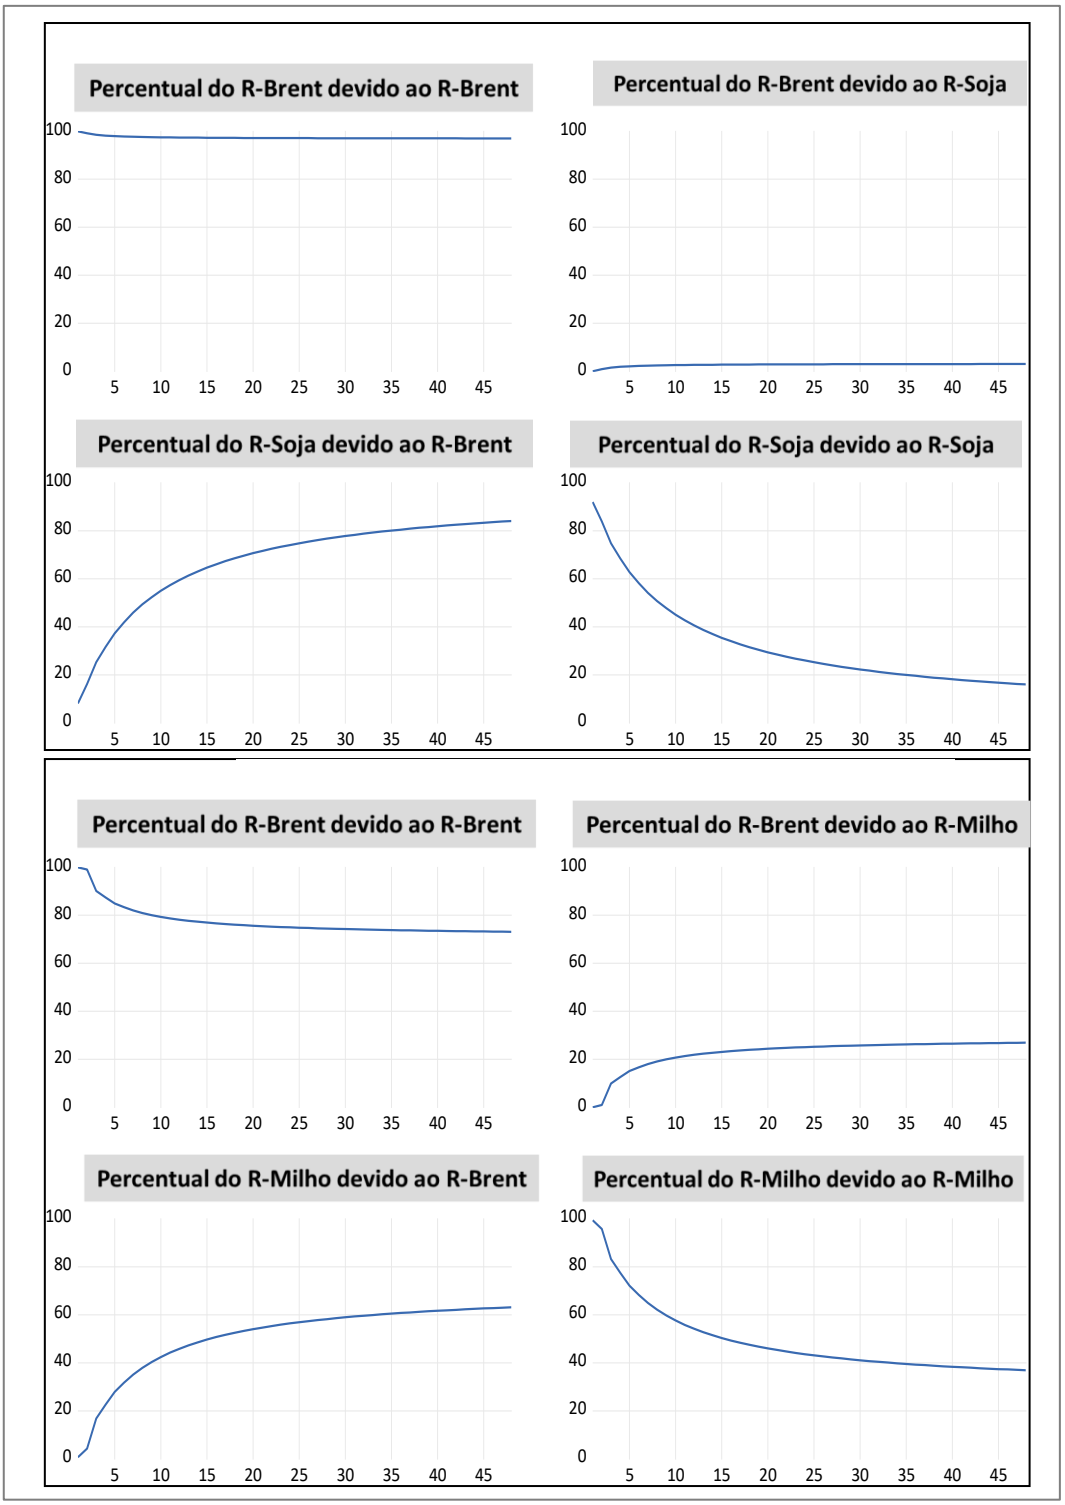

Figura 1011B: Gráficos da Decomposição de Variância - 52 semanas

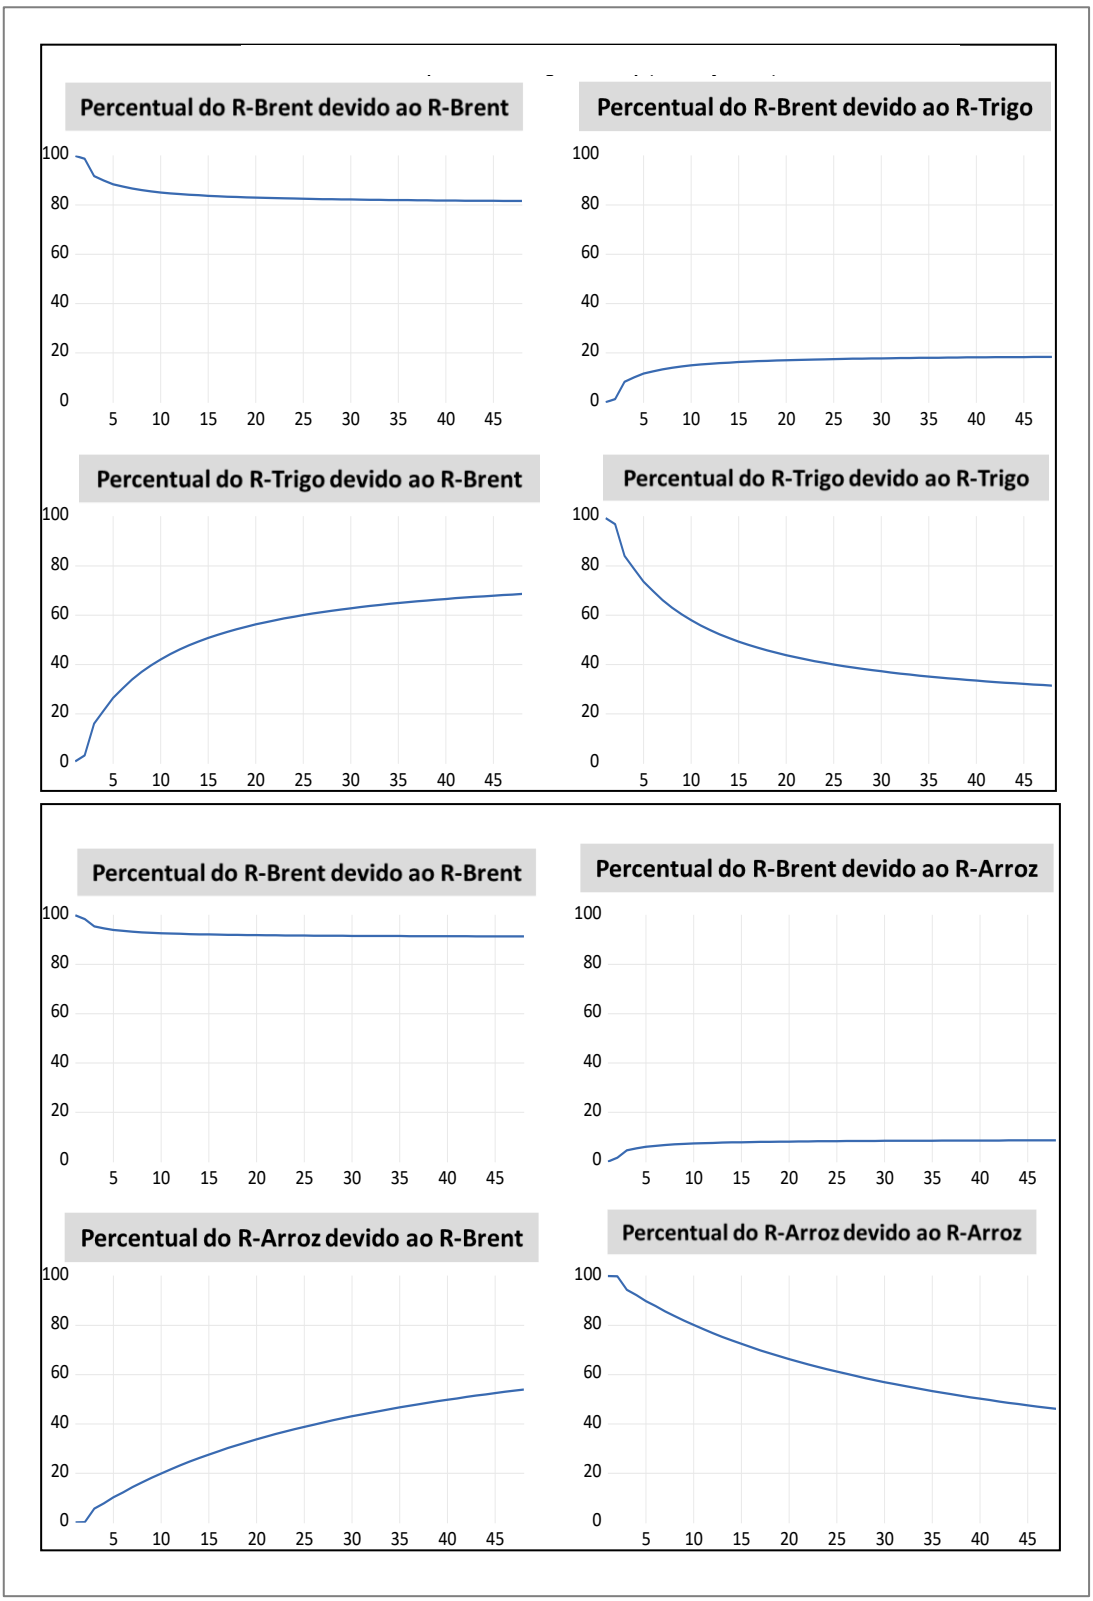

No modelo do milho, a porcentagem da variância do retorno dos preços do petróleo em relação a ele mesmo atinge aproximadamente 80% no 10º período e a porcentagem de variação do retorno do preço do milho em relação ao preço do petróleo tipo Brent atinge aproximadamente 40% nesse mesmo período e atinge 60% ao longo prazo. No que se refere aos retornos dos preços de soja, a porcentagem de variação do retorno do petróleo do tipo Brent em relação a ele mesmo se mantém próxima de 100% a longo prazo e a da variação do preço da soja devido a variação do petróleo atinge aproximadamente 60% em 10 períodos 80% ao longo prazo. Em respeito aos retornos do modelo do arroz, a porcentagem de variação do retorno do petróleo do tipo Brent em relação a ele mesmo começa em 100%, atingindo aproximadamente 90% após 10 períodos e mantém-se constante ao longo prazo. A porcentagem de variação do arroz devido a variação do preço do petróleo começa em 0% e sobre constantemente até aproximadamente 50% ao longo prazo. Com relação ao modelo do trigo, a porcentagem de variação do retorno do petróleo do tipo Brent em relação a ele mesmo começa em 100%, atingindo aproximadamente 80% após 10 períodos, mantendo-se constante desde então. A porcentagem de variação dos retornos dos preços do trigo em relação ao retorno do preço do petróleo tipo Brent começa em 0%, atinge aproximadamente 40% em 10 período e atinge 70% ao longo prazo. É interessante notar que, no prazo de 1 ano, a porcentagem da variância do retorno do preço do petróleo tipo Brent representada pelo retorno do preço das variáveis agrícolas aumenta, podendo chegar até 20% no caso do milho e trigo. Com respeito a porcentagem da variância dos retornos dos preços das *commodities* causado pelo retorno do preço do petróleo do tipo Brent no mesmo prazo é muito maior atingindo entre 50% a 80% nos modelos apresentados.

6. COMENTÁRIOS FINAIS

Este estudo foi motivado pelo fato das *commodities* agrícolas arroz, trigo, milho e soja serem determinantes para a alimentação segurança alimentar da população mundial. A produção e os preços de alimentos estão relacionados com os preços de energia, sobretudo por meio da produção de biocombustíveis e de fertilizantes. Nesse sentido, sendo o petróleo é uma das principais fontes de energia da matriz energética mundial, o objetivo do estudo foi examinar a interação entre os preços das *commodities* agrícolas de grãos como o arroz, trigo, milho e soja e o preço do petróleo bruto do tipo Brent no mercado internacional. Estudar o comportamento e a interação desses preços é fundamental para os agentes econômicos, principalmente para os que estão envolvidos nas tomadas de decisões relacionadas a políticas macroeconômicas.

Assim, inicialmente com o intuito de analisar as séries temporais dos preços do petróleo bruto e dos grãos mencionados anteriormente, foram realizados testes estatísticos das hipóteses de violação dos pressupostos fundamentais para a construção dos modelos vetoriais autorregressivos utilizados para atingir os objetivos deste estudo. Em relação à estacionariedade das séries de dados, testada por meio de testes de raízes unitárias, conclui-se que as 5 séries temporais de *commodities* estudadas não tiveram a hipótese de estacionariedade aceita com 95% de confiança. A fim de superar a violação desse pressuposto, foram realizadas análises com base na variação ou retornos de cada uma dessas séries temporais sendo, nesses casos, aceita com 95% de confiança a hipótese de estacionariedade e os modelos foram estimados com base nos retornos dos preços. No que se refere a normalidade, a qual foi testada por meio do teste de Jarque-Bera (JB), as 5 séries de *commodities* estudadas não tiveram a hipótese de normalidade aceita com 95% de confiança. Em relação às séries de retorno dos preços, observa-se que a série temporal de retorno dos preços do arroz se ajusta a uma normal com 90% de confiança, no entanto as outras quatro séries temporais estudadas não se ajustam a uma normal com o mesmo coeficiente de confiança, o que não foi considerada uma limitação para as análises posteriores. Porém, deve-se observar que o cenário ideal para a o método de estimação utilizado é o de não rejeição da hipótese de normalidade para todas as séries estudadas, o que impõe ressalvas aos resultados obtidos. Como sugestão para estudos futuros, sugere-se a utilização de modelos que corrijam a violação do pressuposto de normalidade, por exemplo modelos construídos com a utilização da distribuição *t* de Student que tem se mostrado uma alternativa adequada à distribuição de probabilidade normal.

Em seguida, a relação entre essas variáveis foi estudada por meio de análises de cointegração, realizadas por meio do teste de Johansen e Juselius. Os resultados indicaram que

a série temporal do retorno do preço do petróleo bruto do tipo Brent possui uma relação de longo prazo com as séries temporais de retorno dos preços dos quatro grãos estudados. Então, foram estimados modelos vetoriais autorregressivos. Porém, como as séries temporais dos retornos foram consideradas estacionárias e as variáveis cointegradas, foram acrescentados ao modelo mecanismos de correção de erros, tornando os modelos VAR em modelos VECM. Verificou dessa forma se as séries temporais são inter-relacionadas sendo possível estimar relações entre a variação do preço do petróleo e a variação do preço de cada *commodity* de grão individualmente e vice-versa. Nesses modelos, nos quais todas as variáveis são endógenas, cada variável é explicada por uma função linear da sua evolução passada e da outra variável analisada em conjunto. Além disso, foi verificada a existência da causalidade bidimensional das variáveis nos modelos estimados e, deste modo, infere-se que existe interação no curto e no longo prazo entre as variáveis estudadas. Com o objetivo de analisar o impacto dinâmico de distúrbios aleatórios no sistema de variáveis, foram estudadas as funções impulso-resposta, que retratam o comportamento das variáveis em resposta a choques e mudanças residuais. A partir das funções impulso-resposta, observou-se que não há impactos significativos devido ao choque de preço de uma *commodity* de grão (arroz, trigo, milho ou soja) com o petróleo e vice-versa. Por fim, as análises de decomposição de variância retrataram como a variabilidade uma variável pode afetar a da outra variável. Pode-se notar que a porcentagem da variância do retorno do preço do petróleo tipo Brent representada pelo retorno do preço das variáveis agrícolas aumenta ao longo do tempo quando é analisado por um período de um ano.

Por fim, em trabalhos futuros pode-se analisar a relação entre e o preço do petróleo do tipo Brent e as quatro *commodities* de grãos simultaneamente. Ou ainda, uma outra análise interessante seria relacionar o preço do petróleo com os preços das *commodities* agrícolas utilizadas para a produção de biocombustíveis (milho e soja) em um modelo único e relacionar o preço do petróleo com as *commodities* agrícolas não utilizadas para a produção de biocombustíveis separadamente em outro modelo.

REFERÊNCIAS BIBLIOGRÁFICAS

Ahumada, H.; Cornejo, M. **Forecasting food prices: The case of corn, soybeans and wheat**. International Journal of Forecasting, v. 32, n. 3, p. 838–848, 2016.

Akaike,H.,**A new look at the statistical model identification**. IEEE Transactions on Automatic Control, AC-19,n.6, pp. 716-723, Dez. 1974.

ANP. **Biocombustíveis**. Disponível em <http://www.anp.gov.br/biocombustiveis>. Acesso em 14/11/2020.

Bakhat, Mohcine; Würzburg, Klaas. **Price Relationships of Crude Oil and Food Commodities**. Economics for Energy, p. 1–22, 2013.

Bernhardt, Matthias. **Return and volatility spillover effects in agricultural commodity markets**. Working Papers in Economics No. 2017-03.

Bin, Chin Lit; Yun, Fong Woei Lunn Tan Zhi; Kuen, Teoh Poh Shen Yue Hui. **Asymmetric adjustment between crude oil and commodity market. Evidence from corn, soybeans, palm oil, wheat and sugar**. V. 2, N. 1, P. 1–7, 2014.

Capital Research. **Commodities agrícolas: o que são e como investir neles**. Disponível em: < https://www.capitalresearch.com.br/blog/investimentos/commodities-agricolas/>. Acesso em: 12/09/2020. Publicado em 16/01/2020.

Center for Advanced Medicine. **The Big Three: Soy, Wheat and Corn**. n. 760, p. 1–5, 2020.

Chen, Sheng Tung; Kuo, Hsiao I.; Chen, Chi Chung. **Modeling the relationship between the oil price and global food prices**. Applied Energy, v. 87, n. 8, p. 2517–2525, 2010.

C. M. Jarque; A. K. Bera. **A Test for Normality of Observations and Regression Residuals**. International Statistical Review, vol. 55, pp. 163–172, 1987.

Da Silva Nunes, José Luís. **Importância Econômica do Arroz**. Agrolink. Disponível em: <https://www.agrolink.com.br/culturas/arroz/informacoes/importancia_361560.html>. Acesso em: 12/09/2020.

Da Silva Nunes, José Luís. **Importância Econômica do Milho**. Agrolink. Disponível em: <https://www.agrolink.com.br/culturas/milho/informacoes/importancia_361402.html>. Acesso em: 12/09/2020.

Damba, T. O.; Bilgic, A.; Yavuz, F.; Bilgin, O. C. **Volatility Transmission between prices of selected Agricultural Products with Crude Oil and Exchange Rates in Ghana and Turkey**. Ghanaian Journal of Economics, v. 7, n. December, p. 119, 2019.

Dickey, D. A.; Fuller, W. A. **Distribution of the Estimators for Autoregressive Time Series with a Unit Root**. Journal of the American Statistical Association, v. 74, pp. 427-431, 1979.

Eviews, Manual de Referência do software econométrico Econometric Views. Disponível em: <http://www.eviews.com/help/helpintro.html#page/content%2FVAR-Vector_Autoregression_and_Error_Correction_Model.html%23>. Acesso em: 12/09/2020.

FAO. **The State of Food Security and Nutrition in the World 2020**. Transforming food systems for affordable healthy diets. [S.l: s.n.], 2020.

FGV/EESP. **Por que o preço das commodities subiu e como isso influi na economia**. Disponível em: < https://eesp.fgv.br/noticia/por-que-o-preco-das-commodities-subiu-e-como-isso-influi-na-economia>. Acesso em 14/11/2020. Publicado em 05/01/2017.

Gardebroek, Cornelis; Hernandez, Manuel A. **Do energy prices stimulate food price volatility? Examining volatility transmission between US oil, ethanol and corn markets**. Energy Economics, v. 40, p. 119–129, 2013.

Gujarati, D.; Porter, D. **Econometria Básica**. 5 ed, McGraw-Hill, 2011.

Guo, Hui; Kliesen, Kevin L. **Oil price volatility and U.S. macroeconomic activity**. Federal Reserve Bank of St. Louis Review, v. 87, n. 6, p. 669–683, 2005.

Harri, Ardian; Hudson, Darren. **Mean and Variance Dynamics between Agricultural Commodity Prices and Crude Oil Prices**. Economics of Alternative Energy Sources and Globalization: The Road Ahead meeting, Orlando, FL, November 15-17, 2009, v. 53, n. 9, p. 1689–1699, 2009.

Herwartz, Helmut; Saucedo, Alberto. **Food–oil volatility spillovers and the impact of distinct biofuel policies on price uncertainties on feedstock markets**. Agricultural Economics (United Kingdom), v. 51, n. 3, p. 387–402, 2020.

Hespanhol, Antonio Nivaldo; Aparecida, Rosangela; Hespanhol, De Medeiros. **Os Efeitos Da Elevação Dos Preços Das Commodities Agrícolas Sobre a Segurança Alimentar**. Revista Faz Ciência, v. 12, n. 15, p. 73, 2010.

IFC Markets. **Valor e Cotação do Arroz Bruto**. Disponível em < https://www.ifcmarkets.com.br/market-data/commodities-prices/rice>. Acesso em: 12/09/2020.

Inoue, Letícia. **Cultura da soja: sua importância na atualidade**. Agromove. Disponível em: <https://blog.agromove.com.br/cultura-soja-importancia-na-atualidade/>. Acesso em 12/09/2020. Publicado em 26/01/2019.

Johansen, S.; K. Juselius. **Maximum Likelihood Estimation and Inference on Cointegration with Applications to Demand for Money**. Oxford Bulletin of Economics and Statistics 52, 169-210, 1990.

Kumar, Dilip. **On Volatility Transmission from Crude Oil to Agricultural Commodities**. Theoretical Economics Letters, v. 07, n. 02, p. 87–101, 2017.

Ljung, G. M.; Box, G. E. **On a measure of lack of fit in time series models**. Biometrika, v. 65, n. 2, p. 297-303, 1978.

Manera, Matteo; Nicolini, Marcella; Vignati, Ilaria. **Financial speculation in energy and agriculture futures markets: A multivariate garch approach**. Energy Journal, v. 34, n. 3, p. 55–81, 2013a.

Manera, Matteo; Nicolini, Marcella; Vignati, Ilaria. **Futures Price Volatility in Commodities Markets: The Role of Short Term vs Long Term Speculation**. SSRN Electronic Journal, p. 1–27, 2013b.

Mensi, Walid et al. **Correlations and volatility spillovers across commodity and stock markets: Linking energies, food, and gold**. Economic Modelling, v. 32, n. 1, p. 15–22, 2013.

Murteira, Bento José Ferreira. **Análise Exploratória de Dados - Estatística descritiva**. McGraw Hill, Lisboa. ISBN: 9729241252. ISBN-13: 9789729241253. 1993.

Nunez, Christina. **Biofuels, explained**. National Geographic. Disponível em: <https://www.nationalgeographic.com/environment/global-warming/biofuel/>; Acesso em 14/11/2020. Publicado em 15/07/2019.

N. Sönnichsen. **Global oil industry - Statistics & facts**. Statista. Disponível em https://www.statista.com/topics/1783/global-oil-industry-and-market/. Acesso em 14/11/2020. Publicado em 19/10/2020.

Paula, Nilson Maciel De; Santos, Valéria Faria Santos; Pereira, Wellington Silva Pereira. **A financeirização das commodities agrícolas e o sistema agroalimentar**. Estudos Sociedade e Agricultura, v. 23, n. 2, p. 294–314, 2015.

Pesaran, M. Hashem; Yongcheol Shin. **Generalized Impulse Response Analysis in Linear Multivariate Models**. Economics Letters 58, 17-29, 1998.

Pickup, M. **Introduction to time series analysis**. Sage Publications. 2014.

Politize. **O que são commodities agrícolas?** Disponível em: < https://www.politize.com.br/commodities-agricolas/>. Acesso em: 12/09/2020. Publicado em 30/11/2018.

Rafiq, Shuddhasawtta; Salim, Ruhul; Bloch, Harry. **Impact of crude oil price volatility on economic activities: An empirical investigation in the Thai economy**. Resources Policy, v. 34, n. 3, p. 121–132, 2009.

Salles. A. **Notas de Aula – Séries temporais – introdução aos modelos de previsão**. Escola Politécnica / Universidade Federal do Rio de Janeiro, 2005.

Salles, Andre Assis De; Oliveira, Erick Meira De. **The Relationship between Oil and Brazilian Agricultural Commodities Prices**. MPRA Paper No. 98390.

Salles, Andre Assis De. **On the Relationship between Crude Oil Prices and Stock Market : The Brazilian Case**. International Research Journal of Finance and Economicsn. ISSN 1450-2887 Issue 176 November, 2019.

Schwarz, G. **Estimating the Dimension of a Model**. The Annals of Statistics, v.6, n.2, pp. 461-464, Mar. 1978.

Sims, C. A. **Macroeconomics and Reality**. Econometrica, 48, 1-48, 1980.

Todsadee, Areerat; Kameyama, Hiroshi; Ito, Shoichi. **Price Volatility of Grains: Relationship with Crude Oil Price Using CCC-Multivariate GARCH Model**. American Journal of Economics and Business Administration, v. 6, n. 4, p. 138–142, 2014.

Upton, Graham; Cook, Ian. **A Dictionary of Statistics**. Oxford University Press, 2 Ed, 2006.

Wooldridge, J. **Introduction to Econometrics: EMEA Edition**, 1 Ed, 2014.

World Agricultural Production. **World Wheat Production 2020/2021**. Disponível em <http://www.worldagriculturalproduction.com/crops/wheat.aspx>. Acesso em 12/09/2020. Publicado em 05/2020.

Wright, Brian D. **The economics of grain price volatility**. Applied Economic Perspectives and Policy, v. 33, n. 1, p. 32–58, 2011.

APÊNDICE A: Resultados Testes de Cointegração

A.1 Retorno do Brent e retorno do trigo

Included observations: 545 after adjustments
Trend assumption: No deterministic trend
Series: RBRENT RWHEAT
Lags interval (in first differences): 1 to 1

Unrestricted Cointegration Rank Test (Trace)

Hypothesized No. of CE(s)	Eigenvalue	Trace Statistic	0.05 Critical Value	Prob.**
None *	0.364297	455.1562	12.32090	0.0000
At most 1 *	0.317591	208.2585	4.129906	0.0000

Trace test indicates 2 cointegrating eqn(s) at the 0.05 level
* denotes rejection of the hypothesis at the 0.05 level
**MacKinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegration Rank Test (Maximum Eigenvalue)

Hypothesized No. of CE(s)	Eigenvalue	Max-Eigen Statistic	0.05 Critical Value	Prob.**
None *	0.364297	246.8978	11.22480	0.0000
At most 1 *	0.317591	208.2585	4.129906	0.0000

Max-eigenvalue test indicates 2 cointegrating eqn(s) at the 0.05 level
* denotes rejection of the hypothesis at the 0.05 level
**MacKinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegrating Coefficients (normalized by b'*S11*b=I):

RBRENT	RWHEAT
14.71009	27.72532
29.59546	-19.31586

Unrestricted Adjustment Coefficients (alpha):

D(RBRENT)	-0.015901	-0.024102
D(RWHEAT)	-0.028250	0.012503

1 Cointegrating Equation(s): Log likelihood 1823.668

Normalized cointegrating coefficients (standard error in parentheses)

RBRENT	RWHEAT
1.000000	1.884782
	(0.12893)

Adjustment coefficients (standard error in parentheses)

D(RBRENT)	-0.233911
	(0.03011)
D(RWHEAT)	-0.415564
	(0.02743)

A.2 Retorno do Brent e retorno do arroz

Included observations: 545 after adjustments
Trend assumption: No deterministic trend
Series: RBRENT RRICE
Lags interval (in first differences): 1 to 1

Unrestricted Cointegration Rank Test (Trace)

Hypothesized No. of CE(s)	Eigenvalue	Trace Statistic	0.05 Critical Value	Prob.**
None *	0.373199	467.9502	12.32090	0.0000
At most 1 *	0.323957	213.3666	4.129906	0.0000

Trace test indicates 2 cointegrating eqn(s) at the 0.05 level
* denotes rejection of the hypothesis at the 0.05 level
**MacKinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegration Rank Test (Maximum Eigenvalue)

Hypothesized No. of CE(s)	Eigenvalue	Max-Eigen Statistic	0.05 Critical Value	Prob.**
None *	0.373199	254.5836	11.22480	0.0000
At most 1 *	0.323957	213.3666	4.129906	0.0000

Max-eigenvalue test indicates 2 cointegrating eqn(s) at the 0.05 level
* denotes rejection of the hypothesis at the 0.05 level
**MacKinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegrating Coefficients (normalized by b'*S11*b=I):

RBRENT	RRICE
7.130448	40.69478
32.31380	-15.85746

Unrestricted Adjustment Coefficients (alpha):

D(RBRENT)	-0.011382	-0.026716
D(RRICE)	-0.023633	0.005708

1 Cointegrating Equation(s): Log likelihood 1966.887

Normalized cointegrating coefficients (standard error in parentheses)

RBRENT	RRICE
1.000000	5.707184
	(0.33691)

Adjustment coefficients (standard error in parentheses)

D(RBRENT)	-0.081161
	(0.01507)
D(RRICE)	-0.168512
	(0.00987)

A.3 Retorno do Brent e retorno da soja

Included observations: 545 after adjustments
Trend assumption: No deterministic trend
Series: RBRENT RSOY
Lags interval (in first differences): 1 to 1

Unrestricted Cointegration Rank Test (Trace)

Hypothesized No. of CE(s)	Eigenvalue	Trace Statistic	0.05 Critical Value	Prob.**
None *	0.348242	451.3560	12.32090	0.0000
At most 1 *	0.329743	218.0512	4.129906	0.0000

Trace test indicates 2 cointegrating eqn(s) at the 0.05 level
* denotes rejection of the hypothesis at the 0.05 level
**MacKinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegration Rank Test (Maximum Eigenvalue)

Hypothesized No. of CE(s)	Eigenvalue	Max-Eigen Statistic	0.05 Critical Value	Prob.**
None *	0.348242	233.3047	11.22480	0.0000
At most 1 *	0.329743	218.0512	4.129906	0.0000

Max-eigenvalue test indicates 2 cointegrating eqn(s) at the 0.05 level
* denotes rejection of the hypothesis at the 0.05 level
**MacKinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegrating Coefficients (normalized by b'*S11*b=I):

RBRENT	RSOY
-15.70180	45.01338
29.78574	11.18400

Unrestricted Adjustment Coefficients (alpha):

D(RBRENT)	0.006469	-0.028305
D(RSOY)	-0.021817	-0.008598

1 Cointegrating Equation(s): Log likelihood 1960.674

Normalized cointegrating coefficients (standard error in parentheses)

RBRENT	RSOY
1.000000	-2.866766
	(0.16854)

Adjustment coefficients (standard error in parentheses)

D(RBRENT)	-0.101582
	(0.03378)
D(RSOY)	0.342562
	(0.02252)

A.4 Retorno do Brent e retorno do milho

Included observations: 545 after adjustments
Trend assumption: No deterministic trend
Series: RBRENT RCORN
Lags interval (in first differences): 1 to 1

Unrestricted Cointegration Rank Test (Trace)

Hypothesized No. of CE(s)	Eigenvalue	Trace Statistic	0.05 Critical Value	Prob.**
None *	0.338234	441.0553	12.32090	0.0000
At most 1 *	0.327284	216.0554	4.129906	0.0000

Trace test indicates 2 cointegrating eqn(s) at the 0.05 level
* denotes rejection of the hypothesis at the 0.05 level
**MacKinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegration Rank Test (Maximum Eigenvalue)

Hypothesized No. of CE(s)	Eigenvalue	Max-Eigen Statistic	0.05 Critical Value	Prob.**
None *	0.338234	224.9999	11.22480	0.0000
At most 1 *	0.327284	216.0554	4.129906	0.0000

Max-eigenvalue test indicates 2 cointegrating eqn(s) at the 0.05 level
* denotes rejection of the hypothesis at the 0.05 level
**MacKinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegrating Coefficients (normalized by b'*S11*b=I):

RBRENT	RCORN
17.62417	26.82594
28.28222	-24.95700

Unrestricted Adjustment Coefficients (alpha):

D(RBRENT)	-0.017948	-0.022539
D(RCORN)	-0.023358	0.014269

1 Cointegrating Equation(s): Log likelihood 1864.460

Normalized cointegrating coefficients (standard error in parentheses)

RBRENT	RCORN
1.000000	1.522111
	(0.12261)

Adjustment coefficients (standard error in parentheses)

D(RBRENT)	-0.316319
	(0.03537)
D(RCORN)	-0.411663
	(0.03112)

APÊNDICE B: Tabelas Resultado da Decomposição da Variância

B.1 Retorno do Trigo

Variance Decomposition of RBRENT:

Period	S.E.	RBRENT	RWHEAT
1	0,0478	100,0000	0,0000
2	0,0529	98,7782	1,2218
3	0,0617	91,7696	8,2304
4	0,0671	89,9215	10,0786
5	0,0732	88,4377	11,5623
6	0,0783	87,5119	12,4882
7	0,0834	86,6756	13,3244
8	0,0880	86,0537	13,9464
9	0,0925	85,5334	14,4666
10	0,0967	85,1108	14,8892
11	0,1008	84,7508	15,2492
12	0,1047	84,4452	15,5548
13	0,1084	84,1804	15,8196
14	0,1121	83,9499	16,0501
15	0,1156	83,7468	16,2532
16	0,1190	83,5668	16,4332
17	0,1223	83,4060	16,5940
18	0,1256	83,2616	16,7384
19	0,1287	83,1311	16,8689
20	0,1318	83,0127	16,9873
21	0,1348	82,9048	17,0952
22	0,1377	82,8059	17,1941
23	0,1406	82,7151	17,2849
24	0,1434	82,6314	17,3687
25	0,1462	82,5539	17,4461
26	0,1489	82,4820	17,5180
27	0,1516	82,4152	17,5849
28	0,1542	82,3528	17,6472
29	0,1568	82,2945	17,7055
30	0,1593	82,2399	17,7601
31	0,1618	82,1887	17,8114
32	0,1643	82,1404	17,8596
33	0,1667	82,0950	17,9050
34	0,1691	82,0521	17,9479
35	0,1714	82,0116	17,9884
36	0,1737	81,9732	18,0268
37	0,1760	81,9368	18,0633
38	0,1783	81,9022	18,0978
39	0,1805	81,8693	18,1307
40	0,1827	81,8380	18,1620
41	0,1849	81,8082	18,1918
42	0,1871	81,7797	18,2203
43	0,1892	81,7525	18,2475
44	0,1913	81,7265	18,2735
45	0,1934	81,7016	18,2984
46	0,1955	81,6778	18,3222
47	0,1975	81,6549	18,3451
48	0,1995	81,6330	18,3670
49	0,2015	81,6119	18,3881
50	0,2035	81,5917	18,4083
51	0,2054	81,5722	18,4278
52	0,2074	81,5534	18,4466

Variance Decomposition of RWHEAT:

Period	S.E.	RBRENT	RWHEAT
1	0,0435	0,6356	99,3644
2	0,0445	3,1130	96,8870
3	0,0481	15,9708	84,0292
4	0,0500	21,2881	78,7119
5	0,0525	26,4036	73,5964
6	0,0545	30,2910	69,7091
7	0,0565	33,9284	66,0716
8	0,0585	36,9772	63,0228
9	0,0604	39,6894	60,3106
10	0,0622	42,0637	57,9363
11	0,0640	44,1869	55,8131
12	0,0657	46,0842	53,9159
13	0,0674	47,7952	52,2049
14	0,0691	49,3435	50,6565
15	0,0707	50,7525	49,2475
16	0,0723	52,0397	47,9603
17	0,0738	53,2204	46,7796
18	0,0753	54,3072	45,6928
19	0,0768	55,3109	44,6891
20	0,0783	56,2407	43,7593
21	0,0797	57,1045	42,8955
22	0,0811	57,9090	42,0910
23	0,0825	58,6602	41,3398
24	0,0838	59,3632	40,6368
25	0,0852	60,0224	39,9776
26	0,0865	60,6419	39,3581
27	0,0878	61,2252	38,7749
28	0,0891	61,7752	38,2248
29	0,0903	62,2948	37,7052
30	0,0916	62,7865	37,2135
31	0,0928	63,2524	36,7476
32	0,0940	63,6945	36,3055
33	0,0952	64,1146	35,8855
34	0,0964	64,5142	35,4858
35	0,0975	64,8949	35,1051
36	0,0987	65,2580	34,7420
37	0,0998	65,6046	34,3954
38	0,1009	65,9359	34,0641
39	0,1020	66,2528	33,7472
40	0,1031	66,5563	33,4437
41	0,1042	66,8472	33,1528
42	0,1053	67,1262	32,8738
43	0,1064	67,3941	32,6059
44	0,1074	67,6516	32,3484
45	0,1085	67,8992	32,1008
46	0,1095	68,1374	31,8626
47	0,1105	68,3669	31,6331
48	0,1116	68,5880	31,4120
49	0,1126	68,8013	31,1987
50	0,1136	69,0071	30,9929
51	0,1145	69,2058	30,7942
52	0,1155	69,3978	30,6022

B.2 Retorno do Arroz

Variance Decomposition of RBRENT:			
Period	S.E.	RBRENT	RRICE
1	0,0493	100,0000	0,0000
2	0,0560	98,4183	1,5817
3	0,0663	95,4896	4,5104
4	0,0732	94,5898	5,4102
5	0,0804	94,0375	5,9625
6	0,0866	93,6289	6,3711
7	0,0925	93,2995	6,7006
8	0,0980	93,0475	6,9525
9	0,1033	92,8460	7,1540
10	0,1083	92,6810	7,3190
11	0,1131	92,5430	7,4570
12	0,1176	92,4261	7,5739
13	0,1221	92,3258	7,6742
14	0,1263	92,2387	7,7613
15	0,1304	92,1625	7,8375
16	0,1344	92,0952	7,9048
17	0,1383	92,0354	7,9646
18	0,1421	91,9818	8,0182
19	0,1457	91,9335	8,0665
20	0,1493	91,8898	8,1102
21	0,1528	91,8501	8,1499
22	0,1562	91,8138	8,1862
23	0,1596	91,7805	8,2195
24	0,1628	91,7498	8,2502
25	0,1661	91,7216	8,2784
26	0,1692	91,6954	8,3046
27	0,1723	91,6710	8,3290
28	0,1753	91,6484	8,3516
29	0,1783	91,6272	8,3728
30	0,1813	91,6074	8,3926
31	0,1842	91,5888	8,4112
32	0,1870	91,5714	8,4286
33	0,1898	91,5550	8,4450
34	0,1926	91,5395	8,4605
35	0,1953	91,5249	8,4751
36	0,1980	91,5110	8,4890
37	0,2006	91,4979	8,5021
38	0,2032	91,4855	8,5145
39	0,2058	91,4737	8,5263
40	0,2084	91,4624	8,5376
41	0,2109	91,4517	8,5483
42	0,2134	91,4415	8,5585
43	0,2158	91,4318	8,5682
44	0,2183	91,4224	8,5776
45	0,2207	91,4135	8,5865
46	0,2231	91,4050	8,5950
47	0,2254	91,3968	8,6032
48	0,2277	91,3890	8,6110
49	0,2301	91,3814	8,6186
50	0,2323	91,3742	8,6258
51	0,2346	91,3672	8,6328
52	0,2368	91,3605	8,6395

Variance Decomposition of RRICE:			
Period	S.E.	RBRENT	RRICE
1	0,0323	0,0142	99,9858
2	0,0325	0,1486	99,8515
3	0,0334	5,6442	94,3558
4	0,0338	7,8112	92,1889
5	0,0344	10,2180	89,7820
6	0,0348	12,2408	87,7592
7	0,0353	14,3492	85,6508
8	0,0357	16,2804	83,7196
9	0,0362	18,1395	81,8605
10	0,0366	19,8957	80,1043
11	0,0371	21,5755	78,4245
12	0,0375	23,1754	76,8247
13	0,0379	24,7042	75,2958
14	0,0384	26,1651	73,8349
15	0,0388	27,5633	72,4367
16	0,0392	28,9023	71,0977
17	0,0396	30,1861	69,8139
18	0,0400	31,4178	68,5822
19	0,0404	32,6006	67,3994
20	0,0408	33,7374	66,2626
21	0,0412	34,8308	65,1692
22	0,0416	35,8833	64,1168
23	0,0420	36,8970	63,1030
24	0,0424	37,8741	62,1259
25	0,0428	38,8165	61,1835
26	0,0431	39,7262	60,2739
27	0,0435	40,6046	59,3954
28	0,0439	41,4535	58,5466
29	0,0443	42,2742	57,7258
30	0,0446	43,0682	56,9318
31	0,0450	43,8367	56,1633
32	0,0453	44,5810	55,4190
33	0,0457	45,3022	54,6978
34	0,0460	46,0013	53,9987
35	0,0464	46,6794	53,3206
36	0,0467	47,3373	52,6627
37	0,0471	47,9760	52,0240
38	0,0474	48,5962	51,4038
39	0,0478	49,1989	50,8011
40	0,0481	49,7846	50,2154
41	0,0485	50,3542	49,6458
42	0,0488	50,9083	49,0917
43	0,0491	51,4474	48,5526
44	0,0494	51,9723	48,0277
45	0,0498	52,4834	47,5166
46	0,0501	52,9813	47,0187
47	0,0504	53,4665	46,5335
48	0,0507	53,9394	46,0606
49	0,0511	54,4006	45,5994
50	0,0514	54,8505	45,1495
51	0,0517	55,2894	44,7106
52	0,0520	55,7179	44,2822

B.3 Retorno da Soja

Variance Decomposition of RBRENT:			
Period	S.E.	RBRENT	RSOY
1	0,05022	100,0000	0,0000
2	0,0574	99,1434	0,8566
3	0,0683	98,4787	1,5213
4	0,0758	98,1921	1,8079
5	0,0834	97,9559	2,0441
6	0,0900	97,8057	2,1943
7	0,0963	97,6868	2,3133
8	0,1022	97,5969	2,4031
9	0,1078	97,5242	2,4759
10	0,1131	97,4651	2,5349
11	0,1181	97,4158	2,5842
12	0,1230	97,3741	2,6259
13	0,1276	97,3384	2,6616
14	0,1321	97,3075	2,6925
15	0,1365	97,2805	2,7195
16	0,1407	97,2567	2,7433
17	0,1448	97,2355	2,7645
18	0,1488	97,2165	2,7835
19	0,1527	97,1995	2,8005
20	0,1564	97,1841	2,8159
21	0,1601	97,1701	2,8299
22	0,1637	97,1573	2,8427
23	0,1673	97,1456	2,8544
24	0,1707	97,1348	2,8652
25	0,1741	97,1248	2,8752
26	0,1774	97,1156	2,8844
27	0,1807	97,1071	2,8929
28	0,1839	97,0991	2,9009
29	0,1871	97,0917	2,9083
30	0,1902	97,0847	2,9153
31	0,1932	97,0782	2,9218
32	0,1962	97,0721	2,9279
33	0,1992	97,0663	2,9337
34	0,2021	97,0609	2,9391
35	0,2050	97,0558	2,9442
36	0,2078	97,0509	2,9491
37	0,2106	97,0463	2,9537
38	0,2133	97,0420	2,9580
39	0,2161	97,0379	2,9622
40	0,2187	97,0339	2,9661
41	0,2214	97,0302	2,9698
42	0,2240	97,0266	2,9734
43	0,2266	97,0232	2,9768
44	0,2292	97,0199	2,9801
45	0,2317	97,0168	2,9832
46	0,2342	97,0138	2,9862
47	0,2367	97,0110	2,9890
48	0,2392	97,0082	2,9918
49	0,2416	97,0056	2,9944
50	0,2440	97,0031	2,9970
51	0,2464	97,0006	2,9994
52	0,2487	96,9983	3,0017

Variance Decomposition of RSOY:			
Period	S.E.	RBRENT	RSOY
1	0,0335	8,0311	91,9689
2	0,0351	16,1897	83,8103
3	0,0374	25,2585	74,7415
4	0,0391	31,5661	68,4339
5	0,0409	37,2424	62,7576
6	0,0426	41,8616	58,1384
7	0,0443	45,8730	54,1270
8	0,0458	49,3180	50,6820
9	0,0474	52,3351	47,6650
10	0,0488	54,9891	45,0109
11	0,0503	57,3458	42,6542
12	0,0517	59,4510	40,5490
13	0,0530	61,3435	38,6565
14	0,0544	63,0537	36,9463
15	0,0557	64,6069	35,3931
16	0,0569	66,0237	33,9763
17	0,0581	67,3214	32,6786
18	0,0594	68,5142	31,4858
19	0,0605	69,6146	30,3854
20	0,0617	70,6327	29,3673
21	0,0629	71,5775	28,4225
22	0,0640	72,4567	27,5433
23	0,0651	73,2768	26,7232
24	0,0662	74,0436	25,9564
25	0,0672	74,7622	25,2378
26	0,0683	75,4369	24,5631
27	0,0693	76,0716	23,9284
28	0,0703	76,6699	23,3301
29	0,0713	77,2347	22,7653
30	0,0723	77,7688	22,2312
31	0,0733	78,2746	21,7254
32	0,0743	78,7543	21,2457
33	0,0752	79,2099	20,7901
34	0,0762	79,6432	20,3568
35	0,0771	80,0557	19,9443
36	0,0780	80,4489	19,5511
37	0,0789	80,8242	19,1758
38	0,0798	81,1827	18,8173
39	0,0807	81,5255	18,4745
40	0,0816	81,8537	18,1463
41	0,0824	82,1682	17,8318
42	0,0833	82,4697	17,5303
43	0,0841	82,7591	17,2409
44	0,0850	83,0372	16,9628
45	0,0858	83,3045	16,6955
46	0,0866	83,5616	16,4384
47	0,0875	83,8092	16,1908
48	0,0883	84,0478	15,9522
49	0,0891	84,2778	15,7222
50	0,0899	84,4997	15,5003
51	0,0906	84,7139	15,2861
52	0,0914	84,9209	15,0792

B.4 Retorno do Milho

Variance Decomposition of RBRENT:			
Period	S.E.	RBRENT	RCORN
1	0,0468	100,0000	0,0000
2	0,0511	99,0177	0,9823
3	0,0588	90,1321	9,8679
4	0,0634	87,4656	12,5345
5	0,0688	84,8992	15,1008
6	0,0732	83,3710	16,6291
7	0,0776	81,9803	18,0197
8	0,0817	80,9419	19,0581
9	0,0856	80,0520	19,9480
10	0,0893	79,3261	20,6739
11	0,0929	78,7017	21,2983
12	0,0964	78,1692	21,8308
13	0,0997	77,7049	22,2951
14	0,1029	77,2988	22,7012
15	0,1061	76,9395	23,0606
16	0,1091	76,6198	23,3802
17	0,1121	76,3334	23,6666
18	0,1150	76,0754	23,9246
19	0,1178	75,8417	24,1583
20	0,1205	75,6290	24,3710
21	0,1232	75,4347	24,5653
22	0,1258	75,2564	24,7436
23	0,1284	75,0923	24,9077
24	0,1309	74,9408	25,0593
25	0,1334	74,8003	25,1997
26	0,1358	74,6698	25,3302
27	0,1382	74,5483	25,4517
28	0,1406	74,4348	25,5652
29	0,1429	74,3286	25,6714
30	0,1451	74,2290	25,7711
31	0,1474	74,1353	25,8647
32	0,1496	74,0472	25,9528
33	0,1517	73,9641	26,0360
34	0,1539	73,8855	26,1145
35	0,1560	73,8112	26,1888
36	0,1581	73,7408	26,2593
37	0,1601	73,6739	26,3261
38	0,1622	73,6104	26,3896
39	0,1642	73,5500	26,4500
40	0,1661	73,4924	26,5076
41	0,1681	73,4375	26,5625
42	0,1700	73,3851	26,6149
43	0,1720	73,3350	26,6650
44	0,1738	73,2871	26,7129
45	0,1757	73,2412	26,7588
46	0,1776	73,1972	26,8028
47	0,1794	73,1550	26,8450
48	0,1812	73,1144	26,8856
49	0,1830	73,0755	26,9245
50	0,1848	73,0381	26,9620
51	0,1865	73,0020	26,9980
52	0,1883	72,9673	27,0327

Variance Decomposition of RCORN:			
Period	S.E.	RBRENT	RCORN
1	0,0412	0,7152	99,2848
2	0,0427	4,2699	95,7301
3	0,0471	16,8214	83,1786
4	0,0495	22,5724	77,4276
5	0,0526	27,8567	72,1433
6	0,0551	31,7138	68,2862
7	0,0576	35,1254	64,8746
8	0,0600	37,9234	62,0766
9	0,0623	40,3486	59,6514
10	0,0645	42,4292	57,5708
11	0,0667	44,2525	55,7475
12	0,0688	45,8552	54,1448
13	0,0708	47,2787	52,7213
14	0,0728	48,5498	51,4502
15	0,0747	49,6925	50,3076
16	0,0765	50,7249	49,2751
17	0,0784	51,6625	48,3376
18	0,0802	52,5176	47,4824
19	0,0819	53,3007	46,6993
20	0,0836	54,0206	45,9794
21	0,0853	54,6846	45,3154
22	0,0869	55,2989	44,7011
23	0,0885	55,8690	44,1310
24	0,0901	56,3994	43,6006
25	0,0917	56,8942	43,1059
26	0,0932	57,3567	42,6433
27	0,0947	57,7902	42,2098
28	0,0962	58,1972	41,8028
29	0,0976	58,5800	41,4200
30	0,0991	58,9409	41,0591
31	0,1005	59,2815	40,7185
32	0,1019	59,6036	40,3964
33	0,1032	59,9087	40,0913
34	0,1046	60,1980	39,8020
35	0,1059	60,4728	39,5273
36	0,1073	60,7340	39,2660
37	0,1086	60,9828	39,0172
38	0,1099	61,2199	38,7801
39	0,1111	61,4462	38,5538
40	0,1124	61,6624	38,3377
41	0,1137	61,8691	38,1309
42	0,1149	62,0669	37,9331
43	0,1161	62,2565	37,7435
44	0,1173	62,4383	37,5617
45	0,1185	62,6129	37,3872
46	0,1197	62,7805	37,2195
47	0,1209	62,9416	37,0584
48	0,1220	63,0967	36,9033
49	0,1232	63,2459	36,7541
50	0,1243	63,3898	36,6103
51	0,1255	63,5284	36,4716
52	0,1266	63,6622	36,3378