

idp

idn

MESTRADO PROFISSIONAL EM ECONOMIA

**INFLUÊNCIAS MACROECONÔMICAS NA VOLATILIDADE
DOS DERIVATIVOS DE COMMODITIES BRASILEIROS: UMA
ABORDAGEM DCC-GARCH**

NOEMI DA SILVA FERREIRA

Brasília-DF, 2024

NOEMI DA SILVA FERREIRA

**INFLUÊNCIAS MACROECONÔMICAS NA
VOLATILIDADE DOS DERIVATIVOS DE COMMODITIES
BRASILEIROS: UMA ABORDAGEM DCC-GARCH**

Dissertação apresentada ao Programa de Pós Graduação em Economia, do Instituto Brasileiro de Ensino, Desenvolvimento e Pesquisa, como requisito parcial para obtenção do grau de Mestre.

Orientador

Professor Doutor Mathias Schneid Tessmann.

Brasília-DF 2024

NOEMI DA SILVA FERREIRA

**INFLUÊNCIAS MACROECONÔMICAS NA
VOLATILIDADE DOS DERIVATIVOS DE COMMODITIES
BRASILEIROS: UMA ABORDAGEM DCC-GARCH**

Dissertação apresentada ao Programa de Pós Graduação em Economia, do Instituto Brasileiro de Ensino, Desenvolvimento e Pesquisa, como requisito parcial para obtenção do grau de Mestre.

Aprovado em 25 / 11 / 2024

Banca Examinadora

Prof. Dr. Mathias Schneid Tessmann - Orientador

Prof. Dr. Luiz Ricardo Mattos Teixeira Cavalcante

Prof. Dr. Luiz Augusto Ferreira Magalhães

F383i Ferreira, Noemi da Silva
Influências macroeconômicas na volatilidade dos derivativos de commodities brasileiros: uma abordagem DCC-GARCH / Noemi da Silva Ferreira. – Brasília: IDP, 2024.

68 f.
Inclui bibliografia.

Dissertação – Instituto Brasileiro de Ensino, Desenvolvimento e Pesquisa – IDP, Mestrado Profissional em Economia, Brasília, 2024.
Orientador: Prof. Dr. Mathias Schneid Tessmann.

1. Volatilidade. 2. Derivativos futuros. 3. Juros- chave. I. Título.

CDD: 330

Ficha catalográfica elaborada pela Biblioteca Ministro Moreira Alves
Instituto Brasileiro de Ensino, Desenvolvimento e Pesquisa

AGRADECIMENTOS

Dedico todas as obras de minhas mãos a aquele que é o dono da vida e que concede contentamento e felicidade plena. A Jesus meu Senhor e Salvador.

Agradeço a todos que me guiaram na jornada da vida, especialmente aos meus pais. Minha mãe Miriam da Silva Ferreira, e ao meu pai Ananias Ferreira dos Santos “in memoriam”, que me ensinaram valores e princípios elevados e sobretudo amaram a mim e meus irmãos e dedicaram-se a construir pessoas de bom caráter.

Ademais, dedico aos meus bisavós e avós, tios e irmãos. E a todos os professores que tive em minha jornada, inclusive aqueles que em alguns momentos, mesmo sem diploma, me ensinaram ações práticas tão importantes para viver a vida, de forma simples e feliz.

Por fim, agradeço ao professor Orientador: Dr. Mathias Schneid Tessmann e aos professores que fizeram parte da banca: Dr. Luiz Augusto Ferreira Magalhães e Dr. Luis Ricardo Mattos T. Cavalcante.



**Bendiga o Senhor a minha alma!
Não esqueça nenhuma de suas bênçãos!**

RESUMO

Este trabalho busca investigar a relação entre derivativos futuros de commodities e de variáveis macroeconômicas ao identificar as influências das volatilidades do câmbio, juros e risco país nas volatilidades dos preços futuros do boi gordo, café, milho e soja negociados no Brasil. Para isso, são considerados o modelo DCC-GARCH e dados diários de dezembro de 2013 a outubro de 2024. Os resultados indicam que o risco-país apresenta uma associação positiva com a volatilidade dos derivativos de boi gordo, soja e café, enquanto exerce uma associação negativa com o milho. A taxa de juros tem uma influência negativa sobre boi gordo, soja e café, mas uma relação muito fraca e ligeiramente positiva com o milho. Em relação à taxa de câmbio, observa-se que o milho e a soja respondem de forma positiva à sua volatilidade, enquanto o boi gordo e o café apresentam uma associação negativa. Esses resultados podem ser úteis para investidores, produtores e analistas interessados em compreender melhor as flutuações dos preços das commodities agrícolas, especialmente no contexto de gestão de riscos e tendências econômicas.

Palavras-chave: Volatilidade, Derivativos futuros, Commodities, Macroeconomia, DCC-GARCH.

Classificação JEL: G13, C58, Q02, Q14, E44

ABSTRACT

This study aims to investigate the relationship between commodity futures derivatives and macroeconomic variables by identifying the influences of exchange rate, interest rate, and country risk volatilities on the volatilities of the futures prices of live cattle, coffee, corn, and soybeans traded in Brazil. The DCC-GARCH model and daily data from December 2013 to October 2024 are considered for this purpose. The results indicate that country risk has a positive association with the volatility of live cattle, soybean, and coffee derivatives, while showing a negative association with corn. The interest rate has a negative influence on live cattle, soybean, and coffee, but a very weak and slightly positive relationship with corn. Regarding the exchange rate, it is observed that corn and soybeans respond positively to its volatility, while live cattle and coffee show a negative association. These results may be useful for investors, producers, and analysts interested in better understanding the fluctuations in agricultural commodity prices, especially in the context of risk management and economic trends.

Keywords: Volatility, futures derivatives, commodities, macroeconomics, DCC-GARCH.

LISTA DE ABREVIATURAS E SIGLAS

APARCH	Asymmetric Power Autoregressive Conditional Heteroskedasticity
ARCH	Autoregressive Conditional Heteroskedasticity
ARFIMA	AutoRegressive Fractionally Integrated Moving Average
ARIMA	AutoRegressive Integrated Moving Average.
B3	Brasil, Bolsa, Balcão
CDI	Certificado de Depósito Interbancário
DCC-GARCH	Dynamic Conditional Correlation Generalized Autoregressive Conditional Heteroskedasticity
GJR-GARCH	Variação do modelo Garch, cujas as siglas GJR fazem referencias ao nomes dos autores: Glosten, Jagannathan e Runkle (1993), que propuseram o modelo.
DCC-MIDAS	Dynamic Conditional Correlation - Mixed Data Sampling
EWZ	iShares MSCI Brazil ETF
FIGARCH	Fractionally Integrated Generalized Autoregressive Conditional Heteroskedasticity
GARCH	Generalized Autoregressive Conditional Heteroskedasticity - Mixed Data Sampling
MIDAS	Mixed Data Sampling
USD/BRL	Dólar Americano / Real brasileiro

LISTA DE ILUSTRAÇÕES

Figura 1 Logaritmos Naturais das Séries de Commodities	32
Figura 2 Logaritmos Naturais das Variáveis Macroeconômicas	32
Figura 3 Histograma das Séries de Commodities	35
Figura 4 Histograma das Séries das Variáveis Macroeconômicas	35
Figura 5 Volatilidade e Resíduos – Série Boi Gordo	44
Figura 6 Volatilidade e Resíduos – Série Café	46
Figura 7 Volatilidade e Resíduos – Série Milho	47
Figura 8 Volatilidade e Resíduos – Série Soja	49
Figura 9 Correlação Condicional Dinâmica – Série Boi Gordo	51
Figura 10 Correlação Condicional Dinâmica – Série Café	55
Figura 11 Correlação Condicional Dinâmica – Série Milho	57
Figura 12 Correlação Condicional Dinâmica – Série Soja	59

LISTA DE TABELAS

Tabela 1 Estatística Descritiva	34
Tabela 2 Teste de Jarque Bera e Ljung Box das séries temporais	36
Tabela 3 Estacionalidade das Séries	41
Tabela 4 Estimativa GARCH Univariado – Série Boi Gordo	43
Tabela 5 Estimativa GARCH Univariado – Série Café	45
Tabela 6 Estimativa GARCH Univariado – Série Milho	46
Tabela 7 Estimativa GARCH Univariado – Série Soja	48
Tabela 8 Resultados DCC-GARCH para o Boi Gordo	49
Tabela 9 DCC-GARCH – Média das Correlações Condicionais: Boi Gordo	50
Tabela 10 Resultados DCC-GARCH para o Café	53
Tabela 11 DCC-GARCH – Média das Correlações Condicionais: Café	53
Tabela 12 Resultados DCC-GARCH para o Milho	55
Tabela 13 DCC-GARCH – Média das Correlações Condicionais: Milho	56
Tabela 14 Resultados DCC-GARCH para a Soja	57
Tabela 15 DCC-GARCH – Média das Correlações Condicionais: Soja	58

SUMÁRIO

1. INTRODUÇÃO 14

2. REVISÃO DE LITERATURA 18

2.1 VOLATILIDADE E FATORES MACROECONÔMICOS 18

2.2 LITERATURA INTERNACIONAL 20

2.3 LITERATURA NACIONAL 22

3. METODOLOGIA 29

3.1 DADOS 29

3.2 MODELO GARCH UNIVARIADO 36

3.3 MODELO GARCH MULTIVARIADO 37

3.3.1 MODELAGEM UNIVARIADA DE VOLATILIDADE 38

3.3.2 ESTRUTURA E ESPECIFICAÇÃO DO MODELO DCC-GARCH 38

3.3.3 PROCESSO DE ESTIMATIVA DOS PARÂMETROS 38

3.3.4 INTERPRETAÇÃO DAS CORRELAÇÕES DINÂMICAS 39

3.3.5 VALIDAÇÃO DO MODELO 39

4. RESULTADOS 41

4.1 TESTES DE ESTACIONARIEDADE 41

4.2 MODELOS GARCH UNIVARIADOS 42

4.2.1 BOI GORDO 42

4.2.2 CAFÉ 45

4.2.3 MILHO 46

4.2.4 SOJA 48

4.3 MODELO MULTIVARIADO – DCC GARCH 49

4.3.1 DCC-GARCH BOI GORDO 49

4.3.2 DCC-GARCH CAFÉ 52

4.3.3 DCC-GARCH MILHO 55

4.3.4 DCC-GARCH SOJA 57

4.4 PERSISTÊNCIAS DAS SÉRIES 59

5. CONCLUSÃO 62

REFERÊNCIAS 65



1

INTRODUÇÃO

As commodities desempenham um papel proeminente tanto na economia global quanto na brasileira, e são importantes para o bom funcionamento de diversos setores e para a estabilidade econômica do país. No mercado global, as commodities representam uma parte significativa do comércio internacional, servindo como matéria-prima para a produção de uma ampla variedade de bens e produtos e são de particular importância para o Brasil, que possui vantagens comparativas nesse segmento devido a sua grande extensão e diversidade climática. De acordo com a EMBRAPA atualmente o Brasil, é um dos maiores produtores e exportadores mundiais de produtos agrícolas como soja, milho, café e açúcar, essa trajetória foi construída nos últimos 40 anos, em que o país mudou sua trajetória saindo da condição de importador de alimentos para se tornar um grande provedor para o mundo.

Por definição, commodities são bens primários padronizados e comercializados em mercados globais. Esses produtos podem ser divididos em duas categorias principais: commodities agrícolas, como soja, milho, café e açúcar; e commodities minerais e energéticas, como petróleo, gás natural, minério de ferro e ouro. Elas são necessárias para diversas indústrias, tais como: de alimentos, de energia, de construção e manufatura. A comercialização das commodities contribui para a estabilização dos preços globais, pois a negociação em mercados futuros permite a previsão e o gerenciamento de riscos associados à oferta e à demanda.

Como é possível ver em Assaf (2000), os mercados futuros e de opções propiciam aos investidores uma tomada de decisão mais técnica quanto às alternativas de investimento em condições de risco. Esses derivativos oferecem proteção contra prejuízos ocasionados por alterações desfavoráveis nas cotações de ativos. Os mercados futuros e de opções permitem que os investidores integralizem os seus investimentos em seus vencimentos, desde que as cotações de mercado lhes sejam adversas. Mesmo que possam perder o depósito efetuado, o prejuízo tende a ser menor do que se houvesse a obrigação de pagamento futuro. O uso de derivativos no mercado financeiro oferece várias vantagens: i) maior atração ao capital de risco,

permitindo uma garantia de preços futuros para os ativos; ii) criação de defesas contra variações adversas nos preços; iii) estímulo à liquidez do mercado físico; iv) melhor gerenciamento do risco e, por consequência, redução dos preços dos bens; v) possibilidade de realizar negócios de maior porte com um volume relativamente pequeno de capital e nível de conhecimento de risco.

A Bolsa de valores oficial do Brasil: B3 (Brasil, Bolsa, Balcão) permite a negociação de contratos futuros. Esse tipo de contrato trata-se de uma obrigação entre as partes de comprar ou vender determinado ativo em uma data futura, a um preço preestabelecido. Eventuais variações no preço ajustado em relação a determinado valor de referência são cobradas ou pagas pelos compradores e vendedores. Os principais produtos e instrumentos financeiros negociados a futuro são produtos agropecuários, taxas de juros, taxa de câmbio, ouro, índice Bovespa, entre outros. Nesse mercado os participantes são: Hedgers (investidores que buscam proteção quanto a flutuações de preços de diversos ativos), especuladores (investidores que buscam ganhos financeiros, assumindo o risco de variação) e arbitradores – participantes que procuram obter vantagens financeiras ao perceber que os preços em dois ou mais mercados apresentam-se distorcidos) — conceitos extraídos de Assaf (2000).

Os preços no mercado futuro podem apresentar grandes variações (volatilidade) durante o período de vigência dos contratos, permitindo que se realizem ganhos ou perdas expressivas. Essas perdas e ganhos não ficam restritos apenas aos fundamentos microeconômicos, visto que o Brasil, com sua vasta produção agrícola, depende fortemente das exportações de commodities, que são essenciais para a balança comercial e a geração de renda. Por conseguinte, essa produção agrícola necessita de mecanismos de hedge bem fundamentados que forneçam aos produtores e compradores um mercado de futuros eficiente.

Dentro deste contexto, é crucial compreender os fatores que influenciam os preços das commodities, especialmente no que diz respeito à volatilidade desses preços. A volatilidade das commodities pode ter impactos significativos em diversos setores da economia, afetando desde os produtores rurais até os consumidores finais, passando pelos investidores e formuladores de políticas públicas.

Assim, este trabalho busca analisar a relação entre derivativos futuros das commodities boi gordo, café, milho e soja negociadas no Brasil e variáveis macroeconômicas juros, câmbio e risco país. O qual postulamos que essas variáveis influenciam a volatilidade das commodities. Utilizamos o modelo DCC-GARCH que conforme proposto por Engle (2002) é adequado para capturar variação na dependência entre séries temporais. Essa modelagem foi escolhida, por haver suspeitas de que as correlações entre as commodities e os fatores macroeconômicos não eram constantes no tempo e que haveriam correlações condicionais dinâmicas. Os resultados comprovaram a correlação condicional visto que as relações entre as séries (comodities e fatores macroeconômicos) não se mostraram fixas no tempo e foi evidenciada a influência dos choques na volatilidade. O que demonstrou que o modelo capturou a dinâmica.

Os resultados obtidos com a modelagem DCC-GARCH demonstraram que as variáveis macroeconômicas exercem alguma influência sobre a volatilidade das commodities. Para os derivativos futuros boi gordo foi evidenciada pouca influência das variáveis juros, risco país e câmbio. O café é afetado moderadamente pelas séries câmbio e risco país. O preço do café diminui quando o câmbio é apreciado e os preços se elevam quando o risco país aumenta. O câmbio é a variável que mais influencia a volatilidade do derivativo futuro milho, já o risco país e os juros exercem influências menores sobre a volatilidade. A soja possui elevada sensibilidade aos choques no câmbio e no risco país.

Espera-se que este estudo contribua para a literatura acadêmica ao investigar, com base na metodologia DCC-GARCH, a dinâmica e o comportamento dos derivativos futuros de commodities agrícolas brasileiras em resposta a variáveis macroeconômicas.

Além desta introdução, o trabalho é composto por mais quatro seções. A segunda seção fornece uma breve revisão da literatura sobre o tema. A terceira seção detalha a base de dados e o modelo econométrico empregados. A quarta seção apresenta e analisa os resultados. Finalmente, a quinta seção traz as conclusões.



2

REVISÃO DE LITERATURA

A revisão de literatura foi dividida em subtópicos: i) Volatilidade e fatores macroeconômicos, que apresenta o referencial teórico sobre a formação de preços no mercado de derivativos futuros, com foco em commodities, na qual destaca a teoria da estocagem e os fenômenos contango e backwardation que se relacionam com fatores macroeconômicos; ii) Literatura Internacional, expõe trabalhos que estudaram a influência de fatores macroeconômicos na volatilidade de derivativos futuros de commodities e métodos econométricos usados para captar essa influência; iii) Literatura Nacional, externa trabalhos que analisaram a volatilidade das commodities futuros com vários modelos (ARCH, GARCH, APARCH, EGARCH, ARFIMA e GARCH-MIDAS).

2.1 VOLATILIDADE E FATORES MACROECONÔMICOS

Para entender a volatilidade dos derivativos futuros de commodities, faz-se necessário recorrer ao conhecimento teórico sobre a formação dos preços neste mercado. Conforme Assaf (2000) os preços no mercado futuro diferem dos praticados no mercado à vista, são geralmente superiores pela presença de custo de carregar uma determinada posição física até a data de vencimento do contrato. Esses custos de carregamento inclui o armazenamento do produto (commodities), aluguel de locais apropriados para conservação, transporte, seguros, custo financeiro do capital aplicado no estoque mais o prêmio pela incerteza quanto ao comportamento dos preços no mercado, que são explicados por diversos fatores

Oliveira (2020) descreve que os preços formados nos mercados à vista e futuro deveriam, supostamente, seguir trajetórias paralelas. Uma queda no preço à vista deveria ser acompanhada por uma queda proporcional no preço do contrato futuro, devido aos princípios de arbitragem que regem a formação de preços futuros. No mercado de commodities, o processo de formação de preços futuros pode romper as regras de arbitragem, causando fenômenos denominados como contango e backwardation, que podem ser explicados pela teoria da estocagem.

Contango ocorre quando o preço dos contratos futuros é superior ao preço à vista atual da commodity. Esse fenômeno indica que os participantes do mercado esperam que o preço da commodity aumente no futuro. As principais razões para que ocorra esse fenômeno são: i) Custos de Armazenagem (o custo de armazenar a commodity até a data de entrega do contrato futuro pode elevar o preço do contrato); ii) Custos de Financiamento; iii) Expectativas de Preço (se os participantes do mercado acreditarem que os preços das commodities subirão).

Backwardation ocorre quando o preço à vista da commodity é superior ao preço dos contratos futuros. Esse fenômeno sugere que os participantes do mercado esperam que o preço da commodity diminua no futuro. As principais razões para que este efeito ocorra são: i) Demanda Imediata Alta, porque pode elevar o preço à vista acima do preço futuro; ii) Custo de Armazenagem Negativo; iii) Expectativas de Queda de Preço (os participantes do mercado acreditam que os preços das commodities vão cair).

Conforme Oliveira (2020) A Teoria da Estocagem busca explicar as diferenças de preços entre os mercados à vista e futuro de commodities. Em certos momentos, o preço à vista pode superar o preço no mercado futuro devido ao benefício que o detentor da mercadoria física tem ao manter os estoques e esperar por melhores preços para realizar a venda. Ao tomar essa decisão, o detentor do estoque deve considerar variáveis importantes, como taxas de juros, sazonalidade dos preços, custo de armazenagem e o benefício esperado com o aumento do preço de venda.

Adotando o pressuposto, de que a formação dos preços no mercado de Derivativos futuros das commodities não seguem regras de arbitragem em que os preços futuros e à vista de commodities seguem trajetórias paralelas, na qual o desvio desta relação pode ser explicado pelos fenômenos de contango e backwardation, que são influenciados pela demanda e expectativa dos agentes econômicos, faz sentido analisar a influência das variáveis macroeconômicas na volatilidade das commodities futuras.

Neste modelo, utilizaremos as variáveis macroeconômicas taxa de juros, risco país e taxa de câmbio, que se relacionam diretamente com a demanda e as expectativas dos agentes econômicos da seguinte forma: i) o risco país serve como uma proxy para o mercado de ações

brasileiro, refletindo o ambiente de investimento e podendo influenciar a demanda e as expectativas sobre retornos; ii) a taxa de câmbio está associada à competitividade das exportações e ao custo de importações, impactando as expectativas de preços no setor de commodities; iii) e a taxa de juros, como indicador de taxa de juros doméstica, influencia as expectativas dos agentes em relação ao custo de capital e às decisões de investimento.

2.2 LITERATURA INTERNACIONAL

A literatura internacional para esse trabalho é importante por dois aspectos: i) apresentar trabalhos que realizaram estudos em que são analisadas influências de fatores macroeconômicos na volatilidade das commodities; e ii) apresentar estudos que realizaram ensaios econométricos que abordaram a modelagem DCC-GARCH. Portanto o referencial teórico, apesar de muitas das vezes adotar modelos diferentes apresentam aspectos interessantes que agregam valor ao nosso objetivo de averiguar as influências da taxa de juros, taxa de câmbio e risco país para os derivativos futuros de commodities Boi Gordo, Café, Milho e Soja

Mo et al, no estudo sobre a volatilidade dos mercados de futuros de commodities na China e na Índia, analisaram diversas commodities e variáveis macroeconômicas para compreender suas dinâmicas. Para o mercado chinês, as commodities futuras analisadas incluíram cobre, alumínio, níquel, ouro, soja, óleo de soja, milho e açúcar. As variáveis macroeconômicas consideradas para este mercado foram o Índice de Preços ao Consumidor (CPI), o Produto Interno Bruto (GDP), a Produção Industrial (IP), a Oferta de Dinheiro (M2), o Indicador Líder Composto da China (CLI_C), o Índice de Confiança do Consumidor (CCI), o Índice de Ações (STOCK), a Taxa de Juros de Curto Prazo (IR), o Spread de Prazo (T-spread) e a Taxa de Câmbio Real Efetiva do Yuan Chinês (CNY). Para o mercado indiano, as commodities futuras analisadas incluíram cobre, ouro, soja, óleo de soja, milho, açúcar e óleo combustível. As variáveis macroeconômicas utilizadas para a Índia foram o Índice de Preços ao Consumidor (CPI), a Produção Industrial (IP), a Oferta de Dinheiro (M2), o Índice de Ações (STOCK), a Taxa de Juros de Curto Prazo (IR), o Spread de Prazo (T-spread), o Indicador Líder Composto da Índia (CLI-IND) e a Taxa de Câmbio Real Efetiva das Rúpias Indianas (INR).

Mo et al (2018) menciona a importância de compreender a dinâmica da volatilidade para adoção de estratégias de otimização das

carteiras de derivativos futuros, para atender as necessidades de produtores, investidores, consumidores em fazer suas escolhas ótimas de investimentos. Os autores estudaram os mercados emergentes de derivativos futuros de commodities, na qual consideraram o impacto macroeconômico no preço das commodities, com a finalidade de responder as perguntas: i) mudanças nas variáveis macroeconômicas determinam a volatilidade a longo prazo das commodities futuras; ii) A incerteza nas variáveis macroeconômicas determina a volatilidade a longo prazo desses ativos. Como conclusão demonstraram que a volatilidade das commodities futuras podem ser afetadas pelas condições econômicas internas e pela situação internacional do ambiente macroeconômico. E no caso específico do mercado chinês os resultados apontaram que tanto as variáveis macroeconômicas nacionais como internacionais têm um fraco impacto econômico na volatilidade das commodities.

O trabalho de Amendola et al. (2017) avaliou a influência da política monetária dos EUA na volatilidade do preço da commodity petróleo bruto, construindo um intervalo de confiança em torno dos preços previstos, porque a volatilidade deste ativo tem implicações na gestão de risco, preços de ativos e gestão de carteira. Investigaram o impacto dos determinantes macroeconômicos tradicionais do petróleo bruto, juntamente com a política monetária dos EUA, na volatilidade diária do petróleo bruto. Consideraram diferentes proxies da taxa diretora dos EUA, juntamente com a procura agregada dos EUA (representada pela produção industrial dos EUA) e a oferta de petróleo dos EUA como determinantes da volatilidade.

O modelo DCC-GARCH tem sido empregado em diversos estudos como uma ferramenta robusta para a análise da dinâmica de volatilidade e correlação em mercados financeiros, sendo amplamente utilizado em estudos sobre risco sistêmico, diversificação de carteiras e interdependência entre mercados. Sua origem remonta do estudo realizado por Engle (2002) que propôs uma classe de modelo GARCH, denominados modelo de Correlação Condicional Dinâmica (DCC). Esse modelo apresenta vantagem computacional sobre o GARCH multivariado porque permite que o número de parâmetros a ser estimado no processo de correlação, independente do número de séries envolvidas, permitindo assim a estimação de matrizes de correlação muito grandes. Empiricamente, Engle (2002) demonstra que o modelo DCC-GARCH fornece uma boa aproximação para diversos processos de correlação variável ao longo do tempo.

Swamy (2020) utilizou o modelo DCC-GARCH para investigar como o índice de ações indiano (NIFTY 50) e 4 índices de commodities: não agrícolas (MCX Energy e MCX Metal) e agrícolas (Bharanya e MCX Agri) se movimentam juntos ao longo do tempo e como a volatilidade de um mercado afeta o outro mercado. Os resultados obtidos demonstraram que as combinações de ações com commodities tem correlações mais baixas e negativas e que essa diversificação é uma boa alternativa para os investidores. Eles também demonstraram que diversificar commodities não agrícolas com agrícolas aprimora a cesta de investimentos.

Jang et al (2019) investigou a relação dinâmica entre o mercado global de Petróleo e o mercado de commodities da China. Utilizaram o modelo denominado DCC-GJR-GARCH, cujo GJR-GARCH, modela a volatilidade dos retornos, considerando que os choques negativos podem afetar mais a volatilidade que os positivos. E demonstraram em seus resultados que mudanças no mercado de petróleo afetam diretamente os retornos das commodities chinesas e que existe uma ligação de longo prazo e que varia com o tempo entre a volatilidade do petróleo e as commodities chinesas.

Mishra et al (2024) utilizou o DCC-GARCH para averiguar correlações dinâmicas entre os preços das commodities agrícolas: arroz, trigo, grão-de-bico, banana, amendoim, cebola, batata e cana de açúcar. Os resultados obtidos demonstraram que o grão de bico tem forte correlação condicional com outras culturas (banana, amendoim, cebola e batata) por longo período. E que mudanças no preço do arroz influenciam os preços das commodities agrícolas analisadas.

2.3 LITERATURA NACIONAL

No campo da literatura nacional consideramos trabalhos que realizaram estudos sobre os derivativos futuros de commodities agrícolas boi gordo, café, milho e soja, e empregaram métodos econométricos da família GARCH. Campos (2007) utilizou os modelos ARCH e GARCH para analisar a volatilidade das séries de retornos mensais de quatro commodities: Soja, café, Milho e boi gordo, com o objetivo de fornecer subsídios para o delineamento de estratégias adequadas ao gerenciamento do risco de variações nos preços dessas commodities.

Campos (2007) indica que as flutuações cíclicas e, ou, sazonais dos preços dos produtos agropecuários provocam instabilidade tanto na renda do produtor como nas despesas dos consumidores urbanos. Essa instabilidade pode provocar desestímulos à produção em períodos de baixa dos preços ou excesso de produção em períodos de preços muito elevados. Assim, é necessário conhecer o padrão de flutuação sazonal ou a volatilidade desses preços, para que possam ser implementadas políticas de estabilização dos preços dos produtos agropecuários ao longo do ano. A oscilação na renda de produtores e investidores, proveniente de flutuações nos preços agropecuários, configura-se como um problema cujas características e causas devem ser amplamente pesquisadas, dada a importância da commodity para o agronegócio nacional e dadas as perdas que essas flutuações podem provocar tanto na lucratividade para o setor quanto nos empregos e divisas para o Brasil.

Silva (2005) em seu artigo investigou a volatilidade dos retornos do café e da soja, duas importantes commodities agrícolas brasileiras, focando na persistência de choques e assimetrias na volatilidade. A metodologia adotada consistia em três variantes do modelo ARCH (GARCH, EGARCH e TARARCH) para analisar a volatilidade das séries de retornos mensais do café (1967-2002) e da soja (1957-2002). Os dados são séries de preços mensais à vista em dólares, e os retornos são calculados como a diferença logarítmica dos preços consecutivos. Os modelos mostraram que tanto o café quanto a soja apresentam assimetria na volatilidade, com choques negativos tendo um impacto maior que choques positivos. Os choques de volatilidade são persistentes, levando vários períodos para se dissiparem. E esta persistência indicam a necessidade de políticas que facilitem o acesso dos produtores a instrumentos de hedging baseados no mercado para gerenciar o risco e minimizar a exposição à volatilidade dos preços dessas commodities.

Ceretta et al. (2007) analisaram o comportamento temporal das taxas de retorno e da volatilidade de cinco commodities agrícolas (algodão, café, milho, soja e trigo) no mercado brasileiro e descreveram que entender o comportamento da volatilidade ao longo do tempo possibilita aos investidores estruturarem estratégias de negociação baseada em hedging para fazer frente a instabilidade do mercado. O bom gerenciamento do risco na comercialização é dependente de uma boa previsão da oscilação de preço das commodities agrícolas. A forma tradicional de se aferir a volatilidade de qualquer ativo é através do seu

desvio padrão, que nada mais é do que uma perspectiva histórica de sua variação, ao qual se assume que o comportamento é constante ao longo do tempo. Porém, no contexto das finanças, o valor histórico e constante não é o mais importante, pois se busca entender a dinâmica relacionada ao futuro, e o futuro, mesmo tendo raízes no passado, não se comporta de modo estático.

Ceretta et al. (2007) apresentam o histórico de modelagens, descrevendo que Engle (1982) foi um dos estudiosos pioneiros a focar a utilização da volatilidade condicional antes da volatilidade não condicional. Relativo ao comportamento condicional, os modelos GARCH têm sido as ferramentas mais amplamente utilizadas para capturar as oscilações da volatilidade ao longo do tempo. Os modelos GARCH capturam as oscilações na volatilidade condicional observando o erro ao quadrado e a própria volatilidade condicional em períodos anteriores.

Freitas e Safadi (2015) estimaram a persistência e o efeito alavancagem da volatilidade nas principais séries de retornos de commodities agropecuárias brasileiras, utilizando o modelo APARCH4 a fim de capturar características de cauda pesada, excesso de curtose e efeito alavancagem nas séries de retornos de produtos como açúcar, soja, café, boi gordo, entre outros. Os resultados apresentados não confirmaram a existência de efeito alavancagem nas séries estudadas. O coeficiente de potência assimétrica δ não foi significativo para as séries de retorno do açúcar e da soja, sugerindo a viabilidade de modelos mais simples. As séries dos retornos do etanol e do bezerro apresentaram persistência elevada na volatilidade condicional, sem reversão rápida à média histórica.

O açúcar, soja, café, trigo, frango e boi gordo mostraram volatilidade intensa, com um lento processo de reversão. O arroz demonstrou dissipação rápida dos choques de volatilidade. Maiores volatilidades incondicionais foram encontradas nas séries de etanol, frango, algodão, soja e açúcar. A distribuição t simétrica ajustou melhor a maioria das séries, exceto soja e arroz, que ajustaram melhor com a distribuição normal. A principal contribuição desse trabalho foi demonstrar que, embora o modelo APARCH tenha captado a intensa volatilidade das séries de retornos, a ausência de efeito alavancagem sugere que choques positivos e negativos têm impactos semelhantes na volatilidade (Freitas e Safadi, 2015).

Bayer et al. (2008) em seu estudo, buscou prever a média condicional e a volatilidade dos preços da soja e do milho no mercado do Rio Grande do Sul utilizando modelos ARFIMA-GARCH. Para analisar e prever os preços e a volatilidade das commodities soja e milho, a análise baseou-se em dados históricos de preços, levando em consideração a longa memória dos preços e a variância não constante. Os modelos ARFIMA¹ (1, d, 0) – GARCH (0, 1) para a soja e ARFIMA (1, d, 2) – GARCH (0, 2) para o milho foram eficazes na modelagem dos dados. Foi possível fornecer previsões de curto prazo, identificando tendências de alta nos preços que aumentam a volatilidade até estabilizar em um novo patamar. Esta análise empírica mostrou que os modelos ARFIMA-GARCH são adequados para prever preços e volatilidade, sendo essenciais para a tomada de decisões no agronegócio. A pesquisa sugere utilização dos modelos FIGARCH² em novos estudos.

De Moraes (2023) utilizou a abordagem de Diebold e Yilmaz (2012) para investigar o spillover de volatilidade direcional³ entre os mercados de commodities agrícolas, o petróleo da West Texas Intermediary - WTI, S&P 500, REITs, Treasury e ICE com base no modelo FEV/VAR juntamente com o índice spillover. Para analisar o comportamento da variável de volatilidade das variações de preço ao longo do tempo das commodities e os índices financeiros em um período de 2014 a 2021. Os resultados apresentam evidências da inexistência de uma rede conectividade de volatilidade entre as variações dos preços dos WTI e as commodities agrícolas. Índice spillover de volatilidade entre commodities-WTI e commodities-índices financeiros evidenciaram que a interação entre esses mercados, foram afetados durante o Covid-19, com repercussões positivas e negativas.

¹ O modelo ARFIMA é uma extensão do modelo ARIMA que permite a inclusão de componentes de integração fracionária. Ele é usado para modelar séries temporais que exibem dependência de longo alcance, ou seja, séries em que as observações mais antigas ainda influenciam as observações mais recentes, mesmo que essa influência diminua gradualmente ao longo do tempo. Isso é especialmente útil em séries financeiras, onde a volatilidade pode ser persistente e exibir comportamento de longa memória

²FIGARCH (Fractionally Integrated Generalized Autoregressive Conditional Heteroskedasticity) é uma extensão do modelo GARCH que permite modelar a persistência de longa memória na volatilidade condicional de uma série temporal financeira

³ O spillover de volatilidade direcional refere-se à transferência de volatilidade de um mercado ou ativo financeiro para outro, onde essa transferência tem uma direção específica. Em outras palavras, ele descreve como a volatilidade de um mercado (ou ativo) influencia a volatilidade de outro mercado (ou ativo) de forma direcionada, capturando a assimetria ou a direção do impacto.

Do et al. (2007) aborda que a volatilidade pode ser expressa pelos movimentos oscilatórios dos preços dos produtos de commodities negociados na Bolsa de Mercadorias e Futuros. Quanto mais voláteis forem esses preços, maiores serão os riscos desse investimento. A volatilidade pode definir-se como uma medida da intensidade das variações dos retornos dos preços. Assim, pode-se dizer que a volatilidade é uma variável aleatória que segue um processo estocástico. Qualquer modelo de volatilidade tem como finalidade descrever o comportamento da volatilidade passada e, através deste, prever a volatilidade futura. Uma característica importante no mercado financeiro é a existência de um comportamento assimétrico na volatilidade. Ou seja, períodos de elevada volatilidade tendem a ser mais persistentes do que os períodos de baixa volatilidade.

Uma maneira de fornecer subsídios para o delineamento de estratégias adequadas para o gerenciamento de variações nos preços de commodities agrícolas é verificada por Silva et al. (2005), que procuram analisar a volatilidade das séries de retornos mensais dos preços a partir dos modelos ARCH (heteroscedasticidade condicional autorregressiva). Dos Santos (2018) informa que Séries financeiras, em geral, dada a elevada probabilidade de eventos extremos, possuem assimetria diferente de zero e elevados valores de curtose, revelando a presença de caudas pesadas e agrupamentos de volatilidade (Morettin; Tolo, 2006; Bueno, 2011; Isengildina; Irwin; Good, 2016; Karali, 2012).

Conforme Brooks (2008), modelos de volatilidade condicional multivariados são uma extensão dos modelos univariados da família ARCH, tendo como principal diferença em relação aos modelos univariados o fato de que os modelos multivariados especificam equações que mostram como as covariâncias se movem conjuntamente ao longo do tempo. O termo GARCH multivariado refere-se ao modelo de séries temporais multivariadas nas quais as variâncias condicionais de cada série e as covariâncias condicionais entre as séries são estimadas simultaneamente a partir do método de máxima verossimilhança, sob a hipótese de erros gaussianos multivariados (ENGLE, 2002; BROOKS, 2008).

De acordo com Gaio (2006) foi possível observar em seu estudo que o mercado do boi gordo é suscetível a reações de persistência e assimetria na sua volatilidade. Ou seja, as variações dos retornos sofrem impactos diferenciados para boas e más notícias, o que pode ser comprovado pelos modelos GARCH, EGARCH e TARARCH gaussianos.

A literatura nacional sobre a volatilidade das commodities agrícolas evidencia o uso de técnicas econométricas avançadas para análise dos retornos e gerenciamento de riscos associados às flutuações de preços. Estudos como os de Campos (2007), Silva (2005), Ceretta et al. (2007), Freitas e Safadi (2015), Bayer et al. (2008), De Moraes (2023) e Dos Santos (2018) destacam a importância desses modelos para entender a dinâmica da volatilidade e implementar estratégias de hedging e políticas de estabilização de preços

Neste trabalho, a modelagem da volatilidade será conduzida utilizando o modelo DCC-GARCH, com o objetivo de avaliar o impacto das variáveis exógenas juros, risco país e câmbio sobre as volatilidades das séries de preços futuros das commodities boi gordo, café, milho e soja. Essas abordagens permitem captar não apenas os efeitos individuais das variáveis exógenas sobre a volatilidade de cada commodity, mas também as interdependências dinâmicas entre as volatilidades dessas séries.



3

3

METODOLOGIA

Nesta seção, descrevemos a metodologia adotada para avaliar as influências das variáveis exógenas — taxa de juros, risco país e taxa de câmbio — na volatilidade das séries de derivativos futuros das commodities agrícolas (boi gordo, café, milho e soja). O objetivo principal é capturar as dinâmicas de interdependência entre essas volatilidades e compreender como estas variáveis macroeconômicas influenciam o comportamento dos mercados de commodities. A proposta é realizar a modelagem DCC-GARCH multivariada, que possibilita a análise conjunta das volatilidades, revelando a interdependência entre as séries apresentadas.

3.1 DADOS

A base de dados utilizada neste trabalho consiste em observações com frequência diária dos preços de fechamento dos derivativos futuros de commodities agrícolas: boi gordo (live cattle) – BGI; CCM; café (café arábica) – ICF; milho (corn) – e, soja (soybeans) – SFI, negociadas na Bolsa de Valores Brasileira – B3. E as séries macroeconômicas: taxas de juros, risco Brasil e taxa de câmbio. Todas as séries possuem frequência diária (período de dezembro de 2013 até outubro de 2024).

As variáveis macroeconômicas consideradas são: Taxa de juros denominada CDI (DIJc2): Este indicador reflete a taxa média de juros praticada entre os bancos em transações de um dia. Como indicador de Risco Brasil utilizado a série EWZ (iShares MSCI Brazil ETF): Este índice busca refletir a performance do índice iShares MSCI Brazil Capped, composto por empresas brasileiras de médio e grande porte listadas na bolsa de valores. A finalidade dessa série é compreender a demanda internacional por empresas brasileiras. Ela indica a confiança dos investidores na economia brasileira. Os investidores terão expectativas de crescimento ou de recuperação quando o índice sobe e expectativas de retração quando o índice cai. Se o dólar cai o risco país aumenta e vice-versa.

Utilizamos o índice denominado USD/BR como proxy de câmbio: ele indica o valor do dólar americano em relação ao real brasileiro. A

variação dessa taxa pode ocorrer por diversas ações, tais como: políticas monetárias realizadas pela atuação do Banco Central, interações entre importações e exportações e outras. Flutuações na taxa de câmbio podem afetar os preços das commodities, porque boa parte delas são negociadas em dólares no mercado internacional.

Quando o real é apreciado frente ao dólar. Essa moeda estrangeira fica mais barata e o preço das commodities em reais aumentam, isto pode tornar as commodities brasileiras menos competitivas. Por outro lado, os exportadores perdem rentabilidade porque recebem menos em reais. Essa apreciação pode desestimular a produção ou realização de investimentos nos setores agrícolas. Quando o real é desvalorizado na relação cambial, o dólar fica mais caro, tornando as commodities brasileiras mais baratas para os compradores externos e a safra brasileira fica mais competitiva, o que pode gerar um aumento na demanda externa. Os exportadores recebem mais reais por cada dólar exportado, o que estimula a produção para atender os demandantes externos.

Como estamos realizando a modelagem DCC-GARCH, que tem como principal meta capturar a volatilidade condicional e as correlações dinâmicas entre as séries, todas as séries utilizadas foram transformadas em logaritmos naturais, visto que os retornos logarítmicos medem a variação percentual de um preço ao longo do tempo usando logaritmo natural. Essa ação foi feita para i) estabilizar a variância – a transformação logarítmica diminui a variabilidade das séries – Engle (2002); ii) aproximar-se da distribuição normal⁴, o que melhora os desempenhos dos modelos GARCH pois as séries financeiras frequentemente apresentam caudas mais pesadas. O cálculo do retorno logaritmo é feito da seguinte forma:

$$r_t = \ln \left(\frac{p_t}{p_{t-1}} \right) \quad (1)$$

onde r_t representa log retorno no tempo t , p_t é o preço da série no tempo t , p_{t-1} é da série no tempo anterior, e \ln é o logaritmo natural.

⁴ De Assis (2023) A transformação logarítmica estabiliza a variância, na situação em que as variâncias são proporcionais ao quadrado das médias dos tratamentos. Em alguns casos, pode contribuir para a normalização dos dados e para a adequação do modelo aditivo linear.

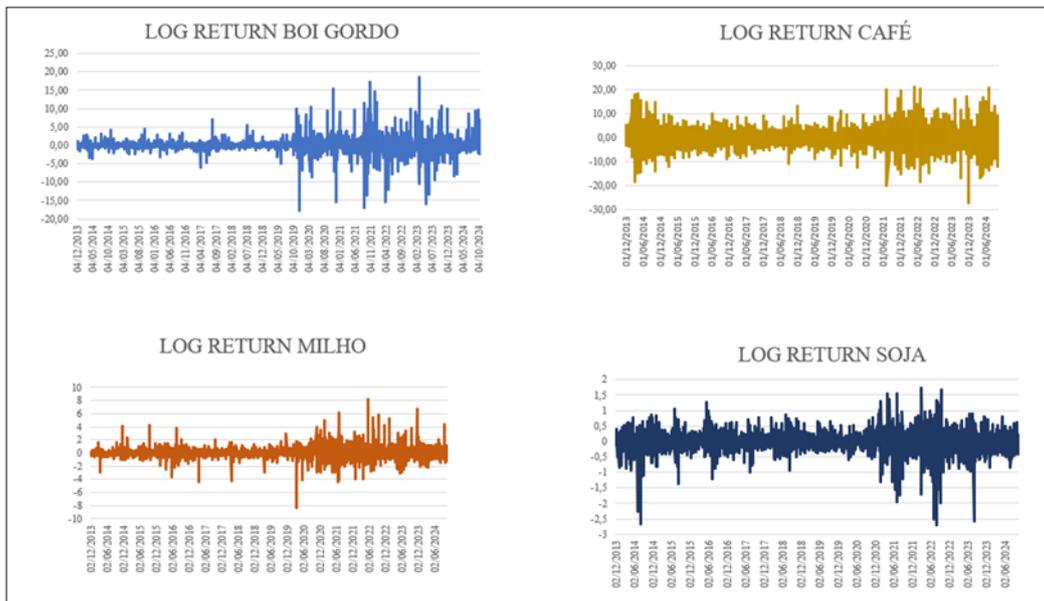
Conforme Alube (2007) a maioria dos estudos financeiros concentram-se na análise de séries de retornos ao invés do uso da série de preços. Ele cita Campbell et al (1997) para explicar a razão dessa preferência, que, está relacionada a dois fatos. Em primeiro lugar o retorno contém as informações que atendam aos interesses dos investidores e em segundo lugar a série possui propriedades estatísticas mais interessantes que a série de preços.

Apresentamos na figura 1, os gráficos dos retornos logarítmicos das séries de Commodities: boi gordo, café, milho e soja. Observamos que os retornos das séries boi gordo e milho apresentam baixa amplitude nos períodos iniciais (2013 a 2019), com oscilações relativamente contidas, enquanto, ao longo do tempo, a partir de 2019, os picos se tornam progressivamente mais acentuados, (serie boi gordo mais acentuada ainda que a série milho) indicando um aumento da volatilidade. Esse padrão sugere a presença de heterocedasticidade condicional crescente, característica comum em séries financeiras.

No gráfico café a amplitude é mais elevada nos períodos iniciais (2013 a 2014), refletindo uma volatilidade inicialmente intensa. Essa volatilidade se reduz no segmento intermediário da série (2015 a 2020), indicando um período de maior estabilidade, e volta a crescer ainda mais nos períodos finais, com picos mais pronunciados. Essa dinâmica evidencia uma estrutura de volatilidade em forma de U ao longo do tempo. A série temporal soja também apresenta a estrutura em forma de U, entretanto, se distingue-se pela ocorrência de amplitudes negativas significativamente mais acentuadas em determinados intervalos, sugerindo a presença de assimetria nos choques

A volatilidade mais alta pode refletir choques de mercado, incertezas políticas, mudanças estruturais ou eventos externos, enquanto os períodos de estabilização podem indicar período de maior previsibilidade

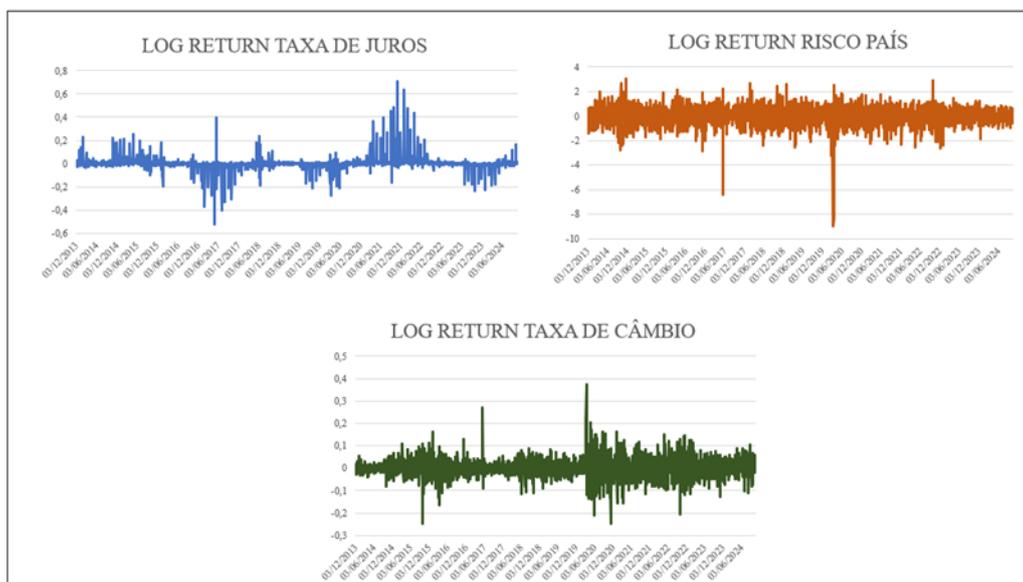
Figura 1 – Logaritmos Naturais das Séries de Commodities



Fonte: Elaborado pela autora

Na figura 2 apresentamos os gráficos dos retornos logarítmicos das variáveis macroeconômicas: taxa de juros, risco país e taxa de câmbio. A série da taxa de juros apresenta um comportamento oscilatório, marcado por sucessivos picos e vales que, visualmente, lembram formas triangulares ascendentes e descendentes. Essa estrutura reflete variações cíclicas, em que períodos de alta são seguidos por quedas, sugerindo um padrão de alternância que pode estar associado a decisões de política monetária ou à resposta do mercado frente a choques econômicos.

Figura 2 – Logaritmos Naturais das Variáveis Macroeconômicas



Fonte: Elaborado pela autora

A série do risco-país exibe uma variação oscilatória com picos positivos e negativos de amplitudes semelhantes ao longo do tempo. Essa configuração sugere uma alternância regular entre momentos de maior e menor percepção de risco. Há dois episódios em que a série apresenta quedas abruptas, configurando picos negativos acentuados. Esses eventos indicam choques pontuais de confiança ou mudanças bruscas na avaliação do ambiente econômico e político 2016 (pode estar relacionado a instabilidade política) e entre 2019 e 2020 (que pode estar relacionado a crise sanitária da covid 10).

A série de câmbio começa com variações moderadas, apresentando picos para cima e para baixo, com amplitudes menores. No decorrer do tempo, essas oscilações se intensificam, ampliando a amplitude dos picos. Durante esse processo, há um pico negativo acentuado que indica um choque ou um período de grande instabilidade nos períodos: 2016 e entre 2019 e 2020. Após esse evento, a volatilidade tende a diminuir, com os picos se tornando menores novamente. No entanto, ao longo da série, dois picos positivos mais pronunciados se destacam, sugerindo momentos de forte valorização da moeda em relação ao contexto anterior. Os choques na série cambial e risco país ocorreram no mesmo período entretanto respectivamente na primeira o pico foi negativo e na segunda positivo.

A Tabela 1 apresenta as principais estatísticas descritivas das séries que foram transformadas em séries logarítmica: média, desvio padrão, valores mínimos e máximo, curtose, assimetria. As médias das séries de preços futuros das commodities boi gordo 0, 0.073 e café 0.066 indicam retornos positivos moderado. milho e soja apresentam indicadores de média baixíssimo. O desvio padrão boi gordo e café apresentam maiores patamares indicando maior volatilidade. A curtose elevada em algumas séries (como juros) indica que as distribuições têm caudas mais pesadas do que a distribuição normal, o que é uma característica importante para modelos GARCH, pois sugere que a volatilidade pode ser mais extrema do que o previsto. A assimetria indica a direção das distribuições. Valores positivos (boi gordo) sugerem uma tendência à direita, enquanto valores negativos (soja) sugerem uma tendência à esquerda.

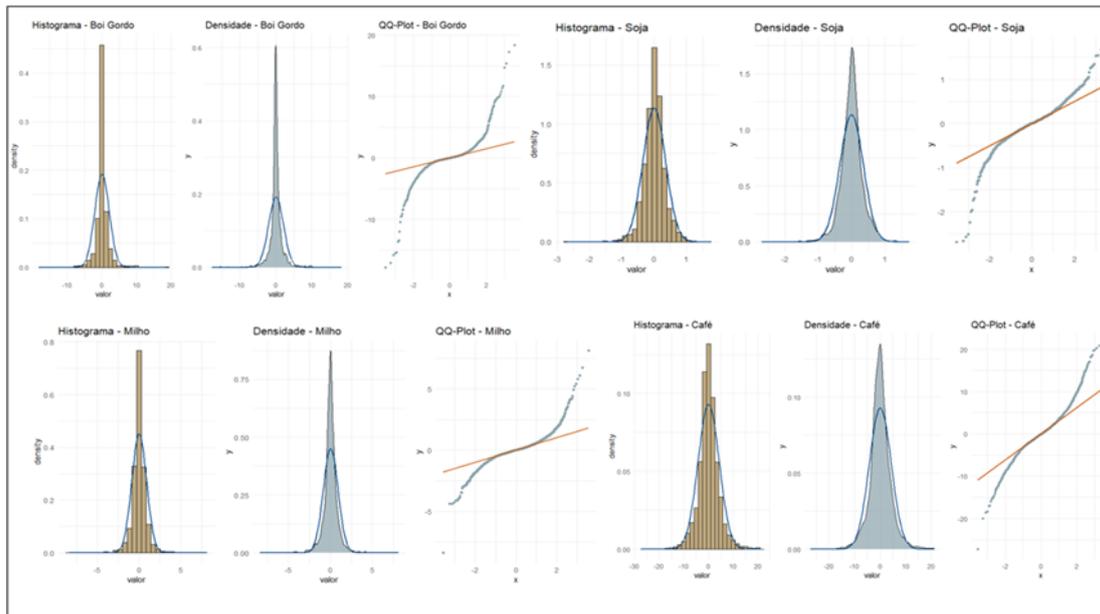
Tabela 1 – Estatísticas Descritivas

Séries	Média	Desvio Padrão	Mínimo	Máximo	Curtose	Assimetria
Boi Gordo	0.0735	2.0783	-17.8000	18.3800	22.2231	0.0602
Café	0.0661	4.2895	-27.3000	21.3000	6.5185	0.1856
Juros	0.0004	0.0484	-0.5200	0.7080	61.6491	2.9631
Risco País	-0.0064	0.7480	-8.9900	3.0300	18.8117	-1.5265
Milho	0.0158	0.8827	-8.3800	8.1100	15.7537	0.5210
Soja	-0.0029	0.3514	-2.6900	1.7300	10.5757	-0.8693
Câmbio	0.0012	0.0414	-0.2492	0.3728	8.9632	0.2680

Fonte: Elaborado pela autora

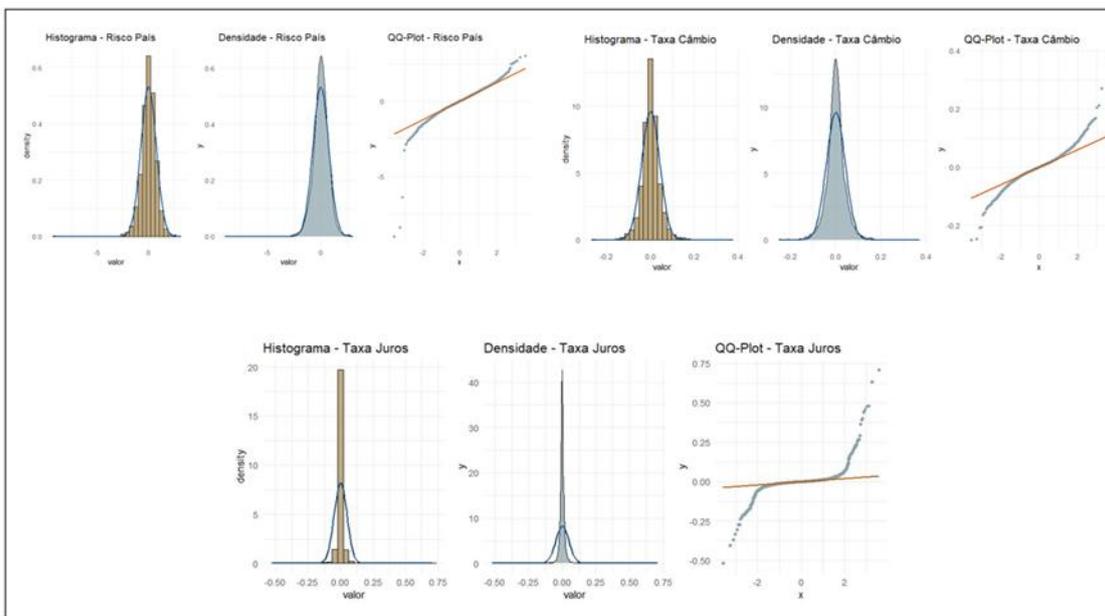
As figuras 3 e 4 demonstram as distribuições dos retornos logarítmicos das séries com maiores detalhes por meio dos histogramas de cada série. Neles, observamos as principais características das distribuições: dispersão dos dados, assimetrias e curtoses, além de identificar desvios em relação à normalidade. Quanto a assimetria, as variáveis risco país e soja tem cauda para esquerda. Juros têm cauda para direita, bem como as demais variáveis. As séries boi gordo, milho e juros apresentam menos dispersão. Quanto à curtose, todas têm distribuições leptocúrticas (distribuição de dados que apresenta um pico relativamente alto e um coeficiente de curtose maior que 3).

Figura 3 – Histograma das Séries de Comodities



Fonte: Elaborado pela autora

Figura 4 – Histograma das Variáveis macroeconômicas



Fonte: Elaborado pela autora

Na tabela 2 apresentamos o teste Jarque Bera e o Ljung Box das séries de retorno logarítmicos, em que pelo Jarque Bera indicou todas as séries não seguem distribuição normal ($p\text{-valor} = 0$). É esperado que séries financeiras tenham caudas pesadas e assimétricas. A não normalidade das séries temporais pode ser vistas também nos histogramas das séries (figura 3 e 4).

Tabela 2 – Teste de Jarque Bera e Ljung Box das séries temporais

Série	Estatística JB	p-valor JB	Normalidade	Estatística LB	p-valor LB	Autocorrelação
Boi Gordo	41.373,41	0.0000	Não	55.39	<0.000001	Sim
Café	1.403,53	0.0000	Não	32.12	0.00038	Sim
Milho	18.434,56	0.0000	Não	50.85	<0.000001	Sim
Risco País	29.077,54	0.0000	Não	8.37	0.5931	Não
Soja	6.794,12	0.0000	Não	19.29	0.0367	Sim
Taxa Câmbio	4.019,36	0.0000	Não	32.18	0.00037	Sim
Taxa Juros	389.616,57	0.0000	Não	255.11	<0.000001	Sim

Fonte: Elaborado pela autora

Costa 2001 analisou as propriedades estatísticas de séries de retornos financeiros (ações brasileiras) as quais apresentaram a não normalidade vista em teste Jarque Bera. Ele cita o trabalho de Fama (1965) concluiu que as séries financeiras têm distribuições com caudas pesadas incompatíveis com a da distribuição normal e ele cita outros autores para explicar essa situação:

“A explicação mais aceita atualmente para as caudas pesadas das distribuições de retornos é a de mistura de distribuições; muitos autores, como Praetz (1972) e Clark (1973) argumentam que esta mistura é de distribuições normais. A ideia da mistura de normais deu origem a muitos modelos não lineares para as séries de retornos e os mais difundidos nesta linha são os da família GARCH, introduzida por Engel (1982) e generalizada por Bollerslev (1986), onde fica caracterizada uma dependência não linear entre os retornos, função da dependência serial da variância condicional”

3.2 MODELO GARCH UNIVARIADO

A modelagem univariada é o primeiro passo do DCC-GARCH. Essa abordagem analisa cada série temporal (boi gordo, café, milho e soja) individualmente, sem considerar relações com outras séries, a fim de obter as propriedades dinâmicas exclusivas de cada série, e assim obter sua volatilidade individual e as suas variâncias condicionais. Esse passo é necessário porque o DCC-GARCH usa essas variâncias

univariadas para compor a matriz de variância-covariância condicional multivariada. O nosso modelo univariado inclui variáveis exógenas que afetam a média (juros, câmbio e risco país). Essas variáveis são incorporadas como regressores na equação da média, mas o foco principal do modelo continua sendo a previsão da média e da volatilidade de cada série.

Utilizamos o modelo GARCH (1,1) univariado, que permite modelar a volatilidade condicional ao longo do tempo. Cada série de commodities foi transformada em logaritmos naturais. A estrutura do modelo univariado é composta por duas equações: i) equação da média (que inclui as variáveis exógenas na série de preços futuros (juros, câmbio e risco país), conforme discrimina Engle (2002) ser possível a inclusão de variáveis exógenas; e, ii) a equação da variância, que captura a volatilidade condicional.

A equação da média para cada série de commodities foi formulada como:

$$\gamma_t = C + \beta_1 \cdot CDI + \beta_2 \cdot EWZ + \beta_3 \cdot USD_BRL + \varepsilon_t \quad (1)$$

onde γ_t representa a série de preços futuros da commodity em logaritmos naturais, C é o intercepto, e β_1 , β_2 e β_3 são os coeficientes das variáveis exógenas: juros (cdi), risco país (ewz) e câmbio (usd/brl), respectivamente. O termo ε_t denota o termo de erro, que é assumido como heterocedástico.

A equação da variância condicional foi especificada como um GARCH (1,1):

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

onde h_t é a variância condicional no período α_0 é o termo constante, α_1 captura o efeito ARCH (impacto dos choques anteriores na variância condicional) e β_1 captura o efeito GARCH (persistência dos choques de volatilidade ao longo do tempo).

3.3 MODELO GARCH MULTIVARIADO

O DCC-GARCH (Dynamic Conditional Correlation - Generalized Autoregressive Conditional Heteroskedasticity) conforme Engle (2002) permite a modelagem dinâmica das correlações entre séries temporais e se ajusta às mudanças que ocorrerem ao longo do tempo; ii) é capaz

de captar a volatilidade de longa duração. A abordagem DCC possibilita a identificação de mudanças nas interdependências entre as volatilidades das commodities e as variáveis exógenas – que em nosso estudo são taxa de juros, taxa de câmbio e risco país (Conforme proxy discriminadas no item 3.1)

3.3.1 MODELAGEM UNIVARIADA DE VOLATILIDADE

Em primeiro lugar o DCC-GARCH requer que cada série de commodities seja modelada individualmente com um GARCH (1,1) univariado, conforme apresentado na seção anterior, para que seja obtida a variância condicional de cada série H_{it} (onde i representa cada commodity). Após esse passo partimos para estruturação e especificação do modelo.

3.3.2 ESTRUTURA E ESPECIFICAÇÃO DO MODELO DCC-GARCH

O modelo DCC-GARCH, divide a matriz de variância-covariância condicional conjunta H_t em dois componentes principais: i) matriz diagonal D_t , a qual inclui as variâncias condicionais univariadas de cada série; e, ii) matriz de correlação condicional dinâmica R_t , cuja função é capturar a evolução temporal das correlações entre as séries. É formulado com a seguinte especificação:

$$H_t = D_t R_t D_t \quad (3)$$

onde:

H_t é a matriz de variância-condicional conjunta.

D_t é uma matriz diagonal contendo as variâncias condicionais univariadas de cada série de commodities.

R_t é a matriz de correlação condicional dinâmica, que captura as interdependências temporais entre as séries de commodities.

De acordo Engle (2002), a matriz R_t é atualizada em cada período, permitindo que as correlações entre as séries mudem ao longo do tempo. A atualização de R_t é feita conforme o processo DCC proposto no artigo citado.

3.3.3 PROCESSO DE ESTIMATIVA DOS PARÂMETROS

O processo de ajuste dos parâmetros no modelo DCC-GARCH ocorre em duas etapas: i) Modelagem Univariada GARCH (1,1): conforme descrito no item 3.2; ii) Ajuste do Processo DCC: é realizado a partir dos resíduos padronizados obtidos das séries univariadas, no qual aplica-se o processo DCC, cuja finalidade é ajustar a estrutura de correlação condicional entre as séries de commodities. A estimativa dos parâmetros do modelo multivariado é realizada pela função `dccfit` no software R, a qual utiliza os resíduos das séries individuais para construir a matriz de correlação condicional dinâmica R_t .

3.3.4 INTERPRETAÇÃO DAS CORRELAÇÕES DINÂMICAS

Engle (2002) conclui que o modelo DCC apresenta a característica prática de que as previsões de volatilidade multivariadas e univariadas são consistentes entre si. Quando novas variáveis são adicionadas ao sistema, as previsões de volatilidade dos ativos originais permanecerão inalteradas e as correlações podem até mesmo permanecer inalteradas, dependendo de como o modelo é revisado. Esse modelo permite i) monitorar como as correlações entre as volatilidades das commodities e as variáveis exógenas evoluem ao longo do tempo; ii) compreender como os choques em uma variável exógena afetam outras variáveis.

3.3.5 VALIDAÇÃO DO MODELO

Após a realização do ajuste do modelo, realizam-se a análise dos resíduos e testes adicionais de autocorrelação. Não encontrando autocorrelações significativas nos resíduos infere-se que o modelo está capturando adequadamente as dependências temporais e espaciais entre as séries.



4

4

RESULTADOS

4.1 TESTES DE ESTACIONARIEDADE

Os resultados dos testes de estacionariedade, descritos na tabela 3 – Estacionariedade das séries, apontam rejeição da hipótese nula (H_0 : a série possui uma raiz unitária – não estacionária) para todas as séries analisadas, sugerindo que elas são estacionárias. A aplicação de logaritmos naturais nas séries de preços futuros contribuiu para estabilizar a variância, favorecendo a obtenção de séries estacionárias. É importante que as séries tenham essa característica, pois isto torna a análise mais robusta e ajuda a mitigar a presença de tendências ou sazonalidades que poderiam comprometer a acurácia dos resultados.

Tabela 3 – Estacionariedade das Séries

Série	Teste	Estatística_do_Teste	Valor_p	Hipótese
Boi Gordo	ADF	-11.921625	0,01	Rejeitar H_0 (estacionária)
Café	ADF	-15.771272	0,01	Rejeitar H_0 (estacionária)
Juros	ADF	-8.793261	0,01	Rejeitar H_0 (estacionária)
Risco País	ADF	-13.805737	0,01	Rejeitar H_0 (estacionária)
Milho	ADF	-13.331937	0,01	Rejeitar H_0 (estacionária)
Soja	ADF	-13.032185	0,01	Rejeitar H_0 (estacionária)
Câmbio	ADF	-13.512634	0,01	Rejeitar H_0 (estacionária)
Boi Gordo	PP	-2704.334917	0,01	Rejeitar H_0 (estacionária)

Café	PP	-3290.959265	0,01	Rejeitar H0 (estacionária)
Juros	PP	-3630.233157	0,01	Rejeitar H0 (estacionária)
Risco País	P	-2630.229605	0,01	Rejeitar H0 (estacionária)
Milho	P	-2650.934932	0,01	Rejeitar H0 (estacionária)
Soja	PP	-2743.551525	0,01	Rejeitar H0 (estacionária)
Câmbio	PP	-2524.506812	0,01	Rejeitar H0 (estacionária)
Boi Gordo	DF-GLS	-24.471990	NA	Rejeitar H0 (estacionária)
Café	DF-GLS	-17.422776	NA	Rejeitar H0 (estacionária)
Juros	DF-GLS	-23.160891	NA	Rejeitar H0 (estacionária)
Risco País	DF-GLS	-23.247982	NA	Rejeitar H0 (estacionária)
Milho	DF-GLS	-19.634567	NA	Rejeitar H0 (estacionária)
Soja	DF-GLS	-25.019876	NA	Rejeitar H0 (estacionária)
Câmbio	DF-GLS	-21.934221	NA	Rejeitar H0 (estacionária)

Fonte: Elaborado pela autora

4.2 MODELOS GARCH UNIVARIADOS

4.2.1 BOI GORDO

Os resultados do modelo GARCH para a série temporal do boi gordo, descritos na tabela 4, demonstram como os parâmetros influenciam a média e a volatilidade desse derivativo futuro de commodity. O coeficiente μ (Intercepto - 0,0421), sugere uma tendência média positiva nos retornos logarítmicos do boi gordo. Este parâmetro é estatisticamente significativo (valor $p = 0,0413$), indicando que essa tendência média é consistente. Em contrapartida, o

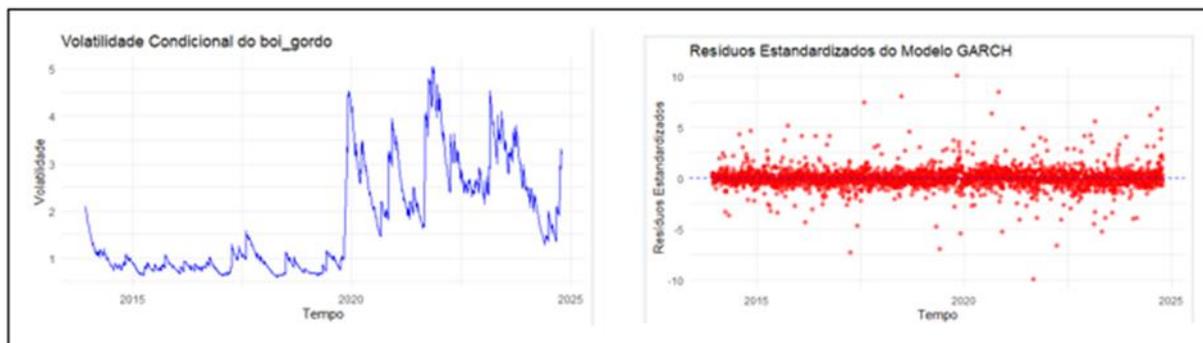
coeficiente mxreg1 (juros-0,0142) não é estatisticamente significativo (valor $p = 0,6448$).

Tabela 4 – Estimativa GARCH Univariado – Série Boi Gordo				
Termo	Estimativa	Erro Padrão	Estatística Z	Valor_p
Um	0,04214093	0,02065677	2,0400545	0,0413449
mxreg1	-0,01416249	0,0307177	-0,46105301	0,64476057
mxreg2	0,86833527	0,51224232	1,69516503	0,09004412
mxreg3	-0,40652143	0,68529146	-0,59320953	0,55304093
omega	0,00638192	0,00105324	6,0593269	1,37E-09
alpha1	0,03004346	0,0019214	15,6362262	0
beta1	0,96895654	0,0016686	580,699252	0

Fonte: Elaborado pela autora

O coeficiente mxreg2 (risco país - 0,8683) e um p-valor de 0,0900, demonstra uma relação positiva moderada com o preço do boi gordo. Esse coeficiente se aproxima do nível de significância. O coeficiente mxreg3 (câmbio: estimativa -0,40650) não apresenta significância estatística (valor $p = 0,5530$), indicando que esta variável não tem um efeito relevante sobre a média dos preços. O termo ômega (ω), estimado em 0,0064 e altamente significativo ($p < 0,001$), representa a variância constante no modelo e sugere uma volatilidade base positiva no retorno do boi gordo. O coeficiente alpha1 (α), com um valor de 0,0300 é altamente significativo ($p < 0,001$), indica que choques de volatilidade passados impactam a volatilidade atual. O coeficiente beta1 (β), estimado em 0,9690 possui um nível de significância muito elevado ($p < 0,001$), indica uma forte persistência da volatilidade ao longo do tempo, sugerindo que aumentos na volatilidade tendem a se manter em períodos subsequentes.

Figura 5 – Volatilidade e Resíduos – Série Boi Gordo



Fonte: Elaborado pela autora

Observamos, na figura 5, o gráfico de volatilidade condicional do Derivativo futuro do boi gordo a formação de picos, com destaque para o período da pandemia, onde há um grande salto de volatilidade. A distância desses picos aumentou nesse período, indicando maior persistência a voltar ao patamar anterior. No gráfico fica nítida menor volatilidade no período anterior a pandemia e maior volatilidade após a pandemia (seria interessante, em trabalhos futuros, averiguar esse comportamento e quais fatores podem ter influenciado o aumento de volatilidade). O gráfico de resíduos estandarizados indica que os resíduos estão padronizados demonstrando que o modelo capturou a dependência temporal dos dados.

O trabalho de Araújo (2023) procurou explicações para a ocorrência de picos na pandemia e demonstra que diversos fatores foram responsáveis, como: aumento da exportação para China, e fechamento das alfandegas que ocasionaram em aumento dos custos de produção:

A associação significativa e positiva entre pandemia e preço da arroba do boi gordo mostra que a conjuntura socioeconômica decorrente da pandemia no país e no exterior 19 estimulou o crescimento dos preços da carne bovina. No exterior, mesmo com a pandemia a economia chinesa cresceu e a demanda por proteína animal, também, principalmente pela substituição à carne suína cuja produção naquele país sofreu redução por questão sanitária. O que exigiu aumento imediato da oferta de boi para o abate (HONIGMANN, 2020; RÜBENICH, 2020). Os efeitos da pandemia nos preços do boi gordo, também, estão associados aos efeitos da pandemia nos preços do boi gordo, também, estão associados aos prejuízos causados devido ao fechamento das alfandegárias para contém o risco de propagação da Covid-19. Os custos de produção de insumos, devido aos fechamentos de diversas zonas portuárias tornaram os custos de produção mais caro, fazendo que os

preços da arroba se ajustem (PINHEIRO; KONDA; BONINI, 2022; SCHNEIDER et al., 2020),

4.2.2 CAFÉ

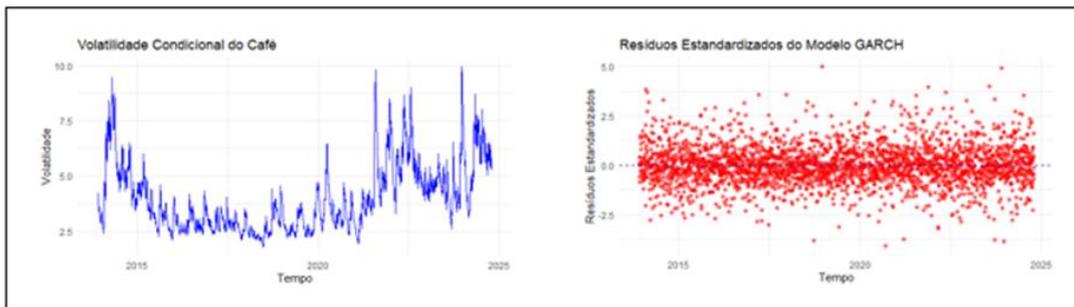
Os resultados do modelo GARCH na modelagem da volatilidade do preço do café, descritos na tabela 5, revelam que: o coeficiente μ (Intercepto - 0,0419) sugere uma média logarítmica positiva, embora seu p-valor (0,4995) não seja estatisticamente significativo. O coeficiente $mxreg1$ (juros), apresenta um valor negativo -0,0708 e um p-valor de 0,9595, demonstrando pouca associação ao preço do café. Por outro lado, o coeficiente $mxreg2$ (risco país - 0,4566) com um p-valor inferior a 0,001, (alta significância), sugerindo que aumentos nesta variável estão associados a aumentos nos preços do café.

Tabela 5 – Estimativa GARCH Univariado – Série Café				
Termo	Estimativa	Erro Padrão	Estatística Z	Valor_p
μ	0,04185661	0,06198758	0,67524193	0,49952207
$mxreg1$	-0,07077985	1,39238575	-0,05083351	0,95945819
$mxreg2$	0,45658594	0,09432184	4,84072348	1,2937E-06
$mxreg3$	-13,0849359	1,74574926	-7,49531226	6,6169E-14
ω	0,19432482	0,06479109	2,99925237	2,71E-03
$\alpha1$	0,08108364	0,01486906	5,4531783	4,9477E-08
$\beta1$	0,91068611	0,01639897	55,5331212	0

Fonte: Elaborado pela autora

O coeficiente $mxreg3$ (câmbio) é negativo (-13,0849) e com p-valor $< 0,001$, indicando um efeito forte e inverso sobre a média do preço do café. O termo constante na equação de variância, representado por ω (ω), é significativo com um valor de 0,1943 e p-valor $< 0,01$. O coeficiente $\alpha1$ (α) é de 0,0811 e significativo ($p < 0,001$), o que implica que choques de volatilidade passada afetam a volatilidade atual, enquanto $\beta1$ (β), estimado em 0,9107 e altamente significativo ($p < 0,001$), sugere uma forte persistência da volatilidade ao longo do tempo, indicando que um aumento na volatilidade atual tende a se manter em períodos subsequentes.

Figura 6 – Volatilidade e Resíduos – Série Café



Fonte: Elaborado pela autora

Observamos na figura 6 o gráfico de volatilidade condicional do Derivativo futuro do café a formação de picos de maiores e menores distâncias ao longo dos anos. O gráfico de resíduos estandarizados indica que os resíduos estão padronizados, demonstrando que o modelo capturou a dependência temporal dos dados.

4.2.3 MILHO

O coeficiente μ (Intercepto) é estimado em $-0,00183761$, o que indica uma média logarítmica ligeiramente negativa para o preço do milho. O p-valor de $0,8907501$ sugere que esse parâmetro não é estatisticamente significativo. O coeficiente $mxreg1$ (juros) apresenta uma estimativa de $1,28916121$ e um valor p de $2,0653E-05$, indicando associações positivas e altamente significativo sobre os preços do milho. Essas observações podem ser vistas com mais detalhes na tabela 6:

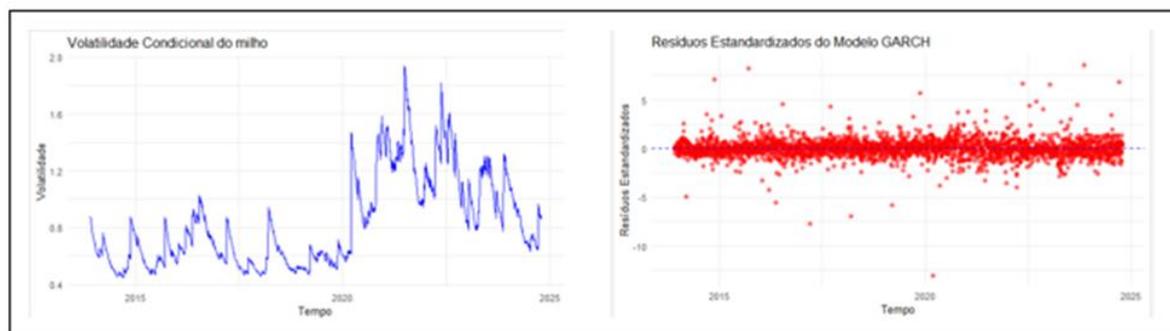
Tabela 6 – Estimativa GARCH Univariado – Série Milho				
Termo	Estimativa	Erro Padrão	Estatística Z	Valor_p
μ	-0,00183761	0,01337854	-0,13735513	0,8907501
$mxreg1$	1,28916121	0,30278293	4,25770772	2,0653E-05
$mxreg2$	0,06370457	0,02170218	2,9353994	0,00333119
$mxreg3$	2,64617254	0,43710639	6,05384089	1,4143E-09
ω	0,0039599	0,00061311	6,45871014	1,06E-10
$\alpha1$	0,02606064	0,00224517	11,6074371	0
$\beta1$	0,9697755	0,00196046	494,666143	0

Fonte: Elaborado pela autora

Em relação ao coeficiente $mxreg2$ (risco país), a estimativa de 0,06370457 e um p-valor de 0,00333119 indica que um aumento na variável EWZ está associado a um leve aumento nos preços do milho. O coeficiente $mxreg3$ para (câmbio) estimado em 2,64617254 possui um p-valor inferior a 0,001, altamente significativo, sugere que, quando ocorre valorização do real em relação ao dólar, há um aumento nos preços do milho.

O termo constante na equação de variância, representado por ω , é estimado em 0,0039599 e é altamente significativo ($p < 0,01$), indicando uma variância subjacente positiva, o que é essencial para a modelagem da volatilidade. O coeficiente α_1 , estimado em 0,02606064, é significativo ($p < 0,001$), sugerindo que choques de volatilidade passados têm um efeito positivo sobre a volatilidade atual, implicando que aumentos inesperados na volatilidade tendem a persistir no tempo. O coeficiente β_1 , estimado em 0,9697755, é altamente significativo ($p < 0,001$) e indica uma forte persistência na volatilidade, mostrando que a volatilidade do preço do milho tende a ser duradoura e influenciada por choques anteriores.

Figura 7 – Volatilidade e Resíduos – Série Milho



Fonte: Elaborado pela autora

Demonstramos na figura 7 o gráfico de volatilidade condicional do derivativo futuro milho, que apresenta picos com grandes saltos de volatilidade principalmente no período da pandemia. Nesse período, a distância desses picos aumentara e houve maior persistência até a volatilidade voltar ao patamar anterior. O gráfico de resíduos estandarizados demonstra que os resíduos estão padronizados, indicando que o modelo capturou a dependência temporal dos dados.

4.2.4 SOJA

Visualizamos na tabela 7 o coeficiente μ (Intercepto) estimado em $-0,0018$, o que sugere uma média logarítmica ligeiramente negativa, embora o p-valor $0,8908$ não seja estatisticamente significativo. Em relação ao coeficiente $mxreg1$ (juros), variável de controle, obtém a estimativa de $1,2892$ e um p-valor inferior a $0,0001$ (significativo) demonstrando uma associação da variável sobre os preços da soja.

Tabela 7 – Estimativa GARCH Univariado – Série soja				
Termo	Estimativa	Erro Padrão	Estatística Z	Valor_p
μ	-0,00183761	0,01337854	-0,13735513	0,8907501
$mxreg1$	1,28916121	0,30278293	4,25770772	2,0653E-05
$mxreg2$	0,06370457	0,02170218	2,9353994	0,00333119
$mxreg3$	2,64617254	0,43710639	6,05384089	1,4143E-09
ω	0,0039599	0,00061311	6,45871014	1,06E-10
$\alpha1$	0,02606064	0,00224517	11,6074371	0
$\beta1$	0,9697755	0,00196046	494,666143	0

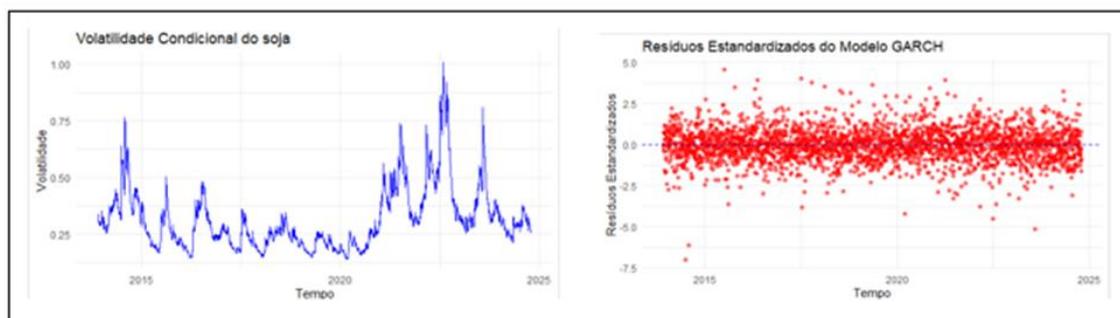
Fonte: Elaborado pela autora

O coeficiente $mxreg2$ (risco país estimado em $0,0637$) e p-valor de $0,0033$, estatisticamente significativo, sugere que a variável correspondente a este coeficiente está associada aos preços da soja. Já o coeficiente $mxreg3$ (câmbio), estimado em $2,6462$ e com um p-valor inferior a $0,0001$, indica que esta variável tem uma relação positiva com a média dos preços da soja.

O termo constante na equação de variância, representado por ω (ω), estimado em $0,00396$ e p-valor de $1,0560E-10$, o que indica uma variância subjacente positiva e altamente significativa, sugerindo que há uma variabilidade nos preços da soja. O coeficiente $\alpha1$ (α) estimado em $0,0261$ é altamente significativo ($p < 0,001$), o que implica que choques de volatilidade passada têm um efeito na volatilidade atual. O coeficiente $\beta1$ (β), estimado em $0,9698$ e com p-valor igual a 0 , sugere uma forte persistência da volatilidade ao longo do tempo,

indicando que um aumento na volatilidade atual tende a se manter em períodos subsequentes.

Figura 8 – Volatilidade e Resíduos – Série Soja



Fonte: Elaborado pela autora

A figura 8 expressa: i) o gráfico de volatilidade condicional do Derivativo futuro da soja, que apresenta picos elevados em 2014, 2021 e 2023. A partir de 2021, houve uma grande escalada dos saltos de volatilidade, tanto para cima quanto para baixo; ii) O gráfico de resíduos estandarizados demonstra que os resíduos estão padronizados, indicando que o modelo capturou a dependência temporal dos dados.

4.3 MODELO MULTIVARIADO – DCC GARCH

4.3.1 DCC-GARCH BOI GORDO

O modelo DCC-GARCH possui estrutura de ordem (1,1) para as variâncias condicionais e as correlações dinâmicas. A tabela 8 demonstra, que o μ possui estimativa 0.0411 (não significativo, $p = 0.078$). ω : 0.0065 (significativo, $p = 0.048$) contribui para explicar a variância base da série. α_1 : 0.0301 (significativo, $p < 0.001$) - efeito do choque anterior na volatilidade atual. β_1 : 0.9689 (significativo, $p < 0.001$) - persistência da volatilidade; próximo de 1, indicando alta persistência e longo tempo para dissipação dos choques.

Tabela 8 – Resultados DCC-GARCH para o Boi Gordo

Série	μ	ω	α_1	β_1	p-valor α_1	p-valor β_1	DCCA1	DCCB1
Boi_gordo	0.041099	0.006484	0.030090	0.968910	0.077695	0	0.01196	0.9144

Risco país	-0.000796	0.000010	0.043411	0.955589	0.599180	0	(p=0.091)	
Juros	0.003339	0.017447	0.075678	0.892497	0.793542	0		
Câmbio	0.001077	0.000013	0.089962	0.908156	0.143221	0		

Fonte: Elaborado pela autora

O parâmetro $dcca1$: 0.01196 ($p=0.091$) do modelo DCC-GARCH indica que as correlações dinâmicas respondem lentamente a novos choques. O parâmetro $dccb1$: 0.9144 (significativo, $p < 0.001$) – indica a persistência das correlações dinâmicas. Sua proximidade de 1 demonstra que as correlações tendem a ser altamente persistentes, sugerindo que os choques nos retornos têm efeitos duradouros sobre as correlações entre as séries.

A alta persistência dos parâmetros β_{11} em cada série e $dccb1$ na correlação dinâmica sugere que a volatilidade das séries e as correlações entre elas reagem lentamente a novos choques. O modelo DCC-GARCH captou as interdependências dinâmicas entre as volatilidades das séries. A estrutura DCC reflete que, enquanto cada série tem uma dinâmica individual de volatilidade, existe também uma estrutura temporal que sincroniza as volatilidades e as correlações.

A tabela 9 descreve as correlações condicionais entre a série boi gordo e as séries (risco país, juros e câmbio):

Tabela 9 – Estimativa DCC-GARCH – Média das Correlações Série Boi Gordo	
Series	Mean_Correlation
Boi Gordo e Risco País	0.0177106
Boi Gordo e Juros	-0.0130207
Boi Gordo e Câmbio	-0.0152855

Fonte: Elaborado pela autora

A série boi gordo e a série risco país: apresentam média das correlações condicionais positiva, com um valor de aproximadamente 0.0177. Isso indica que, ao longo do período analisado, houve uma leve tendência de que as variações de preços do boi gordo se movessem na

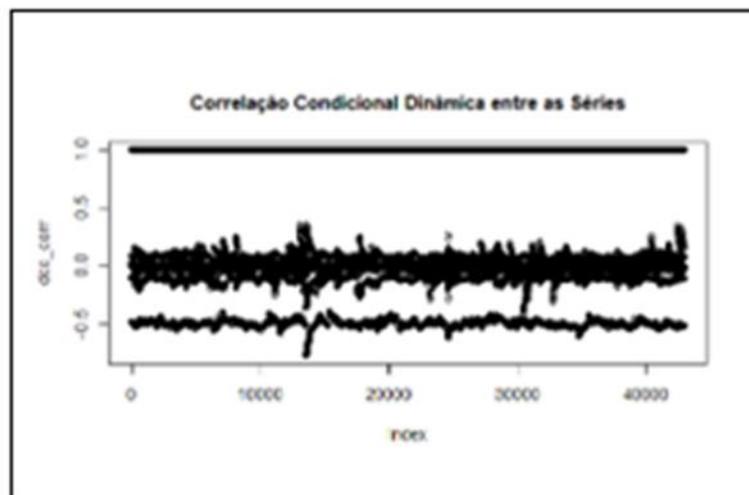
mesma direção que as variações do índice risco país. quando o risco país apresenta alta, há uma tendência de que os preços do boi gordo também aumentem, embora a força dessa correlação seja relativamente fraca;

A média de correlação entre as séries boi gordo e juros é negativa: com um valor de aproximadamente -0.0130 . Isso sugere que, em média, há uma leve tendência de que os preços do boi gordo se movam na direção oposta às variações dos juros, o que indica que quando ocorre aumento de juros, os preços do boi gordo tendem a diminuir, embora essa relação seja fraca.

As séries boi gordo e câmbio apresentam a média das correlações negativas, com um valor de aproximadamente -0.0153 . Quando o valor do dólar em relação ao real (USD/BRL) aumenta, os preços do boi gordo tendem a diminuir.

Observamos na figura 6 a correlação condicional dinâmica entre as séries boi gordo, risco país, juros e câmbio ao longo do tempo. Nos períodos que a correlação entre as séries aumenta, a influência sobre os preços do boi gordo aumenta. E quando a correlação é baixa ou negativa, evidencia que não há relação entre as séries.

Figura 9 – Correlação Condicional Dinâmica – Série Boi Gordo



Fonte: Elaborado pela autora

A análise das correlações condicionais sugere que as variáveis externas (juros, risco país e câmbio) têm uma influência relativamente fraca sobre a volatilidade da série do boi gordo, com correlações muito próximas de zero. Embora a correlação com o risco país seja ligeiramente positiva, as correlações com a juros e o câmbio são

negativas, indicando diferentes dinâmicas entre essas variáveis e a volatilidade do boi gordo.

A correlação condicional positiva, ainda que fraca, entre a volatilidade da série do boi gordo e a série risco país indica que, em períodos de alta nos mercados financeiros, o setor agropecuário (quanto a commodities boi gordo) pode se beneficiar. Quando o mercado acionário se valoriza, há um aumento na confiança dos investidores, o que pode resultar em um maior consumo e demanda por produtos, incluindo carne bovina. Isso pode ser causado por expectativas positivas dos agentes econômicos sobre a atividade econômica. Estas ações impulsionam o aumento da renda da população e, conseqüentemente, a demanda por alimentos.

A Correlação Negativa com o índice de juros sugere que, à medida que este índice aumenta, a volatilidade da série do boi gordo tende a diminuir. No contexto macroeconômico, taxas de juro mais altas geralmente indicam um ambiente econômico mais restritivo. Quando os juros sobem, o custo do crédito aumenta, o que pode reduzir o investimento no setor agropecuário e limitar o crescimento da produção. Assim, a pressão sobre os preços pode ser menor, levando a uma menor volatilidade no mercado de carne bovina. Além disso, os juros altos podem afetar negativamente a renda disponível das famílias, reduzindo a demanda por produtos de carne.

A Correlação Negativa com o câmbio reflete a valorização ou desvalorização do real em relação ao dólar americano. Uma correlação negativa indica que, à medida que o real se desvaloriza frente ao dólar, a volatilidade do boi gordo tende a diminuir. Na perspectiva macroeconômica, uma desvalorização do real torna os produtos brasileiros mais competitivos no mercado internacional, o que pode aumentar as exportações de carne bovina.

4.3.2 DCC-GARCH CAFÉ

Observa-se na tabela 10 que o DCCA1 (Impacto dos Choques nas Correlações Dinâmicas) apresenta estimativa positiva de 0,013478, com Valor t (t value): 2.68951, um valor t acima de 2 (ou abaixo de -2) geralmente indica que a estimativa é estatisticamente significativa. Possui valor p ($\Pr(>|t|)$): 0.007156 inferior a 0,05 indicando que a estimativa de DCCA1 é estatisticamente significativa ao nível de 5%. Isso

sugere que a correlação dinâmica responde significativamente a novos choques.

Tabela 10 – Resultados DCC-GARCH para o Café								
Série	μ	ω	α_1	β_1	p-valor α_1	p-valor β_1	DCCA1	DCCB1
Café	0.015044	0.180478	0.071578	0.920514	0.081656	0	0.013478	0.919078
Risco país	0.004403	0.018049	0.082868	0.887442	0.006441	0		
Juros	-0.000786	0.000010	0.041479	0.957521	0.005100	0		
Câmbio	0.000881	0.000015	0.096445	0.902554	0.000116	0		

Fonte: Elaborado pela autora

O DCCB1 (Persistência das Correlações Dinâmicas): apresenta estimativa de 0.919078 Um valor próximo de 1 indica que as correlações tendem a ser altamente persistentes, significando que um choque em uma série terá um efeito duradouro sobre a correlação com outras séries. O valor t (31.48245) é extremamente alto, indicando uma forte evidência contra a hipótese nula de que o parâmetro é igual a zero. Isso significa que a persistência das correlações é altamente significativa. O valor p é praticamente zero, o que confirma que a estimativa de DCCB1 é altamente significativa. Isso indica que as correlações entre as séries reagem lentamente a novos choques e que a relação entre as séries tende a ser duradoura.

Tabela 11 – Estimativa DCC-GARCH – Média das Correlações Série Café	
Series	Mean_Correlation
Café e Risco País	0.1695709
Café e Juros	-0.0136327
Café e Câmbio	-0.2113954

Fonte: Elaborado pela autora

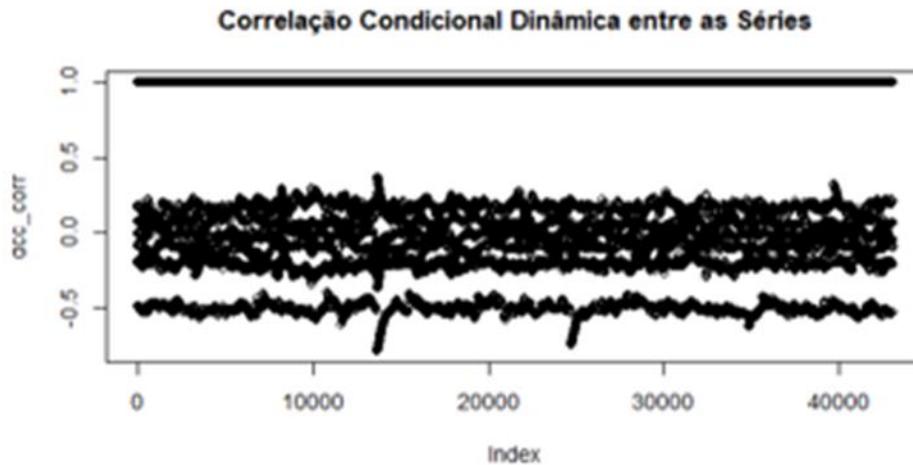
A tabela 11 descreve as correlações condicionais entre a série de logaritmos naturais do café e as séries financeiras externas (risco país, juros e câmbio). A média das correlações condicionais entre café e risco país é positiva, com um valor de aproximadamente 0.1696. No período analisado, há uma tendência moderada de que as variações de preços do café se movam na mesma direção que as variações do índice risco país.

A média das correlações condicionais entre a série do café e juros é negativa, com um valor de aproximadamente -0.0136. Isso sugere que, em média, há uma leve tendência de que os preços do café se movam na direção oposta às variações dos juros. Ou seja, quando a taxa CDI aumenta, os preços do café tendem a diminuir, embora essa relação seja muito fraca. Do ponto de vista macroeconômico, juros mais altos costumam indicar um ambiente econômico mais restritivo, que pode levar os investidores a reduzirem o consumo e o investimento.

A média das correlações condicionais entre a série do café e o câmbio é negativa, com um valor de aproximadamente -0.2114. Isso implica que, em média, existe uma tendência inversa entre os preços do café e as variações na taxa de câmbio. Assim, quando o valor do dólar em relação ao real aumenta, os preços do café tendem a diminuir. Essa correlação pode ser explicada pela dinâmica de exportação e pelos custos de insumos. A desvalorização do real pode tornar os produtos brasileiros mais competitivos no mercado internacional, o que, em um primeiro momento, poderia impulsionar as exportações de café. No entanto, a maior parte dos insumos e investimentos necessários para a produção do café são importados, e uma desvalorização do real também pode elevar os custos de produção.

A figura 10 identifica a correlação condicional dinâmica entre as séries café, risco país, juros e câmbio ao longo do tempo. Nos períodos que a correlação entre as séries aumenta, a influência sobre os preços do café aumenta. E quando a correlação é baixa ou negativa, evidencia que não há relação entre as séries.

Figura 10 – Correlação Condicional Dinâmica– Série Café



Fonte: Elaborado pela autora

4.3.3 DCC-GARCH MILHO

A tabela 12 descreve os principais resultados da modelagem DCC-GARCH para série milho:

Tabela 12 – Resultados DCC-GARCH para o Milho								
Série	μ	ω	α_1	β_1	p-valor α_1	p-valor β_1	DCCA1	DCCB1
Milho	- 0.002481	0.00380 8	0.023541	0.972340	0.00005 5	0	0.010566	0.900977
Risco país	0.002910	0.017865	0.073780	0.893982	0.00052 0	0	(p=0.416 006)	(p=0,000 00)
Juros	- 0.00083 4	0.000010	0.042833	0.956167	0.003472	0		
Câmbio	0.001118	0.000012	0.088721	0.910279	0.00007 0	0		

Fonte: Elaborado pela autora

A distribuição utilizada no modelo e a multivariada normal e ele foi ajustado com estrutura de ordem 1 para ambos os componentes – DCC (1,1). Para a série milho, temos que o alfa1 (0,023541) é significativo, porque o p é inferior a 0,001. Isto indica a sensibilidade da volatilidade a choques passados. O beta 1 (0,972340) é significativo p inferior a 0,001

indica que a volatilidade tem um efeito persistente. Conforme pode ser visto na tabela acima, as séries riscos país, juros e câmbio o α_1 e o β_1 também são significativos, porque em ambas as séries esses parâmetros têm p menor que 0,001. Os parâmetros conjuntos DCC o $dcca_1$ (0,010566) é não significativo pois $p=0,416$ e o $dccb_1$ é significativo, porque p é menor que 0,001, denota que há uma persistência nas correlações dinâmicas.

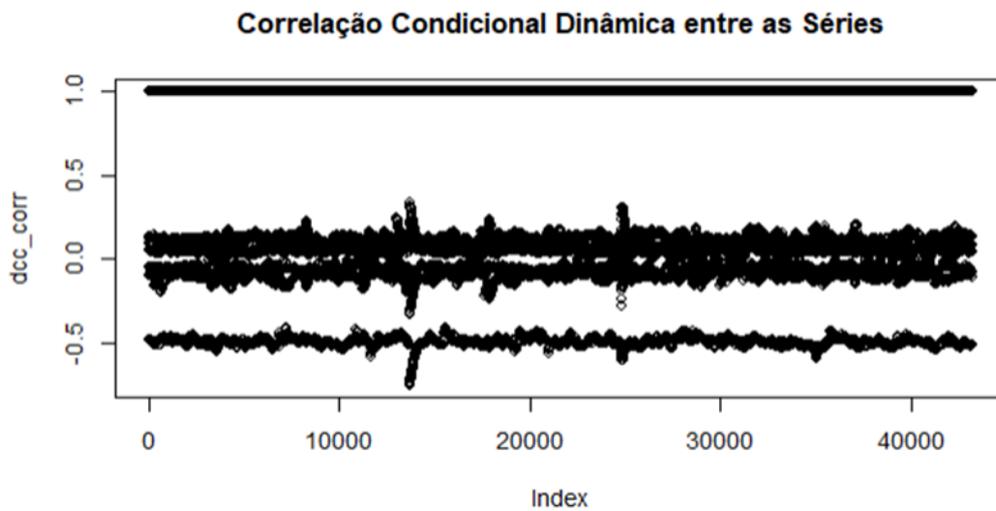
Tabela 13 – Estimativa DCC-GARCH – Média das Correlações Série Milho	
Series	Mean_Correlation
Milho e Risco País	-0.0603352
Milho e Juros	0.0431987
Milho e Câmbio	0.1202352

Fonte: Elaborado pela autora

Na tabela 13 identificamos a média das correlações condicionais entre o milho e as variáveis financeiras foram calculadas em que: i) a correlação entre milho e risco país (- 0.0603352) apresenta comportamento negativo sugerindo que, em média, quando o risco país cai, pode haver uma tendência de que os preços do milho aumentem; ii) milho e juros (0.0431987) apresentam correlação positiva, porém fraca, denotando que as flutuações no preço do milho não estão diretamente ligadas às variações nos juros; iii) milho e câmbio (0.1202352) apresentam correlação positiva e moderada, o que sugere que, em média, um aumento no valor do dólar em relação ao real tende a estar associado a um aumento nos preços do milho. Isso pode ser explicado pela dinâmica de mercado que liga a taxa de câmbio ao setor de commodities, onde um dólar mais forte pode tornar as exportações de milho mais competitivas.

A figura 11 descreve a correlação condicional dinâmica entre as séries milho, risco país, juros e câmbio ao longo do tempo. Nos períodos que a correlação entre as séries aumenta, a influência sobre os preços do milho aumenta. E quando a correlação é baixa ou negativa, evidencia que não há relação entre as séries.

Figura 11 – Correlação Condicional Dinâmica– Milho



Fonte: Elaborado pela autora

4.3.4 DCC-GARCH SOJA

Na tabela a seguir descrevemos os principais resultados da modelagem DCC-GARCH para série DI Futuro soja:

Tabela 14 – Resultados DCC-GARCH para a Soja								
Série	μ	ω	α_1	β_1	p-valor α_1	p-valor β_1	DCCA1	DCCB1
Soja	0,00070 5	0,00058 4	0,061848	0,935839	0	0	0,014673	0,900285
Risco país	0,002901	0,017605	0,073657	0,894687	0,00042 2	0	(p=0,037 822)	(p=0,000 00)
Juros	-0,00083	0,00001	0,04294	0,95606	0,003396	0		
Câmbio	0,001119	0,000012	0,088699	0,910301	0,00006 2	0		

Fonte: Elaborado pela autora

Alfa1 é o parâmetro que mede o impacto dos choques passados na volatilidade atual (o termo ARCH). Um valor alto indica que a série é mais sensível a choques de volatilidade anteriores. Das quatro séries, o câmbio responde mais fortemente a choques passados (0,0886990), seguido do risco país (0,073657), soja (0,061848) e por fim o menor patamar é da série juros (0,04294).

O parâmetro GARCH: β_1 mede a persistência da volatilidade. Valores próximos de 1 indicam alta persistência. Nesse caso, a volatilidade demora mais para voltar ao seu nível médio após um choque. Considerando estas informações, todas as séries apresentam alta persistência na volatilidade: soja: 0,935839, Risco País: 0,894687, Juros: 0,95606 (o mais alto, indicando maior persistência) e Câmbio: 0,910301.

Os parâmetros p-valor α_1 e p-valor β_1 : são analisados para avaliação de significância. Valores baixos (geralmente abaixo de 0,05) sugerem que o parâmetro é significativo. Nossas séries apresentaram os seguintes resultados: soja (p-valores são 0), apresenta significância estatística; Risco País (p-valor de α_1 é 0,000422 e de β_1 é 0) ambos são significativos; Juros é significativo: 0,003396 para α_1 e β_1 é 0; Câmbio, ambos os p-valores também são baixos, o que denota que há significância.

Apresentamos a seguir a tabela de média de correlação condicionais da soja e o gráfico da correlação dinâmica, a seguir:

Tabela 15 – Estimativa DCC-GARCH – Média das Correlações Série Soja	
Series	Mean_Correlation
Soja e Risco País	0.2480239
Soja e Juros	-0.0611808
Soja e Cambio	-0.2379619

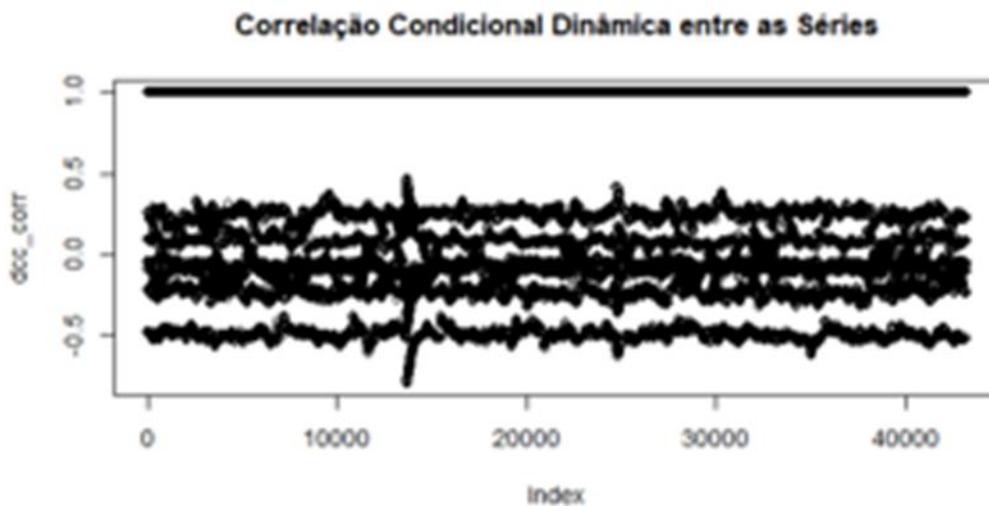
Fonte: Elaborado pela autora

Observamos na tabela 15 que a correlação média entre a soja e Risco País (0.2480239) é positiva demonstrando que, em média, quando o Risco País aumenta (ou diminui), a série de soja tende a se mover na mesma direção, embora a correlação seja moderada. Isso sugere que o Risco País pode ter alguma influência sobre o preço da soja, mas não é uma relação muito forte. Entre a soja e Juros (-0.0611808) a correlação média negativa e fraca, em média, o comportamento dos juros parece ter pouca influência sobre os preços da soja, com uma tendência leve de movimentação em direções opostas, mas essa relação é muito fraca. A correlação média entre a soja e Câmbio (-0.2379619) é negativa e há uma associação inversa

moderada, em média, quando o câmbio aumenta (depreciação da moeda), o preço da soja tende a cair, e vice-versa. Essa relação inversa pode refletir a influência das variações cambiais no preço das commodities, especialmente as exportadas, como a soja.

Na figura 12 observamos a correlação condicional dinâmica entre as séries soja, risco país, juros e câmbio ao longo do tempo. Notamos que, em alguns períodos, a correlação entre as séries aumenta. Nestes períodos, a influência sobre os preços da soja aumenta. No caso oposto, quando a correlação é baixa ou negativa, evidencia que não há relação entre as séries.

Figura 12 – Correlação Condicional Dinâmica– Soja



Fonte: Elaborado pela autora

4.4 PERSISTÊNCIAS DAS SÉRIES

A persistência de uma série, no modelo DCC-GARCH, é medida pelos seus parâmetros $\alpha_1 + \beta_1$. Quando estes valores se aproximam de 1 encontramos alta persistência nas séries, denotando que os choques apresentam efeitos prolongados. Considerando este fundamento, encontramos persistência elevada em todas as séries, demonstrando que a volatilidade dos derivativos futuros de commodities e séries financeiras utilizadas persistem ao longo do tempo. A alta persistência encontrada indicam que as séries têm um comportamento fortemente autoregressivo, o que implica em uma tendência para manter níveis de volatilidade ao longo do tempo. No entanto, como os valores α_1 são relativamente baixos, os choques

iniciais não são tão intensos, indicando que qualquer reversão à média ocorre de forma lenta.

Analisando os parâmetros das séries de Derivativos Futuros de commodities (boi gordo, café, milho, soja) com as variáveis macroeconômicas (Risco País, Juros e Câmbio), encontramos que as séries de produtos financeiros agrícolas possuem maior grau de persistência (valores β_1 mais elevados) e reagem menos a choques imediatos (valores α_1 mais baixo). Visivelmente, as séries agrícolas denotam ser mais estáveis em relação aos choques de curto prazo do que as variáveis macroeconômicas que podem ser mais sensíveis a fatores externos no mercado internacional, culminando em séries mais voláteis.

Considerando os resultados apresentados, em que há grandes níveis de persistência e que as séries não perderão sua característica de volatilidade, podemos desenvolver estratégias de Hedging e gestão de risco apostando na diversificação de ativos. Por exemplo, soja e milho apresentaram correlação negativa com o câmbio, em cenários de desvalorização do câmbio eles tendem a se valorizar. Dessa forma, podem ser anexados a carteiras de investimentos com a finalidade de compensar perdas com outros ativos. A série café apresenta correlação com Juros, ele pode servir como um hedge natural em ciclos de política monetária restritiva, cenários em que os investidores esperam altas taxas de juros.



5

5

CONCLUSÃO

O presente trabalho buscou investigar como as variáveis Risco País, Juros e Câmbio influenciam cada série de derivativos futuros das commodities boi gordo, café, milho e soja ao longo do tempo. O modelo DCC-GARCH foi utilizado para capturar, e assim facilitar a compreensão de como as variáveis macroeconômicas descritas influenciam as séries de commodities, principalmente em termos de volatilidade e correlação dinâmica.

A volatilidade do boi gordo sofre pouca influência das variáveis externas, como juros, risco país e câmbio. Os parâmetros não são fortes o suficiente para indicar efeitos significativos na volatilidade do boi gordo. A dependência condicional dinâmica entre os preços do café e as variáveis financeiras (câmbio, juros e risco país) sugere que essas variáveis têm peso moderado sobre a dinâmica dos preços do café. A taxa de câmbio e o Café se movem em direções opostas e juros e café se movimentam na mesma direção. Da mesma forma, o comportamento entre risco país e café ocorrem na mesma direção.

A modelagem DCC-GARCH para o milho destaca a persistência da volatilidade e as interações dinâmicas entre o mercado de commodities e as variáveis macroeconômicas, sendo o câmbio o fator mais relevante nas flutuações dos preços dessa série. A volatilidade dos preços é influenciada por choques passados, com alta persistência ao longo do tempo. O câmbio exerce maior influência que o risco país e juros, agindo de forma moderada enquanto essas duas últimas variáveis são mais fracas. O modelo capturou que a volatilidade do preço da soja é mais afetada por choques passados nas variáveis câmbio risco país. O câmbio é mais influente e esta relação é inversa. Com o risco país a relação é positiva embora não seja muito forte. Já a taxa de Juros tem pouca influência sobre os preços da soja.

Os resultados apresentados demonstraram que há elevados níveis de persistência e que as séries não perderão sua característica de volatilidade. Embasados em modelagens como estas é possível desenvolver estratégias de Hedging e gestão de risco apostando na diversificação de ativos com o propósito de compensar perdas com outros ativos. Porém é de grande valia desenvolver novas análises,



incorporando novas variáveis macroeconômicas e adotando outras modelagens da família GARCH.





REFERÊNCIAS

REFERÊNCIAS

REFERÊNCIAS

AJUBE, Fernando Antonio Lucena. "Econometria para séries financeiras." Rio de Janeiro: Notas: Pontifícia Universidade Católica do Rio de Janeiro (2007).

AMENDOLA, Alessandra; CANDILA, Vincenzo; SCOGNAMILLO, Antonio. On the influence

ARAÚJO, Wenia Alves Ferreira De. "Análise do preço da arroba do boi gordo no período de 2016 a 2023." (2023)

ASSAF NETO, Alexandre. Mercado financeiro. 2000.

BAYER, Fábio Mariano et al. Previsão do preço e da volatilidade de commodities agrícolas, por meio de modelos ARFIMA-GARCH. 2008.

CAMPOS, Kilmer Coelho. Análise da volatilidade de preços de produtos agropecuários no Brasil. *Revista de Economia e Agronegócio/Brazilian Review of Economics and Agribusiness*, v. 5, n. 3, p. 303-327, 2007.

CERETTA, Paulo Sergio; VENTURINI, Jonas Cardona; GENDELSKY, Vanessa Rabelo Dutra. Assimetria na Volatilidade de Commodities Agrícola. In: *Anais do Congresso Brasileiro de Custos-ABC*. 2007.

CONRAD, Christian; LOCH, Karin; RITTLER, Daniel. On the macroeconomic determinants of long-term volatilities and correlations in US stock and crude oil markets. *Journal of Empirical Finance*, v. 29, p. 26-40, 2014.

Costa, Paulo Henrique Soto, and Tara Keshar Nanda Baidya. "Propriedades estatísticas das séries de retornos das principais ações brasileiras." *Pesquisa Operacional* 21 (2001): 61-87.

DE ASSIS, Janilson Pinheiro, et al. "Transformação de dados Aplicada à Estatística. 2023

DE MORAES, Alexandra Kelly; CERETTA, Paulo Sergio. spillover de volatilidade direcional entre commodities agrícolas, petróleo e índices financeiros. *Organizações Rurais & Agroindustriais*, v. 25, p. e1903-e1903, 2023.

DO, ANÁLISE DA VOLATILIDADE DOS PREÇOS, et al. Análise da volatilidade dos preços do boi gordo no Estado de São Paulo: uma aplicação dos modelos ARCH/GARCH, 2007.

DOS SANTOS, Valéria Faria. Impacto de hedge e especulação sobre a volatilidade dos mercados de commodities agrícolas: um estudo empírico para os EUA e Brasil. Diss. [sn], 2018.

EMBRAPA: Trajetória da agricultura brasileira. <https://www.embrapa.br/visao/trajetoria-da-agricultura-brasileira>

Engle, Robert. "Dynamic conditional correlation: A simple class of multivariate generalized autoregressive conditional heteroskedasticity models." *Journal of business & economic statistics* 20.3 (2002): 339-350.

ENGLE, Robert F.; RANGEL, Jose Gonzalo. The spline-GARCH model for low-frequency volatility and its global macroeconomic causes. *Review of financial studies*, v. 21, n. 3, p. 1187-1222, 2008.

ENGLE, Robert F.; GHYSELS, Eric; SOHN, Bumjean. Stock market volatility and macroeconomic fundamentals. *Review of Economics and Statistics*, v. 95, n. 3, p. 776-797, 2013.

FREITAS, Clailton Ataídes de; SÁFADI, Thelma. Volatilidade dos Retornos de Commodities Agropecuárias Brasileiras: um teste utilizando o modelo APARCH. *Revista de Economia e Sociologia Rural*, v. 53, p. 211-228, 2015.

GAIO, Luiz Eduardo, et al. "Volatilidade no mercado futuro de Boi Gordo na BM&F: um estudo empírico utilizando modelos da classe ARCH." (2006).

GHYSELS, Eric; SINKO, Arthur; VALKANOV, Rossen. MIDAS regressions: Further results and new directions. *Econometric reviews*, v. 26, n. 1, p. 53-90, 2007.

GORTON, Gary; ROUWENHORST, K. Geert. Facts and fantasies about commodity futures. *Financial Analysts Journal*, v. 62, n. 2, p. 47-68, 2006.

JIANG, Yonghong, et al. "The time-varying linkages between global oil market and China's commodity sectors: Evidence from DCC-GJR-GARCH analyses." *Energy* 166 (2019): 577-586.

KAJIYA, Daniel Yuzo Shimada. Volatilidade no mercado de ações ajuda a prever a atividade econômica? Uma comparação entre processos lineares e não lineares para Brasil e Estados Unidos. 2021. Tese de Doutorado.

MO, Di et al. The macroeconomic determinants of commodity futures volatility: Evidence from Chinese and Indian markets. *Economic Modelling*, v. 70, p. 543-560, 2018.

MISHRA, Eva, and R. Murugesan. "An analysis on the time-varying correlation among selected agricultural commodities: a DCC-GARCH model-based approach." *International Journal of Enterprise Network Management* 15.3 (2024): 261-285.

OLIVEIRA, Gabriel Carvalho. A formação de preços de commodities e o processo de financeirização do setor. 2020.

SILVA, Washington Santos da; SÁFADI, Thelma; CASTRO JÚNIOR, Luiz Gonzaga de. Uma análise empírica da volatilidade do retorno de commodities agrícolas utilizando modelos ARCH: os casos do Café e da Soja. *Revista de Economia e Sociologia Rural*, v. 43, p. 119-134, 2005

Swamy, Perumandla, and Kurisetti Padma. "An empirical examination of correlation dynamics between commodity and equity derivative indices: evidence from India using DCC-GARCH models." *Afro-Asian Journal of Finance and Accounting* 10.2 (2020): 207-234

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



idp

Bo
pro
cit
ref
Ness
são e

idp

A ESCOLHA QUE
TRANSFORMA
O SEU CONHECIMENTO