

Volatilidade setorial: análise de causalidade e transbordamentos cambiais e financeiros

Resumo: Este estudo utiliza dados diários dos retornos de sete índices setoriais, do Ibovespa e do Dólar para análise de transbordamentos de volatilidade por meio de correlações condicionais, visando a identificação do comportamento dos setores. Modelos GARCH univariados demonstraram que as séries dos retornos dos índices setoriais são caracterizadas por presença de caudas pesadas, assimetria e curtose e foram utilizados como indicativo das ordens dos modelos multivariados. Modelos GARCH multivariados do tipo Diagonal BEKK com parâmetros de assimetria e ordens baixas representaram satisfatoriamente as séries geradoras dos índices setoriais. Foram estimadas correlações condicionais em três diferentes modelos, combinando a volatilidade de cada setor com diferentes choques: volatilidade do Dólar, volatilidade do Ibovespa e volatilidade do Dólar e Ibovespa. Testes CN foram utilizados para verificar a existência de transbordamentos de volatilidade e as direções, de forma a caracterizar efeitos *lead-lag*.

Palavras-chave: GARCH multivariado; Teste CN; *Spillover* de volatilidade; Índices Setoriais; *Lead-lag*.

Abstract: *This study uses daily return data from seven sector indexes, Ibovespa index and Dollar to analyze volatility spillovers through conditional correlations, aiming at identifying the behavior of the sectors. Univariate GARCH models demonstrate that the return series of the sectoral indexes are characterized by the presence of heavy tails, skewness and kurtosis and were used as an indication of the multivariate model orders. Diagonal Multivariate GARCH-BEKK models with skewness parameters and low orders represented satisfactorily the sectoral indices generating series. Conditional correlations were estimated for three different models, combining the volatility of each sector with different shocks: dollar volatility, Ibovespa volatility and dollar and Ibovespa volatility. CN tests were used to check for the presence of volatility spillovers and the directions, in order to characterize lead-lag effects.*

Keywords: *Multivariate GARCH; CN test; Volatility Spillover; Stock market sector; Lead-lag.*

Classificação JEL: C58, G15, G17.

André Nunes Maranhão¹

Rodrigo Fortes Lopes²

¹ Doutor em Economia e professor no Departamento de Economia da Fundação Getúlio Vargas.
E-mail: andrenmaranhao@gmail.com

² Graduado em Engenharia Química e técnico da Secretaria-Executiva da CMED, Agência Nacional de Vigilância Sanitária.
E-mail: rodrigoforteslopes@gmail.com

1. Introdução

O presente estudo procura contribuir com a literatura brasileira sobre *spillovers* de volatilidade e efeito *lead-lag* ao analisar os transbordamentos de volatilidades cambiais para o mercado acionário, representado pelos índices setoriais da principal bolsa de valores brasileira. Busca-se identificar as características dos transbordamentos sobre diferentes setores, proporcionando informações potencialmente úteis para a tomada de decisão em investimentos. Por meio da aplicação da metodologia GARCH-BEKK e de testes de Cheung e Ng (CN), é identificada a direção dos transbordamentos, denominados pela literatura como efeitos *lead-lag*. Testes de médias de correlações condicionais são realizados para identificar comportamentos dos índices setoriais.

O estudo da volatilidade das séries financeiras desempenha importante papel nas finanças, possibilitando a escolha de arranjos eficazes de alocação de recursos baseados em risco e retorno. Conforme descrito em Borges (2012), a avaliação do risco de ativos pode ser medida a partir do parâmetro de volatilidade e a tomada de decisões de investimentos envolvendo vários ativos desperta o interesse na medida da covariância entre eles. Sadorsky (2012) ressalta que a modelagem e previsão de volatilidade ocupa papel central nas finanças modernas, pois são necessárias para avaliação de preços de derivativos, otimização de portfólio, gerenciamento de riscos e *hedge*.

Conforme descrito em Maranhão e Oliveira (2017a), na abordagem clássica de estudo da volatilidade univariada, os principais modelos utilizados são VaR (Valor em Risco), GARCH e suas especificações. Já os modelos GARCH multivariados possibilitam analisar efeitos cruzados de volatilidade (variâncias e correlações condicionais). Comparações entre modelos GARCH são objetos de estudos, como em Choudhry, Hasan e Zhang (2019), onde os autores utilizaram diferentes modelos GARCH em análises de comportamento de índices de *hedge* e avaliaram os desempenhos das previsões desses modelos.

Diversos estudos têm examinado a medida em que a volatilidade de um mercado de ações se espalha para diferentes ativos, como outros mercados de ações e índices de commodities. A existência de *spillovers* entre câmbio e mercados financeiros tem sido estimada e testada por diferentes métodos, desde o trabalho de Kanas (2000), que trouxe evidências e questões sobre transbordamentos de volatilidades, contrariando os resultados obtidos por Bodart e Reding (1999), que não identificou relação entre esses mercados, até trabalhos mais recentes como Leung, Schiereck e Schroeder (2017) que identificaram aumento geral de *spillovers* entre esses mercados durante períodos de crise.

Os efeitos *lead-lag* estão relacionados com a precedência estatística dos *spillovers* de volatilidade e representam uma linha de pesquisa importante. Inicialmente estudados para preços, esses efeitos passaram a ser estudados para movimentos de volatilidade e buscam identificar qual mercado lidera os movimentos de preços ou de volatilidade seguido em defasagem por outro mercado, conforme Madhavan (2000). A possibilidade de ocorrência de efeitos *lead-lag* relacionados à volatilidade entre diferentes mercados pode ser avaliada por testes de causalidade de Granger de segunda ordem e de testes CN.

Nesse estudo, são analisados os seguintes setores cobertos pelos índices da B3 S.A.: Utilidade Pública (UTIL), Materiais Básicos (IMAT), Financeiro (IFNC), Imobiliário (IMOB), Consumo (ICON), Industrial (INDX) e Energia Elétrica (IEE). Os índices setoriais também são comparados com Índice da Bolsa de Valores de São Paulo (IBOV).

2. Revisão de literatura

2.1 Estudos sobre os índices setoriais do mercado acionário brasileiro

As possibilidades de estudos envolvendo esses índices têm sido exploradas por pesquisadores brasileiros, embora ainda possa ser considerada pequena a quantidade de publicações. Os estudos descritos a seguir apresentam diferentes técnicas econométricas para avaliação de índices setoriais do mercado brasileiro.

O padrão da volatilidade do IEE e do INDX, assim como do IBOV, Índice de Sustentabilidade Empresarial (ISE) e Índice de Telecomunicações (ITEL) foi analisado por Jubert et al. (2009). A análise econométrica foi realizada por meio dos modelos estimados GARCH, EGARCH e TARCH, apresentando parâmetros estatisticamente significativos e testes de performance (ARCH-LM e Q de Ljung-Box) satisfatórios em todas as estimações. Os resultados evidenciaram o efeito alavancagem no qual os retornos negativos estão mais associados aos aglomerados de volatilidade, ou seja, choques negativos provocam maior instabilidade no mercado de ações.

Righi, Ceretta e Silveira (2012) utilizaram indicadores referenciados na literatura de finanças para verificar qual dos índices apresenta melhor desempenho, concluindo que o IEE é o mais recomendado para diversas composições de carteira. Sampaio (2015) investigou a sensibilidade dos índices setoriais BMFBovespa a mudanças nas expectativas dos participantes do mercado para as variáveis econômicas constantes do Relatório Focus através de modelagem da média das séries dos índices, fundamentando-se na teoria de precificação multifatorial. Foram utilizadas variáveis *forward-looking* e a heterocedasticidade condicional nas séries de retornos dos índices setoriais foi modelada por arcabouço GARCH. Os resultados indicaram que algumas variáveis de expectativas são significativas para explicação das variações dos índices setoriais brasileiros.

Estudo conduzido por CARVALHO, SOUSA e CALLADO (2016) teve como objetivo analisar o Desempenho Financeiro dos Índices de Sustentabilidade em comparação aos demais grupos de índices que compõe a BMFBovespa. Os resultados demonstraram inexistência de variação estatística significativa entre os retornos médios diários dos Índices de Sustentabilidade e os demais índices da BMFBovespa. Entretanto, as medianas dos retornos diários dos índices foram estatisticamente diferentes. Trabalho de autoria de Dalcin et al. (2017) utilizou análise de dados em painel com *threshold* para analisar a exposição dos setores da economia listados na BMFBovespa à taxa de câmbio entre o período de 2011 e 2016. O procedimento consistiu em verificar se existia evidência para o efeito *threshold*, considerando a hipótese nula de inexistência desse efeito e computando os p-valores por meio da técnica *bootstrap*. Foi constatado que todos os setores são afetados pelo câmbio significativamente e negativamente.

Fernandes-Freire et al. (2017), com objetivo de identificar a contribuição marginal de risco dos setores brasileiros ao risco sistêmico, consideraram, via testes de quebras estruturais, fatores relevantes da economia brasileira e/ou mundial. Foi utilizado modelo de gerenciamento de risco denominado *Conditional Value-at-Risk* (CoVaR). Os resultados evidenciaram que o setor industrial foi o que mais contribuiu para o risco sistêmico do mercado acionário brasileiro e o financeiro foi o que menos contribuiu.

Utilizando algoritmo de seleção de modelos lineares *Autometrics*, Costa e Costa (2018) analisaram os impactos de variáveis macroeconômicas domésticas e internacionais sobre o retorno das ações de índices setoriais divulgados pela B3 S.A., concluindo a existência de uma relação inversa entre a taxa de câmbio e os retornos de todos os índices setoriais.

Bernardino et al. (2019) utilizaram metodologia GARCH-VaR para analisar oito

índices setoriais com relação ao Valor em Risco. O estudo identificou que diferentes setores da economia brasileira possuem comportamentos significativamente diferentes, com destaque para os índices setoriais industrial e de consumo, que tiveram melhores performances em relação ao risco. Constatou-se que o VaR pode ser uma medida efetiva na minimização da exposição ao risco, podendo atenuar perdas. Almeida et al. (2019), buscando avaliar a transmissão de volatilidade entre os índices setoriais do Ibovespa, utilizaram teste de causalidade proposto por Cheung e Ng (1996). Os resultados demonstraram que a causalidade entre os ativos é, em geral, bidirecional e que, em momentos de incerteza, ocorre aumento da volatilidade geral do mercado, podendo os movimentos serem explicados como causa e/ou efeito de movimento em outro mercado.

Monte (2019) buscou verificar as inter-relações entre o IBOV e os índices financeiros setoriais ICON, IEE, IFNC, INDX e IMAT utilizando metodologia VAR/VECM. O estudo não identificou relação de longo prazo entre os índices, ou seja, concluiu pela inexistência de um vetor de cointegração. Ainda, identificou que os efeitos de um índice sobre os demais são rapidamente dissipados.

Bressan, Souza e Amarante (2021) estimaram Valor em Risco (VaR) para os índices setoriais IFNC, ICON, INDX e IMAT, índice de Governança Corporativa (IGCX) e IBOV, considerando a comparação entre dois modelos univariados. Os autores concluíram que os melhores resultados foram apresentados pelo modelo que une Teoria do Valor Extremo (EVT) e modelagem condicional de variâncias heterocedásticas. Identificaram a superioridade do modelo EVT condicional sobre o *Riskmetrics* nas condições estudadas, bem como comprovaram a hipótese de que o setor de empresas financeiras (IFIN) apresenta um menor número de violações à cobertura do EVT condicional. Já Conte (2021) utilizou modelos de regimes de Markov para análise dinâmica da volatilidade de setores do mercado brasileiro. Foi constatada similaridade entre o IFNC e IBOV, bem como entre IEE e UTIL. Também foi demonstrado que o setor financeiro não é o único setor potencialmente capaz de provocar crises sistêmicas.

2.2 Spillovers de volatilidade e efeitos *lead-lag* na literatura

A literatura acadêmica denominada Microestruturas de Mercado trata do processo pelo qual demandas latentes dos investidores se convertem em transações, conforme descreve Madhavan (2000). O papel da informação é fundamental nesse processo. Maranhão e Oliveira (2017b) descrevem que é ponto de debate na literatura a forma pela qual a informação pode ser incorporada aos preços e a maneira como indivíduos a utilizam para tomada de ações efetivas e ressaltam que, entre as linhas de pesquisa em microestruturas de mercado que consideram o papel da incorporação de informações nos preços de ativos, destacam-se: i) a adoção de incrementos fixos para as cotações dos ativos (tickets), ii) intervalos irregulares de tempo observado (ou não observado) entre as diferentes transações ocorridas ao longo de um período, iii) a existência de spreads entre os preços de compra e venda dos formadores de mercado e iv) a variação do volume (número de contratos) referente a cada operação realizada ao longo de um período.

As teorias acerca da disponibilidade de informações na tomada de decisões econômicas e incorporação nos preços possuem linhas distintas. Alguns autores consideram que toda informação disponível está refletida nos preços, gerando equilíbrio, como Lucas (1978), Lucas (1986) e Fama (1991). Outra linha de pesquisa considera que oportunidades de arbitragem podem ser geradas a partir de desequilíbrios originários de momentos em que ocorrem erros de incorporação de informações. O trabalho de Byrne e Brooks (2008) discute finanças comportamentais e as possibilidades de arbitragem. Mitchell, Pulvino e Stafford (2002) examinaram 82 situações de oportunidades de arbitragem geradas pelo fato de valores de empresas serem inferiores aos de subsidiárias.

Questões relacionadas com limites de arbitragem também são discutidas por Barberis e Thaler (2003).

O estudo de Beirne et al. (2010) examinou *spillovers* de mercados maduros (globais) e 41 mercados emergentes (regionais) na Ásia, Europa, América Latina (incluindo o Brasil) e Oriente Médio por meio de modelos VARGARCH trivariados. *Spillovers* dos mercados regionais e globais foram identificados para a maioria dos mercados emergentes, embora a natureza da ligação varie entre países e regiões. *Spillovers* nos retornos médios são dominantes nos mercados emergentes da Ásia e da América Latina, enquanto *spillovers* na variância exercem papel fundamental nos países emergentes europeus. Para Brasil e México, em contraste com os demais países da América Latina, os *spillovers* regionais não se mostraram iguais ou mais importantes que os globais.

Mensi et al. (2014) encontrou, por meio de modelos VAR-BEKK-GARCH e VAR-DCC-GARCH, evidências de ligações significativas entre mercado de petróleo e de commodities agrícolas. Kundu e Sarkar (2016) avaliaram, por meio de modelos GARCH bivariados e considerando duas condições de mercado, os comportamentos dos retornos dos mercados de ações e os *spillovers* de volatilidades entre pares de países dentre quatro em desenvolvimento (Brasil, Rússia, Índia e China) e dois desenvolvidos (Estados Unidos e Reino Unido). Os resultados indicaram que existe significativo e assimétrico efeito nos retornos e volatilidades de um mercado em outro, em condições de alta e baixa, mas que o sinal do efeito varia entre os pares de países e condições de mercado.

Estudo de Cardona, Gutiérrez e Agudelo (2017) testou a transmissão de volatilidade entre Estados Unidos e as seis maiores economias da América Latina: Brasil, Argentina, Chile, Colômbia, Peru e México. Os autores utilizaram modelos MGARCH-BEKK para valores diários e encontraram forte evidência de transmissão de volatilidade dos Estados Unidos para a América Latina, mas não na direção oposta (exceto Brasil). A hipótese do fenômeno de *decoupling* entre Estados Unidos, Brasil e México foi rejeitada, sendo encontrada evidência de aumento das correlações condicionais e aumento das transmissões de volatilidade a partir de 2003. O estudo destacou a liderança do mercado brasileiro como único latino-americano a transmitir constantemente volatilidade para os Estados Unidos.

Estudo de Das, Bhowmik e Jana (2018) analisou a integração regional de mercados desenvolvidos do Pacífico (Austrália, Hong Kong, Japão, Nova Zelândia e Cingapura) por meio de estudos de *spillovers* de volatilidades entre as bolsas de valores de tais mercados. Os autores encontraram evidências de grandes *spillovers* de volatilidades durante a crise financeira global e de que a Austrália é o principal emissor de *spillovers*. Os resultados sugeriram que os benefícios de diversificação de investimentos entre os países são limitados, dada a integração entre aqueles mercados.

Tiwari et al. (2018) analisou *spillovers* de volatilidades entre quatro classes globais de ativos: ações, ações soberanas, CDS (*credit default swaps*) e moeda. Os resultados indicaram, além de um baixo nível de conexão entre os mercados, que os mercados de ações e CDS são transmissores líquidos de volatilidade, enquanto os mercados de câmbio e títulos são receptores líquidos dos *spillovers*. Heckeles, Amrouk e Grosche (2018), por meio de modelo BEKK-MGARCH, examinaram o nível de preços e a interação da volatilidade entre os alimentos básicos internacionais e os índices de preços futuros da safra. Os resultados do estudo indicaram que os níveis de correlação e volatilidade são mais fortes em frequências mais baixas (longo prazo) e que mercados se ajustam rapidamente aos choques de volatilidade após alto impacto inicial.

Estudo de Zhipeng e Shenghong (2018) sobre volatilidade do mercado chinês, desenvolvendo um regime de Markov alternando o modelo diagonal de Bekk-Garch permitindo que os parâmetros sejam dependentes do estado do regime de mercado, identificou, via comparações de desempenho de hedge dentro e fora da amostra, que um

modelo de Bekk-Garch com troca de regime é a estratégia ideal de hedge, seguida pelo modelo de Bekk-Garch e Mínimos Quadrados Ordinários. Estudo de Choudhry, Hasan e Zhang (2019) estimou e projetou empiricamente as taxas de hedge de três mercados emergentes de ações europeus e um desenvolvido para mercados futuros por meio de sete versões diferentes do modelo GARCH. Dentre os resultados, foi identificado que as diferenças entre retornos do portfólio indicaram alta capacidade preditiva do modelo GARCH-BEKK.

Conforme descrito por Maranhão e Oliveira (2017b), o efeito *lead-lag* pode ser observado quando existe uma correlação entre movimentos de preços ou de volatilidades de mercados distintos. Nessa relação, um mercado segue, com alguma defasagem, o movimento de outro mercado, considerado “líder”, rompendo com a hipótese desenvolvida por Malkiel e Fama (1970), a qual previa eficiência de mercado e impossibilidade de previsão de arbitragem. Entretanto, devido a custos de transação, a arbitragem pode ser inviabilizada mesmo na presença de efeitos *lead-lag*.

Estudos de diversas áreas econômicas identificaram existência de efeito *lead-lag*. Jiang, Fung e Cheng (2001) estudaram a relação *lead-lag* entre índices futuros e o índice subjacente sob três tipos de restrições de venda a descoberto sobre ações em Hong Kong. Esses autores definem *lead-lag* como dois preços que se movem em sequência, podendo representar flagrante violação do princípio de não arbitragem. Os resultados sugeriram que, na ausência de restrições, a relação de preço contemporânea entre índices futuros e mercados à vista se fortalece, principalmente quando o mercado está em queda ou quando o mercado à vista está relativamente caro. Efeito *lead-lag* entre o preço de atacado, considerado líder na relação, seguido pelo preço do produtor de carne de porco nos Estados Unidos da América, foi identificado em estudo realizado por Miller (1980), que discordava da metodologia estatística utilizada em estudo anterior conduzido pelo governo norte-americano.

Gaio e Rolim (2007) encontraram evidências de que o comportamento das bolsas de valores internacionais influencia preços no mercado acionário brasileiro. Nakamura (2009) identificou efeitos *lead-lag* entre mercado acionário brasileiro e seus ADR. Pena, Guelman e Rabello (2010) identificaram relação contemporânea entre os índices Dow Jones e Nikkei com o Ibovespa e efeitos defasados possivelmente oriundos da diferença de fusos horários. Comovimentos entre os índices Dow Jones e Ibovespa também foram estudados por Oliveira (2008), que identificou existência de efeitos *lead-lag* entre esses mercados, utilizando dados de alta frequência, mas concluindo pela impossibilidade de arbitragem devido aos custos de transação.

Os estudos Maranhão e Oliveira (2017b) e Maranhão e Oliveira (2017a) identificaram transbordamentos de volatilidade e efeitos *lead-lag* entre o mercado cambial e o mercado acionário brasileiro. Utilizando modelos GARCH-BEKK multivariados para estimar correlações condicionais entre o índice Ibovespa em três modelos de choques cambiais, seguidos de testes de causalidade de Granger de segunda ordem e análises comparativas, os autores obtiveram resultados que demonstraram a existência de transbordamentos de choques cambiais para o índice Ibovespa, com correlações apresentando dinâmica temporal e efeito *lead-lag* sempre na direção dos choques cambiais para o índice Ibovespa.

Maranhão e Moreira (2021) utilizaram dados diários da cotação do IBOV, Dólar e de grupos de ações organizadas em função do nível de pagamento de dividendos para avaliação de transbordamentos de volatilidades. Foi identificada presença de efeito *lead-lag*. Asafo-Adjei, Adam e Darkwa (2021) estudaram os efeitos *lead-lag* entre os retornos do preço do petróleo bruto e o retorno de ações de seis países africanos produtores de petróleo. Foi identificada baixa interdependência entre os retornos do petróleo bruto e das ações nos países estudados.

Bangsgaard e Kokholm (2022) utilizaram amostras de alta frequência para estudar os efeitos *lead-lag* entre os índices VIX futuro e SPX futuro, identificando uma fraca conexão para baixas volatilidades, ao passo em que para altas volatilidades foi identificada correlação forte e negativa com os VIX futuro liderando o SPX futuro. Cheng et al. (2022) utilizaram efeitos *lead-lag* como uma das fontes para construção de uma rede neural multimodal de grafos para previsão de séries temporais financeiras. Os resultados alcançados indicam que o modelo de rede neural obtido poderia evitar perdas de investimento financeiro.

3. Metodologia

3.1 Descrição dos índices setoriais

A B3 S.A. é, atualmente, a principal bolsa de valores brasileira, resultado da fusão ocorrida em 2017 da Bolsa de Valores, Mercadorias e Futuros de São Paulo (BMFBovespa) com a Central de Custódia e de Liquidação Financeira de Títulos (CETIP). Essa instituição organiza e divulga índices setoriais, formados por conjuntos de ações representativas de setores específicos da economia brasileira.

A existência dos índices setoriais permite o acompanhamento do desempenho de setores específicos da economia. Como fonte de dados agregada por setores específicos, os índices setoriais fornecem dados relevantes para estudos econômicos, cuja importância reside não apenas na compreensão do funcionamento do mercado, mas também na obtenção de subsídios para realização de investimentos nos setores a partir dos ETFs (*Exchange-Traded Fund*).

Conforme apresentado no site da instituição³, o Índice Utilidade Pública (UTIL) é um indicador do desempenho médio das cotações dos ativos de maior negociabilidade e representatividade do setor de utilidade pública (energia elétrica, água e saneamento e gás). O Índice de Materiais Básicos (IMAT) representa o desempenho médio das cotações dos ativos de maior negociabilidade e representatividade do setor de materiais básicos. O Índice Financeiro (IFNC) trata do desempenho médio das cotações dos ativos de maior negociabilidade e representatividade dos setores de intermediários financeiros, serviços financeiros diversos, previdência e seguros. O Índice Imobiliário (IMOB) é indicador do desempenho médio das cotações dos ativos de maior negociabilidade e representatividade dos setores da atividade imobiliária compreendidos por exploração de imóveis e construção civil. Índice de Consumo (ICON) representa o desempenho médio das cotações dos ativos de maior negociabilidade e representatividade dos setores de consumo cíclico, consumo não cíclico e saúde. Índice do Setor Industrial (INDX) é indicador do desempenho médio das cotações dos ativos de maior negociabilidade e representatividade dos setores da atividade industrial compreendidos por materiais básicos, bens industriais, consumo cíclico, consumo não cíclico, tecnologia da informação e saúde. Já o Índice de Energia Elétrica (IEE) representa indicador do desempenho médio das cotações dos ativos de maior negociabilidade e representatividade do setor de energia elétrica.

Os índices UTIL, IMAT, IFNC, IMOB, ICON e INDX são índices de retorno total, enquanto IEE é um índice de retorno total com reinvestimento no próprio ativo. Segundo a B3, não são elegíveis para compor os índices setoriais as BDRs (*Brazilian Depositary Receipt*) ativos de companhias em recuperação judicial ou extrajudicial, regime especial de administração temporária, intervenção ou que sejam negociados em qualquer outra situação especial de listagem⁴.

³ Disponível para consulta em https://www.b3.com.br/pt_br/market-data-e-indices/indices/indices-de-segmentos-e-setoriais/

⁴ O documento "Manual de Definições e Procedimentos dos Índices da B3", disponível para download em http://www.b3.com.br/pt_br/, apresenta a metodologia de cálculo dos índices.

3.2 Modelo GARCH multivariado BEKK

Os modelos pioneiros para estudo de volatilidade de retorno de ativos financeiros, em especial quando a volatilidade apresenta comportamento variável no tempo, foram univariados. Engle (1982) introduziu o modelo ARCH (auto-regressivos com heteroscedasticidade condicional) e estimou a média e variância da inflação no Reino Unido. Segundo Bera e Higgins (1993), antes da introdução dos modelos ARCH, os pesquisadores tinham conhecimento das mudanças na variância, porém utilizavam procedimentos informais para computar tais variações.

Essa subseção aborda modelos apropriados para análises multivariadas, especificamente algumas extensões da classe de modelos apresentada por Engle (1982), que consideram a variância condicional evoluindo no tempo.

Bollerslev (1990) sugeriu uma generalização do modelo ARCH, denominada GARCH (modelo de heteroscedasticidade condicional autorregressiva generalizada), a qual pode descrever a volatilidade utilizando menos parâmetros do que o modelo ARCH. Segundo Bollerslev (1990), o modelo GARCH pode ser visto como um modelo ARMA univariado para segundos momentos condicional.

Diversas situações de pesquisa exigem a comparação entre ativos, examinando de forma aprofundada suas correlações. Logo, a evolução dos modelos que consideravam a volatilidade variando no tempo levou a modelos que consideram a variação da correlação no tempo. Trata-se dos modelos GARCH multivariados (MGARCH).

Conforme Lütkepohl (2005), a forma geral do modelo MGARCH é seguinte:

$$vech(\Sigma_{t|t-1}) = A_0 + \sum_{j=1}^q A_j vech(u_{t-j} u_{t-j}') + \sum_{j=1}^m B_j vech(\Sigma_{t-j|t-j-1}) \quad (1)$$

onde $vech$ denota o operador de meia vetorização que empilha as colunas de uma matriz quadrada abaixo da diagonal em um vetor, A_0 é um vetor de constantes com dimensão $1/2K(K+1)$ e $\sum_{j=1}^q$ são matrizes de coeficientes com dimensão $(1/2K(K+1) \times 1/2K(K+1))$, onde K é a dimensão do ruído branco z_t de um processo não correlacionado, que pode ser representado por:

$$u_t = \Sigma_t^{1/2} z_t, \quad z_t \sim i.i.d(0, I_K) \quad (2)$$

podendo ser demonstrado (Lütkepohl (2005)) que:

$$\Sigma_t = \Sigma_t^{1/2} (\Sigma_t^{1/2})' \quad (3)$$

onde $\Sigma_t^{1/2}$ é a raiz quadrada simétrica positiva de Σ_t .

Tendo em vista que o modelo MGARCH apresenta espaço de parâmetros com grande dimensão, há, geralmente, necessidade de restrição para obtenção de unicidade na representação e propriedades adequadas de covariâncias condicionais. Nesse sentido, modelos MGARCH diagonais foram discutidos por Bollerslev, Engle e Wooldridge (1988), onde A_j 's e B_j 's são matrizes diagonais.

O modelo BEKK GARCH, opção alternativa para GARCH multivariado, pode ser representado da seguinte forma:

$$\Sigma_{t|t-1} = A_0^{*'} A_0^* + \sum_{n=1}^N \sum_{j=1}^q A_{jn}^{*'} u_{t-j} u_{t-j}' A_{jn}^* + \sum_{n=1}^N \sum_{j=1}^m B_{jn}^{*'} \Sigma_{t-j|t-j-1} B_{jn}^* \quad (4)$$

onde a matriz triangular A_0^* e os coeficientes matriciais A_{jn}^{*} e B_{jn}^{*} possuem dimensão $K \times K$. Conforme Engle e Kroner (1995), a sigla BEKK é um acrônimo criado a partir dos nomes dos pesquisadores Yoshi Baba, Rob Engle, Dennis Kraft e Ken Krone, que realizaram trabalhos com modelos ARCH multivariados.

O modelo BEKK de baixa ordem representa de forma parcimoniosa a estrutura de

covariâncias condicionais. Entretanto, o número de parâmetros cresce rápido com a dimensão do sistema subjacente, de forma que, na prática, pode ser considerado factível somente para sistemas com algumas variáveis sendo consideradas e submetidos a medidas de simplificação para aliviar a modelagem de processos de dimensões mais elevadas. Trata-se de modelos especiais BEKK.

De acordo com Black (1976), é frequentemente observado nos mercados financeiros que choques negativos e positivos, ou notícias, possuem diferentes efeitos. O efeito alavanca pode ser introduzido de formas diferentes em modelos MGARCH. Os trabalhos de Hafner e Herwartz (1998) e Herwartz e Lütkepohl (2000) generalizaram uma proposta univariada de Glosten, Ja-gannathan e Runkle (1993) e substituíram $A_{jn}^* u_{t-j} u_{t-j}^* A_{jn}^*$ por:

$$A_{11}^* u_{t-1} u_{t-1}^* A_{11}^* + A_{-}^* u_{t-1} u_{t-1}^* A_{-}^* I\left(\sum_{k=1}^K u_{kt} < 0\right) \quad (5)$$

em um modelo BEKK com $N = 1$, onde $I(\cdot)$ denota uma função indicadora que assume o valor 1 se o argumento é válido e 0 caso contrário e A_{-}^* é um coeficiente adicional da matriz $(K \times K)$.

Por fim, ressalta-se que existem implementações em relação ao modelo BEKK. Conforme descrito em Erten, Tuncel e Okay (2012), o modelo Diagonal BEKK⁵ é um modelo GARCH multivariado que permite a parametrização explícita e dinâmica de covariâncias condicionais. O modelo reduz o número de parâmetros estimados e garante que a matriz de covariância condicional seja sempre positivo definido.

3.3 Teste de causalidade de Granger de segunda ordem

Conforme Granger (1988), as previsões ótimas podem ser obtidas, sob condições adequadas, como esperanças condicionais. Logo, a definição de causalidade de Granger se baseia em previsões. Podemos definir uma variável de séries de tempo X_t para ser causal de Z_t , se

$$E(z_{t+1} | z_t, z_{t-1}, \dots) \neq E(z_{t+1} | z_t, z_{t-1}, \dots, x_t, x_{t-1}) \quad (6)$$

A definição anterior sugere uma extensão direta de ordem superior de momentos condicionais. Podemos definir x_t como causal para z_t no r -ésimo momento se

$$E(z_{t+1}^r | z_t, z_{t-1}, \dots) \neq E(z_{t+1}^r | z_t, z_{t-1}, \dots, x_t, x_{t-1}) \quad (7)$$

Enquanto a primeira desigualdade define a causalidade em média e considerando os segundos momentos centrais, a segunda desigualdade dá uma definição de causalidade na variância que é análoga à definição prévia de causalidade de Granger em média. Ou seja, se X_t é causal na variância para Z_t , a volatilidade condicional de Z_t pode ser prevista de forma mais precisa, tendo em conta a informação presente e passada em X_t do que sem considerar esta informação.

Conforme Maranhão e Oliveira (2017b), um vetor de variáveis não causa outro vetor de variáveis, conforme a causalidade de Granger de segunda ordem, se as informações do passado sobre a variabilidade do primeiro não podem melhorar a previsão de variâncias condicionais dos últimos. A definição da não causalidade de segunda ordem assume que as relações causais de Granger podem existir no processo de média condicional. No entanto, elas devem ser modeladas a partir de filtros. Caso contrário, essas relações podem ter impacto sobre os parâmetros responsáveis pelas relações causais em variâncias condicionais.

⁵ Detalhamento matemático do modelo Diagonal BEKK foge do escopo desse Artigo.

3.4 Teste CN

O teste CN, desenvolvido por Cheung e Ng (1996) para análise de causalidade no segundo momento, é um procedimento realizado em duas etapas e foi idealizado como uma extensão natural do modelo de causalidade no primeiro momento (Wiener-Granger), desenvolvido por Granger, Robins e Engle (1986). O teste é baseado no valor residual da função de correlação cruzada (CCF - *cross-correlation function*) e é robusta às premissas distributivas.

A modelagem considera, inicialmente, duas séries de tempo estacionárias e ergódicas X_t e Y_t e informações I_t e J_t definidas como $I_t = \{X_{t-j}, j \geq 0\}$ e $J_t = \{X_{t-j}, Y_{t-j}, j \geq 0\}$. Nessa modelagem, podemos considerar que Y_t causa X_{t+1} em termos de variância se, para $\mu_{x,t+1}$ como média de X_{t+1} condicionada a I_t , for satisfeita a seguinte desigualdade:

$$E\{(X_{t+1} - \mu_{x,t+1})^2 | I_t\} \neq E\{(X_{t+1} - \mu_{x,t+1})^2 | J_t\} \quad (8)$$

Também existe a possibilidade de X_t causar efeitos na variância de Y_t e Y_t causar em X_t . Essa situação é definida pelos autores como feedback na variância. Ainda, pode ocorrer causalidade instantânea na variância se for satisfeita a seguinte condição:

$$E\{(X_{t+1} - \mu_{x,t+1})^2 | J_t\} \neq E\{(X_{t+1} - \mu_{x,t+1})^2 | J_t + Y_{t+1}\} \quad (9)$$

Tendo em vista a generalidade das equações (7) e (8), assim como ocorre no modelo de causalidade na média, Cheung e Ng (1996) indicam que são necessárias estruturas adicionais para que o modelo possa ser utilizado de forma prática. Consideremos ε_t e ζ_t como dois ruídos brancos com média zero e variância igual a um, podemos escrever X_t e Y_t como:

$$X_t = \mu_{x,t} + h_{x,t}^{0,5} \varepsilon_t \quad (10)$$

$$Y_t = \mu_{y,t} + h_{y,t}^{0,5} \zeta_t \quad (11)$$

sendo que as médias e variâncias condicionais são dadas por:

$$\mu_{z,t} = \sum_{i=1}^{\infty} \phi_{z,i}(\theta_{z,\mu}) Z_{t-i} \quad (12)$$

e

$$h_{z,t} = \varphi_{z,0} + \sum_{i=1}^{\infty} \varphi_{z,i}(\theta_{z,h}) \{(Z_{t-i} - \mu_{z,t-i})^2 - \varphi_{z,0}\} \quad (13)$$

onde θ_{zw} é um vetor de parâmetro $p_{zw} \times 1$; $W = \mu, h$; $\phi_{z,i}(\theta_{z,\mu})$ e $\varphi_{z,i}(\theta_{z,h})$ são funções definidas de $\theta_{z,\mu}$ e $\theta_{z,h}$; e $Z = X, Y$.

Essas especificações incluem modelos de séries temporais, como ARMA e GARCH. Assume-se estacionariedade, a qual define implicitamente o conjunto viável de parâmetros. A seguir, são definidos os seguintes quadrados padronizados:

$$U_t = (X_t - \mu_{x,t})^2 / h_{x,t} = \varepsilon_t^2 \quad (14)$$

$$V_t = (Y_t - \mu_{y,t})^2 / h_{y,t} = \zeta_t^2 \quad (15)$$

A correlação transversal com lag k é dada por $r_{uv}(k)$:

$$r_{uv}(k) = e_{uv}(k)(e_{uu}(0)e_{vv}(0))^{-1/2} \quad (16)$$

onde $e_{uv}(k)$ é o k -ésimo *lag* da covariância transversal amostral dada por

$$e_{uv}(k) = T^{-1} \sum (U_t - \bar{U})(V_{t-k} - \bar{V}), \quad k = 0, \pm 1, \pm 2, \dots \quad (17)$$

sendo $e_{uv}(0)$ e $e_{vv}(0)$, respectivamente, as variâncias amostrais de U e V .

Conforme Cheung e Ng (1996), a independência de $\{U_t\}$ e $\{V_t\}$ faz com que a existência do segundo momento implique em

$$\begin{pmatrix} \sqrt{T} r_{uv}(k) \\ \sqrt{T} r_{uv}(k') \end{pmatrix} \rightarrow AN \left(\begin{bmatrix} 0 \\ 0 \end{bmatrix}, \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \right), \quad k \neq k' \quad (18)$$

Cheung e Ng (1996) afirmam que a CCF de quadrados dos resíduos padronizados pode ser utilizada para detecção de relações causais e identificação de padrões de causalidade no segundo momento, possuindo vantagens em relação a alguns testes alternativos para causalidade em variância. Os autores ressaltam que o teste proposto apresenta distribuição assintótica bem definida e é assintoticamente robusta às premissas distributivas. Ainda, é útil para situações nas quais há grande número de observações e quando são esperados longos lags no padrão de causalidade padrão. Demonstrações, teoremas e provas podem ser consultados em Cheung e Ng (1996).

3.5 Descrição dos modelos e testes utilizados

Com objetivo de capturar os efeitos da volatilidade cambial nos índices setoriais brasileiros, este estudo utilizou série temporal do dólar, sete índices setoriais da bolsa de valores brasileira B3 e o índice Ibovespa, todos no período de 19/05/2011 a 04/03/2020, diariamente⁶. Os índices setoriais⁷ avaliados neste estudo foram UTIL, IMAT, IFNC, IMOB, ICON, INDX e IEE.

Foram estimados modelos MGARCH BEKK e Diagonal BEKK conforme descrição a seguir. Modelo 1: Retorno de cada índice setorial e retorno do dólar; Modelo 2: Retorno de cada índice setorial e retorno do Ibovespa; Modelo 3: Retorno de cada índice setorial, retorno do Ibovespa e retorno do dólar.

O Modelo 1 permite analisar cada índice em relação ao efeito do retorno do dólar, dado sua importância como principal moeda que compõe reservas internacionais, seguindo análise semelhante a realizada por Maranhão e Oliveira (2017a). O Modelo 2 permite analisar o efeito do Ibovespa nos índices setoriais. Já o Modelo 3 permite analisar o efeito do Ibovespa e do dólar sobre os índices setoriais.

Foram realizados testes de causalidade de segundo momento (Teste CN) com objetivo de identificar a direção da causalidade das correlações condicionais estimadas para os modelos univariados.

4. Resultados

Os resultados das estatísticas exploratórias para as séries dos retornos do dólar, do índice Ibovespa (BVSP) e dos índices setoriais estão apresentados na Tabela 1. Os resultados indicam alguns fatos estilizados de retornos, descritos por Caldeira, Souza e Machado (2010) e também indicados nos trabalhos de Maranhão e Oliveira (2017b) e Maranhão e Oliveira (2017a): presença de assimetria e curtose, média próxima de zero, ausência de normalidade e estacionariedade das séries.

Conforme estudo de Lütkepohl (2005), não há extensa literatura para escolha de ordens de modelo GARCH multivariado, sendo mais desenvolvida a literatura para o caso univariado. Este trabalho utiliza metodologia aplicada por de Maranhão e Oliveira

⁶ Os dados dos índices setoriais utilizados estão disponíveis e foram obtidos na plataforma Investing, enquanto a taxa de câmbio foi obtida da plataforma Bloomberg. Três observações do dia 09/07/2013 (índices INDX, IMAT e IFNC) estavam faltantes e foram estimadas por interpolação.

⁷ A descrição detalhada dos índices setoriais foi apresentada na seção 3.1.

(2017b) e Maranhão e Oliveira (2017a), na qual é utilizada a abordagem de identificação do caso univariado como indicação para o caso multivariado, tendo em vista que a saturação de parâmetros pode rapidamente comprometer a estimação para o MGARCH estrutural (BEKK).

Tabela 1 – Estatísticas exploratórias e retornos das séries

Estatísticas/Testes	Índices Setoriais								
	Dólar	BVSP	UTIL	INDX	IMOB	IMAT	IFNC	IEE	ICON
n	2175	2175	2175	2175	2175	2175	2175	2175	2175
Média	0,00048	0,00025	0,00057	0,00033	0,00018	0,00026	0,00057	0,00046	0,00053
Mediana	0,0004300	0,00027	0,00106	0,00046	0,00027	0,00021	0,00057	0,00069	0,00077
Máximo	0,07270	0,06387	0,05942	0,05248	0,07327	0,06936	0,09308	0,04995	0,05202
Mínimo	-0,05601	-0,0921	-0,1104	-0,0737	-0,1442	-0,0918	-0,1228	-0,1061	-0,0745
Variância	9,64217e-05	0,00021	0,00018	0,00013	0,00026	0,00030	0,00026	0,00015	0,00013
Desvio-padrão	0,00982	0,01440	0,01333	0,01148	0,01623	0,01723	0,01599	0,01213	0,01156
Assimetria	0,11655	-0,2137	-0,6366	-0,2695	-0,3139	-0,0548	-0,0990	-0,6797	-0,3324
Curtose	6,30429	5,12170	7,53783	5,56789	6,83891	4,64460	6,22366	8,17688	5,26098
Coef. Variação	2050,86	57,80	23,57	34,41	90,09	65,22	28,07	26,13	21,84
JarqueBera (<i>p</i> -valor)	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
ADF (<i>p</i> -valor)	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00

Fonte: Elaboração própria.

Nota: Jarque Bera - H0: Os dados possuem distribuição normal. ADF - H0: Presença de raiz unitária. Os resultados com termo constante e termo e/ou com tendência temporal não se alteram. A seleção da defasagem utilizada nos Teste ADF utilizou o critério de Informação de AIC. Fonte: Assimetria e curtose foram calculadas por meio do pacote moments, de Komsta e Novomestky (2015). Teste de Jarque Bera foi calculado por meio do pacote tseries, de Trapletti e Hornik (2019). ADF calculado por meio do pacote urca, de Pfaff (2008).

Para as séries de retornos logarítmicos, foram avaliados os melhores modelos GARCH univariados seguindo etapas que procuraram selecionar modelos com boas características preditivas e explicativas: Utilização das ordens indicadas pelos gráficos de ACF e PACF como valores máximos possíveis das ordens q e p dos modelos univariados GARCH(p,q); Avaliação dos modelos univariados em diferentes combinações (p,q), de GARCH(1,0) até as ordens definidas na etapa anterior, considerando quatro possíveis distribuições condicionais: normal (norm), skew-normal (snorm), t-Student (std) e skew-t (sst); Seleção inicial de modelos pelo menor critério de informação de Akaike (AIC); Considerando os modelos selecionados na etapa anterior, inserir estruturas ARMA buscando remover dos resíduos estruturas remanescentes e escolher os melhores modelos pela combinação de menores critérios de informação e maior quantidade de parâmetros estatisticamente significativos.

A Tabela 2 apresenta os resultados dos melhores modelos GARCH univariados para as 9 séries estudadas neste trabalho.

Os testes LM⁸ para resíduos e resíduos ao quadrado estão apresentados na Figura 1 e na Figura 2, respectivamente, e indicam que os modelos descritos na Tabela 2 não apresentam resíduos com estrutura autocorrelação. Os *p*-valores foram maiores que o nível de significância em todas as defasagens para os resíduos (Figura 1) e, no caso dos resíduos ao quadrado (Figura 2), foram superiores ao nível de significância pelo menos até a sétima defasagem. O nível de significância foi 1% nos dois testes.

Os resultados indicaram que distribuições com caudas mais pesadas apresentaram melhores ajustes às séries estudadas, o que está de acordo com as estatísticas exploratórias. Conforme Tabela 2, as ordens dos modelos GARCH foram baixas, GARCH(1,1), indicando que as ordens dos modelos MGARCH BEKK também são baixas. Ressalta-se que a validação das ordens sugeridas para os modelos multivariados será realizada por meio da eliminação da autocorrelação dos resíduos padronizados e dos quadrados dos resíduos padronizados.


⁸ Teste do Multiplicador de Lagrange para autocorrelação com a H0: Ausência de autocorrelação na k -ésima defasagem. Nível de significância = 1%.

Tabela 2 – Modelos GARCH ajustados para Índices Setoriais, Ibovespa e Dólar


Índice	ACF	PACF	Distribuição	Modelo	AIC
Dólar	6	2	Skew-t	ARMA(2,1) + GARCH(1,1)	-6,592881
BVSP	3	3	t-Student	ARMA(1,1) + GARCH(1,1)	-5,728469
UTIL	3	3	t-Student	ARMA(1,1) + GARCH(1,1)	-5,933986
INDX	3	3	Skew-t	ARMA(1,1) + GARCH(1,1)	-6,189370
IMOB	5	3	t-Student	ARMA(1,1) + GARCH(1,1)	-5,520087
IMAT	4	3	t-Student	ARMA(1,1) + GARCH(1,1)	-5,371847
IFNC	—	2	t-Student	ARMA(1,1) + GARCH(1,1)	-5,54374
IEE	2	2	Skew-t	ARMA(0,1) + GARCH(1,1)	-6,157414
ICON	3	3	Skew-t	GARCH(1,1)	-6,15552

Fonte: Elaboração própria.

Nota: Foi utilizado o pacote fGarch, desenvolvido por Wuertz et al. (2019).

Figura 1 - Teste LM para resíduos padronizados dos modelos GARCH univariados apresentados na Tabela 2


Fonte: Elaboração própria.

Figura 2 - Teste LM para resíduos padronizados ao quadrado dos modelos GARCH univariados apresentados na Tabela 2


Fonte: Elaboração própria.

4.1 Modelos MGARCH-BEKK e MGARCH-DBEKK estimados

Tendo em vista as ordens dos modelos GARCH univariados apresentados na Tabela 2, este estudo priorizou utilização de modelos GARCH multivariados de ordens baixas, estatisticamente significativos conforme testes LM. Os resultados dos modelos escolhidos para cada série estão apresentados na Tabela 3.

Tabela 3 - Modelos GARCH multivariados escolhidos

Índice	Modelo	AIC	BIC	LOG
UTIL	MGARCH-DBEKK(1,1)	-41699,06	-41613,79	20864,53
IMAT	MGARCH-DBEKK(2,2)	-40722,72	-40603,34	20382,36
IFNC	MGARCH-DBEKK(1,1)	-42857,62	-42772,35	21443,81
IMOB	MGARCH-DBEKK(1,1)	-41327,89	-41242,62	20678,94
ICON	MGARCH-DBEKK(2,1)	-43085,51	-42983,18	21560,75
INDX	MGARCH-DBEKK(2,1)	-43352,25	-43249,92	21694,12
IEE	MGARCH-DBEKK(1,1)	-42015,89	-41930,62	21022,95

Fonte: Elaboração própria.

Todos os modelos MGARCH-BEKK⁹ padrão tiveram resultados insatisfatórios nos testes LM para os resíduos ao quadrado, ou seja, não tiveram êxito em eliminar estruturas de autocorrelação. Ainda, os modelos MGARCH-BEKK apresentaram grande quantidade de parâmetros estatisticamente não significativos.

Já os modelos MGARCH-DBEKK (Diagonal BEKK) com inclusão de parâmetros de choques assimétricos¹⁰ apresentaram maior proporção de parâmetros estatisticamente significantes e obtiveram resultados satisfatórios nos testes LM.

4.2 Testes CN

Testes CN foram implementados utilizando os resíduos padronizados dos modelos GARCH univariados estimados para as séries temporais, descritos na Tabela 2.

Este estudo procurou englobar os impactos que diferentes características hipotéticas podem causar nos resultados dos testes. Dessa forma, foram considerados diferentes valores de defasagens (30, 10 ou 3)¹¹, matrizes de Variância-Covariância (homocedástica ou heterocedástica) e erros (correlacionados ou não correlacionados).

Os resultados estão organizados em tópicos agrupados de acordo com a quantidade de defasagens. Os p-valores dos testes são apresentados na forma de tabelas e as hipóteses (exceto para a o teste conjunto), considerando i e j para linha e coluna, respectivamente, são as seguintes: H0: Y(i) não causa Y(j), com $i \neq j$; Ha: Y(i) causa Y(j), com $i \neq j$. Para o teste conjunto, as hipóteses são as seguintes: H0: Y(i) não causa nenhum Y(j), com i algum Y(j), com $i \neq j$.

4.2.1 Testes CN para 30 defasagens

As Tabelas 4, 5, 6 e 7 apresentam os resultados dos testes, considerando 30 defasagens.

Os resultados dos testes indicam que, independentemente das escolhas da Matriz de Variância-Covariância e da correlação dos erros: cada série estudada causa pelo menos uma das demais séries; todas as séries estudadas causam as séries IMAT e IEE; nenhuma série estudada causa as séries IMOB e INDX, considerando nível de significância $\alpha = 1\%$.

⁹ Foram testados para os modelos MGARCH-BEKK e MGARCH-DBEKK, suas versões VAR(P) com vistas a eliminação de possíveis estruturas de autocorrelação dos retornos multivariados, contudo a maior parte dos parâmetros se mostraram estatisticamente insignificantes, além de não alterarem os resultados dos testes LM para os resíduos dos modelos. Desse modo, optamos pela apresentação dos resultados mais relevantes.

¹⁰ Assimetria representada pelos parâmetros γ nos modelos estimados, testes LM para os resíduos dos modelos. Desse modo, optamos pela apresentação dos resultados mais relevantes.

¹¹ A utilização de diferentes defasagens tem como objetivo identificar a possibilidade de dependência temporal nos testes de causalidade de Granger de segunda ordem. Muito embora já existam testes de causalidade de Granger variando no tempo, esses testes não foram utilizados no presente estudo.

Tabela 4 - Testes CN para 30 defasagens, com matriz de variância-covariância heterocedástica e erros correlacionados

	UTIL	IMAT	IFNC	IMOB	ICON	INDX	IEE	Dólar	BVSP	Teste Conjunto
UTIL	-	0,000	0,000	0,565	0,000	0,015	0,000	0,000	0,000	0,000
IMAT	0,000	-	0,000	0,930	0,000	0,651	0,000	0,001	0,000	0,000
IFNC	0,000	0,000	-	0,877	0,000	0,018	0,000	0,000	0,000	0,000
IMOB	0,000	0,000	0,000	-	0,000	0,728	0,000	0,000	0,000	0,000
ICON	0,000	0,000	0,000	0,245	-	0,714	0,000	0,000	0,000	0,000
INDX	0,000	0,000	0,000	0,020	0,000	-	0,000	0,000	0,000	0,000
IEE	0,000	0,000	0,000	0,173	0,000	0,028	-	0,000	0,000	0,000
Dólar	0,000	0,000	0,003	0,949	0,000	0,037	0,000	-	0,001	0,000
BVSP	0,000	0,000	0,000	0,162	0,000	0,091	0,000	0,739	-	0,000

Fonte: Elaboração própria.

Nota: A tabela apresenta os p-valores dos testes CN. Hipóteses (exceto para a o teste conjunto), considerando i e j para linha e coluna, respectivamente: H0: Y(i) não causa Y(j), com $i \neq j$; Ha: Y (i) causa Y(j), com $i \neq j$. Para o teste conjunto: H0: Y(i) não causa nenhum Y(j), com $i \neq j$; Ha: Y(i) causa algum Y(j), com $i \neq j$.

Tabela 5 - Testes CN para 30 defasagens, com matriz de variância-covariância heterocedástica e erros não-correlacionados

	UTIL	IMAT	IFNC	IMOB	ICON	INDX	IEE	Dólar	BVSP	Teste Conjunto
UTIL	-	0,000	0,001	0,861	0,005	0,310	0,002	0,044	0,000	0,000
IMAT	0,008	-	0,018	0,967	0,001	0,822	0,010	0,075	0,018	0,000
IFNC	0,000	0,000	-	0,945	0,007	0,312	0,000	0,025	0,002	0,000
IMOB	0,000	0,000	0,003	-	0,000	0,881	0,000	0,062	0,000	0,000
ICON	0,000	0,000	0,029	0,742	-	0,897	0,000	0,001	0,009	0,000
INDX	0,000	0,000	0,003	0,489	0,010	-	0,000	0,077	0,002	0,000
IEE	0,014	0,000	0,001	0,701	0,002	0,253	-	0,061	0,000	0,000
Dólar	0,018	0,000	0,063	0,966	0,005	0,151	0,002	-	0,175	0,000
BVSP	0,000	0,000	0,014	0,716	0,001	0,626	0,000	0,107	-	0,000

Fonte: Elaboração própria.

Nota: A tabela apresenta os p-valores dos testes CN. Hipóteses (exceto para a o teste conjunto), considerando i e j para linha e coluna, respectivamente: H0: Y(i) não causa Y(j), com $i \neq j$; Ha: Y (i) causa Y(j), com $i \neq j$. Para o teste conjunto: H0: Y(i) não causa nenhum Y(j), com $i \neq j$; Ha: Y(i) causa algum Y(j), com $i \neq j$.

Tabela 6 - Testes CN para 30 defasagens, com matriz de variância-covariância homocedástica e erros correlacionados

	UTIL	IMAT	IFNC	IMOB	ICON	INDX	IEE	Dólar	BVSP	Teste Conjunto
UTIL	-	0,000	0,000	0,682	0,000	0,037	0,000	0,000	0,000	0,000
IMAT	0,000	-	0,001	0,944	0,000	0,733	0,000	0,011	0,000	0,000
IFNC	0,000	0,000	-	0,891	0,000	0,048	0,000	0,000	0,000	0,000
IMOB	0,000	0,000	0,000	-	0,000	0,829	0,000	0,020	0,000	0,000
ICON	0,000	0,000	0,000	0,449	-	0,776	0,000	0,000	0,000	0,000
INDX	0,000	0,000	0,000	0,088	0,000	-	0,000	0,000	0,000	0,000
IEE	0,000	0,000	0,000	0,400	0,000	0,017	-	0,001	0,000	0,000
Dólar	0,012	0,000	0,041	0,959	0,002	0,160	0,002	-	0,143	0,000
BVSP	0,000	0,000	0,000	0,298	0,000	0,203	0,000	0,000	-	0,000

Fonte: Elaboração própria.

Nota: A tabela apresenta os p-valores dos testes CN. Hipóteses (exceto para a o teste conjunto), considerando i e j para linha e coluna, respectivamente: H0: Y(i) não causa Y(j), com $i \neq j$; Ha: Y (i) causa Y(j), com $i \neq j$. Para o teste conjunto: H0: Y(i) não causa nenhum Y(j), com $i \neq j$; Ha: Y(i) causa algum Y(j), com $i \neq j$.

Tabela 7 - Testes CN para 30 defasagens, com matriz de variância-covariância homocedástica e erros não-correlacionados

	UTIL	IMAT	IFNC	IMOB	ICON	INDX	IEE	Dólar	BVSP	Teste Conjunto
UTIL	-	0,000	0,013	0,892	0,092	0,490	0,033	0,220	0,031	0,000
IMAT	0,007	-	0,034	0,965	0,002	0,828	0,009	0,102	0,017	0,000
IFNC	0,008	0,000	-	0,958	0,045	0,445	0,010	0,157	0,031	0,000
IMOB	0,013	0,000	0,033	-	0,014	0,929	0,008	0,334	0,028	0,000
ICON	0,000	0,000	0,074	0,774	-	0,914	0,000	0,014	0,054	0,000
INDX	0,001	0,000	0,011	0,500	0,039	-	0,001	0,145	0,019	0,000
IEE	0,151	0,000	0,030	0,806	0,133	0,486	-	0,335	0,023	0,000
Dólar	0,106	0,001	0,187	0,974	0,050	0,365	0,049	-	0,345	0,000
BVSP	0,001	0,000	0,022	0,757	0,011	0,705	0,002	0,257	-	0,000

Fonte: Elaboração própria.

Nota: A tabela apresenta os p-valores dos testes CN. Hipóteses (exceto para a o teste conjunto), considerando i e j para linha e coluna, respectivamente: H0: Y(i) não causa Y(j), com $i \neq j$; Ha: Y (i) causa Y(j), com $i \neq j$. Para o teste conjunto: H0: Y(i) não causa nenhum Y(j), com $i \neq j$; Ha: Y(i) causa algum Y(j), com $i \neq j$.

4.2.2 Testes CN para 10 defasagens

As Tabelas 8, 9, 10 e 11 apresentam os resultados dos testes, considerando 10 defasagens.

Os resultados dos testes indicam que, independentemente das escolhas da Matriz de Variância- Covariância e da correlação dos erros: cada série estudada causa pelo menos uma das demais séries; todas as séries estudadas causam as séries UTIL e IMAT.

Ao se reduzir o número de defasagem de 30 para 10, a série INDX passou a ter volatilidade antecipada por volatilidade de outras séries (precedência estatística). Já a série IMOB permaneceu sem ter volatilidade antecipada por volatilidade de outras séries.

Tabela 8 - Testes CN para 10 defasagens, com matriz de variância-covariância heterocedástica e erros correlacionados

	UTIL	IMAT	IFNC	IMOB	ICON	INDX	IEE	Dólar	BVSP	Teste Conjunto
UTIL	-	0,000	0,008	0,500	0,075	0,010	0,000	0,004	0,787	0,000
IMAT	0,000	-	0,000	0,073	0,001	0,000	0,000	0,000	0,000	0,000
IFNC	0,000	0,000	-	0,004	0,013	0,011	0,000	0,000	0,000	0,000
IMOB	0,000	0,000	0,000	-	0,012	0,617	0,000	0,035	0,003	0,000
ICON	0,000	0,000	0,000	0,859	-	0,000	0,000	0,000	0,000	0,000
INDX	0,000	0,000	0,000	0,217	0,000	-	0,000	0,000	0,000	0,000
IEE	0,000	0,000	0,006	0,519	0,508	0,000	-	0,003	0,103	0,000
Dólar	0,000	0,000	0,075	0,207	0,014	0,173	0,000	-	0,000	0,000
BVSP	0,000	0,000	0,000	0,018	0,003	0,001	0,000	0,726	-	0,000

Fonte: Elaboração própria.

Nota: A tabela apresenta os p-valores dos testes CN. Hipóteses (exceto para a o teste conjunto), considerando i e j para linha e coluna, respectivamente: H0: Y(i) não causa Y(j), com $i \neq j$; Ha: Y (i) causa Y(j), com $i \neq j$. Para o teste conjunto: H0: Y(i) não causa nenhum Y(j), com $i \neq j$; Ha: Y(i) causa algum Y(j), com $i \neq j$.

Tabela 9 - Testes CN para 10 defasagens, com matriz de variância-covariância heterocedástica e erros não-correlacionados

	UTIL	IMAT	IFNC	IMOB	ICON	INDX	IEE	Dólar	BVSP	Teste Conjunto
UTIL	-	0,000	0,463	0,868	0,597	0,394	0,001	0,463	0,949	0,000
IMAT	0,001	-	0,025	0,559	0,064	0,045	0,000	0,001	0,000	0,000
IFNC	0,001	0,000	-	0,368	0,327	0,364	0,020	0,165	0,111	0,000
IMOB	0,000	0,000	0,054	-	0,323	0,831	0,007	0,385	0,212	0,000
ICON	0,009	0,000	0,036	0,964	-	0,172	0,024	0,033	0,025	0,000
INDX	0,003	0,000	0,020	0,800	0,191	-	0,001	0,003	0,005	0,000
IEE	0,000	0,000	0,453	0,884	0,854	0,194	-	0,388	0,718	0,000
Dólar	0,000	0,000	0,270	0,427	0,097	0,358	0,012	-	0,009	0,000
BVSP	0,000	0,000	0,052	0,654	0,386	0,357	0,001	0,023	-	0,000

Fonte: Elaboração própria.

Nota: A tabela apresenta os p-valores dos testes CN. Hipóteses (exceto para a o teste conjunto), considerando i e j para linha e coluna, respectivamente: H0: Y(i) não causa Y(j), com $i \neq j$; Ha: Y (i) causa Y(j), com $i \neq j$. Para o teste conjunto: H0: Y(i) não causa nenhum Y(j), com $i \neq j$; Ha: Y(i) causa algum Y(j), com $i \neq j$.

Tabela 10 - Testes CN para 10 defasagens, com matriz de variância-covariância homocedástica e erros correlacionados

	UTIL	IMAT	IFNC	IMOB	ICON	INDX	IEE	Dólar	BVSP	Teste Conjunto
UTIL	-	0,000	0,051	0,640	0,228	0,053	0,000	0,129	0,812	0,000
IMAT	0,000	-	0,001	0,220	0,005	0,001	0,000	0,000	0,000	0,000
IFNC	0,000	0,000	-	0,034	0,044	0,057	0,000	0,011	0,001	0,000
IMOB	0,000	0,000	0,007	-	0,082	0,745	0,000	0,227	0,078	0,000
ICON	0,000	0,000	0,000	0,889	-	0,000	0,000	0,000	0,000	0,000
INDX	0,000	0,000	0,000	0,374	0,001	-	0,000	0,000	0,000	0,000
IEE	0,000	0,000	0,081	0,690	0,682	0,004	-	0,108	0,296	0,000
Dólar	0,000	0,000	0,255	0,406	0,042	0,245	0,013	-	0,003	0,000
BVSP	0,000	0,000	0,000	0,056	0,003	0,004	0,000	0,000	-	0,000

Fonte: Elaboração própria.

Nota: A tabela apresenta os p-valores dos testes CN. Hipóteses (exceto para a o teste conjunto), considerando i e j para linha e coluna, respectivamente: H0: Y(i) não causa Y(j), com $i \neq j$; Ha: Y (i) causa Y(j), com $i \neq j$. Para o teste conjunto: H0: Y(i) não causa nenhum Y(j), com $i \neq j$; Ha: Y(i) causa algum Y(j), com $i \neq j$.

Tabela 11 - Testes CN para 10 defasagens, com matriz de variância-covariância homocedástica e erros não-correlacionados

	UTIL	IMAT	IFNC	IMOB	ICON	INDX	IEE	Dólar	BVSP	Teste Conjunto
UTIL	-	0,000	0,517	0,876	0,688	0,519	0,035	0,613	0,937	0,000
IMAT	0,002	-	0,040	0,433	0,073	0,038	0,002	0,003	0,001	0,000
IFNC	0,001	0,000	-	0,414	0,437	0,463	0,039	0,328	0,211	0,000
IMOB	0,007	0,000	0,263	-	0,471	0,893	0,101	0,616	0,465	0,000
ICON	0,005	0,000	0,076	0,958	-	0,184	0,018	0,037	0,055	0,000
INDX	0,005	0,000	0,051	0,725	0,181	-	0,005	0,004	0,014	0,000
IEE	0,006	0,001	0,607	0,907	0,904	0,395	-	0,636	0,759	0,000
Dólar	0,001	0,000	0,462	0,591	0,188	0,453	0,109	-	0,052	0,000
BVSP	0,000	0,000	0,121	0,569	0,384	0,387	0,004	0,057	-	0,000

Fonte: Elaboração própria.

Nota: A tabela apresenta os p-valores dos testes CN. Hipóteses (exceto para a o teste conjunto), considerando i e j para linha e coluna, respectivamente: H0: Y(i) não causa Y(j), com $i \neq j$; Ha: Y (i) causa Y(j), com $i \neq j$. Para o teste conjunto: H0: Y(i) não causa nenhum Y(j), com $i \neq j$; Ha: Y(i) causa algum Y(j), com $i \neq j$.

4.2.3 Testes CN para 3 defasagens

As Tabelas 12, 13, 14 e 15 apresentam os resultados dos testes, considerando 3 defasagens.

Os resultados dos testes indicam que, independentemente das escolhas da Matriz de Variância- Covariância e da correlação dos erros: cada série estudada causa pelo menos uma das demais séries; Todas as séries estudadas causam as séries IMAT e Dólar.

Tabela 12 - Testes CN para 3 defasagens, com matriz de variância-covariância heterocedástica e erros correlacionados

	UTIL	IMAT	IFNC	IMOB	ICON	INDX	IEE	Dólar	BVSP	Teste Conjunto
UTIL	-	0,000	0,422	0,068	0,000	0,383	0,000	0,000	0,019	0,000
IMAT	0,000	-	0,000	0,011	0,000	0,217	0,000	0,000	0,000	0,000
IFNC	0,000	0,000	-	0,084	0,000	0,005	0,000	0,000	0,000	0,000
IMOB	0,000	0,000	0,005	-	0,000	0,061	0,000	0,000	0,000	0,000
ICON	0,000	0,000	0,000	0,275	-	0,011	0,000	0,000	0,000	0,000
INDX	0,000	0,000	0,000	0,158	0,000	-	0,000	0,000	0,000	0,000
IEE	0,000	0,000	0,216	0,013	0,000	0,215	-	0,000	0,000	0,000
Dólar	0,001	0,000	0,853	0,694	0,001	0,044	0,001	-	0,835	0,000
BVSP	0,000	0,000	0,000	0,052	0,000	0,928	0,000	0,000	-	0,000

Fonte: Elaboração própria.

Nota: A tabela apresenta os p-valores dos testes CN. Hipóteses (exceto para a o teste conjunto), considerando i e j para linha e coluna, respectivamente: H0: Y(i) não causa Y(j), com $i \neq j$; Ha: Y (i) causa Y(j), com $i \neq j$. Para o teste conjunto: H0: Y(i) não causa nenhum Y(j), com $i \neq j$; Ha: Y(i) causa algum Y(j), com $i \neq j$.

Tabela 13 - Testes CN para 3 defasagens, com matriz de variância-covariância heterocedástica e erros não-correlacionados

	UTIL	IMAT	IFNC	IMOB	ICON	INDX	IEE	Dólar	BVSP	Teste Conjunto
UTIL	-	0,000	0,786	0,544	0,009	0,830	0,021	0,021	0,516	0,000
IMAT	0,000	-	0,001	0,234	0,016	0,560	0,055	0,003	0,003	0,000
IFNC	0,002	0,000	-	0,524	0,000	0,398	0,010	0,011	0,050	0,000
IMOB	0,001	0,000	0,175	-	0,005	0,526	0,002	0,009	0,067	0,000
ICON	0,000	0,000	0,059	0,712	-	0,465	0,001	0,007	0,014	0,000
INDX	0,000	0,000	0,002	0,650	0,154	-	0,002	0,006	0,001	0,000
IEE	0,011	0,000	0,651	0,417	0,005	0,773	-	0,011	0,250	0,000
Dólar	0,051	0,000	0,893	0,778	0,010	0,232	0,050	-	0,899	0,000
BVSP	0,000	0,000	0,102	0,614	0,004	0,985	0,002	0,017	-	0,000

Fonte: Elaboração própria.

Nota: A tabela apresenta os p-valores dos testes CN. Hipóteses (exceto para a o teste conjunto), considerando i e j para linha e coluna, respectivamente: H0: Y(i) não causa Y(j), com $i \neq j$; Ha: Y (i) causa Y(j), com $i \neq j$. Para o teste conjunto: H0: Y(i) não causa nenhum Y(j), com $i \neq j$; Ha: Y(i) causa algum Y(j), com $i \neq j$.

Tabela 14 - Testes CN para 3 defasagens, com matriz de variância-covariância homocedástica e erros correlacionados

	UTIL	IMAT	IFNC	IMOB	ICON	INDX	IEE	Dólar	BVSP	Teste Conjunto
UTIL	-	0,000	0,524	0,099	0,000	0,489	0,000	0,000	0,030	0,000
IMAT	0,000	-	0,000	0,033	0,000	0,222	0,001	0,000	0,000	0,000
IFNC	0,000	0,000	-	0,224	0,000	0,049	0,000	0,000	0,000	0,000
IMOB	0,000	0,000	0,080	-	0,000	0,213	0,000	0,000	0,005	0,000
ICON	0,000	0,000	0,000	0,463	-	0,019	0,000	0,000	0,000	0,000
INDX	0,000	0,000	0,000	0,349	0,000	-	0,000	0,000	0,000	0,000
IEE	0,000	0,000	0,349	0,058	0,000	0,386	-	0,000	0,001	0,000
Dólar	0,018	0,000	0,878	0,773	0,008	0,108	0,021	-	0,874	0,000
BVSP	0,000	0,000	0,000	0,187	0,000	0,943	0,000	0,000	-	0,000

Fonte: Elaboração própria.

Nota: A tabela apresenta os p-valores dos testes CN. Hipóteses (exceto para a o teste conjunto), considerando i e j para linha e coluna, respectivamente: H0: Y(i) não causa Y(j), com $i \neq j$; Ha: Y (i) causa Y(j), com $i \neq j$. Para o teste conjunto: H0: Y(i) não causa nenhum Y(j), com $i \neq j$; Ha: Y(i) causa algum Y(j), com $i \neq j$.

Tabela 15 - Testes CN para 3 defasagens, com matriz de variância-covariância homocedástica e erros não-correlacionados

	UTIL	IMAT	IFNC	IMOB	ICON	INDX	IEE	Dólar	BVSP	Teste Conjunto
UTIL	-	0,000	0,832	0,582	0,057	0,818	0,062	0,015	0,468	0,000
IMAT	0,001	-	0,000	0,172	0,007	0,434	0,035	0,002	0,000	0,000
IFNC	0,059	0,000	-	0,640	0,002	0,450	0,075	0,049	0,068	0,000
IMOB	0,080	0,000	0,468	-	0,101	0,606	0,076	0,069	0,244	0,000
ICON	0,001	0,000	0,139	0,781	-	0,374	0,005	0,001	0,010	0,000
INDX	0,002	0,000	0,008	0,711	0,132	-	0,011	0,003	0,000	0,000
IEE	0,123	0,000	0,783	0,577	0,086	0,798	-	0,010	0,344	0,000
Dólar	0,126	0,000	0,921	0,852	0,087	0,299	0,135	-	0,918	0,000
BVSP	0,008	0,000	0,174	0,696	0,016	0,983	0,017	0,015	-	0,000

Fonte: Elaboração própria.

Nota: A tabela apresenta os p-valores dos testes CN. Hipóteses (exceto para a o teste conjunto), considerando i e j para linha e coluna, respectivamente: H0: Y(i) não causa Y(j), com $i \neq j$; Ha: Y (i) causa Y(j), com $i \neq j$. Para o teste conjunto: H0: Y(i) não causa nenhum Y(j), com $i \neq j$; Ha: Y(i) causa algum Y(j), com $i \neq j$.

4.2.4 Resultados gerais dos testes CN

Os testes indicaram que alguns resultados ocorreram independentemente da variação de parâmetros dos modelos, ou seja, estão presentes nas 12 tabelas de resultados. Inicialmente, destaca-se que cada série estudada causou pelo menos uma das demais séries, conforme resultados dos testes conjuntos. Todas as séries estudadas causaram a série do Índice de Materiais Básicos (IMAT), ou seja, todas apresentam precedência estatística em relação à IMAT.

A série UTIL antecipa os efeitos de volatilidade (precedência estatística) das séries IMAT e IEE. O mesmo ocorre para: 1) IMAT em relação a UTIL, IFNC, ICON, IEE e BVSP; 2) IFNC em relação a UTIL, IMAT e IEE; 3) IMOB em relação a UTIL e IMAT; 4) INDX em relação a UTIL, IMAT, IFNC e BVSP; 5) IEE em relação a IMAT; 6) Ibovespa (BVSP) em relação a UTIL, IMAT e IEE.

A série ICON antecipa os efeitos de volatilidade de UTIL, IMAT e IEE, mas não antecipa os efeitos de IMOB. A série Dólar antecipa os efeitos de volatilidade de IMAT, mas não de IMOB. A variação na quantidade de defasagens altera algumas das relações de causalidade. Ao diminuir as defasagens de 30 para 3: 1) ICON passa a causar Dólar e BVSP; 2) INDX passa a causar IEE e Dólar e a não causar IMOB; 3) BVSP passa a causar Dólar, ou seja, a volatilidade do Ibovespa passa a anteceder a volatilidade do câmbio.

As séries IMOB e INDX, em geral, não tiveram movimentos antecipados por movimentos de volatilidade das demais séries, ou seja, não receberam *spillovers* de volatilidade das demais, sendo IMOB a série que menos recebeu. Já as séries UTIL, IMAT, IFNC, ICON e IEE receberam *spillovers* de volatilidade de outras séries, sendo que IMAT recebeu *spillovers* de todas as séries, ou seja, a série ocorre de forma defasada (tem movimentos antecipados por todas as séries).

Ocorrem transbordamentos de volatilidade do Dólar e do Ibovespa para os índices setoriais, exceto para IMOB e INDX. Entretanto, também há transbordamentos de IMOB e INDX para Dólar e Ibovespa. Destaca-se que ocorrem mais transbordamentos do Ibovespa para os índices setoriais do que do Dólar para os índices setoriais.

A relação entre Dólar e Ibovespa se mostrou variável a depender do número de defasagens. Para três defasagens, Dólar não causa Ibovespa e Ibovespa causa Dólar, nos quatro testes. Esse resultado indica que, para defasagens pequenas, o Ibovespa pode estar antecipando movimentos do mercado de câmbio.

Para 10 defasagens, em três dos quatro testes, Dólar causou Ibovespa e vice-versa. Somente o teste que considerou Matriz de Variância-Covariância Heterocedástica e Erros Correlacionados indicou que Dólar causa Ibovespa, mas Ibovespa não causa Dólar, resultado semelhante aos encontrados nos trabalhos de Maranhão e Oliveira (2017b) e Maranhão e Oliveira (2017a).

Para 30 defasagens, os quatro testes obtiveram resultados diferentes, os quais ilustram que as hipóteses assumidas nos testes CN podem afetar os resultados. Quando os erros foram não correlacionados, os resultados indicaram não haver *spillovers* de volatilidade entre Dólar e Ibovespa, independentemente da escolha da Matriz de Variância-Covariância (Tabelas 5 e 7). Já para a hipótese de erros correlacionados, ocorreram *spillovers* e a escolha da Matriz de Variância-Covariância determinou a direção desses transbordamentos (Tabelas 4 e 6).

4.3 Análises comparativas

Tendo em vista as evidências, elencadas nas subseções anteriores, da ocorrência de *spillovers* de volatilidade entre câmbio e índices setoriais e entre Ibovespa e índices setoriais, com efeito *lead-lag*, um conjunto de comparações estatísticas foi implementado para identificar quais transbordamentos, estimados pelas médias das correlações condicionais, são mais representativos. As comparações são realizadas por meio de testes de médias¹².

Ocorrem variações nas magnitudes das correlações condicionais, o que será objeto dos testes descritos a seguir na Tabela 16.

Conforme Tabela 16, a média da correlação condicional do índice IFNC com Dólar não é maior do que a correlação condicional média do Ibovespa com o Dólar. Com exceção desse resultado específico, todas as médias das correlações condicionais dos índices setoriais com o Dólar foram maiores (menos intensas) que as médias das correlações condicionais do Ibovespa com o Dólar. Como, em todos os casos, essas médias são negativas, o Ibovespa apresenta menor volatilidade do que os índices setoriais (exceto IFNC) para uma maior volatilidade cambial.

¹² Testes t unicaudais precedidos de testes F para verificação da hipótese de variâncias desiguais. A hipótese de nulidade do teste F é a igualdade das variâncias, de forma que p-valores inferiores ao nível de significância indicam variâncias desiguais. O resultado do teste F é utilizado no cálculo do p-valor do teste t.

Tabela 16 - Teste t para comparações - Índices setoriais

Índices Setoriais	UTIL	IMAT	IFNC	IMOB	ICON	INDX	IEE
A: Média da Corr. Cond. Setor-Dólar	-0,3496	-0,2073	-0,4274	-0,4316	-0,3653	-0,2712	-0,3439
B: Média da Corr. Cond. Setor-Ibovespa	0,7265	0,7383	0,8970	0,7895	0,8200	0,8349	0,7070
C: Média da Corr. Cond. Dólar-Ibovespa	-0,4308	-0,4315	-0,4289	-0,4434	-0,4310	-0,4309	-0,4311
P-valor Teste F (A vs B)	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
Hipótese Alternativa (H(1) do teste t)	B > A	B > A	B > A	B > A	B > A	B > A	B > A
P-valor Teste t	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000
P-valor Teste F (A vs C)	0,0000	0,0000	0,0000	0,0110	0,0000	0,9123	0,0000
Hipótese Alternativa (H(1) do teste t)	A > C	A > C	A > C	A > C	A > C	A > C	A > C
P-valor Teste t	0,0000	0,0000	0,3030	0,0000	0,0000	0,0000	0,0000
P-valor Teste F (B vs C)	0,8737	0,0000	0,0000	0,0000	0,0000	0,0000	0,2203
Hipótese Alternativa (H(1) do teste t)	B > C	B > C	B > C	B > C	B > C	B > C	B > C
P-valor Teste t	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000

Fonte: Elaboração própria.

Nota: Hipótese Nula ($H(0)$): $\mu(i) = \mu(j)$. Nível de significância: $\alpha = 5\%$.

O resultado para IFNC é condizente com o fato de que esse é um indicador do desempenho médio das cotações dos ativos de maior negociabilidade e representatividade dos setores de intermediários financeiros, serviços financeiros diversos, previdência e seguros.

A Tabela 16 demonstra que todas as médias das correlações condicionais dos índices setoriais com o Dólar foram negativas, enquanto as médias das correlações condicionais desses índices com o Ibovespa foram positivas. Ainda, as médias das correlações condicionais do Dólar com Ibovespa foram negativas.

Testes estatísticos para médias¹³ foram realizados para comparar as magnitudes das correlações condicionais dos índices setoriais com o Ibovespa (Tabela 17) e dos índices setoriais com o Dólar (Tabela 18).

As Tabelas 17 e 18 estão organizadas de forma que o conteúdo de cada posição interna corresponde ao p-valor do teste t unicaudal da média apresentada na linha correspondente em relação à média apresentada na coluna correspondente. As médias nas linhas e nas colunas foram organizadas de forma decrescente.

Os resultados apresentados na Tabela 17 indicam que, com relação às correlações condicionais dos índices setoriais com o Ibovespa, não existem médias iguais (p-valor < 5%). O índice setorial com maior correlação condicional com o Ibovespa é o IFNC, seguido de INDX, ICON, IMOB, IMAT, UTIL e IEE, respectivamente.

Esse resultado se soma ao apresentado na Tabela 16, onde IFNC foi o único índice setorial que apresentou média de correlação condicional semelhante à do Ibovespa frente ao Dólar. Ainda, nos testes CN para 30 defasagens, os quatro testes indicaram que Ibovespa causa IFNC. Para 10 defasagens, três dos quatro testes indicaram que Ibovespa causa IFNC e, para 3 defasagens, dois dos quatro testes indicaram essa relação. Dessa forma, os testes apresentaram indícios de que IFNC pode ser o índice setorial que recebe maior *spillover* de volatilidade do Ibovespa e que esse transbordamento é maior conforme aumentam as defasagens. Não foi identificado efeito *lead-lag*, pois os testes de causalidade também indicaram que IFNC causa Ibovespa.

¹³ Testes t unicaudais precedidos de testes F para verificação da hipótese de variâncias desiguais. A hipótese de nulidade do teste F é a igualdade das variâncias, de forma que p-valores inferiores ao nível de significância significam variâncias desiguais. O resultado do teste F é utilizado no cálculo do p-valor do teste t.

Tabela 17 - P-valores dos testes comparativos das médias das correlações condicionais dos índices setoriais com o Ibovespa

Correlação Condicional	(IFNC, BVSP)	(INDX, BVSP)	(ICON, BVSP)	(IMOB, BVSP)	(IMAT, BVSP)	(UTIL, BVSP)	(IEE, BVSP)
Média	0,897	0,835	0,820	0,790	0,738	0,726	0,707
(IFNC, BVSP)	0,897	-	0,000	0,000	0,000	0,000	0,000
(INDX, BVSP)	0,835	-	-	0,000	0,000	0,000	0,000
(ICON, BVSP)	0,820	-	-	-	0,000	0,000	0,000
(IMOB, BVSP)	0,790	-	-	-	-	0,000	0,000
(IMAT, BVSP)	0,738	-	-	-	-	-	0,000
(UTIL, BVSP)	0,726	-	-	-	-	-	0,000
(IEE, BVSP)	0,707	-	-	-	-	-	-

Fonte: Elaboração própria.

Nota: Hipótese Nula ($H(0)$): $\mu(i) = \mu(j)$. Hipótese Alternativa ($H(1)$): $\mu(i) > \mu(j)$. Nível de significância: $\alpha = 5\%$. Cada comparação é realizada entre a média presente na linha i com a média presente na coluna j.

Tabela 18 - P-valores dos testes comparativos das médias das correlações condicionais dos índices setoriais com o Dólar

Correlação Condicional	(IFNC, BVSP)	(INDX, BVSP)	(ICON, BVSP)	(IMOB, BVSP)	(IMAT, BVSP)	(UTIL, BVSP)	(IEE, BVSP)
Média	-0,207	-0,271	-0,344	-0,350	-0,365	-0,427	-0,432
(IMAT-Dólar)	-0,207	-	0,000	0,000	0,000	0,000	0,000
(INDX-Dólar)	-0,271	-	-	0,000	0,000	0,000	0,000
(IEE-Dólar)	-0,344	-	-	-	0,042	0,000	0,000
(UTIL-Dólar)	-0,350	-	-	-	-	0,000	0,000
(ICON-Dólar)	-0,365	-	-	-	-	-	0,000
(IFNC-Dólar)	-0,427	-	-	-	-	-	0,064
(IMOB-Dólar)	-0,432	-	-	-	-	-	-

Fonte: Elaboração própria.

Nota: Hipótese Nula ($H(0)$): $\mu(i) = \mu(j)$. Hipótese Alternativa ($H(1)$): $\mu(i) > \mu(j)$. Nível de significância: $\alpha = 5\%$. Cada comparação é realizada entre a média presente na linha i com a média presente na coluna j.

Os índices setoriais UTIL e IEE, que representam seguimentos fortemente regulados ou estatizados apresentaram as menores médias de correlações condicionais com o Ibovespa. Os testes CN indicaram que, para 10 e 3 defasagens, Ibovespa causa UTIL e IEE, mas que esses índices não causam Ibovespa. Dessa forma, há *spillover* de volatilidade entre o Ibovespa e esses índices, com efeito *lead-lag*, sempre do Ibovespa em direção à UTIL e IEE.

Os resultados apresentados na Tabela 18 indicaram que, ao nível de significância de 5%, as médias das correlações condicionais dos índices IFNC e IMOB foram estatisticamente iguais. Caso seja considerado o nível de significância de 1%, as médias de UTIL e IEE também são consideradas estatisticamente iguais. Conforme Tabela 18, todas as médias são negativas, de forma que as menores médias (IFNC e IMOB) representam os segmentos que, para maiores volatilidades cambiais, representam maiores volatilidades setoriais em sentido oposto (choque positivo em câmbio corresponde a choque negativo no setor e vice-versa).

As correlações condicionais médias em relação ao Dólar são maiores para IMAT e INDX, mas, ressalta-se, as médias são negativas, indicando menores volatilidade setoriais para volatilidade cambiais. Os testes CN indicaram que Dólar causa IMAT para 30, 10 e 3 defasagens. IMAT não causa Dólar para 30 defasagens, mas causa para 10 e 3 defasagens, de forma que há *spillover* mas não foi caracterizado efeito *lead-lag*.

O teste CN para 30 defasagens não indicou que Dólar causa INDX nem INDX causa Dólar. Para 10 e 3 defasagens INDX causa Dólar e Dólar não causa INDX, indicando, para essas defasagens efeito *lead-lag* do índice INDX para o Dólar. Essa situação, oposta ao encontrado por Maranhão e Oliveira (2017b) e Maranhão e Oliveira (2017a) para o mercado acionário brasileiro, representado pelo Ibovespa, pode ser considerado indício de que setores específicos se antecipam aos choques de volatilidade cambial.

5. Conclusões

O presente estudo aplicou, para sete índices setoriais divulgados pela principal bolsa de valores brasileira, metodologia baseada nos trabalhos de Maranhão e Oliveira (2017b) e Maranhão e Oliveira (2017a) para verificação da existência de *spillover* de volatilidade e efeito *lead-lag*.

As séries estudadas apresentam retornos com características de assimetria, curtose, média próxima de zero, ausência de normalidade e estacionariedade. Todas as séries puderam ser modeladas com GARCHs univariados de ordens (p,q) baixas (1,1), em distribuições com caudas pesadas (t-student e skew-t). Os resultados foram validados por testes LM nos resíduos e resíduos ao quadrado e utilizados para inferir que as ordens dos modelos multivariados eram baixas.

Os modelos GARCH multivariados possuíam ordens baixas, no máximo (1,1), conforme indicado pelas ordens dos modelos univariados, em alinhamento com os resultados dos trabalhos de Maranhão e Oliveira (2017b) e Maranhão e Oliveira (2017a). Conforme testes LM, os modelos MGARCH-BEKK não eliminaram a autocorrelação nos resíduos ao quadrado. Esses modelos apresentaram muitos parâmetros estatisticamente não significativos. Modelos Diagonal BEKK (MGARCH-DBEKK) assimétricos se ajustaram adequadamente aos dados, conforme validado por testes LM.

Análise ampla com testes CN, nas quais foram avaliadas diferentes defasagens, matrizes de variância-covariância e correlação de erros, totalizando 12 cenários, identificaram relações de causalidade bem definidas entre os índices setoriais e entre estes e as séries do Dólar e do Ibovespa. As séries UTIL, IMAT, IFNC, ICON e IEE recebem *spillovers* de outras séries, sendo que IMAT tem movimentos antecipados por todas as séries. Já IMOB e INDX não tiveram, em geral, movimentos antecipados por outras séries, sendo que IMOB foi a que menos recebeu *spillovers* de volatilidade, o que demonstra que o movimento do mercado imobiliário não é antecipado por movimentos dos outros mercados. Os diferentes cenários também indicaram séries que não causam outras séries. As séries ICON e Dólar não causam IMOB em nenhum cenário.

A 30 defasagens, Ibovespa não causa Dólar e vice-versa e a 10 defasagens Ibovespa causa Dólar e vice-versa. No cenário com 3 defasagens, o Ibovespa passou a causar Dólar. Esse resultado é diferente do encontrado por Maranhão e Oliveira (2017b) e CARVALHO, SOUSA e CALLADO (2016), o que pode indicar antecipação dos movimentos do Dólar pelo mercado acionário brasileiro.

As correlações condicionais dos índices setoriais com o Ibovespa são positivas, ou seja, variações positivas do retorno do Ibovespa são acompanhadas de variações positivas nos retornos dos sete índices setoriais. Tanto as correlações condicionais do Ibovespa com o Dólar quanto dos índices setoriais com o Dólar são negativas, ou seja, aumento no retorno do dólar provoca redução nos retornos dessas séries.

Considerando o período completo em estudo, com exceção de IFNC, os índices setoriais apresentaram média de correlação condicional com Dólar superior à média da correlação condicional Dólar-Ibovespa. Ou seja, o *spillover* de volatilidade nesses índices, causada pela variação no Dólar, possui magnitude inferior ao *spillover* no Ibovespa. O IFNC apresentou média semelhante à do Ibovespa em relação ao Dólar. O índice IMOB foi

tão volátil quanto IFNC em relação ao Dólar mas estatisticamente superior ao Ibovespa em relação ao Dólar. Destaca-se que UTIL e IEE apresentaram médias de correlação condicional com Dólar e Ibovespa com características semelhantes. Apresentaram menor média em relação ao Ibovespa e médias semelhantes em relação ao Dólar (para $\alpha = 1\%$).

Como extensão desse estudo, outros modelos GARCH multivariados podem ser testados. Testes de causalidade HH, versão multivariada proposta por Hafner e Herwartz (2008), podem ser implementados, assim como séries de choques cambiais geradas por metodologia de análise de componentes principais, em abordagem semelhante à implementada por Maranhão e Oliveira (2017b) e Maranhão e Oliveira (2017a). Ainda, podem ser inseridas outras variáveis e choques, para testar o comportamento dos índices setoriais em diferentes cenários.

Referências

Almeida, H. J. F. et al. (2019). Transmissão de risco entre os índices setoriais do ibovespa: uma aplicação do teste de causalidade em variância. *Revista Economia Ensaios*.

Asafo-adjei, E.; Adam, A. M.; Darkwa, P. (2021). Can crude oil price returns drive stock returns of oil producing countries in africa? evidence from bivariate and multiple wavelet. *Macroeconomics and Finance in Emerging Market Economies*, Taylor & Francis, p. 1–19.

Bangsgaard, C.; Kokholm, T. (2022). The lead-lag relation between vix futures and spx futures. Available at SSRN.

Barberis, N.; Thaler, R. (2003). A survey of behavioral finance. *Handbook of the Economics of Finance*, Elsevier, v. 1, p. 1053–1128.

Beirne, J. et al. (2010). Global and regional spillovers in emerging stock markets: A multivariate garch-in-mean analysis. *Emerging markets review*, Elsevier, v. 11, n. 3, p. 250–260.

Bera, A. K.; Higgins, M. L. (1993). Arch models: properties, estimation and testing. *Journal of economic surveys*, Wiley Online Library, v. 7, n. 4, p. 305–366.

Bernardino, W. et al. (2019). A garch-var investigation on the brazilian sectoral stock indices. *Brazilian Review of Finance*, v. 16, n. 4, p. 573–610.

Black, F. (1976). Studies of stock price volatility changes, proceedings of the 1976 meetings of the business and economic statistics section. 177-191. In: *American Statistical association*. [S.l.: s.n.].

Bodart, V.; Reding, P. (1999). Exchange rate regime, volatility and international correlations on bond and stock markets. *Journal of International Money and Finance*, Elsevier, v. 18, n. 1, p. 133–151.

Bollerslev, T. (1990). Modelling the coherence in short-run nominal exchange rates: a multivariate generalized arch model. *The review of economics and statistics*, JSTOR, p. 498–505.

Bollerslev, T.; Engle, R. F.; Wooldridge, J. M. (1988). A capital asset pricing model with time-varying covariances. *The Journal of Political Economy*, JSTOR, p. 116–131.

Borges, B. K. (2012). Avaliação da habilidade preditiva entre modelos Garch multivariados: uma análise baseada no critério Model Confidence Set. Dissertação (Mestrado).

Bressan, R.; de Souza, D. A.; de Amarante, A. (2021). Aplicando a teoria do valor extremo ao cálculo de risco de índices setoriais da b31. *Revista Brasileira de Economia de Empresas*, Universidade Católica de Brasília UCB, v. 21, n. 1, p. 65–86.

Byrne, A.; Brooks, M. (2008), *Behavioral finance: Theories and evidence*. The Research Foundation of CFA Institute, CFA Institute.

Caldeira, A. M.; Souza, R. C.; Machado, M. A. S. (2010). Identificação automática das ordens dos modelos garch utilizando redes neurais. *Engevista*, v. 11, n. 2.

Cardona, L.; Gutiérrez, M.; Agudelo, D. A. (2017). Volatility transmission between us and latin american stock markets: Testing the decoupling hypothesis. *Research in International Business and Finance*, Elsevier, v. 39, p. 115–127.

de Carvalho, P. L.; Sousa, E.; Callado, A. L. C. (2016). Indicadores de desempenho da bm&fbovespa: Uma análise do desempenho financeiro dos índices de sustentabilidade frente aos demais índice da bolsa.

Cheng, D. et al. (2022). Financial time series forecasting with multi-modality graph neural network. *Pattern Recognition*, Elsevier, v. 121, p. 108218.

Cheung, Y.-W.; NG, L. K. (1996). A causality-in-variance test and its application to financial market prices. *Journal of Econometrics*, Elsevier, v. 72, n. 1, p. 33–48.

Choudhry, T.; Hasan, M.; Zhang, Y. (2019). Forecasting the daily dynamic hedge ratios in emerging european stock futures markets: evidence from garch models. *International Journal of Banking, Accounting and Finance*, Inderscience Publishers (IEL), v. 10, n. 1, p. 67–100.

Conte, B. P. (2021). Análise dinâmica de volatilidade para os setores do mercado acionário brasileiro: uma aplicação do modelo mrs-garch. *Revista Capital Científico-Eletrônica (RCC)*-ISSN 2177-4153, v. 19, n. 2, p. 75–90.

da Costa, L. F. C.; da Costa, M. G. (2018). Os impactos de fatores macroeconômicos sobre índices de ações setoriais: uma análise através do algoritmo de seleção de modelos autometrics. *Revista Evidenciação Contábil & Finanças*, Universidade Federal da Paraíba, v. 6, n. 3, p. 96–109.

Dalcin, L. et al. (2017). Setores da economia frente à exposição cambial: Uma abordagem aplicando painel de dados com threshold. *Revista de Gestão, Finanças e Contabilidade*, v. 7, n. 2, p. 05–21.

Das, D.; Bhowmik, P.; Jana, R. (2018). A multiscale analysis of stock return co-movements and spillovers: Evidence from pacific developed markets. *Physica A: Statistical Mechanics and its Applications*, Elsevier, v. 502, p. 379–393.

Engle, R. F. (1982). Autoregressive conditional heteroscedasticity with estimates of the variance of united kingdom inflation. *Econometrica: Journal of the Econometric Society*, JSTOR, p. 987–1007.

Engle, R. F.; Kroner, K. F. (1995). Multivariate simultaneous generalized arch. *Econometric theory*, Cambridge University Press, v. 11, n. 1, p. 122–150.

Erten, I.; Tuncel, M. B.; Okay, N. (2012). Volatility spillovers in emerging markets during the global financial crisis: diagonal bekk approach.

Fama, E. F. (1991). Efficient capital markets: II. *The journal of finance*, Wiley Online Library, v. 46, n. 5, p. 1575–1617.

Fernandes-Freire, A. P. et al. (2017). Risco sistêmico: uma análise de quebras estruturais nos índices setoriais brasileiros através do modelo covar. *Journal of Globalization, Competitiveness & Governability*, Portal Universia SA, v. 11, n. 3, p. 74–89.

Gaio, L. E.; Rolim, R. C. (2007). Interferência dos mercados externos sobre o ibovespa: uma análise utilizando autoregressão vetorial estrutural. In: X Seminários em Administração FEA-USP, conference. [S.l.: s.n.], p. 9–10.

Glosten, L. R.; Jagannathan, R.; Runkle, D. E. (1993). On the relation between the expected value and the volatility of the nominal excess return on stocks. *The journal of finance*, Wiley Online Library, v. 48, n. 5, p. 1779–1801.

Granger, C. W. (1988). Some recent development in a concept of causality. *Journal of econometrics*, Elsevier, v. 39, n. 1, p. 199–211.

Granger, C. W. J.; Robins, R.; Engle, R. F. (1986). Wholesale and retail prices: Bivariate time series modeling with forecastable error variances. *Model reliability*, MIT Press Cambridge, MA, p. 1–17.

Hafner, C. M.; Herwartz, H. (1998). Structural analysis of portfolio risk using beta impulse response functions. *Statistica Neerlandica*, Wiley Online Library, v. 52, n. 3, p. 336–355.

Hafner, C. M.; Herwartz, H. (2008). Testing for causality in variance using multivariate garch models. *Annales d'Economie et de Statistique*, JSTOR, p. 215–241.

Heckelei, T.; Amrouk, E.; Grosche, S. (2018). International interdependence between cash crop and staple food futures price indices: A wavelet-bekk-garch assessment. Disponível em: <<http://ageconsearch.umn.edu/record/277376>>.

Herwartz, H.; Lütkepohl, H. (2000). Multivariate volatility analysis of vw stock prices. *International Journal of Intelligent Systems in Accounting, Finance & Management*, John Wiley & Sons, Ltd., v. 9, n. 1, p. 35–54.

Jiang, L.; Fung, J. K.; Cheng, L. T. (2001). The lead-lag relation between spot and futures markets under different short-selling regimes. *Financial Review*, Wiley Online Library, v. 36, n. 3, p. 63–88.

Jubert, R. W. et al. (2009). Um estudo do padrão de volatilidade dos principais índices financeiros do bovespa: uma aplicação de modelos arch. *Revista Contabilidade, Gestão e Governança*, v. 11, n. 1-2.

Kanas, A. (2000). Volatility spillovers between stock returns and exchange rate changes: International evidence. *Journal of Business Finance & Accounting*, Wiley Online Library, v. 27, n. 3-4, p. 447–467.

Komsta, L.; Novomestky, F. (2015). moments: Moments, cumulants, skewness, kurtosis and related tests. [S.l.]. R package version 0.14. Disponível em: <<https://CRAN.R-project.org/package=moments>>.

Kundu, S.; Sarkar, N. (2016). Return and volatility interdependences in up and down markets across developed and emerging countries. *Research in International Business and Finance*, Elsevier, v. 36, p. 297–311.

Leung, H.; Schiereck, D.; Schroeder, F. (2017). Volatility spillovers and determinants of contagion: Exchange rate and equity markets during crises. *Economic Modelling*, Elsevier, v. 61, p. 169–180.

Lucas, R. E. (1978). Asset prices in an exchange economy. *Econometrica: Journal of the Econometric Society*, JSTOR, p. 1429–1445.

Lucas, R. E. (1986). Adaptive behavior and economic theory. *Journal of Business*, JSTOR, p. S401–S426.

Lütkepohl, H. (2005). New introduction to multiple time series analysis. [S.l.]: Springer Science & Business Media.

Madhavan, A. (2000). Market microstructure: A survey. *Journal of financial markets*, Elsevier, v. 3, n. 3, p. 205–258.

Malkiel, B. G.; Fama, E. F. (1970). Efficient capital markets: A review of theory and empirical work. *The journal of Finance*, Wiley Online Library, v. 25, n. 2, p. 383–417.

Maranhao, A. N.; Moreira, G. C. C. (2021). Dividends and volatilities: Spillover and second order foreign exchange and financial causality/dividendos e volatilidades: Spillover e causalidade em segunda ordem, cambial e financeira. *Revista Brasileira de Finanças, Sociedade Brasileira de Finanças*, v. 19, n. 4, p. 28–86.

Maranhão, A. N.; Oliveira, W. S. (2017a). Spillovers de volatilidades cambiais e de mercados financeiros internacionais no mercado acionario brasileiro. *Revista Brasileira de Finanças, Sociedade Brasileira de Finanças*, v. 15, n. 4, p. 569–603.

Maranhão, A. N.; Oliveira, W. S. (2017b). Spillovers de volatilidades cambiais e efeito lead-lag no mercado acionário brasileiro. *Revista Brasileira de Economia de Empresas*, v. 17, n. 2.

Mensi, W. et al. (2014). Dynamic spillovers among major energy and cereal commodity prices. *Energy Economics, Elsevier*, v. 43, p. 225–243.

Miller, S. E. (1980). Lead-lag relationships between pork prices at the retail, wholesale, and farm levels. *Southern Journal of Agricultural Economics, Cambridge Univ Press*, v. 12, n. 01, p. 73–76.

Mitchell, M.; Pulvino, T.; Stafford, E. (2002). Limited arbitrage in equity markets. *The Journal of Finance, Wiley Online Library*, v. 57, n. 2, p. 551–584.

Monte, E. Z. (2019). Inter-relações entre os índices financeiros setoriais da bolsa de valores de são paulo e o índice ibovespa. *Revista Economia Ensaios*.

Nakamura, R. (2009). O efeito lead-lag entre o mercado acionário brasileiro e o mercado de ADRs: uma revisão metodológica. *Dissertação (Mestrado)*.

Oliveira, G. (2008). Testando a existência do efeito lead-lag entre os mercados acionários norte-americano e brasileiro. *Dissertação (Mestrado em Administração), Faculdade de Economia, Administração, Contabilidade e Ciências da Informação e Documentação, Universidade de Brasília, Brasília*.

Pena, G. E.; Guelman, B.; Rabello, H. (2010). Influência dos índices dow jones industrial avarage e nikkei-225 sobre o ibovespa. *Faculdades Ibmecc*. Disponível em: <<http://www.administradores.com.br/informe-se/producaoacademica/influencia-dos-indices-dow-jones-e-nikkei-225-sobre-o-ibovespa/785/>>.

Pfaff, B. (2008). *Analysis of Integrated and Cointegrated Time Series with R*. 2. ed. New York: Springer, 2008. ISBN 0-387-27960-1. Disponível em: <<http://www.pfaffikus.de>>.

Righi, M. B.; Ceretta, P. S.; da Silveira, V. G. (2012). Análise de desempenho financeiro setorial no mercado brasileiro. *Estudos do CEPE*, p. 252–272.

Sadorsky, P. (2012). Correlations and volatility spillovers between oil prices and the stock prices of clean energy and technology companies. *Energy economics, Elsevier*, v. 34, n. 1, p. 248–255.

Sampaio, G. R. (2015). Modelagem do comportamento forward-looking dos índices setoriais no Brasil. *Dissertação (Mestrado)*.

Tiwari, A. K. et al. (2018). Volatility spillovers across global asset classes: Evidence from time and frequency domains. *The Quarterly Review of Economics and Finance*, Elsevier, v. 70, p. 194–202.

Trapletti, A.; Hornik, K. (2019). tseries: Time Series Analysis and Computational Finance. [S.l.]. R package version 0.10-47. Disponível em: <<https://CRAN.R-project.org/package=tseries>>.

Wuertz, D. et al. (2019). fGarch: Rmetrics - Autoregressive Conditional Heteroskedastic Modelling. [S.l.]. R package version 3042.83.1. Disponível em: <<https://CRAN.R-project.org/package=fGarch>>.

Zhipeng, Y.; Shenghong, L. (2018). Hedge ratio on markov regime-switching diagonal bekk-garch model. *Finance Research Letters*, Elsevier, v. 24, p. 49–55.